



INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO PIAUÍ
CAMPUS CORRENTE
CURSO DE GRADUAÇÃO EM TECNOLOGIA EM ANÁLISE E
DESENVOLVIMENTO DE SISTEMAS

CRISTIANO GONÇALVES DE OLIVEIRA

APLICAÇÃO *MOBILE* PARA CLASSIFICAÇÃO DO CARCINOMA BASOCELULAR
E MELANOMA UTILIZANDO *DEEP LEARNING*

CORRENTE

2025

CRISTIANO GONÇALVES DE OLIVEIRA

APLICAÇÃO *MOBILE* PARA CLASSIFICAÇÃO DO CARCINOMA BASOCELULAR E
MELANOMA UTILIZANDO *DEEP LEARNING*

Trabalho de Conclusão de Curso (monografia)
apresentado como exigência parcial para obtenção
do diploma do Curso de Tecnologia em Análise e
Desenvolvimento de Sistemas do Instituto Federal
de Educação, Ciência e Tecnologia do Piauí,
Campus Corrente.

Orientador: Prof. Me. Renê Douglas Nobre de
Morais

CORRENTE

2025

Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD

Oliveira, Cristiano Gonçalves de
O48a Aplicação Mobile para classificação do Carcinoma Basocelular e
Melanoma utilizando Deep Learning / Cristiano Gonçalves de Oliveira. -
2024.
62 p.: il. color.
Trabalho de Conclusão de Curso (Análise e Desenvolvimento de
Sistemas) - Instituto Federal de Educação, Ciência e Tecnologia do
Piauí, Campus Corrente, 2024.
Orientador : Prof Me. Renê Douglas Nobre de Moraes.
1. Analise e Desenvolvimento de Sistemas - estudo e ensino. 2. Câncer de
pele. 3. Aprendizado Profundo. 4. MobileNetV2. I.Título.

CDD - 004

Elaborado por Tefischer Huanderson Soares e Sousa CRB 3/1251

AGRADECIMENTOS

Agradeço primeiramente a Deus, pela ajuda nos momentos de dificuldades que passei até a conclusão deste Curso.

Aos meus pais, Conceição Maria e Raimundo por me incentivarem durante toda a trajetória deste curso e por me proporcionarem desde cedo todos os meios para uma boa educação e ao restante de minha família pelo incentivo.

Ao meu orientador, Renê Douglas Nobre de Moraes, que sem sua disponibilidade e ensinamentos este trabalho não seria possível.

Agradeço a todos os professores do Curso de Tecnologia em Análise e Desenvolvimento de Sistemas e servidores do IFPI do Campus Corrente, pois todos direto e indiretamente contribuíram para o alcance desse resultado.

RESUMO

Este trabalho apresenta o desenvolvimento de um modelo de Aprendizado Profundo utilizando a arquitetura MobileNetV2, baseada em Transferência de Aprendizado, para a classificação de lesões cutâneas, especialmente Carcinoma Basocelular e Melanoma. O problema abordado é a dificuldade no diagnóstico precoce do câncer de pele, especialmente em regiões com acesso limitado a especialistas. O objetivo principal é obter/treinar um modelo eficiente para a classificação automática de lesões cutâneas e implementá-lo em um aplicativo móvel, para auxiliar médicos e pacientes no diagnóstico e monitoramento de lesões cutâneas. Para isso, foram utilizados dados do desafio do ISIC 2020, composto por 7800 imagens divididas entre as classes Carcinoma Basocelular e Melanoma. As etapas metodológicas incluíram pré-processamento das imagens, com redimensionamento e normalização e aplicação da técnica Validação Cruzada para validar do modelo. O modelo foi implementado e treinado, alcançando uma acurácia média de 93,67% ao longo dos subconjuntos de treinamento e uma acurácia de 94,24% com dados de teste. Um aplicativo móvel foi desenvolvido para capturar imagens de lesões e classificá-las com base no modelo treinado como forma de apoiar o diagnóstico precoce do câncer de pele.

Palavras-chaves: Câncer de pele; Aprendizado Profundo; MobileNetV2; Diagnóstico móvel.

ABSTRACT

This work presents the development of a Deep Learning model using the MobileNetV2 architecture, based on Transfer Learning, for the classification of skin lesions, especially Basal Cell Carcinoma and Melanoma. The problem addressed is the difficulty in the early diagnosis of skin cancer, especially in regions with limited access to specialists. The main objective is to obtain/train an efficient model for the automatic classification of skin lesions and implement it in a mobile application, to assist doctors and patients in the diagnosis and monitoring of skin lesions. For this, data from the ISIC 2020 challenge were used, consisting of 7800 images divided between the Basal Cell Carcinoma and Melanoma classes. The methodological steps included preprocessing of the images, with resizing and normalization, and application of the Cross-Validation technique to validate the model. The model was implemented and trained, achieving an average accuracy of 93.67% across the training subsets and an accuracy of 94.24% with test data. A mobile application was developed to capture images of lesions and classify them based on the trained model as a way to support early diagnosis of skin cancer.

Keywords: Skin cancer; Deep Learning; MobileNetV2; Mobile diagnostics.

LISTA DE ILUSTRAÇÕES

Figura 1	- Carcinoma Basocelular	21
Figura 2	- Melanoma.....	23
Figura 3	- Regra do ABCDE	24
Figura 4	- Etapas da metodologia do estudo	35
Figura 5	- Distribuição balanceada das imagens por classe.....	38
Figura 6	- Fluxograma do método proposto.....	40
Figura 7	- Estrutura básica e o bloco de construção do <i>MobileNetV2</i> ...	41
Figura 8	- Menu de acesso do SkinAlert.....	45
Figura 9	- Tela inicial de captura do SkinAlert.....	46
Figura 10	- Tela de resultado para as classificações	47
Figura 11	- Tela de resultado para as classificações	47
Figura 12	- Tela de resultado para as classificações	47
Figura 13	- Validação Cruzada	60
Figura 14	- Dimensões de canais de cores RGB	61
Figura 15	- Estrutura de uma rede neural.....	62
Figura 16	- Processo de convolução	63
Figura 17	- Comparativo entre Aprendizagem de Máquina Tradicional com Transferência de Aprendizagem	67
Figura 18	- Acurácia média e desvio padrão por fold	71
Figura 19	- Curva ROC para cada fold.....	72

Figura 20	- Matriz de confusão <i>fold</i> 1.....	73
Figura 21	- Matriz de confusão <i>fold</i> 2.....	74
Figura 22	- Matriz de confusão <i>fold</i> 3.....	75
Figura 23	- Matriz de confusão <i>fold</i> 4.....	76
Figura 24	- Matriz de confusão <i>fold</i> 5.....	77
Figura 25	- Matriz de confusão do conjunto de teste.....	78

LISTA DE TABELAS

Tabela 1	- Comparação das técnicas de desenvolvimento de modelos de Aprendizado Profundo	31
Tabela 2	- Transformações nas amostras de imagens do conjunto de dados ISIC 2020	38
Tabela 3	- Hiperparâmetros aplicados no modelo proposto.....	42
Tabela 4	- Resultados de acurácia do modelo	44
Tabela 5	- Configurações do dispositivo móvel testado.....	49
Tabela 6	- Detalhamento da matriz de confusão fold 1.....	73
Tabela 7	- Detalhamento da matriz de confusão fold 2.....	74
Tabela 8	- Detalhamento da matriz de confusão fold 3.....	75
Tabela 9	- Detalhamento da matriz de confusão fold 4.....	76
Tabela 10	- Detalhamento da matriz de confusão fold 5.....	77
Tabela 11	- Detalhamento da matriz de confusão do conjunto de teste ...	78

LISTA DE ABREVIATURAS E SIGLAS

ABCDE	- Assimetria, Borda, Cor, Dimensão, Evolução
ADAM	- <i>Adaptive Moment Estimation</i>
API	- <i>Interface Application Programming</i>
AUC	- <i>Area Under the Curve</i>
CAD	- <i>Computer-Aided Design</i>
CNNs	- Redes Neurais Convolucionais
CPU	- Unidade Central de Processamento
ESRGAN	- <i>Enhanced Super-Resolution Generative Adversarial Network</i>
FN	- Falso Negativo
FP	- Falso Positivo
FPR	- Taxa de Falso Positivo
FPS	- Fator de Proteção Solar
GANs	- Redes Adversárias Generativas
GPU	- <i>Graphics Processing Unit</i>
IA	- Inteligência Artificial
INCA	- Instituto Nacional de Câncer
ISBI	- <i>International Symposium on Biomedical Imaging</i>
ISIC	- <i>International Skin Imaging Collaboration</i>
KNN	- <i>K-Nearest Neighbors</i>
ML	- <i>Machine Learning</i>
MED-Node	- <i>Medical Datasets for the classification of skin Neoplasms by deep learning</i>

OPAS	- Organização Pan-Americana de Saúde
PCA	- <i>Principal Component Analysis</i>
PH2	- Hospital Pedro Hispano
RAM	- <i>Random Access Memory</i>
R-CNN	- <i>Region-based Convolutional Neural Network</i>
ReLu	- <i>Rectified Linear Unit</i>
RGB	- Vermelho (<i>Red</i>), Verde (<i>Green</i>), Azul (<i>Blue</i>)
ROC	- <i>Receiver Operating Characteristic</i>
RNN	- Redes Neurais Recorrentes
SBCO	- Sociedade Brasileira de Cirurgia Oncológica
SBD	- Sociedade Brasileira de Dermatologia
SIIM	- <i>Society for Imaging Informatics in Medicine</i>
SUS	- Sistema Único de Saúde
SVM	- Máquina de Vetores de Suporte
<i>TFLite</i>	- <i>TensorFlow Lite</i>
TPR	- Taxa de Verdadeiro Positivo
UVB	- Ultravioleta B
VGG16,19	- <i>Visual Geometry Group</i>
VN	- Verdadeiro Negativo
VP	- Verdadeiro Positivo
YOLOv5	- <i>You Only Look Once</i>

SUMÁRIO

1	INTRODUÇÃO	14
1.1	DESAFIOS NA DETECÇÃO DE CÂNCER DE PELE E APLICAÇÃO DE <i>DEEP LEARNING</i>	17
1.2	JUSTIFICATIVA	18
1.3	OBJETIVO GERAL	19
1.4	OBJETIVOS ESPECÍFICOS	19
2	FUNDAMENTAÇÃO TEÓRICA	20
2.1	CARCINOMA BASOCELULAR	20
2.1.1	Sinais e sintomas	20
2.1.2	Detecção precoce	21
2.1.3	Prevenção	22
2.2	MELANOMA	22
2.2.1	Sinais e sintomas	23
2.2.2	Detecção precoce	24
2.2.3	Prevenção	25
3	TRABALHOS RELACIONADOS	26
4	METODOLOGIA	35
4.1	AQUISIÇÃO DE DADOS	35
4.2	CONFIGURAÇÃO DO SISTEMA	36
4.3	PRÉ- PROCESSAMENTO	36
4.3.1	Redimensionamento de imagens	36
4.3.2	Normalização de imagens	37
4.3.3	Otimização	37
4.3.4	Balanceamento de classes	37
4.3.5	Codificação One-Hot	39
4.4	CONJUNTO DE DADOS DE TREINAMENTO E TESTE	39
4.5	ESTIMAÇÃO DO BACKBONE	40
4.5.1	Configuração do modelo MobileNetV2	41
4.6	HIPERPARÂMETROS DO MODELO DE TRANSFERÊNCIA DE APRENDIZADO	42
5	RESULTADOS E DISCUSSÃO	44
5.1	IMPLEMENTAÇÃO DO APLICATIVO MÓVEL	44
5.2	DISCUSSÃO DOS RESULTADOS	48
5.2.1	Comparação com os estudos relacionados	49
6	CONCLUSÃO	51
6.1	TRABALHOS FUTUROS	52
	REFERÊNCIAS	53
	APÊNDICE A - RECURSOS TECNOLÓGICOS	58
	APÊNDICE B - MÉTRICAS DE AVALIAÇÃO	70

1 INTRODUÇÃO

Câncer é uma nomenclatura genética dada para um grupo de mais de 200 tipos de doenças de acordo o INCA (2022). Embora existam muitos tipos de câncer, todos eles começam devido ao crescimento anormal e pela multiplicação descontrolada das células em uma determinada região do corpo, como explica Wolff et al. (2019). O câncer é considerado uma doença bastante complexa que se inicia quando algumas células de algum tecido ou órgão começam a crescer de forma descontrolada.

