

PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS

ESCOLA POLITÉCNICA E DE ARTES

GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO



**IDENTIFICAÇÃO DE MELANOMAS UTILIZANDO REDES NEURAIS
CONVOLUCIONAIS**

DIEGO DA SILVA VELOSO DE FARIA

Goiânia

2026

DIEGO DA SILVA VELOSO DE FARIA

**IDENTIFICAÇÃO DE MELANOMAS UTILIZANDO REDES NEURAIS
CONVOLUCIONAIS**

Trabalho de Conclusão de Curso
apresentado à Escola Politécnica e de
Artes, da Pontifícia Universidade Católica
de Goiás, como parte dos requisitos para
obtenção do título de Bacharel em Ciência
da Computação
Orientadora: Profa. Dra. Maria José
Pereira Dantas.

GOIÂNIA

2026

RESUMO

Este trabalho teve como objetivo desenvolver e avaliar um modelo para a classificação automatizada de melanoma e outras lesões cutâneas a partir de imagens dermatoscópicas. Para isso, foi utilizada a arquitetura EfficientNet-B3 com transferência de aprendizado, treinada com o conjunto de dados público HAM10000, composto por 10.015 imagens distribuídas em sete classes de lesões cutâneas. Devido ao acentuado desbalanceamento entre as classes, foram empregadas estratégias como *Focal Loss* com ponderação por classe, *mixup*, *dropout*, amostragem ponderada e ajuste fino progressivo. O fluxo de processamento também incluiu remoção de marcadores coloridos e pelos, realce de contraste, redimensionamento e normalização das imagens. No conjunto de validação, a configuração selecionada alcançou acurácia de 82,38%, F1-score ponderado de 0,828 e macro F1-score de 0,708. Para a classe melanoma, foram obtidos precisão de 0,565, recall de 0,609 e F1-score de 0,586. Os resultados indicam capacidade de discriminação entre as sete categorias avaliadas, porém o desempenho moderado para melanoma e a ausência de validação externa limitam a generalização dos achados. Assim, o modelo deve ser compreendido como um protótipo computacional experimental para classificação de lesões cutâneas, sem inferência de uso clínico nesta etapa.

Palavras-chave: classificação de lesões cutâneas; EfficientNet-B3; aprendizado profundo; HAM10000; *Focal Loss*.

ABSTRACT

This study aimed to develop and evaluate a model for the automated classification of melanoma and other skin lesions using dermoscopic images. The EfficientNet-B3 architecture with *transfer learning* was trained on the public HAM10000 dataset, which contains 10,015 images distributed across seven skin-lesion classes. To address class imbalance, the selected configuration included class-weighted *Focal Loss*, *mixup*, *dropout*, weighted sampling, and progressive *fine-tuning*. The processing workflow also included color-marker and hair removal, contrast enhancement, resizing, and image normalization. On the validation set, the selected configuration achieved an accuracy of 82.38%, a weighted F1-score of 0.828, and a macro F1-score of 0.708. For melanoma, precision was 0.565, recall was 0.609, and the F1-score was 0.586. The results indicate discrimination capability across the seven evaluated categories; however, the moderate melanoma performance and the absence of external validation limit the generalizability of the findings. Therefore, the model should be regarded as an experimental computational prototype for skin-lesion classification, without inference of clinical use at this stage.

Keywords: *skin lesion classification; EfficientNet-B3; aprendizado profundo; HAM10000; Focal Loss.*

LISTA DE SIGLAS

- akiec** – Queratoses actínicas e carcinoma intraepitelial
- AMP** – Precisão mista automática
- AUC** – Área sob a curva ROC
- bcc** – Carcinoma basocelular
- bkl** – Queratoses benignas (queratose seborreica e lentigo solar)
- CLAHE** – Equalização de histograma adaptativa com limitação de contraste (*Contrast Limited Adaptive Histogram Equalization*)
- CNN** – Rede neural convolucional (*Convolutional Neural Network*)
- CPU** – Unidade central de processamento
- CUDA** – Arquitetura de computação paralela da NVIDIA (*Compute Unified Device Architecture*)
- df** – Dermatofibroma
- FN** – Falso negativo
- FP** – Falso positivo
- GAN** – Rede adversária generativa (*Generative Adversarial Network*)
- GPU** – Unidade de processamento gráfico
- HAM10000** – Conjunto de dados “*Human Against Machine*” com 10.000 imagens
- HSV** – Matiz, saturação, valor (espaço de cor) (*Hue, Saturation and Value*)
- IA** – Inteligência Artificial
- ISIC** – Colaboração Internacional de Imagem da Pele (*International Skin Imaging Collaboration*)
- Lab** – Espaço de cor $CIE L * a * b *$
- LIME** – Explicações independentes do modelo interpretável local (*Local Interpretable Model-agnostic Explanations*)
- LR – Taxa de aprendizado** (*Learning Rate*)
- mel** – Melanoma
- nv** – Nevo melanocítico
- RAM** – Memória de acesso aleatório
- ReLU** – Unidade linear retificada (*Rectified Linear Unit*)
- ResNet** – Rede residual (*Residual Network*)
- ROC** – Característica de operação do receptor (*Receiver Operating Characteristic*)
- SVM** – Máquina de vetores de suporte (*Support Vector Machine*)
- TCC** – Trabalho de Conclusão de Curso

vasc – Lesões vasculares

VGG – Grupo de Geometria Visual (*Oxford*) (*Visual Geometry Group*)

VN – Verdadeiro negativo

VP – Verdadeiro positivo

LISTA DE ILUSTRAÇÕES

Figura 1 – Arquitetura LeNet-5.....	16
Figura 2 – Fluxo de pré-processamento das imagens do HAM10000	29
Figura 3 – Curvas de acurácia (treino e validação) ao longo das épocas.....	35
Figura 4 – Curvas de perda (treino e validação) ao longo das épocas.....	36

LISTA DE TABELAS

Tabela 1 – Métricas de classificação por classe no conjunto de validação	33
Tabela 2 – Matriz de confusão no conjunto de validação	34
Tabela 3 – Hiperparâmetros da configuração selecionada	37

SUMÁRIO

1 INTRODUÇÃO	9
2 OBJETIVOS	13
2.1 Objetivo geral	13
2.2 Objetivos específicos	13
3 REFERENCIAL TEÓRICO	15
3.1 Inteligência artificial e aprendizado de máquina em imagens médicas	15
3.2 Redes neurais convolucionais	16
3.3 Regularização para generalização em redes neurais profundas	19
3.3.1 Dropout	19
3.3.2 Normalização em lote (<i>Batch Normalization</i>)	20
3.3.3 Parada antecipada (<i>early stopping</i>)	20
3.3.4 Redução da taxa de aprendizado sob estagnação (<i>ReduceLROnPlateau</i>)	21
3.3.5 Considerações finais sobre a regularização	21
3.4 Melanoma em imagens dermatológicas	22
3.5 Estado da arte em diagnóstico automatizado de lesões cutâneas	22
4 PROCEDIMENTOS METODOLÓGICOS	25
4.1 Bases de dados públicas: HAM10000 e ISIC Archive	25
4.2 Divisão agrupada por identificador de lesão	26
4.3 Desbalanceamento de classes e impacto na classificação	26
4.4 Métricas de avaliação de desempenho	27
4.5 Técnicas de pré-processamento para imagens dermatoscópicas	28
4.6 Remoção de marcadores coloridos	28
4.7 Remoção de pelos com DullRazor aprimorado	29
4.8 Equalização CLAHE	30
4.9 Redimensionamento com GPU e paralelização	30
4.10 Normalização e reprodutibilidade	30
4.11 Aumento de dados	30
4.12 Carregamento de dados e otimização computacional	31
5 RESULTADOS	32
5.1 Caracterização do conjunto de dados	32
5.2 Desempenho do modelo	32
6 DISCUSSÃO	41
7 CONCLUSÃO	43
REFERÊNCIAS	45

1 INTRODUÇÃO

O câncer de pele está entre as neoplasias mais frequentes, e o melanoma, embora menos comum que os carcinomas cutâneos não melanoma, apresenta maior potencial de progressão e metástase. O diagnóstico em estágios iniciais é clinicamente relevante para o prognóstico (Davis; Shalin; Tackett, 2019; Arnold *et al.*, 2022).

De forma tradicional, o diagnóstico de lesões cutâneas é realizado por dermatologistas por meio da inspeção visual, frequentemente apoiada por dermatoscopia e exames histopatológicos. Apesar de ser o padrão clínico estabelecido, esse processo pode apresentar variabilidade interobservadora, uma vez que depende da experiência do especialista e de critérios subjetivos na análise das lesões (Esteva *et al.*, 2017).

A dermatoscopia, em particular, tem ampliado a capacidade de visualização de estruturas subsuperficiais da pele, permitindo uma análise mais detalhada de padrões pigmentares e vasculares. Ainda assim, a interpretação dessas imagens pode ser complexa, especialmente em estágios iniciais da doença, o que motiva o desenvolvimento de sistemas computacionais de apoio.

Projeções globais indicam crescimento da carga de melanoma cutâneo nas próximas décadas, reforçando a relevância de métodos de apoio à análise de imagens dermatológicas (Arnold *et al.*, 2022).

O fototipo cutâneo, conforme a classificação de Fitzpatrick (1988), é uma das características consideradas na avaliação da resposta da pele à exposição solar e deve ser interpretado em conjunto com outros fatores clínicos e epidemiológicos.

