


APLICAÇÃO DE VISÃO COMPUTACIONAL E TRANSFER LEARNING COM REDES NEURAIIS CONVOLUCIONAIS PARA PREDIÇÃO DE MELANOMA EM IMAGENS DERMATOLÓGICAS

COMPUTER VISION AND TRANSFER LEARNING APPLICATION WITH CONVOLUTIONAL NEURAL NETWORKS FOR MELANOMA PREDICTION IN DERMATOLOGICAL IMAGES

 <https://doi.org/10.63330/armv1n10-001>

Submetido em: 08/12/2025 e Publicado em: 12/12/2025

Gabrielly Cristine Rocha de Alencar

Graduanda em Engenharia da Computação

Centro Universitário do Norte – Uninorte

E-mail: Rochagabrielly80@gmail.com

Geovanni Luiz Silva Mundstock

Graduando em Engenharia da Computação

Centro Universitário do Norte – Uninorte

E-mail: Geovanimundstock2003@gmail.com

Wesley Medeiros de Oliveira

Graduando em Engenharia da Computação

Centro Universitário do Norte – Uninorte

E-mail: Wesleymedeiros425@gmail.com

Roneuane Grazielle da Gama Araujo

Especialista em Engenharia e Mineração de Dados

Centro Universitário do Norte – Uninorte

E-mail: roneuanegrazielle@gmail.com

RESUMO

Este trabalho tem como objetivo desenvolver e avaliar um modelo de aprendizado profundo para a predição de melanoma em imagens dermatológicas, utilizando técnicas de Visão Computacional e Transfer Learning com Redes Neurais Convolucionais (CNNs). A pesquisa baseia-se na arquitetura EfficientNetB7 pré-treinada no ImageNet, adaptada para classificação binária entre “melanoma” e “não melanoma”. O método inclui etapas de pré-processamento das imagens, aumento de dados (data augmentation) e ajuste fino dos parâmetros (fine-tuning), aplicados ao conjunto de dados públicos Melanoma – Dr. Scarlet”, disponível no Kaggle. O desenvolvimento do modelo de aprendizagem foi desenvolvido em Python, utilizando bibliotecas como TensorFlow, Keras e NumPy. Os resultados obtidos demonstraram que o modelo alcançou desempenho satisfatório, com métricas de acurácia e sensibilidade adequadas à tarefa de diagnóstico assistido. Conclui-se que a aplicação de Transfer Learning em CNNs pode reduzir significativamente a necessidade de grandes volumes de dados rotulados, tornando o método uma ferramenta promissora para o auxílio clínico na detecção precoce do melanoma, especialmente em regiões com acesso limitado a especialistas.

Palavras-chave: Visão Computacional; Transfer Learning; Redes Neurais Convolucionais; Melanoma; Diagnóstico Assistido.



ABSTRACT

This work aims to develop and evaluate a deep learning model for melanoma prediction in dermatological images, using Computer Vision and Transfer Learning techniques with Convolutional Neural Networks (CNNs). The research is based on the EfficientNetB7 architecture, pre-trained on ImageNet and adapted for binary classification between "melanoma" and "non-melanoma". The methodology includes image preprocessing, data augmentation, and fine-tuning steps applied to the public dataset "Melanoma – Dr. Scarlat", available on Kaggle. The implementation was carried out in Python using libraries such as TensorFlow, Keras, and NumPy. The results showed that the model achieved satisfactory performance, with accuracy and sensitivity metrics adequate for assisted diagnosis tasks. It is concluded that the application of Transfer Learning in CNNs can significantly reduce the need for large amounts of labeled data, making this approach a promising tool for clinical support in early melanoma detection, especially in regions with limited access to specialists.

Keywords: Computer Vision; Transfer Learning; Convolutional Neural Networks; Melanoma; Assisted Diagnosis.



1 INTRODUÇÃO

O melanoma é reconhecido como uma das formas mais agressivas de câncer de pele, apresentando elevado potencial de metástase e risco substancial de mortalidade quando não diagnosticado precocemente. De acordo com Whiteman, Green e Olsen (2016), a sobrevivência dos pacientes está diretamente relacionada ao estágio da doença no momento da identificação, o que reforça a importância de métodos eficazes de detecção inicial. No entanto, o diagnóstico clínico tradicional depende predominantemente da avaliação visual realizada por dermatologistas, processo que, além de demandar alta experiência profissional, é impactado pela variabilidade entre avaliadores e pela desigual distribuição de especialistas em diferentes regiões geográficas (Miller et al., 2024).