Esse crescimento é diferente do crescimento celular normal, pois ao em vez de morrer, as células cancerosas continuam crescendo e formando novas células anormais o que resulta no tumor cancerígeno no corpo, segundo os estudos de Lopes Júnior et al. (2019). Essas condições podem ser resultados de uma série de alterações genéticas provocadas por diversos fatores, como exposição a substâncias químicas nocivas, exposição a radiações, tabagismo e estilo de vida pouco saudável. À medida que as células cancerosas se multiplicam, elas podem comprometer o funcionamento normal dos órgãos e sistemas do corpo, o que futuramente pode comprometer gravemente a saúde do indivíduo.

O câncer de pele é um dos tipos mais comuns de câncer no mundo, com milhões de novos casos diagnosticados anualmente, como é mostrado em OPAS (2020). Dentre os principais tipos, destacam-se o Carcinoma Basocelular (Não-Melanoma) e o Melanoma, que juntos representam cerca de 80% dos diagnósticos segundo dados da SBCO (2024).

O Carcinoma Basocelular menos letal têm maior incidência de casos, o Melanoma é mais agressivo e potencialmente letal em casos de metástase¹, atingindo vasos sanguíneos ou o sistema linfático, podendo alcançar órgãos vitais como pulmões, fígado e cérebro, formando novos tumores. Por isso, a detecção precoce é essencial para aumentar as chances de cura, especialmente considerando a alta incidência global da doença.

Nos Estados Unidos, no ano de 2024 foram registrados 200.340 novos casos de Carcinoma basocelular e um aumento de 7,3% nos diagnósticos de Melanoma, com uma taxa de mortalidade significativa para ambos segundo a Skin Cancer Foundation (2024). No Brasil, entre 2023 e 2025, espera-se que aproximadamente 31,3% dos novos casos de câncer estejam relacionados ao Carcinoma Basocelular e 5% ao Melanoma, de acordo com dados do INCA (2022). Esses dados reforçam a importância de aprimorar as estratégias de triagem e diagnóstico da doença.

Neste cenário, as tecnologias baseadas em inteligência artificial têm se destacado como uma alternativa promissora, especialmente em regiões com acesso limitado a especialistas. De acordo com dados da Sociedade Brasileira de Dermatologia (2024), No Brasil, segundo as estatísticas do INCA (2022), a maioria dos dermatologistas concentra-se nas regiões Sudeste e Sul, especialmente em grandes cidades como São Paulo, Rio de Janeiro e Porto Alegre, o que pode dificultar o acesso a cuidados dermatológicos em regiões rurais e remotas, como nos estados do Acre, Amazonas, Pará, Maranhão e Piauí.

O Instituto Nacional de Câncer explica que no Sistema Único de Saúde, esse cenário é ainda mais desafiador, com oferta restrita de consultas dermatológicas fora dos grandes centros, especialmente no Norte e Nordeste, onde os tempos de espera podem ser longos, o que agrava a dificuldade de acesso a esse tipo de atendimento especializado.

¹ Metástase: processo pelo qual as células cancerígenas se desprendem de um tumor primário e se espalham para outras partes do corpo formando novos tumores. (Fonte: Simões et al. 2023).

Redes Neurais Convolucionais (CNNs) vêm sendo amplamente utilizadas para diagnóstico de imagens médicas, GULARTT et al. (2021), explica que as CNNs são mais indicadas para o diagnóstico de imagens médicas do que modelos como *Recurrent Neural Network*, *Support Vector Machine* e *K-Nearest Neighbors*, devido à sua capacidade de detectar automaticamente padrões complexos, como bordas e texturas, sem necessidade de engenharia manual. Sua estrutura de camadas convolucionais permite extrair informações hierárquicas, com características simples nas camadas iniciais e padrões complexos nas camadas mais profundas.

Além disso, GULARTT et al. (2021), explica que o compartilhamento de pesos reduz a quantidade de parâmetros, tornando o treinamento mais eficiente. As CNNs também são robustas a variações de posição, rotação e escala, tornando-as ideais para imagens médicas com diferentes orientações e tamanhos. Esse comportamento torna as CNNs escaláveis para grandes volumes de dados, sendo ideais para tarefas em domínios como diagnósticos médicos e classificação de imagens dermatoscópicas.

Em conjunto, a Transferência de Aprendizado permite que CNNs apliquem o conhecimento adquirido em tarefas anteriores a novos domínios, mesmo com dados limitados. Oliveira et al. (2019), compara em seu trabalho algumas técnicas de aprendizado como *Representation Learning*, *Ensemble Learning* e *Meta-Learning*, e destaca que o diferencial da Transferência de Aprendizado é a capacidade de usar conhecimento prévio de forma dinâmica, pois adapta e refina o que foi aprendido em uma tarefa para aplicá-lo em um novo contexto. Além de acelerar o treinamento, essa técnica torna as redes neurais mais eficazes em contextos específicos, como a adaptação a novos tipos de imagens ou a classificação em condições extremas.

A aplicação de tecnologias móveis, pode expandir significativamente o acesso a cuidados dermatológicos em regiões remotas, onde há escassez de especialistas. Ao facilitar o compartilhamento de informações entre pacientes e dermatologistas, essas tecnologias permitem diagnósticos precoces e reduzem a necessidade de deslocamentos longos e custosos para consultas presenciais, tornando o atendimento mais inclusivo e eficiente. Além disso, essa abordagem oferece uma alternativa prática para o monitoramento contínuo de lesões cutâneas.

Nesse contexto, estudos recentes têm mostrado avanços promissores em termos de precisão e eficácia no uso de tecnologias móveis para a detecção e monitoramento do Melanoma. Novais (2023), por exemplo, desenvolveu um aplicativo que utiliza Redes Neurais Convolucionais (CNNs) para identificar o risco de Melanoma a partir de imagens capturadas por dispositivos móveis. De forma semelhante, Oliveira (2021) propôs um aplicativo para o monitoramento contínuo de lesões cutâneas, classificando-as como benignas ou malignas.

Ambos os estudos evidenciam a aplicabilidade de soluções móveis no aprimoramento do diagnóstico e acompanhamento dermatológicos, especialmente em regiões com recursos limitados. Esses trabalhos serão detalhados no Referencial Teórico, com uma análise mais técnica sobre a eficácia dos modelos e as especificidades técnicas de cada abordagem.

O desenvolvimento de um aplicativo móvel baseado na arquitetura de rede neural *MobileNetV2* possibilita a classificação do Carcinoma Basocelular e Melanoma, dois dos tipos mais comuns de câncer de pele. A aplicação de técnicas de *Deep Learning* torna o processo mais eficiente e acessível, contribuindo para o diagnóstico precoce e ampliando o acesso à avaliação dermatológica. Além disso, a tecnologia facilita a triagem de risco e o monitoramento contínuo das lesões, especialmente em áreas remotas, onde o acesso a especialistas é limitado.

1.1 DESAFIOS NA DETECÇÃO DE CÂNCER DE PELE E APLICAÇÃO DE *DEEP LEARNING*

Apesar dos avanços na detecção de câncer de pele, a identificação precoce de lesões como o Carcinoma Basocelular e o Melanoma ainda enfrenta desafios. A dermatoscopia, amplamente utilizada, tem limitações na análise de manchas com coloração e bordas irregulares, que podem se assemelhar a lesões benignas, como foi observado por Santos et al. (2021). Essa semelhança visual compromete a precisão do diagnóstico, aumentando o risco de diagnósticos incorretos ou tardios e reduzindo, assim, as chances de um tratamento eficaz e de cura.

A aplicação de técnicas de *Deep Learning*, como as Redes Neurais Convolucionais (CNNs), conforme analisado por Mariano (2022), têm como principal finalidade a extração e análise automática de padrões complexos em dados visuais, oferecendo grande potencial para automatizar e aprimorar a detecção de lesões cutâneas. No entanto, ainda há necessidade de soluções mais eficientes e acessíveis, especialmente em contextos com recursos limitados. Assim, a questão que este trabalho busca responder é: como o uso da Transferência de Aprendizado com o modelo *MobileNetV2* pode melhorar a acurácia e a eficiência na classificação de lesões cutâneas, diferenciando Carcinoma Basocelular e Melanoma, em comparação com métodos tradicionais de diagnóstico e outras abordagens de *Deep Learning*?

1.2 JUSTIFICATIVA

O câncer de pele é uma das neoplasias² mais comuns no mundo, e o diagnóstico precoce é essencial para aumentar as chances de um tratamento eficaz e melhorar a sobrevida dos pacientes. Entre os diferentes tipos, o Carcinoma Basocelular e o Melanoma se destacam tanto pela alta prevalência quanto pela diferença em agressividade e prognóstico. O Melanoma, sendo o mais letal, exige uma detecção rápida e precisa, enquanto o Carcinoma Basocelular, embora menos agressivo, também requer um diagnóstico correto para um tratamento adequado. Nesse contexto, a implantação de um sistema de apoio à decisão baseado em *Deep Learning* pode auxiliar especialistas na análise de lesões cutâneas, fornecendo uma segunda opinião qualificada e reduzindo a subjetividade no diagnóstico. Esse tipo de ferramenta pode otimizar a triagem de casos, priorizando aqueles de maior risco e garantindo um suporte mais eficiente, especialmente em locais com poucos dermatologistas disponíveis.

No entanto, a classificação precisa dessas lesões cutâneas ainda representa um desafio significativo para dermatologistas, especialmente em regiões com acesso limitado a especialistas. Nesse contexto, o uso de técnicas de *Deep Learning*, especificamente a Transferência de Aprendizado com *MobileNetV2*, pode se destacar como uma abordagem promissora. A utilização de redes neurais profundas pré-treinadas em grandes bases de dados permite o desenvolvimento de modelos capazes de realizar a classificação de imagens médicas com alta precisão, mesmo em ambientes com recursos computacionais limitados.

A escolha do *MobileNetV2* justifica-se pela sua eficiência em termos de computação, aliada ao seu bom desempenho em tarefas de classificação de imagens. Srinivasu et al. (2021), explica que esse modelo é ideal para aplicações em dispositivos móveis e sistemas de *Computer-Aided Design* (Desenho Assistido por Computador), facilitando sua implementação em ferramentas acessíveis para a prática clínica e possibilitando a democratização do diagnóstico de lesões cutâneas.

² neoplasias: crescimento anormal de células no corpo, que pode ser benigno ou maligno, sendo este último conhecido como câncer. (Fonte: INCA, 2022)

O desenvolvimento de um modelo de *Deep Learning* para a classificação automática de lesões cutâneas, como Carcinoma Basocelular e Melanoma, utilizando a Transferência de Aprendizado com o *MobileNetV2*, tem um impacto significativo tanto para a comunidade científica quanto para a sociedade. Essa abordagem pode melhorar a precisão dos diagnósticos médicos, especialmente em regiões onde há escassez de especialistas em dermatologia, facilitando o acesso a uma avaliação mais rápida e eficiente.

1.3 OBJETIVO GERAL

Desenvolver e avaliar um modelo de Aprendizado Profundo com a arquitetura *MobileNetV2* para a classificação automática de câncer de pele em imagens dermatológicas, diferenciando Carcinoma Basocelular e Melanoma, e implementar um aplicativo móvel como suporte ao diagnóstico, contribuindo para áreas com déficit de especialistas em dermatologia.

1.4 OBJETIVOS ESPECÍFICOS

- Implementar um modelo de Aprendizado Profundo baseado no *MobileNetV2*, utilizando Transferência de Aprendizado para classificar imagens de lesões cutâneas;
- Treinar e avaliar o desempenho do modelo com um conjunto de dados público, utilizando como métrica de avaliação a acurácia;
- Criar um aplicativo móvel para capturar imagens e classificar lesões de pele automaticamente.
- Avaliar o desempenho do modelo em um ambiente móvel.
- Comparar os resultados do modelo em termos de acurácia e eficiência computacional com outros métodos de classificação de câncer de pele presentes na literatura.

