

Classificação de Lesões de Pele com IA Utilizando uma Abordagem em Cascata

Matheus Kennedy Dionisio Santiago
Orientador: Prof. Tiago Pessoa Ferreira de Lima

RESUMO

O câncer de pele é um problema de saúde pública com alta incidência em países com elevada exposição solar, como o Brasil. Em regiões afastadas dos grandes centros urbanos, a escassez de dermatologistas dificulta o acesso ao diagnóstico especializado e aumenta o risco de detecção tardia. Este trabalho avalia uma abordagem em cascata baseada em Machine Learning para triagem de lesões de pele, utilizando algoritmos de classificação aplicados a imagens dermatoscópicas. A proposta tem como objetivo apoiar profissionais da Atenção Básica em Saúde, como médicos generalistas, na identificação de lesões potencialmente malignas, contribuindo para o encaminhamento mais ágil de casos suspeitos e, conseqüentemente, para a detecção precoce do câncer de pele em regiões com acesso limitado a especialistas.

Palavras-chave: Câncer de pele; Machine learning; Detecção precoce de câncer de pele.

ABSTRACT

Skin cancer is a public health issue with high incidence in countries with intense sun exposure, such as Brazil. In remote regions far from major urban centers, the shortage of dermatologists hinders access to specialized diagnosis and increases the risk of late detection. This work evaluates a cascade-based Machine Learning approach for skin lesion screening, using classification algorithms applied to dermatoscopic images. The proposed method aims to support primary healthcare professionals, such as general practitioners, in identifying potentially malignant lesions, thus contributing to faster referral of suspicious cases and to the early detection of skin cancer in areas with limited access to specialists.

Keywords: Skin cancer; Machine learning; Early detection of skin cancer.

1. Introdução

O câncer de pele representa um desafio significativo para a saúde pública brasileira, sendo o tipo de câncer mais prevalente no país [1]. A detecção precoce é crucial para o sucesso do tratamento, tornando a Atenção Básica em Saúde a linha de frente no combate a essa doença.

No entanto, o diagnóstico precoce e preciso do câncer de pele exige conhecimentos especializados e o domínio de técnicas como a dermatoscopia. Estudos demonstram que a capacitação dos profissionais da atenção primária em dermatoscopia podem aumentar significativamente a taxa de detecção precoce do câncer de pele, impactando positivamente os desfechos clínicos e na qualidade de vida dos pacientes [2, 3, 4].


Além disso, o investimento na capacitação e na disponibilização de recursos diagnósticos na atenção básica pode otimizar o encaminhamento de pacientes para centros especializados, evitando atrasos no tratamento e reduzindo a carga sobre o sistema de saúde. A dermatoscopia inteligente surge como uma solução para aprimorar a capacidade diagnóstica dos profissionais da atenção primária. Através da análise de imagens dermatoscópicas, a inteligência artificial (IA) pode identificar padrões e características sutis que podem indicar a presença de lesões malignas [5, 6, 7], auxiliando os profissionais da atenção primária na tomada de decisões mais assertivas e no encaminhamento adequado dos pacientes. Essa tecnologia tem o potencial de democratizar o acesso ao diagnóstico precoce do câncer de pele, mesmo em regiões com recursos limitados, e de reduzir a dependência de especialistas, otimizando o fluxo de atendimento.

1.1 Objetivo

Este trabalho tem como objetivo propor e avaliar uma abordagem em cascata baseada em inteligência artificial para auxiliar no diagnóstico precoce do câncer de pele na Atenção Básica em Saúde, com foco em aumentar a taxa de detecção precoce, reduzir a mortalidade associada à doença e otimizar o fluxo de atendimento.