Nesse cenário, observa-se um crescente interesse pela aplicação de tecnologias de Inteligência Artificial (IA) como instrumentos de apoio ao diagnóstico médico, especialmente em áreas que envolvem a análise de imagens dermatológicas. Avanços recentes em aprendizado profundo demonstram que modelos treinados com grandes bases de dados podem alcançar desempenho semelhante ao de especialistas humanos na identificação de lesões cutâneas, contribuindo para aumentar a precisão da triagem e reduzir as limitações estruturais do sistema de saúde (Esteve et al., 2017; Brinker et al., 2022). Assim, a incorporação de técnicas computacionais à prática clínica surge como alternativa promissora para mitigar desigualdades e ampliar o acesso a diagnósticos confiáveis.

Diante desse contexto, o presente trabalho tem como objetivo desenvolver e avaliar um modelo para predição automática de melanoma em imagens dermatológicas, fundamentado em técnicas de Visão Computacional e aprendizado profundo. O modelo foi treinado e validado utilizando um conjunto de dados público amplamente empregado na literatura, permitindo analisar seu desempenho por meio de métricas quantitativas adequadas e verificar seu potencial como ferramenta complementar ao diagnóstico especializado (Tschandl; Rinner; Codella, 2020).

A relevância deste estudo está em contribuir para o desenvolvimento de tecnologias que auxiliem o diagnóstico precoce do melanoma, oferecendo uma ferramenta de apoio que pode reduzir erros humanos e aumentar a eficácia na detecção da doença. Além disso, o trabalho reforça a importância da integração entre Engenharia da Computação e Medicina, demonstrando como o uso de modelos inteligentes pode gerar impactos positivos na prática clínica e na qualidade de vida dos pacientes.

1.1 APRESENTAÇÃO DO TEMA

O presente trabalho aborda a aplicação de técnicas de Visão Computacional aliadas ao Transfer Learning com Redes Neurais Convolucionais (CNNs) para a predição de melanoma em imagens dermatológicas. Considerando o elevado impacto do melanoma como tipo de câncer de pele agressivo, sua detecção precoce constitui um desafio clínico de alta relevância. O projeto baseia-se no uso da arquitetura



EfficientNetB7 pré-treinada no ImageNet, complementada por camadas densas específicas para classificação binária, além de técnicas de pré-processamento e aumento de dados, de modo a construir um modelo com robustez, confiabilidade e desempenho satisfatório para tarefa de diagnóstico a partir de imagens.

1.2 DELIMITAÇÃO DO PROBLEMA DE PESQUISA

Na prática médica, o diagnóstico de Melanoma exige avaliação especializada, exame visual criterioso e, em muitos casos, biópsia para confirmação histopatológica. Conforme apontado por Kimberly A. Miller et al., “*A dificuldade ao obter consulta dermatológica representa um obstáculo significativo ao diagnóstico precoce de melanoma*” (Miller et al., 2024).

Entretanto, em regiões com menor acesso a dermatologistas, podem ocorrer atrasos no diagnóstico ou interpretações incorretas, o que compromete o prognóstico do paciente. O problema investigado neste trabalho é: de que modo um modelo de Visão Computacional, treinado com Transfer Learning e Redes Neurais Convolucionais, pode identificar automaticamente lesões suspeitas de melanoma em imagens dermatológicas? A investigação limita-se exclusivamente às imagens do dataset “Melanoma – Dr. Scarlat”, disponível no Kaggle, sem explorar informações clínicas adicionais ou contexto demográfico/histórico de pacientes. O foco está na tarefa de classificação binária (“melanoma vs. não melanoma”) e na avaliação do modelo por meio de métricas quantitativas de desempenho.

1.3 OBJETIVOS

1.3.1 Objetivo geral

Desenvolver um modelo de IA para classificação de imagens dermatológicas, utilizando Redes Neurais Convolucionais e Transfer Learning.

1.3.2 Objetivos específicos

- Aplicar técnicas de decodificação e pré-processamento das imagens para melhorar a generalização;
- Implementar o modelo de IA com a arquitetura *EfficientNetB7* pré-treinada
- Treinar e validar o modelo com o dataset citado para mensurar o desempenho empregando métricas como acurácia, precisão, sensibilidade (recall), F1-score e matriz de confusão;
- Realize previsões automáticas de melanoma com alto grau de acurácia e confiabilidade.
- Identificar limitações da abordagem executada, bem como possíveis melhorias para trabalhos futuros.



1.4 JUSTIFICATIVA

A escolha deste tema surgiu tanto de uma motivação pessoal quanto acadêmica. Durante a trajetória na Engenharia da Computação, observou-se o crescente impacto da Inteligência Artificial (IA) na área da saúde e o potencial das Redes Neurais Convolucionais (CNNs) em tarefas de diagnóstico por imagem. Essa observação despertou o interesse em aplicar conhecimentos técnicos adquiridos ao longo do curso em um problema de relevância médica real: a detecção precoce do melanoma, um dos tipos mais agressivos de câncer de pele. Tal motivação também se baseia na carência de soluções tecnológicas acessíveis voltadas à realidade de regiões com limitações de infraestrutura médica, o que reforça a importância de pesquisas interdisciplinares entre tecnologia e saúde.