2 FUNDAMENTAÇÃO TEÓRICA

Para obter uma análise válida sobre o Carcinoma Basocelular e o Melanoma, é fundamental compreender o que é o câncer de pele e como ele se desenvolve. Esse conhecimento permite treinar a rede neural para identificar lesões em imagens dermatoscópicas e classificá-las com base nas características extraídas de cada uma.

2.1 CARCINOMA BASOCELULAR

Considerado o tipo mais comum de câncer de pele, o Carcinoma Basocelular representa cerca de 80% dos tumores malignos de pele. Ele é originado nas células basais da epiderme, geralmente se desenvolve em áreas da pele expostas de forma excessiva ao sol, como rosto, pescoço e couro cabeludo, como é explicado por Wolff et al. (2019).

Apesar de seu crescimento ser lento e raramente ocorrer casos de metástase, o Carcinoma Basocelular pode causar danos significativos se não for tratado precocemente, invadindo os tecidos adjacentes e causando desfiguração na região afetada, como aponta os estudos de Santos et al. (2023). Os fatores de risco incluem exposição solar de forma excessiva, histórico familiar ou pessoal da doença, idade e possuir uma imunidade enfraquecida.

2.1.1 Sinais e sintomas

O Carcinoma Basocelular geralmente começa como um calombo ou crescimento anormal na pele, com suas características visuais de cor perolada ou rosa como é visto na Figura 1. Outros sinais do Carcinoma Basocelular incluem feridas que não cicatrizam, ou seja, áreas de pele com uma aparência alva e em alguns casos brilhantes, além de lesões com vasos sanguíneos visíveis também pode dar origem ao Carcinoma Basocelular. Além disso, coceira, sangramento ocasional e ulceração (lesões superficiais na mucosa da pele) também podem ser sintomas relacionados à doença, como é apresentado por Wolff et al. (2019).

Figura 1 - Carcinoma Basocelular.



Fonte: International Skin Imaging Collaboration - ISIC (2020).

A Figura 1 apresenta uma lesão cutânea de coloração marrom heterogênea, com bordas irregulares e distribuição assimétrica do pigmento. Observam-se estruturas dermatoscópicas que podem sugerir diferentes diagnósticos, incluindo Nevo Displásico, Melanoma inicial ou Carcinoma Basocelular. A presença de áreas escuras difusas, pontos pigmentados e possível ausência de uma rede típica levanta a necessidade de uma avaliação clínica detalhada. No entanto, o diagnóstico definitivo só pode ser estabelecido por um dermatologista, com base na análise clínica e, se necessário, em exames complementares, como a biópsia.

2.1.2 Detecção precoce

A detecção precoce do Carcinoma Basocelular exerce um papel importante na eficácia do tratamento e na prevenção de complicações graves da doença. Com suspeitas da doença, procurar o profissional da área e fazer exames de rotina na pele pode contribuir para identificação de possíveis alterações suspeitas, como crescimentos anormais de calombos na pele, feridas que não cicatrizam ou mudanças na cor ou na textura da pele, como mostram os estudos de Muñoz-Estrada et al. (2022).

Fazer consultas regulares com um dermatologista também são essenciais, especialmente para pessoas com fatores de risco. Quanto mais cedo o Carcinoma Basocelular for diagnosticado maior será a probabilidade de um tratamento bem-sucedido e de evitar danos significativos à pele e gastos desnecessários.

2.1.3 Prevenção

A prevenção do Carcinoma Basocelular pode ser estabelecida através de medidas para reduzir a exposição excessiva ao sol e proteger a pele contra os danos causados pelos raios ultravioletas. Incluindo o uso de protetores solar com fator de proteção (FPS) de pelo menos 30 que corresponde a uma absorção de 96,7% da radiação ultravioleta B, também, vestir roupas de proteção, como chapéus de abas largas e camisas de manga longa, e evitar a exposição diretas ao sol durante as horas de pico, entre 10h e 16h.

Simões et al. (2023), em seus estudos, explica que é importante evitar também o uso de camas de bronzamento artificial, pois a radiação artificial também pode aumentar o risco de desenvolver o Carcinoma Basocelular e outros tipos de câncer de pele.

2.2 MELANOMA

O Melanoma é considerado o tipo de câncer de pele mais agressivo, se comparado aos outros, ele se origina nas células produtoras de melanina no corpo, chamadas de melanócitos. Essas células são responsáveis pela pigmentação (coloração) da pele, como aponta o trabalho desenvolvido por Sedlmayr et al. (2023).

O Melanoma pode aparecer em qualquer parte do corpo, principalmente em casos de metástase, como explica Simões et al. (2023), quando o câncer de pele já está em um estágio avançado e se espalha de uma região do corpo para outra. As regiões do corpo mais suscetíveis a casos de Melanoma são aquelas expostas de forma excessiva ao sol, como rosto, pescoço, braços, pernas e costas. Alguns fatores de risco que causam o Melanoma incluem bronzamento artificial, existência de casos de Melanoma na família, grandes quantidades de pintas no corpo, olhos claros, cabelos ruivos e pele clara com sardas e exposição intensa e intermitente ao sol.

2.2.1 Sinais e sintomas

Os sinais e sintomas do Melanoma geralmente envolvem mudanças na aparência de pintas ou manchas na pele e o surgimento de crostas ao redor do local seguido de coceira, sangramento ou inflamação, além disso, variação na cor (tons de marrom, preto, azul ou vermelho), manchas ou caroços que não cicatrizam em algumas semanas podem dar origem ao Melanoma. A Figura 2 ilustra um caso de Melanoma em uma imagem dermatoscópica.

Figura 2 - Melanoma.



Fonte: International Skin Imaging Collaboration - ISIC (2020).

A evolução do Melanoma de acordo com a ilustração acima pode causar coceira, sangramento ou dor na região afetada, sendo essencial estar atento a esses sinais e procurar atendimento médico ao notar qualquer alteração suspeita na pele como explica Wolff et al. (2019). A imagem analisada exibe uma lesão pigmentada com bordas irregulares, coloração heterogênea e áreas de tonalidade preta, marrom e avermelhada. A assimetria, a distribuição irregular do pigmento e possíveis sinais de ulceração são características sugestivas de Melanoma, um câncer de pele agressivo que exige diagnóstico precoce para um tratamento eficaz e melhores prognósticos.

2.2.2 Detecção precoce

A detecção precoce do Melanoma é crucial para aumentar as chances de um tratamento bem-sucedido e, com isso, melhorar os resultados para os pacientes diagnosticados com tal doença. Exames regulares da pele são fundamentais para identificar lesões suspeitas, como pintas ou manchas que apresentam mudanças repentinas de cor, tamanho, forma ou textura. É importante estar atento aos sinais de uma nova lesão na pele que pareça diferente das outras, como explica Sedlmayr et al. (2023). Consultar regularmente um profissional da área duas vezes é uma prática recomendada, especialmente para pessoas com fatores de risco, como histórico pessoal ou familiar de Melanoma.

De acordo com SBCO (2024), a regra do ABCDE (que avalia Assimetria, Borda, Cor, Diâmetro e Evolução da lesão cutânea) é um método de autoexame amplamente utilizado para ajudar na identificação de sinais precoces de Melanoma como é ilustrado na Figura 3, um tipo agressivo de câncer de pele.

Figura 3 - Regra do ABCDE.



Fonte: modificada de Centro de Oncologia Oswaldo Cruz (2024).

Cada letra na Figura 3 representa uma característica a ser observada em pintas ou lesões suspeitas: **A** refere-se à assimetria, onde uma metade da lesão é diferente da outra; **B** indica borda, que tende a ser irregular, com contornos mal definidos; **C** está relacionado à cor, sendo preocupante quando há variação de tonalidades, como, marrom, preto, azul ou vermelho na mesma lesão; **D** refere-se ao diâmetro, em que lesões maiores que 6 mm (aproximadamente o tamanho de uma borracha de lápis) podem ser suspeitas; e **E** indica evolução, que envolve mudanças no tamanho, forma, cor ou sintomas, como coceira ou sangramento, ao longo do tempo. A observação desses sinais pode ajudar na detecção precoce e no tratamento mais eficaz do Melanoma.

2.2.3 Prevenção

A prevenção precoce do Melanoma é crucial para reduzir o risco de desenvolvimento desse tipo de câncer de pele. Cuidados básicos como evitar a exposição ao sol, entre 10h e 16h, podem ajudar a proteger a pele dos danos causados pelos raios ultravioletas. Usar regularmente protetores solar com um FPS adequado, além de vestir roupas de proteção, como chapéus de abas largas e roupas de manga longa, são cuidados extras que ajudam a proteger a pele. Além disso, evitar ao máximo o uso de camas de bronzamento artificial, pois elas emitem radiação ultravioleta nociva à pele e ao corpo como explica Simões et al. (2023).

Caso uma mancha na pele apresente mudanças ou pareça anormal, é fundamental realizar exames para verificar e diagnosticar a presença de Melanoma. Os procedimentos mais comuns incluem:

- Exames físicos e avaliação do histórico médico;
- Exame dermatológico detalhado (dermatoscopia);
- Biópsia³ da lesão suspeita.

Após o diagnóstico de Melanoma, é crucial realizar avaliações adicionais para determinar se o câncer se espalhou para outras partes do corpo, já que ele pode surgir em qualquer região da pele. O tratamento pode envolver cirurgia, radioterapia, medicamentos ou, em alguns casos, quimioterapia, dependendo do estágio da doença e das suas características específicas. A escolha da abordagem terapêutica é baseada no avanço do Melanoma e nas condições individuais do paciente segundo a SBCO (2024).

3. TRABALHOS RELACIONADOS

Diversos estudos na literatura abordam a detecção automática de áreas lesionadas na pele para fins de segmentação utilizando técnicas computacionais. A seguir, são apresentados alguns trabalhos que aplicam segmentação automática em lesões cutâneas.

Barman et al. (2023), propuseram um modelo para a classificação de imagens de lesões cutâneas como Queratose Actínica, Carcinoma Basocelular, Fibroma Dermatológico, Melanoma, *Nevus*, Queratose Benigna, Ceratose Seborréica, Carcinoma Espinocelular e Lesão Vascular utilizando a arquitetura *GoogLeNet* e aplicando a Transferência de Aprendizado, com comparação de desempenho entre diferentes modelos. O modelo faz uso de uma rede neural que trabalha diretamente com tensores, explorando representações multidimensionais para capturar a complexidade das características presentes nas imagens cutâneas. Além disso, foi utilizada a função de perda *Cross-Entropy*, escolhida por penalizar previsões incorretas e reforçar a confiança nas previsões corretas, permitindo ao modelo atribuir probabilidades mais altas às classes verdadeiras e, assim, melhorar a acurácia da classificação em um contexto de alta variabilidade de padrões visuais.

Para aprimorar a identificação de atributos discriminativos e relevantes na detecção de câncer de pele, Gouda et al. (2022), propuseram o desenvolvimento de uma Rede Neural Convolucional (CNN) para classificação de lesões cutâneas como Carcinoma Espinocelular, Carcinoma Basocelular e Melanoma. Em seus estudos, os autores utilizaram a técnica *Enhanced Super-Resolution Generative Adversarial Network* (ESRGAN), a fim de transformar imagens granuladas ou pixeladas em versões mais detalhadas e visualmente naturais. Paralelamente, foram aplicadas Redes Adversárias Generativas (GANs) para aumentar a resolução de imagens de baixa qualidade. Além de realizarem a classificação utilizando a rede neural proposta, os autores compararam seu desempenho com outras três arquiteturas distintas, visando avaliar a eficácia do modelo proposto em relação a abordagens alternativas.