Nas últimas décadas, a Inteligência Artificial tem experimentado avanços substanciais, sobretudo no que se refere à aplicação de modelos baseados em Redes Neurais Convolucionais (Convolutional Neural Networks – CNNs) em problemas de classificação de imagens. Várias evidências recentes indicam que tais modelos são capazes de atingir níveis de desempenho comparáveis, e por vezes superiores, aos de especialistas humanos em tarefas específicas, como o diagnóstico dermatológico (Esteva *et al.*, 2017). Não obstante esses avanços, ainda se observam limitações relacionadas à acurácia global e à capacidade de generalização dos modelos em diferentes contextos (Kassem *et al.*, 2021; Shen; Wu; Suk, 2017; Li *et al.*, 2023; Perez *et al.*, 2018). Nesse cenário, o pré-processamento de imagens configura-se como uma etapa crítica, uma vez que contribui diretamente para a qualidade dos dados de entrada e, conseqüentemente, para o desempenho final dos modelos (Lee *et al.*, 1997; Abbas; Celebi; García, 2011; Bibiloni; González-Hidalgo; Massanet, 2017; Perez *et al.*, 2018).

O aprendizado profundo insere-se como um dos principais paradigmas dentro do Aprendizado de Máquina, sendo fundamentado na utilização de Redes Neurais Artificiais estruturadas em múltiplas camadas (Goodfellow; Bengio; Courville, 2016). Inspiradas em abstrações do funcionamento do sistema nervoso biológico, essas redes são projetadas para aprender representações hierárquicas dos dados, possibilitando a extração de características em diferentes níveis de abstração. Tal capacidade torna esses modelos particularmente adequados para o processamento de dados complexos e de alta dimensionalidade, como imagens digitais.

Historicamente, os primeiros modelos de redes neurais foram propostos na década de 1940; entretanto, limitações computacionais e metodológicas restringiram seu desenvolvimento por longo período. Um avanço importante ocorreu com a consolidação do algoritmo de retropropagação do erro, apresentado por Rumelhart, Hinton e Williams (1986), que viabilizou o ajuste iterativo dos pesos em redes com múltiplas camadas.

No processo de treinamento, os parâmetros da rede são inicialmente atribuídos de forma aleatória. A partir da apresentação de exemplos rotulados, o modelo realiza predições que são comparadas com os valores esperados, resultando em um erro que é retro propagado ao longo da rede. Esse mecanismo permite a atualização dos pesos de forma incremental, conduzindo à convergência do modelo para soluções que minimizem a discrepância entre as saídas previstas e os valores reais.

As Redes Neurais Convolucionais constituem uma classe especializada de redes neurais projetadas para lidar com dados organizados em estruturas matriciais, como imagens. Sua consolidação na literatura científica ocorreu com os trabalhos de LeCun *et al.* (1998), que demonstraram a eficácia desse tipo de arquitetura em tarefas de reconhecimento de padrões visuais. A principal vantagem das CNNs reside na capacidade de realizar a extração automática de características diretamente a partir dos dados.

Do ponto de vista estrutural, as CNNs são compostas por diferentes tipos de camadas que desempenham funções específicas no processamento da informação. As camadas convolucionais são responsáveis pela extração de padrões locais por meio da aplicação de filtros; as funções de ativação introduzem não linearidades no modelo; e as camadas de *pooling* realizam a redução da dimensionalidade, preservando as características mais relevantes. Essa organização hierárquica contribui para a eficiência desses modelos na interpretação de dados visuais (Goodfellow; Bengio; Courville, 2016).

Modelos baseados em redes neurais convolucionais têm sido amplamente investigados para classificação de imagens dermatológicas (Esteva *et al.*, 2017; Topol, 2019; Li *et al.*, 2023). Apesar dos resultados experimentais relevantes, permanecem desafios relacionados ao desbalanceamento das classes, à qualidade dos dados, à interpretabilidade e à generalização para populações e dispositivos distintos (Kassem *et al.*, 2021; Omiye *et al.*, 2023). Nesse contexto, o pré-processamento pode reduzir artefatos e padronizar as imagens de entrada, desde que seus efeitos sejam avaliados com cautela (Lee *et al.*, 1997; Abbas; Celebi; García, 2011; Bibiloni; González-Hidalgo; Massanet, 2017).

Diante do exposto, este trabalho adota a arquitetura EfficientNet-B3 como modelo central para a classificação multiclasse de lesões cutâneas. A escolha fundamenta-se no escalonamento composto proposto por Tan e Le (2019), que equilibra profundidade, largura e resolução. Neste TCC, a EfficientNet-B3 não é apresentada como superior a outras arquiteturas: ela constitui a arquitetura selecionada para o experimento, com base em sua eficiência paramétrica e em sua consolidação na literatura de visão computacional.

Diante desse contexto, este trabalho busca responder à seguinte questão: Qual é o desempenho da arquitetura EfficientNet-B3, associada a estratégias de regularização e mitigação do desbalanceamento de classes, na classificação das sete categorias de lesões cutâneas do HAM10000, com ênfase na classe melanoma?

2 OBJETIVOS

2.1 Objetivo geral

- Desenvolver e avaliar um modelo de classificação automatizada de lesões cutâneas baseado na arquitetura EfficientNet-B3 e em transferência de aprendizado, utilizando imagens dermatoscópicas do conjunto HAM10000, com ênfase no tratamento do desbalanceamento das classes e na identificação da classe melanoma.

2.2 Objetivos específicos

- Selecionar e justificar, com base na literatura especializada, a arquitetura EfficientNet-B3 como modelo central para a classificação de lesões cutâneas, considerando seu reconhecido equilíbrio entre acurácia e eficiência computacional.
- Estruturar um fluxo de pré-processamento de imagens dermatoscópicas que inclua remoção de marcadores coloridos, remoção de pelos com o algoritmo DullRazor aprimorado, equalização de contraste (CLAHE) e redimensionamento padronizado para 224×224 pixels, com aceleração por GPU e paralelização.
- Implementar estratégias de mitigação do desbalanceamento das classes do conjunto de dados HAM10000, empregando a função de perda *Focal Loss* com parâmetro $\gamma = 2,0$, ponderação balanceada, técnica de regularização *mixup* ($\alpha = 0,1$) e amostragem ponderada pelo inverso da raiz quadrada da frequência de cada classe.
- Ajustar o modelo EfficientNet-B3 por meio de *fine-tuning* progressivo (congelamento inicial do *backbone*, seguido de ajuste de todas as camadas a partir da época 3 com taxa de aprendizado reduzida), e utilizar técnicas de regularização como *dropout* (0,4), *early stopping* e redução dinâmica da taxa de aprendizado (*ReduceLROnPlateau*).
- Avaliar o desempenho do modelo no conjunto de validação do HAM10000 utilizando métricas sensíveis ao desbalanceamento (precisão, recall, F1-score por classe, matriz de confusão e curvas de acurácia/perda), com ênfase no F1-score da classe melanoma.

- Documentar a configuração final de hiperparâmetros e os principais procedimentos computacionais, favorecendo a reprodutibilidade e fornecendo base para futuros trabalhos de validação externa e explicabilidade.

3 REFERENCIAL TEÓRICO

3.1 Inteligência artificial e aprendizado de máquina em imagens médicas

A Inteligência Artificial (IA) tem se consolidado como uma das mais relevantes inovações tecnológicas no setor da saúde, promovendo avanços significativos no suporte ao diagnóstico clínico, na análise de exames e na tomada de decisão médica. Entre as principais abordagens utilizadas, destaca-se o Aprendizado de Máquina (Machine Learning), subcampo da IA voltado ao desenvolvimento de modelos capazes de aprender padrões a partir de dados sem a necessidade de programação explícita para cada tarefa, e, sobretudo, o Aprendizado Profundo (Deep Learning), que emprega redes neurais artificiais estruturadas em múltiplas camadas para aprender representações hierárquicas diretamente dos dados, reduzindo a dependência de extração manual de características (Li *et al.*, 2023; Terven *et al.*, 2025).

No contexto da visão computacional aplicada à saúde, as redes neurais convolucionais (Convolutional Neural Networks – CNNs) desempenham papel central, sendo amplamente utilizadas em tarefas de classificação, segmentação e detecção de anomalias em imagens médicas. O avanço dessas arquiteturas, aliado ao aumento da capacidade computacional e à disponibilidade de grandes bases de dados, tem impulsionado significativamente o desempenho de sistemas automatizados (Shen; Wu; Suk, 2017).

Na área da dermatologia, a aplicação de IA tem se mostrado particularmente promissora. Sistemas baseados em aprendizado profundo vêm sendo utilizados na análise de imagens dermatoscópicas para identificação de lesões cutâneas, incluindo o melanoma, com resultados promissores em cenários experimentais, embora a literatura ressalte limitações de generalização e de validação externa (Omiye *et al.*, 2023; Kassem *et al.*, 2021). Além disso, o uso de IA tem possibilitado avanços em diagnóstico assistido, triagem automatizada e suporte à decisão clínica, contribuindo para maior eficiência nos sistemas de saúde (Li *et al.*, 2023; Topol, 2019).

A relevância dessas aplicações é reforçada pelo aumento global da incidência de câncer de pele, especialmente o melanoma, considerado uma das formas mais agressivas da doença (Arnold *et al.*, 2022). Adicionalmente, fatores como a variabilidade da pigmentação cutânea e as condições de aquisição das imagens representam desafios importantes para o desenvolvimento de modelos robustos e generalizáveis. Nesse contexto, estudos recentes também destacam o papel de

técnicas de pré-processamento e aumento de dados na melhoria do desempenho dos modelos (Perez *et al.*, 2018; Shorten; Khoshgoftaar, 2019).