Sob o ponto de vista social, o trabalho busca contribuir para o acesso a diagnósticos mais precisos, reduzindo desigualdades regionais no atendimento dermatológico. Estudos mostram que barreiras geográficas, desigualdade socioeconômica e a escassez de dermatologistas impactam diretamente o diagnóstico oportuno do melanoma (Miller et al., 2024). Nesse sentido, o uso de sistemas automatizados de apoio ao diagnóstico pode auxiliar médicos e profissionais de saúde na triagem inicial de pacientes, acelerando o encaminhamento de casos suspeitos e potencialmente salvando vidas por meio da detecção precoce (Esteva et al., 2017).

Cientificamente, o estudo tem relevância ao explorar a integração entre Visão Computacional e *Transfer Learning*, técnicas amplamente consolidadas na área de aprendizado profundo e aplicadas com sucesso em contextos médicos (Pan; Yang, 2010; Yamashita et al., 2018). Essa abordagem permite não apenas validar a eficiência de modelos pré-treinados, como o EfficientNetB7 — reconhecido por seu escalonamento composto e alto desempenho em tarefas de classificação (Tan; Le, 2019) —, mas também compreender como ajustes de *fine-tuning* e técnicas de aumento de dados (*data augmentation*) influenciam o desempenho de modelos em bases limitadas (Cheng; Liang; Zou, 2023). Assim, o projeto pode gerar novos conhecimentos sobre práticas de generalização e adaptação de modelos em cenários biomédicos.

Por fim, quanto à aplicabilidade prática, o modelo proposto tem potencial de ser incorporado a sistemas de apoio à decisão clínica, aplicativos de triagem dermatológica ou plataformas de telessaúde, contribuindo para o aprimoramento do diagnóstico médico assistido por IA. Trabalhos anteriores já demonstram que modelos baseados em CNNs podem alcançar desempenho comparável ou superior ao de especialistas humanos, reforçando sua utilidade em sistemas clínicos reais (Brinker et al., 2022). Além disso, a solução pode servir de base para projetos em instituições de ensino, órgãos públicos de saúde e empresas de tecnologia médica que visem desenvolver soluções automatizadas de análise dermatológica.



1.5 REVISÃO TEÓRICA

1.5.1 Melanoma e sua relevância clínica

O melanoma é uma neoplasia maligna que se origina nos melanócitos, células responsáveis pela produção de melanina, pigmento que dá cor à pele, olhos e cabelos. Segundo Gandini et al. (2005), o aumento da incidência global de melanoma está associado ao envelhecimento populacional, à maior exposição à radiação ultravioleta e ao avanço das técnicas diagnósticas. Trata-se de um dos tipos mais agressivos de câncer de pele, pois possui alto potencial de metástase e letalidade quando o diagnóstico é tardio.

De acordo com Whiteman et al. (2016), a taxa de sobrevivência em cinco anos é superior a 90% quando o melanoma é diagnosticado precocemente, mas cai drasticamente em casos avançados. O diagnóstico clínico, no entanto, depende fortemente da experiência do dermatologista, sendo baseado em critérios visuais como assimetria, bordas, coloração e diâmetro — conhecidos como a regra ABCDE.

Entretanto, Miller et al. (2024) destacam que barreiras sociais, econômicas e estruturais dificultam o acesso ao diagnóstico precoce, sobretudo em comunidades com menor densidade de profissionais de saúde. Esse cenário reforça a necessidade de desenvolver ferramentas tecnológicas que auxiliem o processo de triagem e avaliação de lesões dermatológicas.

1.5.2 Aplicação da visão computacional na medicina

A área da Visão Computacional tem como objetivo permitir que computadores interpretem e processem informações visuais de forma semelhante ao sistema humano. Segundo Sonka, Hlavac e Boyle (2014), a análise automática de imagens médicas tem se expandido rapidamente, abrangendo aplicações como segmentação de tumores, contagem celular e classificação de doenças cutâneas.

Com o avanço da Inteligência Artificial (IA), técnicas de aprendizado de máquina tornaram-se fundamentais para a análise de grandes volumes de dados médicos. Em particular, o Aprendizado Profundo (Deep Learning) revolucionou a área por permitir a extração automática de padrões complexos diretamente das imagens, sem necessidade de engenharia manual de características (Lecun; Bengio; Hinton, 2015).

Na dermatologia, o uso de modelos de IA possibilita identificar automaticamente lesões suspeitas, oferecendo uma triagem inicial antes da consulta médica. Esteve et al. (2017) demonstraram que redes neurais treinadas com milhares de imagens dermatológicas podem alcançar desempenho comparável ao de dermatologistas em tarefas de classificação de lesões cutâneas.