Gururaj et al. (2023), apresentaram um estudo comparativo entre as arquiteturas *DenseNet169* e *ResNet50* na classificação de imagens dermatoscópicas, aplicando a Transferência de Aprendizado. Para aprimorar a

análise dos padrões e das características essenciais das lesões como Carcinoma Basocelular, Dermatofibroma, Queratose Actínica, Queratose Benigna, Lesão Vascular, *Nevus* e Melanoma, os autores utilizaram a técnica *Dull Razor*, que remove fios de cabelo interferentes nas imagens ao substituir ou interpolar *pixels* por valores médios dos *pixels* vizinhos, resultando em uma imagem mais nítida e adequada para análise. No comparativo, a arquitetura *DenseNet169* demonstrou desempenho superior em relação à *ResNet50*.

No trabalho de Indraswari et al. (2022), os autores desenvolveram uma arquitetura de Rede Neural Convolucional inspirada no *MobileNetV2*, empregando a técnica de Transferência de Aprendizado para classificar imagens dermatoscópicas associadas ao Melanoma e Não-Melanoma. A pesquisa utilizou Validação Cruzada (*Cross-Validation*), como forma de avaliar o desempenho do modelo de forma confiável, testando em múltiplos subconjuntos de dados visando garantir que ele se generalize bem e não dependa de uma única divisão de dados. Ao final, as métricas de desempenho de todas as rodadas foram combinadas, resultando em uma avaliação mais robusta e menos suscetível a vieses. Os resultados do modelo proposto foram comparados com os de outras três arquiteturas, proporcionando uma análise detalhada da eficácia do modelo.

³ Biópsia: procedimento médico em que se remove uma pequena amostra de tecido ou células do corpo para análise em laboratório. (Fonte: Simões et al. 2023).

No estudo de Kavitha et al. (2024), os autores propuseram o desenvolvimento de uma rede neural que captura, de forma eficiente, características do câncer de pele utilizando blocos de convolução paralelos baseados na arquitetura *Region-based Convolutional Neural Network* (R-CNN). O modelo também incorpora técnicas de detecção híbridas, combinadas com o uso de Redes Adversariais Generativas (GANs), que auxiliam na geração de amostras sintéticas e na ampliação do conjunto de dados, aprimorando a robustez e a precisão na detecção de lesões cutâneas como Carcinoma Espinocelular, Carcinoma Basocelular e Melanoma.

Lecchi et al. (2022), propuseram um modelo de classificação de imagens dermatoscópicas baseado na arquitetura *YOLOV5*, aplicando técnicas de extração de características e normalização dos dados para aprimorar o desempenho da rede. Além de classificar as lesões como sendo Melanoma ou *Nevus*, o modelo desenvolvido pelos autores também é capaz de identificar e quantificar múltiplas lesões em uma única imagem, o que diferencia o trabalho dos autores na análise automática de imagens dermatoscópicas, especialmente em contextos onde a precisão e a capacidade de detecção múltipla são essenciais.

Mijwil (2021), desenvolveu um modelo de classificação de imagens cutâneas baseado na arquitetura da Rede Neural Convolucional *ConvNet* e comparou seu desempenho com três arquiteturas alternativas. No estudo, foram empregadas técnicas de extração de características e Aumento de Dados com o objetivo de aprimorar as métricas de treinamento e o desempenho geral da rede. O modelo proposto demonstrou desempenho superior em relação às demais arquiteturas analisadas, consolidando-se como uma abordagem promissora para a análise automatizada de imagens cutâneas associadas ao Melanoma.

Em Montagna et al. (2022), foi proposta a construção de um modelo para auxiliar no diagnóstico de lesões de pele como Melanoma, *nevus*, Carcinoma Basocelular, Queratose Actínica, Queratose Seborréica, Dermatofibroma, Lesão Vascular, utilizando seis modelos pré-treinados distintos e aplicando a técnica de Transferência de Aprendizado.

O estudo incorporou a técnica de *Cross-Validation* para avaliar o desempenho do modelo de forma mais robusta, permitindo uma estimativa confiável da acurácia ao utilizar diferentes subconjuntos de dados para o treinamento e a validação. A pesquisa também utilizou a técnica de pré-processamento *Shades Of Gray* para normalizar as cores de cada imagem, ajustando para que a média de cada canal *Red Green Blue* (RGB) se aproxime de um tom de cinza neutro, melhorando assim a qualidade e a consistência das imagens antes de aplicá-las ao modelo de *Deep Learning*.

Muturi et al. (2024), Com base na arquitetura *MobileNetV2*, desenvolveram uma Rede Neural Convolucional para a classificação de imagens dermatoscópicas associadas a lesões de pele como Queratose Actínica, Carcinoma Basocelular, Ceratose Benigna, Dermatofibroma, Melanoma e *Nevus*. Ao aplicar técnicas de pré-processamento, como Aumento de Dados, os autores conseguiram treinar a rede de maneira eficiente. Como forma de facilitar a classificação das imagens, eles criaram um aplicativo *web* desenvolvido com o *framework Flask*, que permite a inserção de dados do paciente e o *upload* da imagem, possibilitando um diagnóstico mais detalhado do tipo de câncer e sua gravidade.

No estudo de Negrete (2020), é realizada uma análise comparativa entre três arquiteturas de redes neurais: *AlexNet*, VGG16 e VGG19. Para essa avaliação, foram desenvolvidos três modelos distintos (A, B e C) com o objetivo de medir o desempenho de cada arquitetura na classificação de imagens dermatoscópicas associadas ao Melanoma e Não-Melanoma. Tanto a VGG16 quanto a VGG19 utilizaram a técnica de Transferência de Aprendizado.

Para abordar o desbalanceamento da base de dados, os autores implementaram técnicas de Aumento de Dados (*Data Augmentation*), como forma de aprimorar o conjunto de treinamento. Além disso, foi empregada a técnica de *Early Stopping* para prevenir o *overfitting*, o que contribuiu para um desempenho superior do modelo baseado no *AlexNet* em comparação com as outras arquiteturas analisadas.

Novais (2023), propôs a criação de um aplicativo móvel para detecção do risco de Melanoma, utilizando a arquitetura pré-treinada VGG16. Novais (2023), destacou o uso de técnicas de morfologia matemática, como dilatação para expandir e erosão para reduzir formas nas imagens. Além disso, aplicou técnicas de pré-processamento, como a Binarização de *Otsu*, para segmentar imagens, convertendo-as de escala de cinza para binárias (preto e branco) como forma de separar os objetos de interesse do fundo. Após o processamento, o aplicativo utiliza critérios visuais conhecidos como "ABCDE" para classificar a lesão como benigna, maligna ou indeterminada.

O aplicativo móvel proposto por Oliveira (2021), foi desenvolvido com base na arquitetura de rede neural *EfficientNet* para a classificação e monitoramento do Melanoma em imagens cutâneas. Para melhorar a qualidade dos dados, foram aplicadas técnicas de pré-processamento como normalização e Aumento de Dados, além do uso de critérios visuais conhecidos como "ABCDE" para avaliar os sinais iniciais da doença. Oliveira (2021), também criou uma versão *web* do aplicativo, que se comunica com o aplicativo móvel por meio de uma *Interface Application Programming* (API) desenvolvida em *Python* utilizando *Flask*. Essa integração permite uma visualização aprimorada das projeções gráficas das classificações e do diagnóstico médico.

Este trabalho apresenta o desenvolvimento de um aplicativo móvel para a classificação de imagens cutâneas relacionadas ao Carcinoma Basocelular e ao Melanoma. O modelo proposto utiliza Transferência de Aprendizado com a rede neural pré-treinada *MobileNetV2*, uma arquitetura leve e de baixo custo computacional, adequada para dispositivos móveis. Para uma análise detalhada e comparativa dos resultados, foi elaborada a Tabela 1, que sintetiza os principais dados dos estudos relacionados, proporcionando uma visão clara da proposta em comparação ao estado da arte.

Tabela 1 - Comparação das técnicas de desenvolvimento de modelos de Aprendizado Profundo.

Artigos	Cânceres	Base de dados	Modelos aplicados	Pré-processamento	Avaliação de desempenho	Métricas de avaliação
Barman et al. (2023)	Queratose Actínica, Carcinoma Basocelular, fibroma Dermatológico, Melanoma, <i>Nevus</i> , Queratose Benigna, Ceratose Seborréica, Carcinoma Espinocelular e Lesão Vascular.	ISIC 2018	<i>GoogLeNet</i> , <i>Xpaction</i> e <i>InceptionResNetV2</i> .	<i>Data Augmentation</i> . Normalização. <i>Resizing</i> . Classificação: feita pela rede neural proposta pelos autores.	Não especificada pelos autores.	Precisão: 76,16%
Gouda et al. (2022)	Carcinoma Espinocelular, Carcinoma Basocelular e Melanoma.	ISIC 2018	<i>ResNet50</i> , <i>InceptionV3</i> e <i>InceptionResNet</i> .	ESRGAN. Normalização. <i>Data Augmentation</i> . Classificação: feita pela rede neural proposta pelos autores.	Não especificada pelos autores.	Acurácia: 83,2%
Gururaj et al. (2023)	Carcinoma Basocelular, Dermatofibroma, Queratose Actínica, Queratose Benigna, Lesão Vascular, <i>Nevus</i> e Melanoma.	HAM10000	<i>DenseNet169</i> e <i>ResNet50</i> .	Balanceamento. Amostragem. Segmentação. Classificações: feitas pelas redes neurais propostas pelos autores.	Não especificada pelos autores.	Precisão. <i>DenseNet169</i> : 91,7%, <i>ResNet50</i> : 83%.

Indraswari et al. (2022)	Melanoma e Não-Melanoma.	ISIC 2020, ISBI 2016, MED-Node e PH2.	<i>MobileNetV2</i> , <i>ResNet50V2</i> , <i>InceptionV3</i> e <i>InceptionResNetV2</i> .	Otimização. <i>Data Augmentation</i> . Classificação: feita pela rede neural proposta pelos autores.	Cross-Validation	Precisão: 85%
Kavitha et al. (2024)	Carcinoma Espinocelular, Carcinoma Basocelular e Melanoma.	ISIC 2016	R-CNN	Normalização. Segmentação. <i>Data Augmentation</i> . Classificação: feita pela rede neural proposta pelos autores.	Não especificada pelos autores.	Precisão: 91,32%
Lecchi et al. (2022)	Melanoma e <i>Nevus</i> .	ISIC 2020	<i>YOLOV5</i>	Normalização. <i>Feature Extraction</i> . Classificação: feita pela rede neural proposta pelos autores.	Não especificada pelos autores.	Precisão. Melanoma: 70%. <i>Nevus</i> : 95%.
Mijwil (2021)	Melanoma	ISIC 2019 e ISIC 2020.	<i>ConvNet</i> , <i>InceptionV3</i> , <i>ResNet</i> e <i>VGG19</i> .	<i>Feature Extraction</i> . <i>Data Augmentation</i> . Classificação: feita pela rede neural proposta pelo autor.	<i>Cross-Validation</i>	Acurácia: 86,60%. Precisão: 87,47%.

Montagna et al. (2022)	Melanoma, <i>Nevus</i> , Carcinoma Basocelular, Queratose Actínica, Queratose Seborréica, Dermatofibroma, Lesão Vascular.	HAM10000	<i>DenseNet</i> , <i>ResNetV2</i> , <i>InceptionV3</i> , <i>InceptionResNetV2</i> , <i>Xception</i> e <i>EfficientNet</i> .	<i>Shades of gray</i> . <i>Data Augmentation</i> . <i>Feature Extraction</i> . Classificação: feita pela rede neural proposta pelos autores.	<i>Cross-Validation</i>	Acurácia: 74,50%
Muturi et al. (2024)	Queratose Actínica, Carcinoma Basocelular, Ceratose Benigna, Dermatofibroma, Melanoma e <i>Nevus</i> .	HAM10000	<i>MobileNetV2</i>	Dimensionamento. Segmentação. <i>Data Augmentation</i> . Classificação: feita pela rede neural proposta pelos autores.	Treinamento, validação e teste.	Precisão: 85%
Negrete (2020).	Melanoma e Não-Melanoma.	ISIC 2018	<i>AlexNet</i> , <i>VGG16</i> e <i>VGG19</i> .	Otimização. Normalização. <i>Data Augmentation</i> . Classificações: feitas pelas redes neurais propostas pelos autores.	Treinamento, validação e teste.	Acurácia. Modelo A: 97,66%. Modelo B: 99,79%. Modelo C: 93,17%.
Novais (2023)	Melanoma	HAM10000	VGG16	Normalização. Segmentação: Binarização de <i>Otsu</i> . Classificação: feita pela rede neural proposta pelo autor.	Não especificada pelo autor.	Acurácia: 85%

Oliveira (2021)	Melanoma	HAM10000	<i>EfficientNet</i>	Redimensionamento. Normalização. <i>Data Augmentation</i> . Classificação: feita pela rede neural proposta pelo autor.	Treinamento, Validação e teste.	Acurácia: 95%
Proposta do trabalho	Carcinoma Basocelular e Melanoma.	ISIC 2020	<i>MobileNetV2</i>	Redimensionamento. Normalização. Otimização. Balanceamento: <i>Aumento de dados</i> . Codificação <i>One-Hot</i> . Classificação: feita pela rede neural proposta.	<i>Cross-Validation</i>	Acurácia: 94,24%.