Apesar dos avanços significativos, ainda existem desafios relevantes, como a necessidade de grandes volumes de dados rotulados, a presença de vieses nos conjuntos de dados e a limitação na interpretabilidade dos modelos, fatores que podem impactar sua adoção em ambientes clínicos reais.

3.2 Redes Neurais Convolucionais

As Redes Neurais Convolucionais (*Convolutional Neural Networks* – CNNs) constituem uma classe específica de redes neurais artificiais projetadas para o processamento de dados estruturados em forma de grade, como imagens. Essas redes foram popularizadas a partir do trabalho de Yann LeCun, Léon Bottou, Yoshua Bengio e Patrick Haffner, publicado em 1998 sob o título “Gradient-Based Learning Applied to Document Recognition”, no qual foi apresentada a arquitetura LeNet-5 para reconhecimento de dígitos manuscritos, sendo amplamente utilizadas em visão computacional.

A arquitetura resultante, denominada LeNet-5, é composta por sete camadas, alternando entre convoluções e camadas densas (*fully connected*), conforme apresentado na Figura 1.

Figura 1 - Arquitetura LeNet-5



Fonte: LeCun *et al.* (1998, p. 7).

Desde então, as (*Convolutional Neural Networks* – CNNs) tornaram-se cada vez mais profundas e complexas, como a AlexNet, proposta por Alex Krizhevsky *et al.* (2012), que, apesar de possuir apenas oito camadas (cinco convolucionais e três *fully connected*), apresenta aproximadamente sessenta milhões de parâmetros, e a

GoogLeNet, proposta por Christian Szegedy *et al.* (2015), com vinte e duas camadas e cerca de quatro milhões de parâmetros.

As CNNs são compostas por diferentes tipos de camadas, dentre as quais se destacam as camadas convolucionais, responsáveis pela extração de características locais por meio da aplicação de filtros, gerando os chamados mapas de características (feature maps); as camadas de *pooling*, que reduzem a dimensionalidade dos dados; e as funções de ativação, que introduzem não linearidades ao modelo. Essa estrutura hierárquica permite que a rede identifique padrões simples nas primeiras camadas e características mais complexas nas camadas mais profundas (Goodfellow; Bengio; Courville, 2016).

Uma das principais vantagens das CNNs é a capacidade de realizar a extração automática de atributos relevantes diretamente dos dados brutos, reduzindo a necessidade de engenharia manual de características e tornando os modelos mais eficientes e adaptáveis a diferentes problemas (LeCun; Bengio; Hinton, 2015).

Posteriormente, o avanço de hardware especializado (GPUs) e o aumento da disponibilidade de grandes bases de dados permitiram a escalabilidade desses modelos, culminando no surgimento de arquiteturas profundas de alto desempenho.

A *AlexNet* consolidou o paradigma do aprendizado profundo em visão computacional ao demonstrar a superioridade das CNNs em competições de classificação de imagens de larga escala. Este marco foi seguido por arquiteturas mais profundas e eficientes, como a *ResNet*.

Em contrapartida, a *ResNet* (He *et al.*, 2016) introduz conexões residuais (skip connections), permitindo o fluxo direto de gradientes entre camadas não adjacentes. Essa inovação arquitetural resolve de forma eficiente o problema do desaparecimento do gradiente (vanishing gradient problem), permitindo o treinamento estável de redes extremamente profundas. Do ponto de vista matemático, tais conexões implementam uma função identidade somada ao mapeamento aprendido, facilitando a otimização em espaços de alta dimensionalidade.

Modelos subsequentes, como DenseNet (Huang *et al.*, 2017), EfficientNet (Tan; Le, 2019) e MobileNet (Howard *et al.*, 2017), avançaram na otimização da eficiência paramétrica e do custo computacional, introduzindo mecanismos de conectividade densa, escalonamento composto e convoluções separáveis em profundidade, respectivamente. Esses avanços têm sido amplamente explorados em aplicações médicas, especialmente em cenários com restrições de recursos computacionais.

Do ponto de vista teórico, a escolha da arquitetura ideal envolve o equilíbrio entre capacidade de representação, complexidade computacional e generalização estatística. Em problemas de visão médica, como a análise de imagens dermatoscópicas, tais fatores tornam-se ainda mais críticos devido à alta variabilidade intraclasse e à sutileza das diferenças entre lesões benignas e malignas.

Nesse contexto, a seleção de arquiteturas como a EfficientNet-B3 justifica-se pela sua ampla validação empírica na literatura e pela sua capacidade de representar diferentes compromissos arquiteturais entre profundidade, eficiência e precisão (Tan; Le, 2019). Diferentemente das abordagens tradicionais que escalonam redes neurais convolucionais (CNNs) de maneira heurística, a família EfficientNet introduz um método sistemático de escalonamento composto, que equilibra uniformemente as três dimensões fundamentais da arquitetura — profundidade (número de camadas), largura (número de canais) e resolução da imagem de entrada — por meio de um coeficiente composto escalar (Tan; Le, 2019). Tal abordagem permite que variantes como B0, B1, B2, B3 e superiores ocupem diferentes pontos no espectro de custo computacional versus acurácia, sendo a EfficientNet-B3 uma escolha estrategicamente intermediária que entrega elevada acurácia — com desempenho comprovado em *benchmarks* como o ImageNet, superando modelos significativamente maiores — sem demandar os recursos computacionais proibitivos das versões superiores ou de arquiteturas clássicas como a ResNet-152 ou DenseNet-201 (He *et al.*, 2016; Huang *et al.*, 2017; Tan; Le, 2019).

No domínio da dermatologia computacional, diferentes arquiteturas profundas têm sido avaliadas em bases públicas de lesões cutâneas. Neste estudo, a escolha da EfficientNet-B3 constitui uma decisão de projeto fundamentada na arquitetura de Tan e Le (2019), sem pretensão de demonstrar superioridade sobre modelos não avaliados experimentalmente no mesmo protocolo.

A configuração de um classificador para imagens dermatoscópicas envolve decisões sobre pré-processamento, resolução de entrada e tratamento do desbalanceamento. Neste trabalho, a remoção de pelos foi fundamentada em métodos clássicos de processamento de imagens (Lee *et al.*, 1997; Abbas; Celebi; García, 2011; Bibiloni; González-Hidalgo; Massanet, 2017), enquanto a EfficientNet-B3 foi escolhida a partir do escalonamento composto descrito por Tan e Le (2019).

Portanto, neste trabalho, optou-se pela EfficientNet-B3 como arquitetura central para a classificação automatizada de melanomas, tendo em vista sua consolidação empírica na literatura e seu equilíbrio entre precisão e custo computacional, fornecendo uma configuração experimental para investigação da classificação automatizada de lesões cutâneas (Li *et al.*, 2023; Topol, 2019; Davis; Shalin; Tackett, 2019).

3.3 Regularização para generalização em redes neurais profundas

No treinamento de redes neurais convolucionais profundas, um dos desafios centrais consiste em obter modelos que apresentem não apenas alto desempenho sobre os dados de treinamento, mas, sobretudo, elevada capacidade de generalização — isto é, que mantenham acurácia preditiva robusta quando expostos a exemplos não vistos (Goodfellow; Bengio; Courville, 2016). O fenômeno oposto, conhecido como sobreajuste (*overfitting*), ocorre quando a rede memoriza ruídos e peculiaridades do conjunto de treino, em vez de capturar os padrões verdadeiramente relevantes da distribuição subjacente. Para mitigar esse problema, recorre-se a um conjunto de estratégias denominadas técnicas de regularização.

Define-se regularização como qualquer modificação introduzida no algoritmo de aprendizado cujo propósito primário é reduzir o erro de generalização, ainda que eventualmente às custas de um aumento no erro de treinamento (Goodfellow; Bengio; Courville, 2016). Em termos práticos, a regularização atua restringindo a capacidade efetiva do modelo ou induzindo preferências por soluções mais simples e estáveis, guiando o processo de otimização para regiões do espaço de parâmetros que generalizam melhor. Dentre as abordagens de regularização implícita amplamente consolidadas na literatura, destacam-se o *Dropout*, a normalização em lote, a Parada Antecipada (*Early Stopping*) e a Redução Dinâmica da Taxa de Aprendizado (*ReduceLROnPlateau*).

3.3.1 *Dropout*

Proposto por Srivastava *et al.* (2014), o *Dropout* é uma técnica de regularização que consiste em “desligar” aleatoriamente uma fração dos neurônios de uma camada durante cada iteração da fase de treinamento. Cada unidade tem uma probabilidade p de ser temporariamente removida da rede, juntamente com todas as suas conexões de entrada e saída. Na prática, o *Dropout* obriga a rede a desenvolver representações internas redundantes e distribuídas, impedindo a co-adaptação excessiva entre neurônios específicos. No momento da inferência, todos os neurônios são mantidos e os pesos são devidamente escalonados, fazendo com que o procedimento se comporte como uma forma eficiente de combinar um conjunto exponencialmente grande de sub-redes distintas (ensemble implícito). Tal mecanismo resulta em modelos com menor propensão ao sobreajuste e maior robustez diante de variações nos dados de entrada (Srivastava *et al.*, 2014).