2. Metodologia

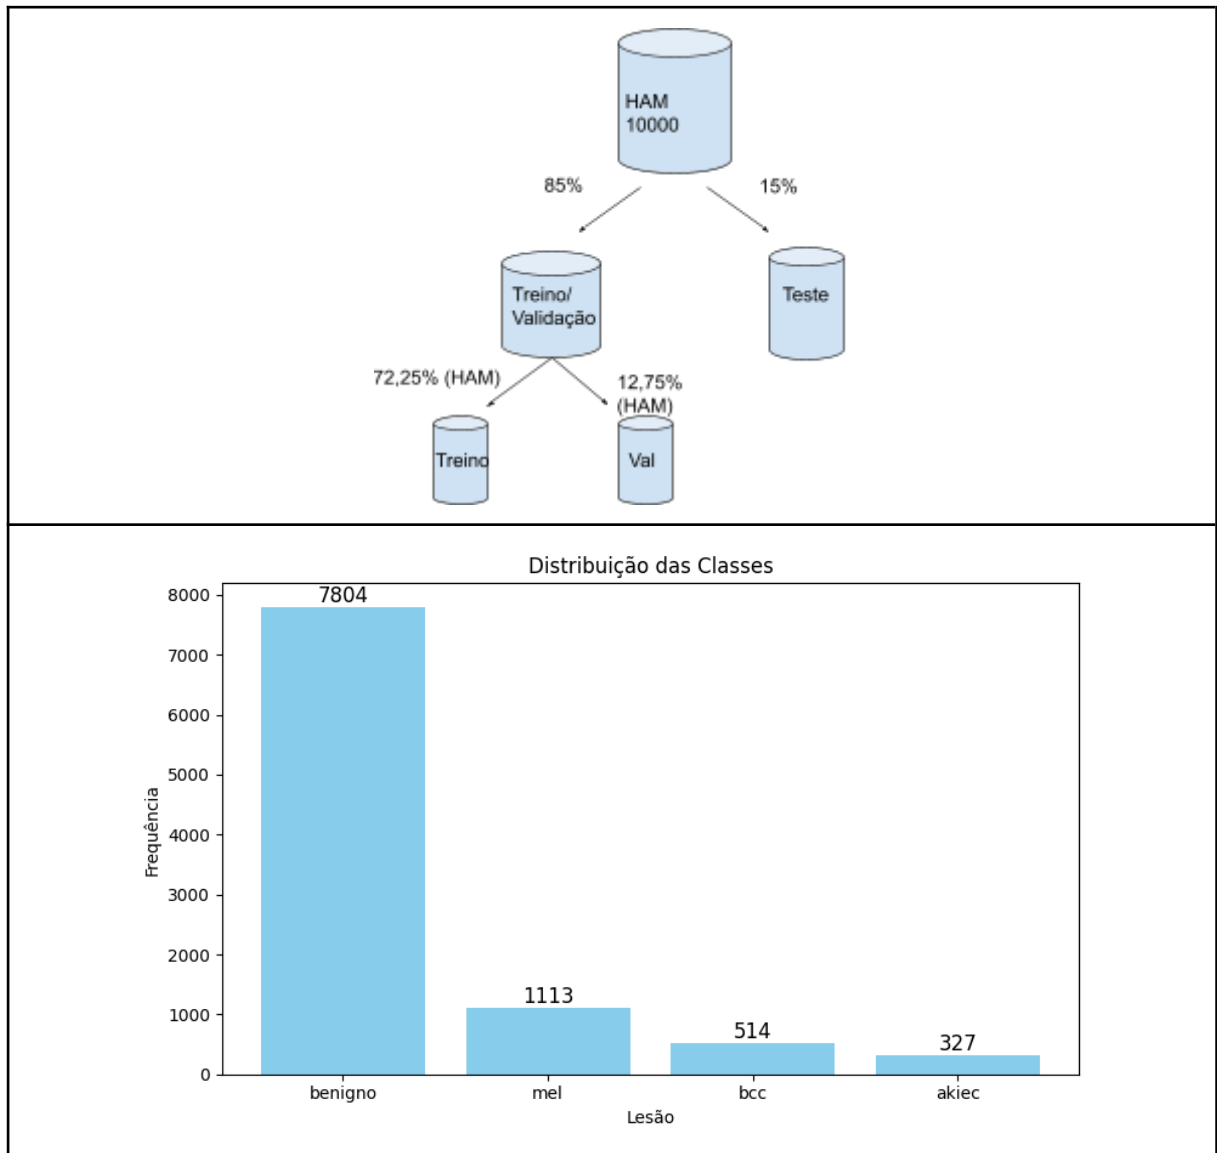
Figura 1: Etapas fundamentais



2.1 Coleta e Preparo dos Dados

A base de dados utilizada para a construção dos modelos foi a HAM10000, que foi dividida da seguinte forma, de acordo com suas finalidades:

Figura 2: Divisão dos Dados e Distribuição das Classes



Os conjuntos de teste e validação foram construídos preservando-se as proporções originais das classes presentes na base de dados. Por outro lado, o conjunto de treinamento foi ajustado para lidar com o desbalanceamento, por meio da aplicação de subamostragem na classe majoritária.

A escolha pela subamostragem da classe majoritária, em detrimento da superamostragem das classes minoritárias, foi motivada principalmente por

restrições relacionadas ao poder computacional disponível para o treinamento do modelo. A superamostragem, embora útil para equilibrar as classes, resulta em um conjunto de dados consideravelmente maior, o que aumenta o tempo de treinamento e a demanda por recursos computacionais, como memória e processamento gráfico.

Devido à baixa quantidade de exemplos, as classes Dermatofibroma e Lesões Vasculares foram removidas da base. As demais classes benignas foram agrupadas em uma única classe, a fim de simplificar o problema e melhorar a capacidade de generalização do modelo.

2.2 Treinamento e Avaliação dos modelos

2.2.1 Framework

Para a tarefa de classificação de imagens, foi utilizado o framework Ultralytics [8], uma ferramenta moderna e de alto nível construída sobre o PyTorch, amplamente adotada para aplicações de visão computacional. O Ultralytics facilita o treinamento, validação e exportação de modelos com apenas algumas linhas de código.