Fonte: elaborada pelo autor (2024).

A análise comparativa realizada revela que a proposta deste trabalho apresenta um desempenho competitivo em relação a outras abordagens discutidas na literatura. A escolha do *MobileNetV2*, associada à Transferência de Aprendizado, demonstrou ser uma estratégia eficaz, especialmente quando complementada por técnicas de redimensionamento, normalização, balanceamento e otimização de dados. Essas técnicas não apenas melhoraram a qualidade das imagens utilizadas no treinamento, mas também contribuíram significativamente para a robustez do modelo. Como resultado, foi alcançada uma acurácia de 94,24%, superando diversas arquiteturas mais complexas que, embora possam oferecer alto desempenho, muitas vezes exigem recursos computacionais consideráveis.

3 METODOLOGIA

Neste capítulo, são detalhadas as etapas metodológicas deste estudo, desde a aquisição e o pré-processamento dos dados até a implementação e análise do modelo. Inicialmente, aborda-se a coleta e preparação dos dados, essenciais para a qualidade do aprendizado.

Figura 4 - Etapas da metodologia do estudo.



Fonte: elaborada pelo autor (2024).

Tal qual apresentado na Figura 4, a metodologia foi iniciada através da aquisição de dados que após sua análise são pré-processados e apresentados os procedimentos para a seleção e ajuste do *backbone*. Na sequência, explica-se a implementação de um modelo de Rede Neural Convolutiva (CNN) e a proposta de um novo modelo CNN otimizado. Por fim, são descritas as técnicas de análise dos dados (ver Apêndice B), que permitiram avaliar a eficácia do modelo.

3.1 AQUISIÇÃO DE DADOS

A base de dados utilizada neste estudo é proveniente da *International Skin Imaging Collaboration* (ISIC), extraída do desafio *Society for Imaging Informatics in Medicine* (SIIM) para análise e detecção de lesões de pele de 2020, conforme descrito por Rotemberg et al. (2021). Esta parceria entre a ISIC e a SIIM visa promover o desenvolvimento de tecnologias de inteligência artificial aplicadas à análise de imagens médicas, com ênfase em diagnósticos de câncer de pele. As competições anuais, como a SIIM-ISIC *Melanoma Classification Challenges*, incentivam a criação de modelos avançados de aprendizado de máquina, com o objetivo de melhorar a precisão e a eficácia na detecção de lesões cutâneas.

O *dataset* público disponibilizado para o estudo contém um total de 7.800 imagens dermatoscópicas, usadas para a classificação de dois tipos de câncer de pele: Carcinoma Basocelular e Melanoma. Para organizar o treinamento do modelo, foi utilizada a rotulagem fornecida pelo arquivo *Ground Truth* disponível no site do ISIC, o que permitiu a categorização de 3.300 imagens como Carcinoma Basocelular e 4.500 imagens como Melanoma.

3.2 CONFIGURAÇÃO DO SISTEMA

Neste sistema, utilizou-se uma rede neural de fluxo tensorial para executar a Rede Neural Convolutiva. Essa abordagem foi escolhida devido à necessidade de realizar várias multiplicações de matrizes. Como o processamento foi realizado apenas na CPU, adotou-se o *Jupyter Lab*, uma versão aprimorada do *Jupyter Notebook*, disponível no site oficial Jupyter (2024). É amplamente utilizado para facilitar o desenvolvimento e a execução interativa de código, especialmente em áreas como ciência de dados, aprendizado de máquina e análise de dados.

Menke (2020), explica que sua principal finalidade é permitir a combinação de código executável, texto explicativo e visualizações em um único documento, o que facilita a experimentação, o compartilhamento e a reprodução de resultados. A linguagem de programação utilizada foi o *Python* (versão 3.11.8), juntamente com a biblioteca *Keras* (versão 3.2.1) para a modelagem de todas as estruturas da CNN utilizada no trabalho.

3.3 PRÉ-PROCESSAMENTO

Como forma de otimizar a qualidade dos dados e garantir que o modelo aprenda de forma eficaz, aplica-se algumas técnicas de pré-processamento como forma de garantir que os dados de entrada estejam de forma otimizada e para aumentar a capacidade do modelo de generalizar para amostra de dados reais.

3.3.1 Redimensionamento de imagens

O redimensionamento de imagens é uma etapa fundamental no pré-processamento de dados para Redes Neurais Convolucionais, especialmente em modelos como *MobileNetV2* que exigem dimensões fixas para as estradas. Para este estudo as imagens foram redimensionadas para 224 x 224 *pixels*. Esse padrão de tamanho permite que todas as imagens possuam as mesmas dimensões, evitando erros no treinamento e garantindo que o modelo possa processá-las de maneira uniforme. Além disso, o uso dessa etapa no pré-processamento pode facilitar a implementação do modelo em diferentes ambientes, além de reduzir o tempo de processamento.

3.3.2 Normalização de imagens

A normalização aplicada individualmente a cada canal *Red Green Blue* (RGB) ajusta os valores dos *pixels* para uma faixa uniforme. Nesta abordagem, os valores dos *pixels* são divididos por 255, transformando-os para o intervalo entre 0 e 1. Esse processo melhora a estabilidade do treinamento e contribui para a precisão do modelo, tornando-o mais robusto em diferentes condições de previsão.

3.3.3 Otimização


No treinamento do modelo, foram otimizados os pesos das camadas da rede neural, incluindo a *MobileNetV2* pré-treinada e as camadas adicionais de processamento. O ajuste desses pesos foi realizado pelo otimizador *Adaptive Moment Estimation* (ADAM), que atualizou os valores iterativamente para minimizar a função de perda *Categorical Cross Entropy*.

Além disso, a taxa de aprendizado foi ajustada dinamicamente pelo *callback ReduceLROnPlateau*, reduzindo seu valor em 30% quando a perda de validação não apresentava melhora por duas épocas consecutivas, ajudando a estabilizar o treinamento. Os parâmetros das camadas densas também foram otimizados, especialmente a camada *Dense(256, activation='relu')*, que aprendeu representações mais discriminativas dos dados, e a camada de saída *Dense(num_classes, activation='softmax')*, responsável pela classificação final.

3.3.4 Balanceamento de classes

Neste estudo, o balanceamento foi realizado por meio da redução (*undersampling*) da quantidade de amostras da classe majoritária, ajustando-a ao tamanho da classe com o menor número de amostras. Para isso, foram eliminadas algumas imagens que apresentavam irregularidades, como marcações de texto e numerações microscópicas, uma vez que esses elementos poderiam prejudicar o desempenho do modelo durante o treinamento.

Figura 5 - Distribuição balanceada das imagens por classe.



Fonte: gerada pelo autor utilizando o *Jupyter Lab* (2024).

Inicialmente, as imagens das duas classes, Carcinoma Basocelular e Melanoma, foram carregadas separadamente. Em seguida, para evitar um viés do modelo em favor da classe com mais exemplos, o código limitou a quantidade de amostras da classe majoritária ao mesmo número de amostras da classe minoritária (Figura 5). Após esse processo, os dados foram embaralhados aleatoriamente para garantir uma distribuição equilibrada durante o treinamento.

E como forma de mitigar a perda de diversidade causada pelo *undersampling* nas informações da classe majoritária foi utilizado o *Data Augmentation* (Aumento de Dados) aplicando as transformações como mostra a Tabela 2.

Tabela 2 - Transformações nas amostras de imagens do conjunto de dados ISIC 2020.

Tipo de transformação	Descrição	Valor configurado
Rotação	Rotação da imagem em torno do centro.	10 graus
Ampliação (zoom)	Ajusta o tamanho da imagem, simulando aproximação ou afastamento.	10%
Mudança horizontal	Desloca a imagem horizontalmente (esquerda/direita).	10% da largura
Mudança vertical	desloca a imagem verticalmente (para cima/baixo).	10% da altura

Fonte: elaborada pelo autor (2024).

A escolha dos valores para *Data Augmentation* no código original foi feita com o objetivo de introduzir variações leves nas imagens sem comprometer suas características essenciais, permitindo que o modelo generalize melhor sem aprender padrões artificiais. Abaixo está a motivação para cada um dos valores escolhidos:

- Rotação (10 graus):
 - As imagens de câncer de pele podem ser capturadas sob ângulos ligeiramente diferentes, aplicando uma rotação moderada ajuda o modelo a aprender variações naturais sem deformar a estrutura da lesão.
- Aplicação (zoom de 10%):
 - Pequenas variações no zoom simulam variações na distância entre a câmera e a pele do paciente. Isso ajuda o modelo a lidar com diferentes níveis de aproximação da imagem.
- Mudanças horizontal (10% da largura) e mudança vertical (10% da altura):
 - Esse ajuste melhora a robustez do modelo sem alterar a posição relativa da lesão de forma drástica durante o enquadramento da imagem capturada.

3.3.5 Codificação One-Hot

A Codificação *One-Hot* é uma técnica utilizada para transformar dados categóricos em um formato numérico que pode ser interpretado por modelos de Aprendizado de Máquina. Nessa abordagem, cada categoria é representada por um vetor binário, onde apenas a posição correspondente à categoria em questão recebe o valor 1, enquanto as demais posições recebem o valor 0. Por exemplo, as categorias ["Gato", "Cachorro", "Pássaro"] seriam codificadas como [1, 0, 0], [0, 1, 0] e [0, 0, 1], respectivamente. Essa técnica é amplamente utilizada para evitar que os modelos interpretem as categorias como valores ordinais ou contínuos, preservando a natureza discreta das variáveis.


3.4 CONJUNTO DE DADOS DE TREINAMENTO E TESTE

A divisão dos dados foi realizada de forma a garantir um conjunto de treinamento e um conjunto de teste bem estruturados. Inicialmente, todas as imagens foram carregadas e balanceadas por meio de *undersampling*. Em seguida, os dados foram divididos em 80% para treinamento e 20% para validação e teste, garantindo que o modelo fosse treinado com a maior parte das amostras disponíveis, enquanto um subconjunto separado foi reservado para avaliar o desempenho final do modelo em dados nunca vistos. Dentro do conjunto de treinamento, a técnica de *K-Fold Cross-Validation* com 5 folds foi aplicada, permitindo que o modelo fosse treinado e validado em diferentes subconjuntos, reduzindo o risco de *overfitting* e garantindo uma avaliação mais robusta.

3.5 ESTIMAÇÃO DO BACKBONE

Um *backbone* é uma rede neural base utilizada em modelos de Aprendizado Profundo, especialmente em tarefas de visão computacional. Essas redes são frequentemente pré-treinadas em grandes conjuntos de dados, como o *ImageNet*, permitindo que aprendam representações visuais úteis e generalizáveis, conforme discutido por Gulartt et al. (2020).

Figura 6 - Fluxograma do método proposto.




Fonte: modificada de Rashid et al. (2022).