3.3.2 Normalização em lote (*Batch Normalization*)

Introduzida por Ioffe e Szegedy (2015), a normalização em lote normaliza as ativações de cada camada para que apresentem média zero e variância unitária, utilizando as estatísticas calculadas sobre o mini-lote (mini-batch) corrente. Originalmente concebida para mitigar o problema do internal covariate shift — a contínua mudança na distribuição das ativações internas durante o treinamento —, essa técnica acelera a convergência, permite o uso de taxas de aprendizado mais elevadas e torna o treinamento menos sensível à inicialização dos parâmetros. Embora seu propósito inicial não fosse explicitamente a regularização, o ruído introduzido pela estimação das estatísticas a partir de mini-lotes finitos produz um efeito regularizador complementar, reduzindo, em diversos contextos, a dependência de outras formas explícitas de regularização, como o próprio *Dropout* (Ioffe; Szegedy, 2015).

3.3.3 Parada antecipada (*early stopping*)

O *Early Stopping* é uma estratégia simples, porém eficaz, de regularização que consiste em monitorar uma métrica de desempenho — tipicamente a perda ou a

acurácia sobre um conjunto de validação — e interromper o processo de treinamento assim que essa métrica deixa de apresentar melhora por um número pré-estabelecido de épocas. Ao final, restauram-se os pesos correspondentes à melhor época registrada durante a validação. Do ponto de vista conceitual, a parada antecipada limita o número efetivo de atualizações dos parâmetros, evitando que o otimizador continue a se adaptar ao ruído dos dados de treino após o modelo já ter capturado os padrões principais. Goodfellow, Bengio e Courville (2016) enquadram o *Early Stopping* como uma forma de regularização implícita que controla a capacidade efetiva da rede sem a necessidade de modificar a função de custo ou a arquitetura.

3.3.4 Redução da taxa de aprendizado sob estagnação (ReduceLROnPlateau)

A técnica conhecida como ReduceLROnPlateau atua dinamicamente sobre a taxa de aprendizado durante o treinamento. Quando a perda de validação estagna e não apresenta redução significativa por um número predefinido de épocas consecutivas, a taxa de aprendizado é multiplicada por um fator de redução (inferior a um). Essa estratégia, discutida em Goodfellow, Bengio e Courville (2016) no contexto mais amplo de esquemas de decaimento adaptativo da taxa de aprendizado, permite que o treinamento prossiga com passos menores de atualização, refinando a convergência em direção a mínimos locais mais estáveis. Mínimos amplos (flat minima), que tendem a ser encontrados com taxas de aprendizado reduzidas, estão frequentemente associados a uma melhor generalização, uma vez que a função de perda na vizinhança desses pontos é menos sensível a pequenas perturbações nos parâmetros do modelo.

3.3.5 Considerações finais sobre a regularização

As técnicas aqui descritas atuam por mecanismos distintos, porém complementares, na supressão do sobreajuste e na promoção da generalização. O *dropout* promove redundância nas representações internas; a normalização em lote estabiliza e acelera o treinamento ao mesmo tempo que adiciona um ruído suave; o *Early Stopping* controla o horizonte de treinamento efetivo; e a redução dinâmica da

taxa de aprendizado refina a busca no espaço de parâmetros. Em cenários com dados limitados — frequentes na área de imagens médicas dermatoscópicas —, a combinação dessas estratégias pode contribuir para controlar o sobreajuste e favorecer a generalização (Goodfellow; Bengio; Courville, 2016; Srivastava *et al.*, 2014; Ioffe; Szegedy, 2015).

3.4 Melanoma em imagens dermatológicas

Especificamente no contexto do melanoma, Esteva *et al.* (2017) demonstraram que redes neurais profundas podem alcançar desempenho comparável ao de especialistas em tarefas específicas de classificação de imagens cutâneas. O estudo constitui um marco para a área ao evidenciar o potencial da classificação automatizada, mas não elimina a necessidade de validação externa, avaliação em populações diversas e análise clínica antes de qualquer uso assistencial.

Dessa forma, sistemas automatizados podem ser investigados como ferramentas auxiliares de análise de imagens, mas sua utilização clínica depende de validação externa, avaliação de segurança e integração com a decisão de profissionais qualificados. Neste trabalho, o modelo é tratado exclusivamente como protótipo experimental.

3.5 Estado da arte em diagnóstico automatizado de lesões cutâneas

A classificação automatizada de lesões cutâneas por redes neurais convolucionais consolidou-se como uma linha relevante de pesquisa a partir de estudos que demonstraram o potencial do aprendizado profundo na análise de imagens dermatológicas (Esteva *et al.*, 2017). A disponibilização do HAM10000 ampliou a possibilidade de avaliação reprodutível em um conjunto público com sete classes diagnósticas e múltiplas imagens por lesão (Tschandl; Rosendahl; Kittler, 2018). Revisões posteriores mostram que o campo avançou rapidamente, mas permanece condicionado à qualidade dos dados, ao desbalanceamento entre classes e à validação em populações e bases distintas (Kassem *et al.*, 2021; Li *et al.*, 2023; Omiye *et al.*, 2023).

Entre os desafios metodológicos, o desbalanceamento das classes é particularmente importante porque métricas globais podem ocultar desempenho insuficiente em categorias minoritárias. Estratégias como aumento de dados, amostragem ponderada e funções de perda sensíveis a exemplos difíceis são empregadas para atenuar esse efeito. Em lesões cutâneas, o aumento de dados é amplamente explorado para introduzir variações geométricas e fotométricas plausíveis (Perez *et al.*, 2018; Shorten; Khoshgoftaar, 2019). A *Focal Loss* foi proposta para reduzir a contribuição relativa de exemplos fáceis e concentrar o aprendizado nos casos mais difíceis (Lin *et al.*, 2017), enquanto o *mixup* constitui uma estratégia de regularização baseada em combinações convexas de amostras e rótulos (Zhang *et al.*, 2018).

A escolha arquitetural também envolve compromisso entre capacidade representacional e custo computacional. A EfficientNet propõe escalonamento composto de profundidade, largura e resolução, buscando eficiência no uso de parâmetros e recursos de processamento (Tan; Le, 2019). Neste TCC, a EfficientNet-B3 foi adotada como arquitetura central por esse equilíbrio descrito na literatura, sem pretensão de demonstrar superioridade experimental sobre outras arquiteturas, uma vez que não foi realizado estudo comparativo com modelos alternativos.

O pré-processamento das imagens constitui outro componente relevante. Pelos, marcadores e variações locais de contraste podem interferir na representação visual da lesão. O DullRazor é uma referência clássica para remoção de pelos em imagens dermatoscópicas (Lee *et al.*, 1997), e estudos comparativos e morfológicos discutem alternativas para identificação e reconstrução dessas regiões (Abbas; Celebi; García, 2011; Bibiloni; González-Hidalgo; Massanet, 2017). No presente trabalho, essas técnicas são tratadas como componentes do fluxo de processamento; seu efeito individual sobre o desempenho não é inferido, pois não foi conduzido estudo de ablação.

Assim, a lacuna abordada por este trabalho não consiste na proposição de uma nova arquitetura nem na validação clínica de um sistema diagnóstico. A contribuição está na implementação e avaliação interna de uma configuração baseada em EfficientNet-B3 no HAM10000, combinando estratégias de regularização e mitigação do desbalanceamento, com análise por classe e ênfase no melanoma. Essa delimitação é compatível com as limitações apontadas na literatura quanto à necessidade de validação externa, controle de viés e interpretação cautelosa de

resultados em inteligência artificial aplicada à dermatologia (Kassem *et al.*, 2021; Omiye *et al.*, 2023; Topol, 2019).

4 PROCEDIMENTOS METODOLÓGICOS

4.1 Bases de dados públicas: HAM10000 e ISIC Archive

Bases públicas de imagens dermatológicas são fundamentais para o avanço da pesquisa. Neste trabalho, utilizou-se o HAM10000 (Human Against Machine with 10000 training images), publicado por Tschandl, Rosendahl e Kittler (2018) e disponível pelo International Skin Imaging Collaboration (ISIC Archive).

O HAM10000 contém 10.015 imagens dermatoscópicas coletadas ao longo de 20 anos em dois centros principais – Universidade de Medicina de Viena (Áustria) e clínica de Cliff Rosendahl em Queensland (Austrália). As lesões são divididas em sete categorias, representando mais de 95% das lesões pigmentadas da prática clínica:

1. akiec – queratoses actínicas e carcinoma intraepitelial;
2. bcc – carcinoma basocelular;
3. bkl – queratoses benignas (incluindo queratose seborreica e lentigo solar);
4. df – dermatofibroma;
5. mel – melanoma (classe de maior interesse);
6. nv – nevos melanocíticos (lesões benignas mais frequentes);
7. vasc – lesões vasculares.

Quanto à natureza, esta pesquisa caracteriza-se como aplicada, pois busca desenvolver e avaliar uma solução computacional voltada à classificação de lesões cutâneas em imagens dermatoscópicas. Em relação à abordagem, trata-se de uma pesquisa quantitativa, uma vez que o desempenho do modelo é avaliado por meio de métricas numéricas, como acurácia, precisão, recall e F1-score. Quanto aos objetivos, apresenta caráter exploratório e descritivo, pois investiga o comportamento da arquitetura EfficientNet-B3 e descreve seu desempenho nas diferentes classes do conjunto HAM10000. Em relação aos procedimentos, combina pesquisa bibliográfica e experimentação computacional, envolvendo o treinamento, a validação e o teste de uma rede neural convolucional. Essa caracterização segue os critérios metodológicos apresentados por Gil (2017).