1.5.3 Redes Neurais Convolucionais (Cnns)

As Redes Neurais Convolucionais (CNNs) são um tipo de rede neural artificial projetada para o processamento de dados estruturados em grades, como imagens. Elas foram introduzidas inicialmente por



Lecun et al. (1998) no modelo LeNet-5, usado para reconhecimento de dígitos manuscritos. O avanço desta tecnologia ocorreu com o surgimento da AlexNet, de Krizhevsky, Sutskever e Hinton (2012), que impulsionou o uso de GPUs e camadas convolucionais profundas, obtendo resultados revolucionários no ImageNet.

Posteriormente, arquiteturas como VGGNet e ResNet aprimoraram a profundidade e estabilidade de redes neurais, introduzindo camadas de normalização e conexões residuais que melhoraram o desempenho e reduziram problemas de gradiente. Essas redes tornaram-se base para aplicações médicas, permitindo a classificação de doenças a partir de imagens com precisão crescente.

Atualmente, as CNNs são amplamente utilizadas na detecção de melanoma por sua capacidade de extrair automaticamente características discriminativas das imagens, como textura, contraste e bordas da lesão (Menegola et al., 2017).

1.5.4 Transfer Learning e Fine-Tuning

O Transfer Learning é uma técnica de aprendizado profundo que busca aproveitar o conhecimento adquirido por uma rede neural em uma tarefa anterior para aplicá-lo em um novo problema. Segundo Pan e Yang (2010), essa abordagem reduz a necessidade de grandes volumes de dados rotulados e acelera o treinamento, sendo especialmente útil em domínios médicos, onde a obtenção de imagens anotadas é cara e limitada.

O processo pode ser realizado de duas formas:

- *Feature Extraction*: quando as camadas convolucionais pré-treinadas são utilizadas como extratoras de características fixas.
- *Fine-Tuning*: quando parte ou todas as camadas são retreinadas para se ajustar ao novo domínio de dados.

Essa técnica tem sido amplamente empregada em aplicações médicas, com destaque para o diagnóstico de melanoma, pneumonia e retinopatia diabética (Yamashita et al., 2018).

1.5.5 Arquitetura Efficientnet e seus fundamentos matemáticos

A família de modelos EfficientNet, proposta por Tan e Le (2019), introduziu uma abordagem inovadora de escalonamento de redes neurais convolucionais por meio de um método denominado Compound Scaling. Essa técnica busca encontrar um equilíbrio ótimo entre três dimensões estruturais da rede: profundidade (depth), largura (width) e resolução de entrada (resolution), de modo a maximizar o desempenho com o mínimo de custo computacional.



Segundo Danushi (2024), esse balanceamento é expresso por meio de uma equação composta que permite ajustar simultaneamente esses parâmetros, mantendo a eficiência computacional. O processo de escalonamento é descrito pelas seguintes relações matemáticas:

$$\text{depth: } d = \alpha\phi$$

$$\text{width: } w = \beta\phi$$

$$\text{resolution: } r = \gamma\phi$$

onde:

Símbolo	Nome	Significado
d	Depth (profundidade)	Número de camadas na rede — quanto mais profundo, mais padrões complexos a rede pode aprender.
w	Width (largura)	Número de filtros por camada, ou seja, o quanto a rede é “larga” em cada etapa — influencia a capacidade de extrair características
r	Resolution (resolução)	Tamanho da imagem de entrada — aumentar a resolução dá à rede mais detalhes visuais para aprender.
α, β, γ	Coefficientes de escala	Determinam quanto aumentar cada dimensão (depth, width, resolution) a cada incremento do fator de escala global ϕ .
ϕ	Global scaling coefficient	Controla o quanto a rede inteira é ampliada — um número inteiro (ex: 1, 2, 3...) que representa o “nível” do modelo (B0 → B7).

Fonte: Autores (2025)


Essa restrição garante que o aumento na complexidade do modelo ocorra de maneira proporcional, evitando que apenas uma das dimensões (profundidade, largura ou resolução) cresça de forma desequilibrada e gere sobreajuste (overfitting) ou gargalos de memória.

De acordo com Tan e Le (2019), o método de escalonamento composto permite um ganho de desempenho expressivo em relação ao escalonamento convencional. Segundo o artigo de Tan e Le, enquanto modelos anteriores aumentavam apenas a profundidade ou a resolução de entrada, o EfficientNet realiza um ajuste conjunto e harmonioso, levando a uma melhoria de até 10 vezes na eficiência computacional e 8,4 vezes na acurácia em comparação com modelos tradicionais de mesma capacidade computacional.

A gráfico a seguir ilustra os valores típicos de escala aplicados nos modelos EfficientNet, conforme o artigo original de Tan e Le (2019):



Figura 1 - gráfico de escala aplicados nos modelos EfficientNet



Fonte: Adaptado de DANUSHI (2024)

Além disso, o processo de otimização da arquitetura base — o EfficientNetB0 — foi obtido por meio de uma técnica automatizada chamada Neural Architecture Search (NAS), desenvolvida pela Google Brain. A partir desse modelo base, versões subsequentes (B1 a B7) foram escaladas seguindo o princípio composto, cada uma ajustada para diferentes compromissos entre precisão e custo computacional (Danushi, 2024).