No fluxograma do método proposto a Transferência de Aprendizado foi aplicada utilizando modelos de arquitetura pré-treinados no *ImageNet*, com a finalidade de extrair informações que possam aprimorar o aprendizado da CNN, conforme descrito por Gulartt et al. (2020) em sua pesquisa. O objetivo de usar a Transferência de Aprendizado foi reduzir o tempo de treinamento e minimizar erros de generalização.

3.5.1 Configuração do modelo MobileNetV2

A primeira etapa do processo consiste na importação do modelo pré-treinado a partir do conjunto de dados do *ImageNet* configurando-o para carregar os pesos pré-treinados desse conjunto de dados, o modelo se beneficia desse conhecimento adquirido o que acelera o processo de aprendizagem para a nova tarefa relacionada como a classificação de imagens dermatoscópica.

Figura 7 - Estrutura básica e o bloco de construção do *MobileNetV2*.



Fonte: modificada de Modal et al. (2023).

Na imagem acima a convolução de expansão aumenta a dimensionalidade dos canais de imagens de entrada para capturar mais informações sem aumentar o custo computacional. Na convolução de profundidade realiza uma convolução separada para cada canal, reduzindo o número de parâmetros e tornando a rede mais eficiente. Já na convolução de projeção reduz a dimensionalidade dos canais novamente para comprimir as informações extraídas e prepará-las para as camadas seguintes.

Além disso, a arquitetura do *MobileNetV2* incorpora conexões residuais, que ajudam a preservar a informação e melhorar o fluxo do gradiente durante o treinamento. A camada de classificação original do modelo foi removida, o que significa que apenas a parte responsável pela extração das características está sendo utilizada. Utilizou-se o *MobileNetV2* como extrator de características para classificar imagens de câncer de pele. Ao manter as camadas convolucionais treinadas e adicionar uma nova camada de saída personalizada e transformar essas saídas em probabilidades de ser um Carcinoma Basocelular ou Melanoma na classificação final.

3.6 HIPERPARÂMETROS DO MODELO DE TRANSFERÊNCIA DE APRENDIZADO

A seleção dos hiperparâmetros foi realizada com base em uma combinação de testes experimentais e considerações teóricas sobre a convergência e generalização do modelo. A função de perda *Categorical Cross-Entropy* foi escolhida por ser a mais adequada para problemas de classificação multiclasse, pois mede a divergência entre a distribuição real das classes e a distribuição prevista, penalizando previsões de baixa confiança.

Tabela 3 - Hiperparâmetros aplicados no modelo proposto.

Identificação	Valor dos hiperparâmetros
Função de perda	Entropia Cruzada Categórica
Épocas	30, 50, 70
Tamanho do <i>batch</i> (lote)	16
Otimizador	<i>Adaptive Moment Estimation</i> (ADAM)
Taxa de aprendizagem	0,001

Fonte: elaborada pelo autor (2024)

O número de épocas foi testado empiricamente com valores de 30, 50 e 70. Durante os experimentos, observou-se que, à medida que o número de épocas aumentava, a precisão no conjunto de treinamento continuava a crescer, enquanto a precisão no conjunto de validação começava a estabilizar ou até diminuir, indicando *overfitting*. O modelo treinado por 30 épocas obteve o melhor equilíbrio entre aprendizado eficaz e generalização, pois ainda estava aprendendo padrões relevantes sem sinais significativos de sobreajuste. Já com 50 e 70 épocas, a diferença entre a precisão de treinamento e validação aumentou, sugerindo que o modelo estava memorizando os dados de treinamento, prejudicando a generalização. Dessa forma, 30 épocas foram escolhidas como o ponto ideal.

O tamanho do *batch* foi definido como 16, equilibrando eficiência computacional e estabilidade na otimização. *Batches* menores promovem maior variação nos gradientes, o que pode ajudar na exploração de mínimos locais e melhorar a generalização. No entanto, *batches* muito pequenos podem gerar gradientes ruidosos e prejudicar a estabilidade da convergência.

O otimizador *Adaptive Moment Estimation* (ADAM) foi adotado por sua capacidade de combinar as vantagens do *RMSprop* e do *Momentum*, ajustando dinamicamente a taxa de aprendizado para cada parâmetro com base no histórico de gradientes. Isso facilita a convergência, mesmo em problemas complexos e com dados ruidosos.

Por fim, a taxa de aprendizado foi fixada em 0,001, considerando um bom equilíbrio entre velocidade de convergência e estabilidade. Taxas mais altas poderiam causar oscilações ou impedir a convergência, enquanto taxas muito baixas tornariam o treinamento excessivamente lento. Esse valor de 0,001 é comumente utilizado em modelos com *Transfer Learning*, pois permite ajustar os pesos pré-treinados sem distorcer excessivamente as representações aprendidas.

4 RESULTADOS E DISCUSSÃO

Este capítulo apresenta os experimentos realizados e os resultados obtidos com a abordagem proposta. O treinamento e a avaliação do modelo foram conduzidos utilizando a técnica de Validação Cruzada (*Cross-Validation*), com o método *KFold*, a fim de garantir a robustez e a generalização dos resultados.

A avaliação nos subconjuntos do conjunto de treinamento revelou uma acurácia média de 93,67%, indicando um desempenho consistente durante o aprendizado do

modelo. Para validar a capacidade de generalização, o modelo foi testado em um conjunto de dados separado, resultando em uma acurácia de 94,24%, evidenciando sua eficácia na classificação de exemplos desconhecidos. A Tabela 4 apresenta um resumo dos resultados obtidos.

Tabela 4 - Resultados de acurácia do modelo.

Conjunto de dados	Acurácia (%)
Treinamento	93,67
Teste	94,24


Fonte: elaborada pelo autor (2024)

Os resultados indicam que o modelo apresentou um bom desempenho tanto no treinamento (93,67% de acurácia) quanto na validação com dados não vistos (94,24% de acurácia). A pequena diferença entre esses valores sugere uma baixa taxa de *overfitting* e uma boa capacidade de generalização.

4.1 IMPLEMENTAÇÃO DO APLICATIVO MÓVEL

O aplicativo móvel, denominado *SkinAlert*⁴, foi desenvolvido utilizando o *framework Android Studio* e a linguagem de programação *Java*, permitindo a criação de uma aplicação *Android* voltada para a classificação do Carcinoma Basocelular e do Melanoma. De forma intuitiva o aplicativo conta com um menu de acesso rápido, conforme ilustrado na Figura 8, para que antes de realizar uma classificação o usuário tenha acesso a informações importantes sobre o aplicativo.

Figura 8 - Menu de acesso do *SkinAlert*.



Fonte: gerada pelo autor utilizando o *SkinAlert* (2024).

O menu dá acesso a seções como Home (Figura 9), que ao tirar uma foto é redirecionado para tela de Resultados (Figuras 10, 11, 12), Sobre o App que explica o

que o *SkinAlert* faz, Sugestões para foto que explica sugestões antes de capturar uma imagem e a seção Sair que finaliza o app.

O aplicativo desenvolvido classifica imagens de câncer de pele em duas categorias: Carcinoma Basocelular e Melanoma. Ele utiliza um modelo de Aprendizado Profundo previamente treinado e convertido para o formato *TensorFlow Lite (TFLite)* para integração no ambiente móvel. O processo começa com o usuário capturando uma foto da lesão ou da imagem dermatoscópica utilizando a câmera do dispositivo como ilustra na tela inicial do aplicativo na Figura 9.

Figura 9 - Tela inicial de captura do *SkinAlert*.




Fonte: gerada pelo autor utilizando o *SkinAlert* (2024).

A imagem capturada é pré-processada para atender às especificações do modelo e, em seguida, analisada pelo *TFLite*, que identifica padrões e características para fornecer uma previsão. Para garantir a confiabilidade dos resultados, foi definido um limiar de confiança de 85% com base na acurácia do modelo. Se a acurácia da classificação for superior a 85%, o aplicativo exibe o resultado indicando se a lesão corresponde a Carcinoma Basocelular ou Melanoma (Figuras 10 e 11). Caso contrário, informa que nenhum câncer de pele foi detectado, pois a lesão analisada não corresponde a nenhum dos tipos identificados pelo modelo (Figura 12). Esse critério busca aumentar a precisão das previsões, minimizando erros na classificação.

⁴ Acesso do repositório do projeto em: <https://github.com/CristianoGO/skin-alert-app-classification.git>

Figuras 10, 11 e 12 - Tela de resultado para as classificações.



Fonte: gerada pelo autor utilizando o *SkinAlert* (2024).

A principal vantagem de usar um limiar de confiança de 85% no modelo *TFLite* do aplicativo é reduzir a chance de classificações erradas, aumentando a confiabilidade dos resultados. Esse critério garante que apenas previsões com alta certeza sejam exibidas, evitando diagnósticos imprecisos que poderiam levar a alarmes falsos ou à subestimação de riscos. Além disso, ele contribui para a segurança do usuário, minimizando erros que poderiam gerar preocupações desnecessárias ou atrasos na busca por atendimento médico. Dessa forma, o limiar funciona como um filtro para aprimorar a precisão das previsões, equilibrando sensibilidade e especificidade na detecção de lesões suspeitas.

O desenvolvimento deste aplicativo representa um avanço significativo na detecção precoce de câncer de pele, oferecendo uma ferramenta acessível e eficiente para a classificação de lesões como o Carcinoma Basocelular e o Melanoma. Ao possibilitar que usuários capturem diretamente de seus dispositivos móveis, o aplicativo promove maior autonomia e praticidade no monitoramento de condições cutâneas suspeitas. Essa inovação não apenas facilita o acesso à triagem inicial, mas também pode auxiliar profissionais de saúde no direcionamento para diagnósticos mais precisos e tratamentos oportunos, contribuindo para a redução da mortalidade associada a esses tipos de câncer.

4.2 DISCUSSÃO DOS RESULTADOS

Os experimentos realizados demonstraram a alta eficácia do modelo de Aprendizado Profundo na classificação de câncer de pele. O modelo alcançou uma acurácia média de 93,67% por meio de Validação Cruzada com cinco *folds*, garantindo uma performance consistente na identificação de Carcinoma Basocelular e Melanoma. Com os dados de teste, a acurácia foi de 94,24%.

A análise detalhada das métricas de desempenho, incluindo as matrizes de confusão (ver Apêndice B), evidenciou uma baixa incidência de falsos positivos e falsos negativos. O equilíbrio entre precisão (capacidade de identificar corretamente as amostras positivas) e *recall* (capacidade de recuperar todas as amostras relevantes) reforça a robustez do modelo, um fator crítico no contexto médico, onde a detecção precoce é essencial.

O pré-processamento dos dados desempenhou um papel fundamental nos bons resultados obtidos. O balanceamento das classes garantiu uma distribuição equitativa entre Carcinoma Basocelular e Melanoma, mitigando vieses inerentes a conjuntos de dados desbalanceados. Além disso, o ajuste de hiperparâmetros, como o uso do otimizador *Adaptive Moment Estimation* (ADAM) com uma taxa de aprendizado de 0,001 e o treinamento por 30 épocas, assegurou a convergência estável do modelo sem comprometer sua capacidade de generalização.

Na prática, a implementação do aplicativo *SkinAlert* permitiu a integração eficiente do modelo treinado em dispositivos móveis. A utilização do *TensorFlow Lite* (TFLite) garantiu um tempo de resposta otimizado de 4,53 segundos em um dispositivo móvel *Samsung Galaxy A20*, cujas especificações estão detalhadas na Tabela 5.

Tabela 5 - Configurações do dispositivo móvel testado.

Configurações	Detalhes
Processador	2x 1.6 GHz Cortex-A73 + 6x 1.35 GHz Cortex-A53
Graphics Processing Unit (GPU)	Mali-G71 MP2
Random Access Memory (RAM)	3 GB
Memória máxima	32 GB

Fonte: elaborada pelo autor (2024)

Essa eficiência torna o aplicativo uma ferramenta acessível para triagem inicial e apoio à detecção do câncer de pele. Dessa forma, o *SkinAlert* se destaca como uma solução promissora para democratizar o acesso à saúde e auxiliar na precisão diagnóstica.