4.2 Divisão agrupada por identificador de lesão

O vazamento de dados ocorre quando imagens da mesma lesão aparecem em subconjuntos diferentes, podendo superestimar o desempenho. Como o HAM10000 contém múltiplas imagens por lesão, adotou-se uma divisão agrupada por *lesion_id* com *GroupShuffleSplit*, da biblioteca scikit-learn (Pedregosa *et al.*, 2011), de modo que todas as imagens de uma mesma lesão permanecessem em um único subconjunto. As proporções utilizadas foram 70% para treino, 15% para validação e 15% para teste. O conjunto de teste foi reservado, mas seus resultados não são reportados neste trabalho.

4.3 Desbalanceamento de classes e impacto na classificação

Conjuntos de dados médicos frequentemente apresentam desbalanceamento. No HAM10000, a classe mel (melanoma) é minoritária em relação à classe nv (nevos melanocíticos). O conjunto contém 10.015 imagens dermatoscópicas distribuídas em sete classes: nv (n=6.705; 66,9%), mel (n=1.113; 11,1%), bkl (n=1.099; 11,0%), bcc (n=514; 5,1%), akiec (n=327; 3,3%), vasc (n=142; 1,4%) e df (n=115; 1,1%). A razão entre a classe mais frequente e melanoma é de aproximadamente 6:1 e chega a cerca de 58:1 entre nv e df. Esse cenário justifica o uso de métricas por classe e de estratégias de treinamento voltadas à redução do viés em favor da classe majoritária. Neste trabalho, foram empregados aumento de dados, *Focal Loss* e amostragem ponderada; como não há estudo de ablação completo, seus efeitos individuais não são inferidos separadamente (Tschandl; Rosendahl; Kittler, 2018; Shorten; Khoshgoftaar, 2019; Lin *et al.*, 2017).

Para assegurar a qualidade dos rótulos, os autores do HAM10000 empregaram quatro métodos de validação: confirmação histopatológica (mais de 50% dos diagnósticos validados por biópsia), acompanhamento clínico (*follow-up* de nevos por período igual ou superior a 1,5 ano), consenso de especialistas e microscopia confocal. Além disso, o conjunto foi propositadamente disponibilizado com características típicas do “mundo real”, como presença de pelos, variações de iluminação e marcadores coloridos, o que o consolida como um *benchmark* robusto (Tschandl; Rosendahl; Kittler, 2018).

4.4 Métricas de avaliação de desempenho

Para avaliar o modelo de classificação multiclasse (sete classes diagnósticas do HAM10000), com ênfase na classe melanoma, utilizaram-se métricas consolidadas na literatura, calculadas por classe segundo a estratégia *one-vs-rest* e agregadas por média macro e ponderada, com destaque para aplicações médicas onde falsos negativos são críticos (Terven *et al.*, 2025). Todas derivam da matriz de confusão, que contabiliza, para cada classe:

- VP (Verdadeiros Positivos): instâncias da classe de interesse corretamente classificadas (ex.: melanomas corretamente identificados como melanoma).
- VN (Verdadeiros Negativos): instâncias das demais classes corretamente classificadas como não pertencentes à classe de interesse (ex.: lesões não malignas corretamente classificadas como não-melanoma).
- FP (Falsos Positivos): instâncias de outras classes incorretamente classificadas como pertencentes à classe de interesse (ex.: não-melanomas classificados como melanoma).
- FN (Falsos Negativos): instâncias da classe de interesse incorretamente classificadas como pertencentes a outra classe (ex.: melanomas classificados como não-melanoma).

Definem-se:

Acurácia (proporção de acertos):

$$\text{Acurácia} = \frac{VP + VN}{VP + VN + FP + FN}$$

Precisão (proporção de predições positivas corretas):

$$\text{Precisão} = \frac{VP}{VP + FP}$$

Recall (Sensibilidade) (proporção de melanomas corretamente identificados):

$$\text{Recall} = \frac{VP}{VP + FN}$$

F1-score (média harmônica entre precisão e recall):

$$F_1 = \frac{2 \cdot \text{Precisão} \cdot \text{Recall}}{\text{Precisão} + \text{Recall}}$$

- Matriz de Confusão: apresentada graficamente, permite visualizar os erros por categoria.
- Suporte: número de instâncias reais de cada classe no conjunto avaliado (ex.: suporte de 128 para a classe mel significa que o conjunto de validação contém 128 imagens rotuladas como melanoma).

Neste trabalho, as métricas foram calculadas sobre o conjunto de validação — o conjunto de teste foi reservado na divisão dos dados (Seção 4.2), mas seus resultados não são reportados nesta versão do trabalho —, e o modelo foi avaliado prioritariamente pelo F1-score para a classe melanoma e pelo recall, por serem mais informativos que a acurácia em cenários desbalanceados.

4.5 Técnicas de pré-processamento para imagens dermatoscópicas

O pré-processamento é fundamental para sistemas de classificação baseados em aprendizado profundo, especialmente em imagens médicas, onde a qualidade dos dados impacta diretamente o desempenho (Abbas; Celebi; García, 2011). Desenvolveu-se um fluxo de processamento para reduzir ruídos, remover artefatos e padronizar as imagens dermatológicas.

4.6 Remoção de marcadores coloridos

Marcadores visuais (linhas, círculos, setas) podem interferir na extração de características. Utilizou-se um método baseado no espaço HSV, com máscaras para as faixas verde ($H \in [35,85]$, $S \geq 40$, $V \geq 40$), azul ($H \in [85,135]$, $S \geq 40$, $V \geq 40$) e amarela ($H \in [20,35]$, $S \geq 40$, $V \geq 40$), unidas por operações *bitwise_or* e refinadas por operações morfológicas de abertura e fechamento (*kernel* 7×7). As regiões identificadas são reconstruídas por *inpainting* por propagação de bordas com


INPAINT_TELEA (raio 10), implementação baseada no método de Telea (2004). Esta etapa é aplicada antes da remoção de pelos.

4.7 Remoção de pelos com DullRazor aprimorado

Pelos são artefatos comuns e prejudiciais (Lee *et al.*, 1997). Adotou-se o algoritmo DullRazor estendido: (a) conversão para escala de cinza; (b) transformação *black-hat*; (c) limiarização adaptativa; (d) dilatação para conectar regiões; (e) *inpainting* para reconstrução (Abbas; Celebi; García, 2011).

Figura 2 – Fluxo de pré-processamento das imagens do HAM10000

DULLRAZOR: ALGORITMO DE REMOÇÃO DE PÊLOS EM IMAGENS DERMATOSCÓPICAS – FLUXO E DETALHES TÉCNICOS



Fonte: elaboração própria.

A Figura 2 ilustra o fluxograma do algoritmo de remoção de pelos adotado como etapa de pré-processamento, composto por duas fases sequenciais — segmentação e reconstrução — cujo objetivo é eliminar artefatos pilosos que comprometem a extração de características das lesões cutâneas. A etapa de segmentação identifica os pelos por meio da transformação morfológica *black-hat*, que realça estruturas escuras e finas em relação ao fundo da pele, seguida de limiarização adaptativa e operações de dilatação para conectar regiões fragmentadas da máscara. A etapa de reconstrução aplica o algoritmo de *inpainting* por propagação de bordas, detalhado na Seção 4.8, para preencher as regiões identificadas com base na textura da pele adjacente, preservando as características morfológicas e colorimétricas da lesão subjacente (Lee *et al.*, 1997; Abbas; Celebi; García, 2011).

4.8 Equalização CLAHE

Para reduzir variações locais de contraste, aplicou-se CLAHE com *clipLimit* = 3,0 e *tileGridSize* = (8, 8). A técnica realça estruturas locais com limitação de contraste, buscando evitar amplificação excessiva de ruído.

4.9 Redimensionamento com GPU e paralelização

Todas as imagens foram redimensionadas experimentalmente para 224×224 pixels, com o objetivo de reduzir o custo computacional e adequar o treinamento aos recursos disponíveis. O fluxo de processamento explora aceleração por GPU via OpenCV CUDA, com *fallback* para CPU e processamento paralelo controlado por múltiplas threads. Essas escolhas são descritas como aspectos de implementação e não como fatores causalmente responsáveis pelo desempenho do classificador.

4.10 Normalização e reprodutibilidade

As imagens foram normalizadas antes do treinamento como parte do fluxo de pré-processamento, com o objetivo de manter uma escala numérica adequada à entrada do modelo. Como as versões textuais consolidadas não preservam de forma inequívoca os parâmetros finais dessa etapa, o trabalho não atribui à normalização um efeito causal isolado sobre o desempenho observado.

4.11 Aumento de dados

Para aumentar a variabilidade do conjunto de treinamento e reduzir o sobreajuste, foram aplicadas transformações geométricas e fotométricas exclusivamente às imagens de treino durante o carregamento dos dados. As transformações incluíram rotação de até $\pm 20^\circ$, translações horizontais e verticais de até 20%, cisalhamento e zoom de até 20%, espelhamentos horizontal e vertical e variação de brilho entre 0,8 e 1,2. Os conjuntos de validação e teste não receberam aumento de dados; foram submetidos apenas às etapas de redimensionamento e normalização.