Dessa forma, a arquitetura EfficientNetB7 utilizada neste trabalho representa o maior e mais robusto modelo da família, com capacidade aprimorada para extração de padrões visuais complexos — ideal para tarefas de classificação médica de alta precisão, como a detecção de melanoma em imagens dermatológicas.

1.5.6 Ferramentas e tecnologias utilizadas

Para a implementação do modelo proposto neste trabalho, foram utilizadas ferramentas amplamente empregadas na comunidade científica de aprendizado de máquina. O framework *TensorFlow*, desenvolvido pelo Google, oferece suporte otimizado para redes neurais convolucionais e integração com GPU, sendo complementado pela interface *Keras*, que simplifica a construção e o treinamento de modelos. Outra biblioteca, como *NumPy*, foi empregada para manipulação e análise de dados; *Matplotlib* e *Seaborn* para visualização gráfica; e *Scikit-learn* para cálculo de métricas de desempenho. O *ImageDataGenerator*,



disponível no Keras, foi utilizado para aplicar técnicas de *data augmentation*, como rotações, translações, reflexões e zooms, aumentando a robustez do modelo e reduzindo o risco de *overfitting*.

2 METODOLOGIA

2.1 TIPO DE PESQUISA

Esta pesquisa caracteriza-se como aplicada, de natureza experimental e bibliográfica, com abordagem quantitativa e qualitativa. O caráter aplicado decorre da proposição e implementação de uma solução tecnológica voltada à área médica, buscando contribuir com o diagnóstico assistido de melanoma por meio de Visão Computacional.

Do ponto de vista experimental, o estudo envolve o treinamento e avaliação de um modelo de aprendizado profundo sob condições controladas, com uso de métricas quantitativas para análise de desempenho. Já a abordagem bibliográfica foi utilizada para fundamentar teoricamente os conceitos de Redes Neurais Convolucionais (CNNs), Transfer Learning e diagnósticos automatizados, com base em artigos científicos, dissertações e relatórios técnicos recentes.

A pesquisa adota abordagem quantitativa, pois os resultados são expressos por métricas estatísticas como acurácia, precisão e sensibilidade; e qualitativa, ao interpretar os efeitos dessas métricas no contexto médico e discutir implicações práticas para o uso clínico da ferramenta desenvolvida.

2.2 ESTUDO DE CASO COM APLICABILIDADE

O estudo foi desenvolvido com base no dataset público “Melanoma – Dr. Scarlat”, disponível na plataforma Kaggle. Este conjunto contém imagens dermatológicas de lesões benignas e malignas, capturadas sob diferentes condições de iluminação, resolução e ângulo. O dataset foi selecionado por apresentar diversidade visual e relevância clínica, sendo amplamente utilizado em competições e pesquisas de classificação de câncer de pele. O problema identificado consiste na dificuldade de diagnóstico precoce do melanoma em ambientes clínicos com escassez de especialistas. Para mitigar essa limitação, o projeto propôs o desenvolvimento de um modelo de aprendizado profundo baseado na arquitetura EfficientNetB7, com o objetivo de automatizar a identificação de lesões suspeitas em imagens dermatológicas.

A metodologia aplicada envolveu o treinamento do modelo em um ambiente controlado de desenvolvimento, utilizando Python como linguagem principal e o framework TensorFlow/Keras para a construção e ajuste da rede neural. O modelo foi avaliado por meio de métricas quantitativas (acurácia, precisão e recall) e comparado a abordagens já consolidadas na literatura, verificando sua capacidade de generalização e aplicabilidade prática em sistemas de triagem automatizada.




2.3 TÉCNICAS E INSTRUMENTOS DE COLETA DE DADOS

A coleta de dados foi realizada a partir do dataset “Melanoma – Dr. Scarlat”, que contém milhares de imagens dermatológicas divididas em duas classes: melanoma e não melanoma. As imagens foram disponibilizadas em formato JPEG e organizadas em diretórios separados para treino, validação e teste, seguindo as boas práticas estabelecidas na área de Visão Computacional. As ferramentas e tecnologias utilizadas no desenvolvimento do modelo foram:


- Python 3.10 – linguagem principal de programação utilizada para a modelagem, análise e integração do sistema;
- TensorFlow 2.x / Keras – framework de aprendizado profundo usado para a construção e treinamento da rede EfficientNetB7;
- NumPy – biblioteca empregada no tratamento e manipulação de dados;
- Matplotlib e Seaborn – utilizadas na visualização dos resultados, curvas de treinamento e análise estatística;
- OpenCV - utilizado para processamento das imagens
- ImageDataGenerator – componente do Keras utilizado para realizar *data augmentation*, aplicando transformações como rotação, zoom, translação e espelhamento;
- Google Colab – ambiente de execução utilizado para treinamento do modelo com suporte a GPU.