O modelo escolhido foi o YOLOv11n-cls, uma versão otimizada da arquitetura YOLO voltada para classificação de imagens. A variante "n" (nano) representa um modelo extremamente leve, projetado especificamente para ambientes com restrição de recursos computacionais, como smartphones. Apesar de sua leveza, o YOLOv11n-cls mantém uma boa capacidade de generalização e desempenho, sendo ideal para integrar-se a um aplicativo móvel, onde o tempo de inferência e o consumo de energia são fatores críticos.

2.2.2 Modelo Padrão

Inicialmente, foi utilizado um modelo YOLOv11n-cls diretamente sobre o conjunto de dados rotulados com todas as classes disponíveis. Essa abordagem direta serviu como linha de base para avaliar a capacidade do modelo em distinguir entre todas as categorias do dataset.

2.2.3 Abordagem em Cascata

Como alternativa à abordagem de classificação única (multi-classe), foi adotada uma estratégia em cascata com o intuito de reduzir a complexidade do espaço de decisão e aumentar a acurácia na detecção de lesões malignas. Essa técnica consistiu na construção de um pipeline com dois modelos especializados:

- O primeiro modelo realiza uma tarefa de classificação binária, distinguindo entre lesões benignas e malignas.

- Imagens classificadas como malignas são então encaminhadas para um segundo modelo, treinado especificamente para discriminar entre os três subtipos de malignidade: akiec, bcc e mel.

Ao dividir o problema original em duas etapas sequenciais, essa abordagem permite que cada modelo aprenda fronteiras de decisão mais simples e bem definidas em seus respectivos domínios. Do ponto de vista teórico, a decomposição do problema em subproblemas reduz a dimensionalidade efetiva do espaço de hipótese H , mitigando o risco de overfitting e facilitando a convergência durante o treinamento.