A escolha dos intervalos de transformação foi baseada em estratégias de aumento de dados reportadas na literatura de análise de lesões cutâneas. Essas

transformações procuram representar variações geométricas e fotométricas plausíveis sem modificar os rótulos das imagens (Perez *et al.*, 2018; Shorten; Khoshgoftaar, 2019).

Dessa forma, o aumento de dados foi empregado como estratégia de regularização durante o treinamento. Como não foi realizado um estudo de ablação completo, seu efeito não é interpretado isoladamente como causa do desempenho final.

4.12 Carregamento de dados e otimização computacional

No estágio de treinamento, o carregamento de dados foi organizado de forma assíncrona, com processos de trabalho em segundo plano para reduzir períodos de ociosidade da GPU. O treinamento também utilizou precisão mista, mantendo operações em menor precisão quando possível e preservando precisão superior nas etapas sensíveis. Esses recursos são descritos apenas como aspectos de execução computacional do experimento.

Esses recursos constituem otimizações computacionais do treinamento e não foram avaliados como contribuições independentes para a acurácia do classificador. Assim, são apresentados como parte da configuração de execução do experimento, e não como evidência de desempenho clínico ou de escalabilidade em produção.

5 RESULTADOS

Este capítulo apresenta os resultados obtidos com a configuração final da arquitetura EfficientNet-B3. São analisadas as métricas de classificação por classe, a matriz de confusão e as curvas de treinamento e validação. Os procedimentos de preparação dos dados, pré-processamento, configuração da arquitetura e treinamento foram descritos no capítulo de Procedimentos Metodológicos.

5.1 Caracterização do conjunto de dados

O experimento utilizou o conjunto público HAM10000, disponibilizado pelo ISIC Archive, com 10.015 imagens dermatoscópicas distribuídas em sete classes diagnósticas. A composição da base e o procedimento de divisão por *lesion_id* foram descritos no Capítulo 4; nesta seção, apresentam-se apenas os elementos necessários à interpretação dos resultados.

5.2 Desempenho do modelo

O modelo alcançou acurácia de 82,38% no conjunto de validação. A Tabela 1 apresenta as métricas de precisão, recall e F1-score para cada uma das sete classes diagnósticas.

Tabela 1 – Métricas de classificação por classe no conjunto de validação

Classe	Precisão	Recall	F1-Score	Suporte
akiec	0,535	0,605	0,568	38
bcc	0,676	0,667	0,672	69
bkl	0,659	0,777	0,713	139
df	0,722	0,867	0,788	15
mel	0,565	0,609	0,586	128
nv	0,936	0,883	0,909	872
vasc	0,609	0,875	0,718	16
média macro	0,672	0,755	0,708	1277
média ponderada	0,836	0,824	0,828	1277

Fonte: elaboração própria.

Observa-se que a classe melanoma (mel) obteve *F1-score* de 0,586, com precisão de 0,565 e *recall* de 0,609. Isso significa que o modelo identificou corretamente 78 das 128 imagens de melanoma do conjunto de validação, correspondendo a aproximadamente 61% dos melanomas reais. Entre as 138 predições atribuídas à classe melanoma, 78 estavam corretas, resultando em precisão de aproximadamente 56,5%. Embora o modelo apresente capacidade de discriminação entre as sete classes, a quantidade de falsos negativos para melanoma permanece relevante.

A Tabela 2 apresenta a matriz de confusão do conjunto de validação. Entre as confusões mais relevantes, 22 imagens reais de melanoma foram classificadas como nevus melanocíticos (nv). Também foram observadas 12 imagens de queratoses benignas (bkl) classificadas como carcinoma basocelular (bcc). No total, 50 das 128 imagens reais de melanoma foram atribuídas a outras classes.

Tabela 2 – Matriz de confusão no conjunto de validação


Real \ Predito	akiec	bcc	bkl	df	mel	nv	vasc
akiec(38)	23	3	0	0	4	8	0
bcc(69)	5	46	3	0	0	15	0
bkl(139)	7	12	108	0	8	4	0
df(15)	0	0	0	13	0	2	0
mel(128)	4	6	18	0	78	22	0
nv(872)	4	1	35	5	48	770	9
vasc(16)	0	0	0	0	0	2	14

Fonte: elaboração própria.

A matriz de confusão totaliza 1.277 amostras e 1.052 classificações corretas, correspondendo à acurácia global de 82,38%. Para melanoma, a matriz resulta em *recall* de $78/128 = 0,609$ e precisão de $78/138 = 0,565$, em concordância com as métricas apresentadas na Tabela 1.

A Figura 3 apresenta as curvas de acurácia e a Figura 4 as curvas da função de perda ao longo das 45 épocas de treinamento. A acurácia de validação estabiliza aproximadamente entre 78% e 82%, enquanto a acurácia registrada durante o treinamento permanece em torno de 55% a 60% nas épocas finais. Esse comportamento, no qual a validação se mantém acima do treinamento, é atípico e pode estar relacionado às condições distintas de cálculo das métricas durante o treino, incluindo técnicas de regularização e aumento de dados. Assim, as curvas não devem ser interpretadas isoladamente como evidência de generalização.

Figura 3 – Curvas de acurácia (treino e validação) ao longo das épocas




Fonte: elaboração própria.

A Figura 3 ilustra a evolução da acurácia ao longo de aproximadamente 45 épocas de treinamento. A curva de treino representa a métrica registrada durante o treinamento, enquanto a curva de validação representa a avaliação no conjunto de validação.

Observa-se uma fase de aprendizado inicial acentuada nas primeiras 8 a 10 épocas, nas quais ambas as métricas partem de valores próximos de 10% e aumentam rapidamente. A partir da época 15, a velocidade de melhora desacelera, entrando em um período de estabilização. Entre as épocas 25 e 45, o modelo atinge um platô claro na validação, estabilizando-se entre 78% e 82%, enquanto a acurácia de treinamento estaciona em torno de 55% a 60%.

Figura 4 – Curvas de perda (treino e validação) ao longo das épocas



Fonte: elaboração própria.

A Figura 4 apresenta a evolução da função de perda ao longo das 45 épocas de treinamento. A curva de treinamento apresenta queda acentuada nas primeiras épocas e, posteriormente, estabilização em valores baixos. A perda de validação também diminui e passa a oscilar em uma faixa relativamente estável nas épocas finais. Em conjunto, as curvas indicam estabilização do processo de treinamento, mas não substituem uma avaliação independente em conjunto de teste ou base externa.

Tabela 3 – Hiperparâmetros da configuração selecionada

Parâmetro	Valor
Arquitetura	EfficientNet-B3
Pré-treinamento	ImageNet
Função de perda	<i>Focal Loss</i> ($\gamma=2,0$, α balanceado)
<i>Mixup α</i>	0,1
Amostragem	Ponderada por $1/\sqrt{\text{frequência}}$
<i>Dropout</i>	0,4
Otimizador	Adam
<i>Learning rate inicial</i>	1e-3
Fine-tuning	Época 3, LR = 1e-4
Mixed-precision	Sim (AMP)
Épocas	45
<i>Early stopping</i>	Paciência 20
Redução LR	ReduceLROnPlateau (fator 0,5, paciência 3)

Fonte: elaboração própria.

Os hiperparâmetros apresentados na Tabela 3 foram definidos empiricamente ao longo de onze rodadas de treinamento. A tabela registra a configuração utilizada para a avaliação reportada neste trabalho. Como não é apresentado um estudo de ablação completo, o efeito individual de cada componente não deve ser interpretado isoladamente.

Arquitetura – *EfficientNet-B3*

A EfficientNet (Tan; Le, 2019) é uma família de redes neurais convolucionais que escala simultaneamente profundidade, largura e resolução da imagem de forma balanceada. Embora a EfficientNet-B3 seja originalmente associada a uma resolução de entrada superior, neste trabalho adotou-se experimentalmente o redimensionamento para 224×224 pixels, com o objetivo de reduzir o custo computacional e adequar o treinamento aos recursos disponíveis.

Pré-treinamento – *ImageNet*

O modelo foi inicializado com pesos pré-treinados no ImageNet. A transferência de aprendizado permite reutilizar representações visuais previamente aprendidas antes do ajuste ao domínio dermatoscópico; neste trabalho, essa opção integra a configuração experimental e não é avaliada isoladamente.

Função de perda – *Focal Loss* ($\gamma = 2,0$, α balanceado)

Proposta por Lin *et al.* (2017) para problemas com forte desbalanceamento entre classes, a *Focal Loss* reduz a contribuição das amostras bem classificadas (fáceis) e concentra o aprendizado nas amostras com maior erro (difíceis). O parâmetro $\gamma = 2,0$ controla a taxa de redução das amostras fáceis. O α balanceado pondera cada classe pelo inverso de sua frequência, reduzindo a influência da classe majoritária nv, que corresponde a aproximadamente 66,9% da base completa.

Mixup $\alpha = 0,1$

Mixup (Zhang *et al.*, 2018) é uma técnica de regularização que gera novas amostras de treinamento por meio de combinações convexas de pares de imagens e seus respectivos rótulos. O coeficiente de mistura λ é amostrado de uma distribuição Beta(α , α). Com $\alpha = 0,1$, a maioria dos valores de λ se concentra próximo de 0 ou 1, produzindo combinações leves que regularizam o modelo sem descaracterizar as classes raras (mel, df, vasc).

Amostragem ponderada por $1/\sqrt{\text{frequência}}$

O amostrador atribui a cada imagem um peso inversamente proporcional à raiz quadrada da frequência de sua classe. Em comparação com o ponderamento linear $\frac{1}{\text{frequência}}$ essa abordagem suaviza o efeito do desbalanceamento, evitando que as classes minoritárias recebam pesos excessivamente altos e desestabilizem o treinamento.