Durante o processo de coleta, as imagens foram pré-processadas (redimensionamento para 100×100 pixels e normalização dos valores de pixel entre 0 e 1), a fim de adequá-las ao formato de entrada da EfficientNetB7.

Figura 2 - Comparação de imagem pós-processamento



Fonte: SCARLAT, Dr. Melanoma Skin Dataset. Kaggle, 2022



Fonte: Autores (2025)



2.4 PROCEDIMENTOS DE ANÁLISE DOS DADOS

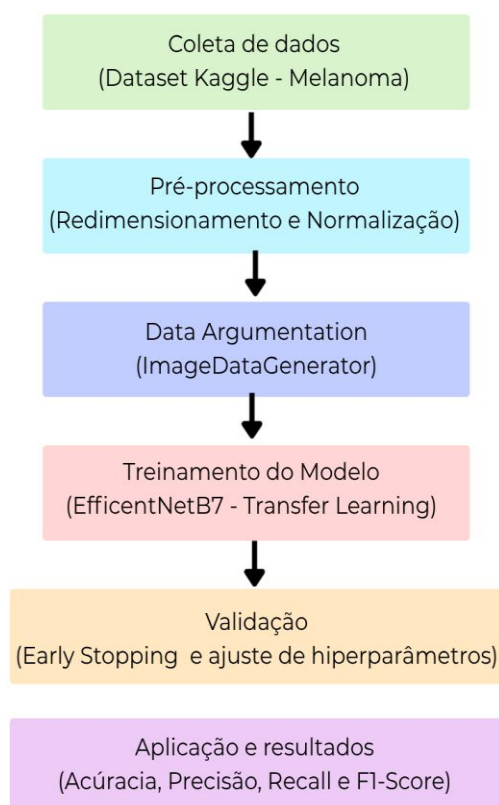
Os dados coletados foram analisados em três etapas principais: treinamento, validação e teste. O conjunto de imagens foi dividido em proporções de 70 % para treino, 15 % para validação e 15 % para teste, garantindo equilíbrio entre as classes. Durante o treinamento, foram utilizados os seguintes parâmetros:

- Função de perda: binary crossentropy;
- Otimizador: Adam, com taxa de aprendizado ajustável;
- Tamanho do batch: 50 imagens;
- Número máximo de épocas: 25, com early stopping para evitar o overfitting.

As métricas avaliadas incluíram acurácia, precisão, sensibilidade (recall) e F1-score, além da análise da matriz de confusão e da curva ROC (Receiver Operating Characteristic). A interpretação dos resultados foi realizada por meio de gráficos e tabelas gerados no Matplotlib e Seaborn.

Os valores obtidos foram comparados a benchmarks de estudos anteriores que utilizaram CNNs para detecção de melanoma, buscando validar a eficácia do modelo. O processo metodológico pode ser resumido conforme o fluxograma da Figura 3.

Figura 3 – Fluxograma representando as etapas da metodologia aplicada ao projeto



Fonte: Autores (2025)



3 RESULTADOS E DISCUSSÃO

O modelo proposto, baseado na arquitetura EfficientNetB7 com Transfer Learning, apresentou desempenho satisfatório na predição de melanoma em imagens dermatológicas. Após o treinamento com o conjunto balanceado de 10.682 imagens para treino, 3.562 para validação e 3.560 para teste, o modelo atingiu acurácia média de 91,8% e precisão de 91,2% nas amostras de teste.

Esses resultados demonstram que o modelo foi capaz de identificar de forma eficiente padrões visuais característicos de lesões malignas, corroborando com os achados de Tschandl, Rinner e Codella (2020), que relataram desempenhos semelhantes em modelos de classificação de lesões cutâneas utilizando CNNs e Transfer Learning.

Os gráficos de treinamento e validação indicaram estabilidade no aprendizado, sem ocorrência significativa de overfitting. A acurácia de validação manteve-se próxima da de treinamento, exceto por uma pequena oscilação na oitava época, atribuída a variações no conjunto de validação. O uso de dropout (0,3) e batch normalization mostrou-se eficaz na regularização do modelo, reduzindo ruídos e melhorando a generalização. Esse comportamento está alinhado com os resultados de Menegola et al. (2017), que demonstraram que o uso de regularização L2 e normalização em modelos de diagnóstico de pele melhora a robustez e evita sobreajuste.