Se $f_1: R^n \rightarrow \{0, 1\}$ e $f_2: R^n \rightarrow \{akiec, bcc, mel\}$ for o classificador multiclasse, então a função de decisão $F(x)$ é definida como:

$$F(x) = \begin{cases} \text{benigno}, & \text{se } f_1(x) = 0 \\ f_2(x), & \text{se } f_1(x) = 1 \end{cases}$$

3. Resultados

3.1 Avaliação dos modelos

A aplicação da técnica de subamostragem da classe majoritária resultou em uma melhora significativa no desempenho do modelo binário, etapa fundamental para a eficácia da abordagem em cascata como um todo. Essa melhora é evidenciada pelas matrizes de confusão apresentadas na Figura 3.

A Figura 4, por sua vez, apresenta a comparação entre as matrizes de confusão das duas abordagens avaliadas (modelo YOLO único e abordagem em cascata), demonstrando que a abordagem em cascata obteve um aumento notável na sensibilidade para as classes malignas. Tal incremento é particularmente relevante, uma vez que a correta identificação de lesões malignas constitui o principal objetivo clínico do sistema proposto. A detecção precoce dessas lesões é essencial para subsidiar decisões médicas mais precisas e oportunas, contribuindo diretamente para o melhor prognóstico e aumento da taxa de sobrevivência dos pacientes.

Figura 3: Matrizes de confusão modelos Binários




Figura 4: Matrizes de confusão Modelo Padrão (a esquerda) e Cascata

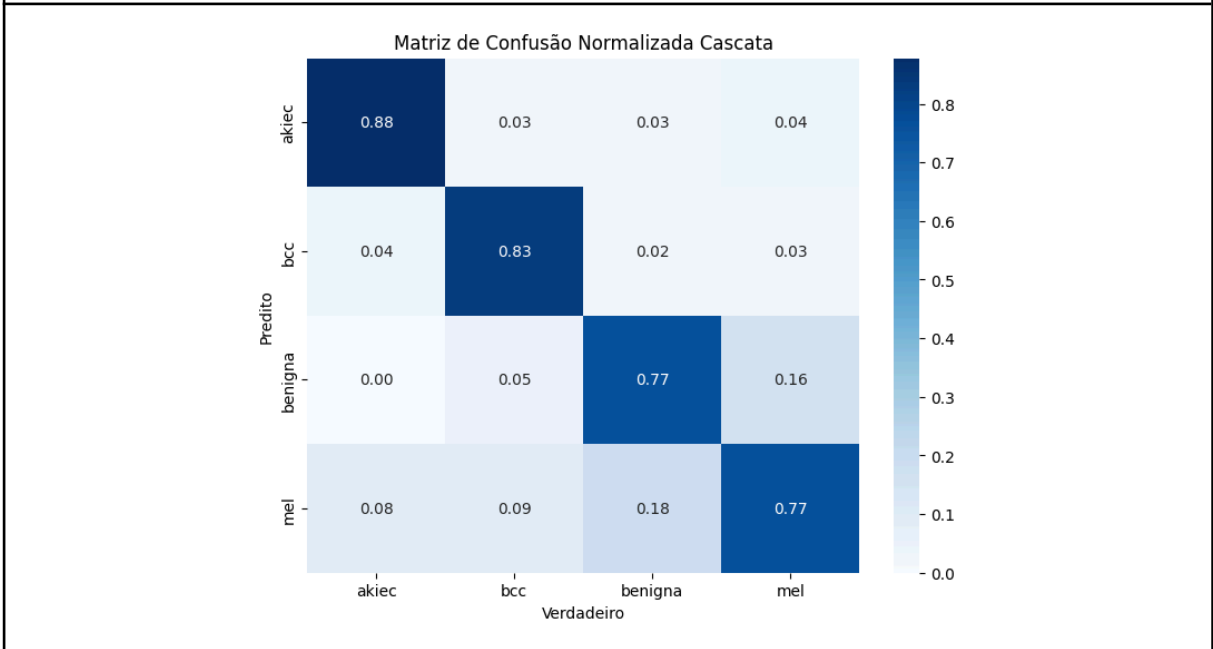
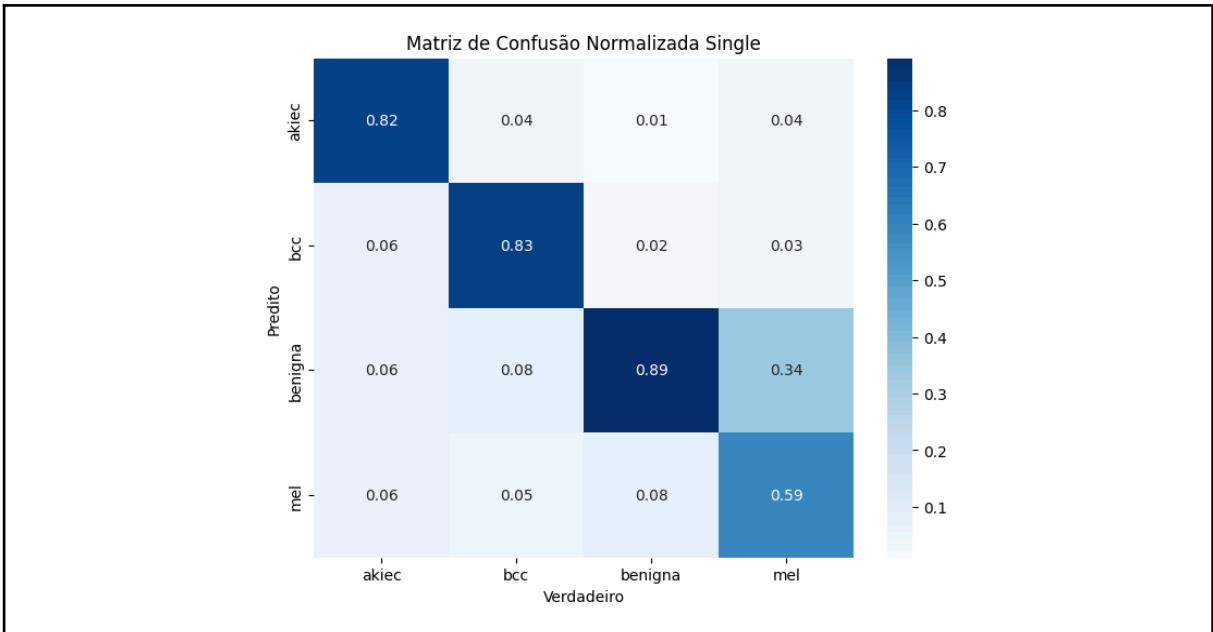