Dropout = 0,4

O *dropout* (Srivastava *et al.*, 2014) desativa aleatoriamente 40% dos neurônios da camada classificadora a cada iteração de treinamento, reduzindo a dependência de unidades específicas. Neste trabalho, adotou-se a taxa de 0,4 como parte da configuração selecionada após as rodadas experimentais.

Otimizador – Adam

Adam (Kingma; BA, 2015) combina as vantagens dos métodos AdaGrad e RMSProp, ajustando a taxa de aprendizado individualmente para cada parâmetro. É amplamente utilizado em redes profundas por sua rápida convergência e robustez à escolha dos hiperparâmetros.

10^{-3} *Learning rate* inicial –

10^{-3} A taxa de aprendizado controla o tamanho do passo na direção oposta ao gradiente. O valor 10^{-3} é uma escolha comum para o Adam em tarefas de classificação de imagens com *transfer learning*, permitindo convergência rápida sem oscilações excessivas.

Fine-tuning – ativado na época 3, com LR = 10^{-4}

10^{-4} Nas primeiras 3 épocas, apenas a cabeça classificadora (as camadas adicionadas) foi treinada, mantendo o *backbone EfficientNet congelado*. A partir da época 3, todas as camadas da rede foram ajustadas (*fine-tuning*), utilizando uma taxa de aprendizado dez vezes menor para preservar os pesos pré-treinados no ImageNet enquanto se adaptam às características dermatológicas.

Mixed-precision – Sim (AMP)

O treinamento com precisão mista (Micikevicius *et al.*, 2018) utiliza operações em ponto flutuante de 16 bits (float16) para a maior parte dos cálculos, mantendo uma cópia dos parâmetros em float32. Essa técnica acelera o treinamento em GPUs compatíveis (arquitetura Volta ou superior) e reduz o consumo de memória, permitindo o uso de lotes maiores.

Número de épocas – 45

Foram executadas 45 épocas completas de treinamento. O mecanismo de *early stopping* permaneceu configurado com paciência de 20 épocas, embora o treinamento reportado tenha alcançado o limite definido.

Early stopping – paciência 20

O treinamento seria interrompido caso a perda de validação não apresentasse melhora por 20 épocas consecutivas. Essa configuração foi utilizada como critério de interrupção antecipada durante as rodadas experimentais.

Redução da taxa de aprendizado – *ReduceLROnPlateau* (fator 0,5, paciência 3)

O *ReduceLROnPlateau* reduz a taxa de aprendizado pela metade (fator 0,5) quando a perda de validação permanece sem melhora por três épocas consecutivas. Essa configuração integrou o procedimento de treinamento utilizado.

6 DISCUSSÃO

No conjunto de validação, o modelo baseado em *EfficientNet-B3* alcançou acurácia global de 82,38%, *F1-score* ponderado de 0,828 e macro *F1-score* de 0,708. O valor inferior do macro *F1-score* em relação ao *F1-score* ponderado evidencia o impacto do forte desbalanceamento entre as classes. Esses resultados devem ser interpretados como desempenho de validação da configuração selecionada, sem inferir superioridade direta sobre outros estudos que utilizam divisões de dados, pré-processamentos e protocolos de avaliação distintos.

Um aspecto que exige cautela é o comportamento das curvas de acurácia (Figura 3), nas quais a validação permaneceu acima do treinamento durante grande parte das épocas. Uma hipótese é que técnicas aplicadas apenas no treinamento, como *mixup* e aumento de dados, tornem a tarefa de treino mais difícil e reduzam a acurácia registrada nessa fase. Entretanto, sem uma avaliação adicional da acurácia no conjunto de treino em condições equivalentes às da validação, essa explicação não pode ser confirmada apenas pelas curvas apresentadas.

Para a classe melanoma, o modelo apresentou *F1-score* de 0,586, *recall* de 0,609 e precisão de 0,565. Das 128 imagens de melanoma presentes no conjunto de validação, 78 foram corretamente classificadas e 50 foram atribuídas a outras classes. Esse desempenho é moderado e a quantidade de falsos negativos permanece elevada para qualquer inferência de aplicação clínica. Portanto, o modelo deve ser considerado exclusivamente experimental.

A *Focal Loss* ($\gamma = 2,0$, α balanceado) integrou a configuração selecionada para reduzir a influência das amostras fáceis e dar maior peso relativo aos exemplos mais difíceis em um cenário de forte desbalanceamento. Como não é apresentado um estudo de ablação completo, o trabalho não permite atribuir isoladamente à *Focal Loss* o desempenho final observado.

A técnica *mixup* ($\alpha = 0,1$) também integrou a configuração final como estratégia de regularização. Os resultados apresentados correspondem ao desempenho da combinação de técnicas adotada, não sendo possível concluir, de forma isolada, que $\alpha = 0,1$ represente um ponto ótimo sem a apresentação sistemática das demais rodadas experimentais.

O amostrador ponderado por $1/\sqrt{\text{frequência}}$ foi empregado para atenuar o efeito do desbalanceamento durante o treinamento, sem impor ponderação linear extrema às classes minoritárias. Seu efeito deve ser interpretado como parte do conjunto de estratégias utilizadas, e não como contribuição causal isolada.

O *fine-tuning* foi ativado a partir da terceira época, com redução da taxa de aprendizado para $1e-4$, permitindo o ajuste do *backbone* pré-treinado ao domínio dermatoscópico. Essa configuração foi a utilizada no modelo reportado, mas a ausência de uma tabela comparativa das onze rodadas impede afirmar superioridade isolada em relação a outros momentos de descongelamento.

As maiores dificuldades concentram-se na distinção entre melanoma (mel) e nevos melanocíticos (nv), além de confusões entre queratoses benignas (bkl) e carcinoma basocelular (bcc). Na matriz de confusão, 22 melanomas foram classificados como nv, enquanto 12 imagens de bkl foram classificadas como bcc. Esses padrões de erro reforçam a necessidade de avaliar o desempenho por classe, e não apenas a acurácia global.

Limitações do estudo incluem:

- Validação apenas interna: os resultados são baseados exclusivamente no *HAM10000*, sem testes em bases externas independentes (ex.: *ISIC 2020*, *BCN20000*).
- Baixo suporte para classes raras: df (15 amostras na validação) e vasc (16 amostras) têm suporte muito pequeno, tornando as métricas estatisticamente menos confiáveis.
- Ausência de validação cruzada: a divisão única treino/validação/teste, agrupada por *lesion_id*, produz uma estimativa dependente da partição escolhida. Além disso, embora o conjunto de teste tenha sido reservado na divisão dos dados, seus resultados não são reportados nesta versão.
- Interpretabilidade limitada: o modelo opera como uma “caixa-preta”; não são fornecidas explicações visuais (ex.: mapas de ativação) sobre os critérios utilizados para cada decisão.

Futuros trabalhos devem contemplar validação externa, validação cruzada estratificada, aplicação de técnicas de explicabilidade (*Grad-CAM*, *LIME*) e exploração de arquiteturas mais recentes; essas direções são detalhadas na conclusão.

7 CONCLUSÃO

Este trabalho desenvolveu e avaliou um modelo baseado em rede neural convolucional, utilizando a arquitetura EfficientNet-B3, para a classificação automatizada de lesões cutâneas em imagens dermatoscópicas do conjunto HAM10000, com ênfase na identificação da classe melanoma. Após a definição de um fluxo de pré-processamento (remoção de marcadores, remoção de pelos, CLAHE e redimensionamento) e a seleção empírica de hiperparâmetros, a configuração final selecionada alcançou os seguintes resultados:

- Acurácia global: 82,38%
- F1-score ponderado: 0,828
- Macro F1-score: 0,708
- F1-score para melanoma (mel): 0,586 (precisão 0,565, recall 0,609)
- F1-score para outras classes minoritárias: df = 0,788; vasc = 0,718.

Os resultados indicam que a configuração selecionada, composta por Focal Loss com α balanceado, mixup com $\alpha = 0,1$, amostragem ponderada pelo inverso da raiz quadrada da frequência e fine-tuning a partir da terceira época, apresentou capacidade de discriminação entre as sete classes de lesões cutâneas. Entretanto, o recall de 0,609 para melanoma demonstra que ainda existe uma quantidade relevante de falsos negativos, impedindo sua aplicação clínica no estágio atual.

Como contribuições práticas, este trabalho apresenta:

- O desenvolvimento do código correspondente ao fluxo de pré-processamento com aceleração por GPU e paralelização.
- A documentação da configuração de hiperparâmetros utilizada na avaliação (Tabela 3), favorecendo a reprodução do procedimento por outros pesquisadores.
- Uma análise das classes de erro, com destaque para melanoma e para as classes de menor suporte, que pode orientar futuras etapas de validação e ampliação da base.

Para trabalhos futuros, recomenda-se:

1. Validação externa – testar o modelo em bases independentes, como ISIC 2020, BCN20000 ou conjuntos de dados hospitalares.
2. Validação cruzada estratificada – repetir os experimentos com 5 ou 10 folds para estimar a variabilidade do desempenho.
3. Explicabilidade – implementar técnicas como *Grad-CAM* ou LIME para gerar mapas de calor que evidenciem as regiões da imagem mais influentes para a decisão, aumentando a confiança clínica.
4. Arquiteturas mais recentes – avaliar *EfficientNet-B4/B5*, *Vision Transformers* (ViT) ou modelos híbridos *CNN-Transformer*.
5. Avaliação translacional futura – somente após validação externa e análise clínica, investigar formas apropriadas de integração do modelo a fluxos de apoio à pesquisa e à triagem supervisionada.