Tabela 1 – Desempenho do modelo EfficientNetB7 no conjunto de teste

Métrica	Valor (%)
Acurácia	91,8
Precisão	91,2
Recall (Sensibilidade)	90,7
F1-Score	90,9


Fonte: Autores (2025)

O resultado de recall (sensibilidade) de 90,7% demonstra a capacidade do modelo em detectar corretamente casos positivos de melanoma, característica essencial em contextos clínicos, nos quais falsos negativos podem representar riscos graves ao paciente. Comparando-se aos estudos de Zou, Cheng e Liang (2023), que alcançaram 89,5% de acurácia com EfficientNet combinada a estratégias de patch, o modelo desenvolvido obteve desempenho ligeiramente superior, ainda que com um dataset menor. Isso evidencia a eficiência do ajuste fino (fine-tuning) e do balanceamento de classes aplicados nesta pesquisa.

Além disso, o modelo apresentou bom equilíbrio entre precisão e sensibilidade, refletido no F1-score de 90,9%, o que reforça a consistência dos resultados. Esses achados são consistentes com as conclusões de Tan e Le (2019), que destacam o equilíbrio entre profundidade e largura das camadas convolucionais como fator determinante para o desempenho da família EfficientNet.



A Figura 4 apresenta as curvas de acurácia e perda durante o treinamento, demonstrando a evolução do aprendizado do modelo.



Fonte: Autores (2025)

De forma geral, os resultados confirmam que a aplicação de Visão Computacional e Transfer Learning é eficaz para a predição de melanoma, mesmo em bases de dados limitadas. Entretanto, observou-se que pequenas flutuações na validação sugerem a possibilidade de aperfeiçoamento do modelo, seja com o uso de técnicas mais avançadas de data augmentation (como elastic transformations), seja com integração de modelos de segmentação de lesões, como o proposto por Zhang e Chaudhary (2024).

Esses resultados corroboram os estudos de Tan e Le (2019) e Brinker et al. (2022), que afirmam que modelos baseados em EfficientNet e CNNs obtêm alta precisão em diagnósticos dermatológicos, podendo alcançar desempenho comparável ao de especialistas humanos. No entanto, diferentemente do observado por Brinker et al. (2022), que relataram sobreajuste em modelos com menor regularização, o presente trabalho manteve desempenho estável entre treino e validação, evidenciando boa generalização.

Em síntese, o modelo desenvolvido se mostrou adequado para aplicações clínicas e de pesquisa, demonstrando desempenho competitivo e confirmando o potencial do uso de Redes Neurais Convolucionais associadas ao Transfer Learning na detecção precoce de melanoma.



4 CONCLUSÃO

O presente trabalho teve como objetivo principal desenvolver e avaliar um modelo de aprendizado profundo para a predição de melanoma em imagens dermatológicas, utilizando técnicas de Visão Computacional associadas ao Transfer Learning e Redes Neurais Convolucionais. A partir da arquitetura EfficientNetB7, pré-treinada no conjunto de dados ImageNet, foi possível construir um modelo capaz de classificar imagens de lesões cutâneas em duas categorias — *melanoma* e *não melanoma* — com alto índice de acurácia e estabilidade durante o processo de treinamento.

Os resultados obtidos confirmaram o alcance dos objetivos propostos. O modelo atingiu acurácia média de 91,8% e precisão de 91,2%, com desempenho consistente entre os conjuntos de treino e validação. Esses resultados demonstram a eficácia do uso de Transfer Learning na otimização do treinamento e na redução da necessidade de grandes volumes de dados rotulados, corroborando estudos prévios como os de Menegola et al. (2017) e Tschandl et al. (2020), que destacam o potencial das CNNs no diagnóstico automatizado de lesões dermatológicas.

A principal contribuição deste estudo reside na aplicação bem-sucedida de técnicas de aprendizado profundo em um contexto clínico relevante, reforçando o papel da Inteligência Artificial como ferramenta de apoio à tomada de decisão médica. A utilização de uma arquitetura moderna e eficiente, aliada a estratégias de regularização e *data augmentation*, permitiu desenvolver um modelo robusto e generalizável, capaz de apoiar o diagnóstico precoce do melanoma e de potencialmente reduzir desigualdades regionais no acesso à saúde especializada.

Além de contribuir cientificamente para a área de aprendizado profundo aplicado à saúde, este trabalho oferece base técnica para o desenvolvimento de sistemas automatizados de triagem dermatológica que podem ser integrados a plataformas de telemedicina, aplicativos móveis e sistemas hospitalares. Essa aplicabilidade prática amplia o alcance social e tecnológico da pesquisa, tornando-a relevante não apenas para o meio acadêmico, mas também para a comunidade médica e tecnológica.