4.2.1 Comparação com os estudos relacionados

Este estudo empregou a arquitetura *MobileNetV2* para a classificação do Carcinoma Basocelular e Melanoma utilizando o conjunto de dados ISIC 2020. Para otimizar o desempenho do modelo, foram aplicadas técnicas como balanceamento de dados, normalização, codificação *One-Hot* e *Data Augmentation*. Como resultado, a abordagem proposta alcançou uma acurácia média de 93,67% nos dados de treinamento e 94,24% nos dados de teste, demonstrando sua eficácia na tarefa de classificação.

Para avaliar o desempenho do modelo em relação a trabalhos anteriores, foram analisados diversos estudos que utilizaram a base de dados ISIC. A precisão e acurácia

relatadas nesses estudos variam consideravelmente, dependendo do modelo e do pré-processamento adotados. Por exemplo, Montagna et al. (2022) obtiveram 74,50% de acurácia, enquanto Negrete (2020) reportou um desempenho significativamente superior, atingindo 99,79%.

Estudos mais recentes, como os de Gururaj et al. (2023) e Kavitha et al. (2024), apresentaram resultados com precisão de 91,7% e 91,32%, respectivamente, valores que estão próximos ao desempenho alcançado pelo modelo proposto neste trabalho. Além disso, ao considerar abordagens que utilizaram a base HAM10000, destaca-se o estudo de Oliveira (2021), que alcançou uma acurácia de 95% utilizando a arquitetura *EfficientNet*.

Os resultados obtidos demonstram que o modelo desenvolvido apresenta um desempenho competitivo em relação ao estado da arte, alcançando alta precisão na classificação de imagens cutâneas. Além disso, o uso da *MobileNetV2* se destaca por ser uma arquitetura mais leve e eficiente, tornando-se uma alternativa viável para implementação em dispositivos móveis sem comprometer a qualidade da predição.

5 CONCLUSÃO

O câncer de pele é uma das neoplasias mais comuns no mundo, e a detecção precoce é essencial para um tratamento eficaz. Este estudo propôs um modelo de Aprendizado Profundo baseado na *MobileNetV2*, integrado a um aplicativo móvel, para a classificação de lesões cutâneas.

A solução apresentada visa auxiliar médicos e pacientes no diagnóstico e monitoramento de lesões cutâneas, considerando a falta de acesso a especialistas em regiões remotas. O modelo foi treinado com a base ISIC 2020, utilizando técnicas robustas de pré-processamento e Validação Cruzada para garantir a confiabilidade do desempenho. A integração com dispositivos móveis facilita sua implementação em cenários de recursos limitados.

Os resultados mostraram um desempenho competitivo, com acurácias de 93,67% (treinamento) e 94,24% (teste), demonstrando a capacidade de generalização do modelo. Comparando-se com estudos relacionados, a solução se destaca pela eficiência e acessibilidade para aplicações móveis.

A integração com um aplicativo móvel torna essa abordagem prática e acessível, facilitando a triagem e o diagnóstico dermatológico. Apesar das limitações computacionais, o modelo se mostrou funcional e eficiente, podendo ser aprimorado com bases de dados mais amplas e maior poder computacional. Por fim, este estudo reforça a relevância do *Deep Learning* na medicina, abrindo caminhos para futuras aplicações em diagnósticos assistidos por computador.

Em conclusão, o desenvolvimento deste modelo de Aprendizado Profundo integrado a um aplicativo móvel representa um avanço significativo na detecção precoce do câncer de pele, proporcionando uma ferramenta acessível e eficiente para médicos e pacientes, especialmente em regiões com limitações de recursos. A alta acurácia alcançada nas fases de treinamento e teste evidencia a eficácia da solução proposta, enquanto a integração com dispositivos móveis amplia sua aplicabilidade em cenários do mundo real. O impacto desse modelo pode abrir portas para novos avanços tecnológicos no diagnóstico e tratamento de doenças dermatológicas, contribuindo para uma medicina mais acessível e precisa.

5.1 TRABALHOS FUTUROS

Embora os resultados tenham sido promissores, este estudo representa um ponto de partida para avanços futuros na detecção assistida de câncer de pele. A aplicação do modelo em dispositivos móveis demonstrou sua viabilidade, mas há espaço para otimizações que podem aprimorar sua precisão, eficiência e aplicabilidade clínica. Melhorias no desempenho do modelo, na usabilidade do aplicativo e na integração com sistemas de saúde podem ampliar significativamente o impacto da solução, tornando-a ainda mais acessível e eficaz para pacientes e profissionais da área.

Entre as possíveis melhorias e expansões, destacam-se:

- Expansão do conjunto de dados, incluindo mais categorias de câncer de pele para aumentar a capacidade de generalização do modelo.
- Exploração de arquiteturas mais avançadas, como *EfficientNet* e *Vision Transformers*, para otimizar a precisão e a eficiência computacional.
- Integração com sistemas eletrônicos de saúde, permitindo o compartilhamento seguro de diagnósticos com profissionais.
- Validação clínica mais ampla, garantindo maior robustez e confiabilidade na aplicação médica.
- Aprimoramento da interface do aplicativo, visando maior acessibilidade e usabilidade.

Além disso, a inclusão de análises preditivas baseadas no histórico médico pode personalizar os diagnósticos, enquanto um sistema de aprendizado incremental poderia aprimorar continuamente a precisão do modelo. Essas iniciativas têm o potencial de fortalecer a proposta apresentada, tornando o *SkinAlert* uma ferramenta essencial no diagnóstico e monitoramento de lesões cutâneas.

REFERÊNCIAS

ACADEMY, E. Como o otimizador Adam otimiza o modelo de rede neural? - Academia EITCA. In: EITCA ACADEMY. 8 ago. 2023. Disponível em: <https://pt.eitca.org/intelig%C3%A2ncia-artificial/eitc-ai-dltf-aprendizado-profundo-com-tensorflow/fluxo-tensor/modelo-de-rede-neural/revis%C3%A3o-de-exame-modelo-de-rede-neural/como-o-otimizador-adam-otimiza-o-modelo-de-rede-neural/>. Acesso em: 25 nov. 2024.

BARMAN, S.; BISWAS, M. R.; MARJAN, S.; NAHAR, N.; HOSSAIN, M. S.; ANDERSSON, K. Transfer Learning Based Skin Cancer Classification Using GoogLeNet. In: SATU, Md. S. et al. (org.). **Machine Intelligence and Emerging Technologies**. Cham: Springer Nature Switzerland, 2023. (Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering). v. 490, p. 238–252.

BARRETO JÚNIOR, B. G. B. O. Pigmented Dermatological Lesions Classification Using Convolutional Neural Networks Ensemble Mediated by Multilayer Perceptron Network. **IEEE Latin America Transactions**, v. 17, n. 11, p. 1902–1908, 2019.

BRO, R.; SMILDE, A. K. Principal component analysis. **Analytical Methods**, v. 6, n. 9, p. 2812–2831, 2014.

CENTRO de Oncologia Oswaldo Cruz: câncer e tumores de pele. In: agende sua consulta ou exame no Hospital Alemão Oswaldo Cruz. Disponível em: <https://www.hospitaloswaldocruz.org.br/centro-especializado/oncologia/cancer-de-pele/>. Acesso em: 5 out. 2024.

COSTA, M. G. F. Redes Neurais Convolucionais na Saúde. *Journal of Health Informatics*, v. 9, n. 4, 2017. Disponível em: <https://jhi.sbis.org.br/index.php/jhi-sbis/article/view/615>. Acesso em: 15 maio 2024.

FALCÃO, J. V. R.; MOREIRA, V. A.; SANTOS, F. A. O.; RAMOS, C. de A. REDES NEURAIAS DEEP LEARNING COM TENSORFLOW. *RE3C - Revista Eletrônica Científica de Ciência da Computação*, v. 14, n. 1, 2019. Disponível em: <https://revistas.unifenas.br/index.php/RE3C/article/view/232>. Acesso em: 16 maio 2024.

GOUDA, W.; SAMA, N. U.; WAAKID, G.; HUMAYUN, M.; JHANJHI, N. Z. Detection of Skin Cancer Based on Skin Lesion Images Using Deep Learning. *Healthcare*, v. 10, n. 7, p. 1183, 2022.

GULARTT, V. A.; ANTONIAZZI, R. L. MobileNetV2 Model for Image Classification. In: 2020 2ND International Conference on Information Technology and Computer Application, 2020. **2020 2nd International Conference on Information Technology and Computer Application (ITCA)**, v. 8, p. 48 - 57, ISSN 2358 - 6053, 2020. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9422058>. Acesso em: 26 maio 2024.

GURURAJ, H. L.; MANJU, N.; NAGARJUN A.; ARADHYA, V. N. M.; FLAMMINI, F. DeepSkin: A Deep Learning Approach for Skin Cancer Classification. *IEEE Access*, v. 11, p. 50205–50214, 2023.

INDRASWARI, R.; ROKHANA, R.; HERULAMBANG, W. Melanoma image classification based on MobileNetV2 network. *Procedia Computer Science*, v. 197, p. 198–207, 2022.

INSTITUTO Nacional de Câncer: INCA estima 704 mil casos de câncer por ano no Brasil até 2025. Disponível em: <https://www.gov.br/inca/pt-br/assuntos/noticias/2022/inca-estima-704-mil-casos-de-cancer-por-ano-no-brasil-ate-2025>. Acesso em: 27 set. 2024.

INTERNATIONAL Skin Imaging Collaboration: ISIC Archive. ISIC - International Skin Imaging Collaboration. Disponível em: <https://challenge.isic-archive.com/data/#2020>. Acesso em: 01 out. 2024.

JUPYTER. Jupyter: open-source web application for creating and sharing documents. Disponível em: <https://jupyter.org/>. Acesso em: 20 nov. 2024.

KAVITHA, C.; PRIYANKA, S.; KUMAR, M. P.; KUSUMA, V. Skin Cancer Detection and Classification using Deep Learning Techniques. *Procedia Computer Science*, v. 235, p. 2793–2802, 2024.

LACERDA, L. Deep Learning & Visão computacional: REDES NEURAIAS CONVOLUCIONAIS. *Medium*, 22 set. 2019. Disponível em: <https://medium.com/@lucaaslb/deep-learning-vis%C3%A3o-computacional-redes-n>

eurais-convolucionais-c21f19f5ec34>. Acesso em: 17 maio. 2024

LECCHI, T.; ALMEIDA, G. M. D.; VIVACQUA, R. P. D. Algoritmo de Deep Learning baseado na rede neural YOLOv5 para classificação dermatoscópica e detecção de câncer (melanoma). **Concilium**, v. 22, n. 7, p. 813–827, 23 dez. 2022.

LOPES JÚNIOR, L. C.; LIMA, R. A. G. de. Cuidado ao câncer e a prática interdisciplinar. **Cadernos de Saúde Pública**, v. 35, n. 1, 2019. Disponível em: <https://repositorio.usp.br/item/003001841>. Acesso em: 26 maio 2024.

MARIANO, E. B. TÉCNICAS DE SEGMENTAÇÃO DE IMAGENS ATRAVÉS DE REDES NEURAIAS CONVOLUCIONAIS. 2022.

MENKE, E. J. Series of Jupyter Notebooks Using Python for an Analytical Chemistry Course. **Journal of Chemical Education**, v. 97, n. 10, p. 3899–3903, 2020.

MIJWIL, M. M. Skin cancer disease images classification using deep learning solutions. **Multimedia Tools and Applications**, v. 80, n. 17, p. 26255–26271, 2021.

MONDAL, S.; De Pratyay; MALAKAR, S.; SARKAR, R. OMRNet: A lightweight deep learning model for optical mark recognition. **Multimedia Tools and Applications**, v. 83, n. 5, p. 14011–14045, 2023.

MONTAGNA, D. A.; PEREIRA, W. D.; FERNANDES, A. M. da R.; DAZZI, R. L. S. Classificação Automática para Auxílio no Diagnóstico de Lesões de Pele Usando Deep Convolucional Neural Network com Modelos de Transfer Learning. In: COMPUTER ON THE BEACH, 2022, Itajaí - Santa Catarina - Brasil. **Anais do XIII Computer on the Beach - COTB'22**. Itajaí - Santa Catarina - Brasil: Universidade do Vale do Itajaí, 2022. p. 228–235. Disponível em: <https://periodicos.univali.br/index.php/acotb/article/view/18814>. Acesso em: 15 out. 2024.