Por fim, os resultados demonstram o potencial experimental das redes neurais convolucionais com transferência de aprendizado para a classificação de lesões cutâneas. Entretanto, a ausência de validação externa, o desempenho moderado para melanoma e a utilização de uma única divisão dos dados limitam a generalização dos resultados.

REFERÊNCIAS

- ABBAS, Q.; CELEBI, M. E.; GARCÍA, I. F. Hair removal methods: a comparative study for dermoscopy images. *Biomedical Signal Processing and Control*, v. 6, n. 4, p. 395-404, 2011. DOI: 10.1016/j.bspc.2011.01.003.
- ARNOLD, M. *et al.* Global burden of cutaneous melanoma in 2020 and projections to 2040. *JAMA Dermatology*, v. 158, n. 5, p. 495-503, 2022. DOI: 10.1001/jamadermatol.2022.0160.
- BIBILONI, P.; GONZÁLEZ-HIDALGO, M.; MASSANET, S. Skin hair removal in dermoscopic images using soft color morphology. In: *CONFERENCE ON ARTIFICIAL INTELLIGENCE IN MEDICINE IN EUROPE*, 2017. Proceedings [...]. Cham: Springer, 2017. p. 322-326. DOI: 10.1007/978-3-319-59758-4_37.
- DAVIS, L. E.; SHALIN, S. C.; TACKETT, A. J. Current state of melanoma diagnosis and treatment. *Cancer Biology & Therapy*, v. 20, n. 11, p. 1366-1379, 2019. DOI: 10.1080/15384047.2019.1640032.
- ESTEVA, A. *et al.* Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, v. 542, p. 115-118, 2017. DOI: 10.1038/nature21056.
- FITZPATRICK, T. B. The validity and practicality of sun-reactive skin types I through VI. *Archives of Dermatology*, v. 124, n. 6, p. 869-871, 1988.
- GIL, A. C. Como elaborar projetos de pesquisa. 6. ed. São Paulo: Atlas, 2017.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep learning*. Cambridge: MIT Press, 2016.
- HE, K. *et al.* Deep residual learning for image recognition. In: *IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR)*, 2016. Proceedings [...]. p. 770-778. DOI: 10.1109/CVPR.2016.90.
- HOWARD, A. G. *et al.* MobileNets: efficient convolutional neural networks for mobile vision applications. arXiv preprint arXiv:1704.04861, 2017.
- HUANG, G. *et al.* Densely connected convolutional networks. In: *IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR)*, 2017. Proceedings [...]. p. 4700-4708. DOI: 10.1109/CVPR.2017.243.
- IOFFE, S.; SZEGEDY, C. Batch normalization: accelerating deep network training by reducing internal covariate shift. In: *INTERNATIONAL CONFERENCE ON MACHINE LEARNING (ICML)*, 2015. Proceedings of Machine Learning Research, v. 37, p. 448-456, 2015.
- KASSEM, M. A. *et al.* Machine learning and deep learning methods for skin lesion classification and diagnosis: a systematic review. *Diagnostics*, v. 11, n. 8, 1390, 2021. DOI: 10.3390/diagnostics11081390.
- KINGMA, D. P.; BA, J. Adam: a method for stochastic optimization. In: *INTERNATIONAL CONFERENCE ON LEARNING REPRESENTATIONS*, 2015. Anais [...]. 2015.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, v. 25, p. 1097-1105, 2012.

LECUN, Y.; BENGIO, Y.; HINTON, G. *Deep learning*. *Nature*, v. 521, n. 7553, p. 436-444, 2015.

LECUN, Y. *et al.* Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, v. 86, n. 11, p. 2278-2324, 1998.

LEE, T. *et al.* DullRazor: a software approach to hair removal from images. *Computers in Biology and Medicine*, v. 27, n. 6, p. 533-543, 1997.

LIN, T.-Y. *et al.* Focal loss for dense object detection. In: *IEEE INTERNATIONAL CONFERENCE ON COMPUTER VISION (ICCV), 2017. Proceedings [...]*. p. 2980-2988. DOI: 10.1109/ICCV.2017.324.

LI, X.; ZHAO, X.; MA, H.; XIE, B. Image analysis and diagnosis of skin diseases: a review. *Current Medical Imaging*, v. 19, n. 3, p. 199-242, 2023. DOI: 10.2174/1573405618666220516114605.

MICIKEVICIUS, P. *et al.* Mixed precision training. In: *INTERNATIONAL CONFERENCE ON LEARNING REPRESENTATIONS*, 2018. Anais [...]. 2018.

OMIYE, J. A.; GUI, H.; DANESHJOU, R.; CAI, Z. R.; MURALIDHARAN, V. Principles, applications, and future of artificial intelligence in dermatology. *Frontiers in Medicine*, v. 10, 1278232, 2023. DOI: 10.3389/fmed.2023.1278232.

PEDREGOSA, F. *et al.* Scikit-learn: machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825-2830, 2011.

PEREZ, F.; VASCONCELOS, C.; AVILA, S.; VALLE, E. Data augmentation for skin lesion analysis. In: *INTERNATIONAL WORKSHOP ON SKIN IMAGE ANALYSIS*, 2018. *Proceedings [...]*. Cham: Springer, 2018. p. 303-311. DOI: 10.1007/978-3-030-01201-4_33.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. *Nature*, v. 323, n. 6088, p. 533-536, 1986.

SHEN, D.; WU, G.; SUK, H.-I. *Deep learning* in medical image analysis. *Annual Review of Biomedical Engineering*, v. 19, p. 221-248, 2017. DOI: 10.1146/annurev-bioeng-071516-044442.

SHORTEN, C.; KHOSHGOFTAAR, T. M. A survey on image data augmentation for *deep learning*. *Journal of Big Data*, v. 6, n. 1, p. 60, 2019.

SRIVASTAVA, N. *et al.* Dropout: a simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, v. 15, n. 1, p. 1929-1958, 2014.

SZEGEDY, C. *et al.* Going deeper with convolutions. In: *IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR)*, 2015. *Proceedings [...]*. p. 1-9. DOI: 10.1109/CVPR.2015.7298594.

TAN, M.; LE, Q. V. EfficientNet: rethinking model scaling for convolutional neural networks. In: *INTERNATIONAL CONFERENCE ON MACHINE LEARNING (ICML)*, 2019. *Proceedings of Machine Learning Research*, v. 97, p. 6105-6114, 2019.

TELEA, A. An image inpainting technique based on the Fast Marching Method. *Journal of Graphics Tools*, v. 9, n. 1, p. 23-34, 2004. DOI: 10.1080/10867651.2004.10487596.

TERVEN, J. *et al.* A comprehensive survey of loss functions and metrics in deep learning. *Artificial Intelligence Review*, v. 58, art. 195, 2025. DOI: 10.1007/s10462-025-11198-7.

TOPOL, E. J. High-performance medicine: the convergence of human and artificial intelligence. *Nature Medicine*, v. 25, n. 1, p. 44-56, 2019.

TSCHANDL, P.; ROSENDAHL, C.; KITTLER, H. The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions. *Scientific Data*, v. 5, art. 180161, 2018. DOI: 10.1038/sdata.2018.161.

ZHANG, H. *et al.* mixup: beyond empirical risk minimization. In: INTERNATIONAL CONFERENCE ON LEARNING REPRESENTATIONS, 2018. Anais [...]. 2018.

RESOLUÇÃO nº 038/2020 – CEPE

ANEXO I

APÊNDICE ao TCC

Termo de autorização de publicação de produção acadêmica

O estudante Diego da Silva Veloso de Faria do Curso de Ciência da Computação matrícula 20182002800900, telefone: 6298140-1343 e-mail: diegodefaria02@gmail.com, na qualidade de titular dos direitos autorais, em consonância com a Lei nº 9.610/98 (Lei dos Direitos do Autor), autoriza a Pontifícia Universidade Católica de Goiás (PUC Goiás) a disponibilizar o Trabalho de Conclusão de Curso intitulado Identificação de Melanomas Utilizando Redes Neurais Convolucionais, gratuitamente, sem ressarcimento dos direitos autorais, por 5 (cinco) anos, conforme permissões do documento, em meio eletrônico, na rede mundial de computadores, no formato especificado (Texto(PDF); Imagem (GIF ou JPEG); Som (WAVE, MPEG, AIFF, SND); Vídeo (MPEG, MWV, AVI, QT); outros, específicos da área; para fins de leitura e/ou impressão pela internet, a título de divulgação da produção científica gerada nos cursos de graduação da PUC Goiás.

Goiânia, 05 de Julho de 2026.

Assinatura do autor:



Documento assinado digitalmente

DIEGO DA SILVA VELOSO DE FARIA

Data: 05/07/2026 15:46:33-0300

Verifique em <https://validar.itl.gov.br>

Nome completo do autor: Diego da Silva Veloso de Faria

Assinatura do professor-orientador:



Documento assinado digitalmente

MARIA JOSE PEREIRA DANTAS

Data: 05/07/2026 15:54:59-0300

Verifique em <https://validar.itl.gov.br>

Nome completo do professor-orientador: Maria Jose Pereira Dantas