Tabela 1: Métricas da Abordagem em Cascata

| Métrica | Lesão | | | |
|-----------|--------|--------|---------|--------|
| | akiec | bcc | benigna | mel |
| Recall | 88% | 83% | 77% | 77% |
| F1 | 88,88% | 86,44% | 77,76% | 72,63% |
| Precision | 89,79% | 90,21% | 78,57% | 68,75% |

Tabela 2: Métricas do modelo Padrão

| Métrica | Lesão |
|---------|-------|
|---------|-------|

| | akiec | bcc | benigna | mel |
|-----------|--------|--------|---------|--------|
| Recall | 82% | 83% | 89% | 59% |
| F1 | 85,85% | 85,56% | 75,09% | 66,28% |
| Precision | 90,10% | 88,29% | 64,96% | 75,64% |

3.2 Aplicativo Móvel (Mínimo Produto Viável)

A abordagem em cascata foi integrada a um aplicativo móvel multiplataforma (MVP) desenvolvido com o framework React Native, que permite a criação de interfaces nativas para dispositivos Android e iOS a partir de uma única base de código em JavaScript/TypeScript. Essa escolha possibilitou maior agilidade no desenvolvimento e compatibilidade com diferentes dispositivos móveis, sem comprometer o desempenho.

O aplicativo permite ao usuário capturar uma imagem diretamente pela câmera do dispositivo ou selecionar uma foto existente da galeria. Após a seleção da imagem, ela é pré-processada e submetida ao modelo de classificação embarcado no próprio dispositivo.

O modelo de IA utilizado foi treinado previamente e exportado no formato TensorFlow Lite (TFLite) com precisão float32, garantindo compatibilidade com dispositivos móveis e mantendo o equilíbrio entre desempenho e consumo de recursos. O processo de inferência é realizado de forma local no aparelho, eliminando a necessidade de conexão com a internet.

Um exemplo de uso da aplicação é apresentado na Figura 5.

Figura 5: Exemplo de uso do Aplicativo



4. Conclusão

Este trabalho apresentou um protótipo funcional de um sistema de dermatoscopia inteligente baseado em inteligência artificial, com o objetivo de apoiar o diagnóstico precoce do câncer de pele. A estratégia adotada foi fundamentada em uma abordagem em cascata composta por dois modelos especializados, que demonstrou desempenho superior na detecção de lesões malignas em comparação com um modelo YOLO único, especialmente em relação à sensibilidade — métrica crítica em aplicações médicas.

O sistema foi implementado como um MVP (Produto Mínimo Viável) e integrado a um aplicativo móvel multiplataforma, permitindo validar sua viabilidade técnica e demonstrar seu potencial de aplicação em cenários reais, como unidades da Atenção Básica em Saúde, onde há restrições de recursos computacionais e necessidade de triagem ágil.

Como possibilidades para trabalhos futuros, destaca-se a ampliação do conjunto de dados com imagens provenientes de diferentes fontes e populações, de modo a aumentar a robustez e a generalização do modelo. Adicionalmente, a incorporação de técnicas de explicabilidade, como Grad-CAM ou LIME, poderia contribuir para aumentar a confiança dos profissionais de saúde nos resultados fornecidos pelo sistema. Por fim, futuras etapas deste projeto poderiam incluir o desenvolvimento de um aplicativo móvel com funcionalidades como armazenamento seguro dos exames, integração com sistemas de prontuário eletrônico e suporte a telemedicina.

5. Referências

1. Instituto Nacional de Câncer (INCA). (2024). Estimativa 2024: Incidência de Câncer no Brasil. Rio de Janeiro: INCA.
2. BROWN, A. E. et al. Skin Cancer Education Interventions for Primary Care Providers: a scoping review. *Journal Of General Internal Medicine*, [S.L.], v. 37, n. 9, 2022. Springer Science and Business Media LLC
3. JONES, O. T. et al. Artificial intelligence and machine learning algorithms for early detection of skin cancer in community and primary care settings: a systematic review. *The Lancet Digital Health*, [S.L.], v. 4, n. 6, 2022. Elsevier BV.
4. GONNA, N. et al. Sensitivity and Specificity for Skin Cancer Diagnosis in Primary Care Providers: a systematic literature review and meta-analysis of educational interventions and diagnostic algorithms. *Journal Of Cancer Education*, [S.L.], v. 37, n. 5, 2022. Springer Science and Business Media LLC.
5. Reddy S, Shaheed A, Patel R. Artificial Intelligence in Dermoscopy: Enhancing Diagnosis to Distinguish Benign and Malignant Skin Lesions. *Cureus*. 2024 Feb 21;16(2):e54656. doi: 10.7759/cureus.54656. PMID: 38523958; PMCID: PMC10959827.
6. Advances in early detection of melanoma and the future of at-home testing. Garrison ZR, Hall CM, Fey RM, Clister T, Khan N, Nichols R, Kulkarni RP. *Life (Basel)* 2023;13
7. U-Net-based models for skin lesion segmentation: more attention and augmentation. Mohammadi KP, Koosheshi MH, Ali S, Sadar AV. *arXiv*. 2022
8. ULTRALYTICS. *Ultralytics YOLO Docs*. Disponível em: <https://docs.ultralytics.com>. Acesso em: 15 jul. 2025.