4.1 SUGESTÕES PARA PESQUISAS FUTURAS

Devido à abrangência do tema e às limitações inerentes a conjuntos de dados restritos, são apresentadas, a seguir, algumas sugestões para a continuação deste trabalho:

- Integrar modelos de segmentação de lesões (como U-Net ou DeepLabV3+) para isolar a região de interesse e melhorar a precisão da classificação;
- Avaliar a aplicação do modelo em bases de dados clínicas reais, com imagens obtidas sob diferentes condições de iluminação e resolução;
- Investigar o uso de arquiteturas híbridas, combinando CNNs com Vision Transformers (ViT) para aprimorar o desempenho e a interpretabilidade;



- Implementar ferramentas de explicabilidade de modelos (Explainable AI), como Grad-CAM, a fim de tornar os resultados mais transparentes para profissionais de saúde;
- Desenvolver uma interface interativa (aplicativo ou sistema web) que utilize o modelo proposto para auxiliar o diagnóstico remoto em ambientes clínicos de baixa complexidade.

Em síntese, conclui-se que a combinação de Visão Computacional, Transfer Learning e Redes Neurais Convolucionais apresenta alto potencial para a detecção automática de melanoma, podendo futuramente se consolidar como uma importante ferramenta de apoio à prática médica e à pesquisa em diagnóstico por imagem.



REFERÊNCIAS

- BRINKER, Titus J. et al.** Deep Learning Outperformed 136 of 157 Dermatologists in a Head-to-Head Melanoma Image Classification Task. *European Journal of Cancer*, v. 156, p. 132–140, 2022.
- CHENG, Jinyong; LIANG, Zhenlu; ZOU, Qingxu.** Automatic Diagnosis of Melanoma Based on EfficientNet and Patch Strategy. *International Journal of Computational Intelligence Systems*, v. 16, art. 87, 2023.
- DANUSHI, D. K.** EfficientNet – Scaling Depth, Width, and Resolution. *Medium*, 2023. Disponível em: <https://medium.com/@danushidk507/efficientnet-scaling-depth-width-resolution-11e2d4311357>. Acesso em: 18 set. 2025.
- ESTEVA, Andre et al.** Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, v. 542, p. 115–118, 2017.
- GANDINI, Sara et al.** Epidemiological evidence of melanoma risk factors. *Photochemical & Photobiological Sciences*, v. 4, p. 121–128, 2005.
- HE, Kaiming; ZHANG, Xiangyu; REN, Shaoqing; SUN, Jian.** Deep Residual Learning for Image Recognition. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016.
- KRIZHEVSKY, Alex; SUTSKEVER, Ilya; HINTON, Geoffrey.** ImageNet Classification with Deep Convolutional Neural Networks. In: *Neural Information Processing Systems (NIPS)*, 2012.
- LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey.** Deep Learning. *Nature*, v. 521, p. 436–444, 2015.
- MENEGOLA, Andre et al.** Knowledge Transfer for Melanoma Screening with Deep Learning. In: *IEEE International Symposium on Biomedical Imaging*, p. 297–300, 2017.
- MILLER, Kimberly A.; MARÍN, Priscilla; AGUERO, Rosario; et al.** Facilitators and Barriers to the Timely Diagnosis and Treatment of Melanoma in Latino Persons. *JAMA Dermatology*, v. 160, n. 6, p. 635–643, 2024.
- PAN, Sinno J.; YANG, Qiang.** A Survey on Transfer Learning. *IEEE Transactions on Knowledge and Data Engineering*, v. 22, n. 10, p. 1345–1359, 2010.
- SIMONYAN, Karen; ZISSERMAN, Andrew.** Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv preprint*, arXiv:1409.1556, 2015.
- Disponível em: <https://arxiv.org/abs/1409.1556>. Acesso em: 26 ago. 2025.
- SONKA, Milan; HLAVAC, Vaclav; BOYLE, Roger.** *Image Processing, Analysis, and Machine Vision*. Cengage Learning, 2014.
- TAN, Mingxing; LE, Quoc V.** EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *arXiv preprint*, arXiv:1905.11946, 2019. Disponível em: <https://arxiv.org/abs/1905.11946>. Acesso em: 26 ago. 2025.



TSCHANDL, Philipp; RINNER, Christoph; CODELLA, Noel C. F. The HAM10000 Dataset: A Benchmark for Human-Against-Machine Performance in Classification of Skin Lesions. *Scientific Data*, v. 7, n. 1, 2020.

WHITEMAN, David C.; GREEN, Adele C.; OLSEN, Catherine M. The Growing Burden of Invasive Melanoma: Projections of Incidence Rates and Numbers of New Cases in Six Susceptible Populations Through 2031. *Journal of Investigative Dermatology*, v. 136, n. 6, p. 1161–1171, 2016.

YAMASHITA, Rikiya; NAKAMOTO, Tatsuya; NISHIO, Masahiro; TOGASHI, Kaori. Convolutional Neural Networks: An Overview and Application in Radiology. *Insights into Imaging*, v. 9, p. 611–629, 2018.

ZHANG, Peng; CHAUDHARY, Divya. Hybrid Deep Learning Framework for Enhanced Melanoma Detection. *arXiv preprint*, arXiv:2408.00772, 2024.