MOTURI, D.; SURAPANENI, R. K.; AVANIGADDA, V. S. G. Developing an efficient method for melanoma detection using CNN techniques. **Journal of the Egyptian National Cancer Institute**, v. 36, n. 1, p. 6, 2024. Disponível em: <https://link.springer.com/article/10.1186/s43046-024-00210-w>.

MUÑOZ-ESTRADA, V. F.; YLÉ-ARÁMBURO, E. L.; LEÓN, V. Y. C.-C. y. Carcinoma Basocelular. **Revista Médica de la Universidad Autónoma de Sinaloa REVMEDUAS**, v. 12, n. 2, p. 157–158, 2022.

NEGRETE, P. D. M. **Uso de técnicas de deep learning para classificação de imagens dermatoscópicas com lesões na pele**. 2020. Mestre em Engenharia Elétrica - Universidade Estadual de Campinas, Campinas, SP, 2020.

NOVAIS, Arthur Costa de. Desenvolvimento de aplicativo para a detecção de riscos de câncer de pele. Centro Universitário Norte do Espírito Santo, **Universidade Federal do Espírito Santo, São Mateus**, 2023.

OLIVEIRA, B. A. G. D.; FERRAZ, P. A. P.; COELHO, T. M. M.; RUNGUE, A. H. de A.; DOS SANTOS, W. A.; FERREIRA, F. M. F.; GÓES, L. F. W.; SOARES, G. L.; MARTINS, C. A. P. Da S. AVALIAÇÃO DE TÉCNICAS DE TRANSFERÊNCIA DE

APRENDIZADO EM CNNs. **Congresso Brasileiro de Automática - CBA**. v. 1, n. 1, 2019. Disponível em: https://www.sba.org.br/open_journal_systems/index.php/cba/article/view/703. Acesso em: 12 nov. 2024.

OLIVEIRA, Bernardo Góes Barreto Júnior Barros de. Monitoramento e detecção de risco de melanoma por meio de análise de imagens. Escola Politécnica, **Universidade Positivo**, Curitiba, 2021.

ORGANIZAÇÃO Pan-Americana Da Saúde. Câncer. 2024. Disponível em: <https://www.paho.org/pt/topicos/cancer>. Acesso em 28 set. 2024.

PAN, S. J.; YANG, Q. A Survey on Transfer Learning. **IEEE Transactions on Knowledge and Data Engineering**, v. 22, n. 10, p. 1345–1359, 2010.

PEREIRA, R. M. P.; MAIA, L. B.; SILVA, T. A.; PESSOA, A. C. P.; BRAZ JÚNIOR, G. Um Estudo sobre Diferentes Tipos de Funções de Custo Para Redes Neurais Convolucionais. **ISSN**, 2016.

PINA, D.; KUNSTMANN, L.; DE OLIVEIRA, D.; VALDURIEZ, P.; MATTOSO, M. Uma abordagem para coleta e análise de dados de configurações em redes neurais profundas. In: SIMPÓSIO BRASILEIRO DE BANCO DE DADOS (SBBB), 2020. **Simpósio Brasileiro de Banco de Dados (SBBB)**. SBC, 2020. p. 187–192. Disponível em: <https://sol.sbc.org.br/index.php/sbbd/article/view/13639>. Acesso em: 15 maio 2024.

RASCHKA, S.; MIRJALILI, V. Python Machine Learning: Machine Learning and Deep Learning with Python, scikit-learn, and TensorFlow 2. Packt Publishing Ltd, 2019.

RASHID, J.; ISHFAQ, M.; ALI, G.; SAEED, MR. ALKAHALIFAH, T.; ALTURISE, F.; SAMND, M. HUSSAIN, M.; Skin Cancer Disease Detection Using Transfer Learning Technique. **Applied Sciences**, v. 12, n. 11, p. 5714, 2022.

ROTEMBERG, V.; KURTANSKY, N.; BETZ-STABLEIN, B.; CAFFERY, L.; CHOUSAKOS, E.; CODELLA, N.; COMBALIA, M.; DUSZA, S.; GUITERA, P.; GUTMAND.; HALPENRN, A.; HELBA, B.; KITTLER, H.; KOSE, K.; LANGER, S.; LIOPRYS, K.; MALVEHY, J.; MUSTHAQ, S.; NANDA, J.; REITER, O.; SHIH, G.; STRANTIGO, A.; TSCHANDL, P.; WEBER, J.; SOYER, P. A patient-centric dataset of images and metadata for identifying melanomas using clinical context. **Scientific Data**, v. 8, n. 1, p. 34, 2021.

SARKAR, D. **A Comprehensive Hands-on Guide to Transfer Learning with Real-World Applications in Deep Learning**. 2018. Disponível em: <https://towardsdatascience.com/a-comprehensive-hands-on-guide-to-transfer-learning-with-real-world-applications-in-deep-learning-212bf3b2f27a>. Acesso em: 26 maio 2024.

SANTOS, C. G.; BITENCOURT, D. S. R.; DE BRITO, L. G.; NETO, J. F., De A. OS PRINCIPAIS ATIVOS USADOS NA PREVENÇÃO E TRATAMENTO DO MELASMA. **Revista Ibero-Americana de Humanidades**, Ciências e Educação, v. 7, n. 11, p. 943–963, 2021.

SANTOS, M. de O.; DE LIMA, F. C. Da S.; MARTINS, L. F. L.; OLIVEIRA, J. L. P.; DE ALMEIDA, L. M.; CANCELA, M. De C. Estimativa de Incidência de Câncer no Brasil, 2023-2025. **Revista Brasileira de Cancerologia**, v. 69, n. 1, p. e-213700, 2023.

SCIKIT-LEARN. CROSS-VALIDATION: EVALUATING ESTIMATOR PERFORMANCE. Disponível em: https://scikit-learn/stable/modules/cross_validation.html. Acesso em: 21 nov. 2024.

SEDLMAYR, I. A.; DOWSLEY, T. C.; BARCARO, K. P. P.; LOPES, L. L.; VARGAS JUNIOR, A. S.; GUIMARÃES, A. D. Melanoma: uma análise abrangente das características, diagnóstico e avanços no tratamento. **Brazilian Journal of Health Review**, v. 6, n. 5, p. 20367–20381, 2023. Disponível em: <https://ojs.brazilianjournals.com.br/ojs/index.php/BJHR/article/view/62847>

SIMÕES, Y. B. J.; VILELA, H. R.; ROCHA, R. V. S.; LIMA, L. G. B. D.; DE SÁ, L. C.; MACHADO, G. U. Estratégias de prevenção do Câncer de Pele no Brasil. **Brazilian Journal of Health Review**, v. 6, n. 3, p. 9749–9758, 2023. Disponível em: <https://ojs.brazilianjournals.com.br/ojs/index.php/BJHR/article/view/59821>

SKIN Cancer Foundation. Skin Cancer Facts and Statistics. Disponível em: <https://www.skincancer.org/skin-cancer-information/skin-cancer-facts/>. Acesso em: 27 set. 2024.

Sociedade Brasileira de Cirurgia Oncológica. Mortes por Melanoma no Brasil podem aumentar 80% em duas décadas, aponta Cancer Tomorrow da OMS. Disponível em: <https://sbco.org.br/atualizacoes-cientificas/mortes-por-melanoma-no-brasil-podem-aumentar-80-em-duas-decadas-aponta-cancer-tomorrow-da-oms/#:~:text=E%20os%20n%C3%BAmeros%20requerem%20aten%C3%A7%C3%A3o,comparativo%20entre%20os%20dois%20anos.>>. Acesso em: 28 set. 2024.

SOCIETE Brasileira de Dermatologia. Derma Brasil revela características regionais de cuidados com a pele. Disponível em: <https://www.sbd.org.br/derma-brasil-revela-caracteristicas-regionais-de-cuidados-com-a-pele/>. Acesso em: 12 nov. 2024.

SRINIVASU, P. N. et al. Classification of Skin Disease Using Deep Learning Neural Networks with MobileNet V2 and LSTM. **Sensors**, v. 21, n. 8, p. 2852, 2021.

TENSORFLOW. TensorFlow API Documentation. Disponível em: https://www.tensorflow.org/api_docs/python/tf. Acesso em: 14 nov. 2024.

Tensorflow Lite. Uso do TensorFlow Lite em dispositivos móveis. Disponível em: <https://www.tensorflow.org/lite/guide?hl=pt-br>. Acesso em: 6 out. 2024.

WOLFF, K. et al. Dermatologia de Fitzpatrick: Atlas e Texto McGraw Hill Brasil, 2019.

APÊNDICE A - RECURSOS TECNOLÓGICOS

Foram utilizadas neste trabalho tecnologias amplamente conhecidas e utilizadas na área de inteligência artificial para auxiliar no desenvolvimento do modelo de aprendizado e suportar a execução da aplicação e de todos os sistemas integrados a ela. Algumas foram o *Python*, *TensorFlow*, Validação Cruzada (*Cross-Validation*), Redes Neurais Convolucionais (CNNs), Transferência de Aprendizado e a arquitetura *MobileNetV2* para que fosse possível aplicar os conceitos e lógicas associados ao *Deep Learning*.

Linguagem de programação *Python*

Python é uma linguagem de programação bem conhecida no ambiente de análise e desenvolvimento de sistemas, especialmente em projetos de *Machine Learning* e inteligência artificial. Sua popularidade deve-se à sua sintaxe simples e ao grande conjunto de bibliotecas que suportam o desenvolvimento de modelos de *Deep Learning*. Entre essas bibliotecas, destacam-se o *TensorFlow*, *PyTorch*, *Keras* e *Scikit-learn*, que facilitam o treinamento e a implementação de redes neurais complexas como foi mostrado no trabalho de Raschka et al. (2019).

No contexto de Aprendizado de Máquina, *Python* oferece uma série de recursos que simplificam o processamento de grandes volumes de dados, como imagens dermatológicas. Sua facilidade de integração com outras linguagens e ferramentas permite que modelos desenvolvidos em *Python* sejam facilmente implementados em diversas plataformas, desde servidores até dispositivos móveis, como é o caso deste estudo.

Além disso, o *Python* possui uma comunidade global ativa que constantemente contribui com novas ferramentas, bibliotecas e documentação. Isso garante que a linguagem continue evoluindo rapidamente, mantendo-se uma das melhores opções para o desenvolvimento de soluções baseadas em *Deep Learning*.

Framework *TensorFlow*

TensorFlow é uma biblioteca *open-source* desenvolvida pelo *Google*, amplamente utilizada para a construção e treinamento de modelos de Aprendizado Profundo. Sua documentação oficial *TensorFlow* (2024), oferece recursos e orientações detalhadas para o desenvolvimento de soluções em inteligência artificial. Desde sua introdução, a plataforma se consolidou como uma das mais populares no campo da pesquisa e desenvolvimento em IA, especialmente em tarefas que envolvem grandes volumes de dados e exigem processamento eficiente, como a classificação de imagens.


Uma das principais vantagens do *TensorFlow* é sua capacidade de escalar de um único dispositivo a grandes *clusters* de máquinas, permitindo que os pesquisadores treinem modelos muito complexos com grandes volumes de dados, como explica Pina et al. (2020). No contexto de *Deep Learning*, ele oferece suporte total para Redes Neurais Convolucionais (CNNs), que são a base do modelo de classificação de imagens utilizado neste estudo.

Outro ponto importante do *TensorFlow* é sua compatibilidade com o *TensorFlow Lite*, uma versão otimizada para dispositivos móveis e embarcados, como *smartphones*, de acordo com *TensorFlow Lite* (2024). Isso torna a biblioteca uma escolha ideal para a implementação de modelos em plataformas móveis, permitindo que soluções como a classificação de câncer de pele possam ser acessíveis a qualquer pessoa com um dispositivo *Android*.

Técnica de Validação Cruzada

A Validação Cruzada (*Cross-Validation*) é uma técnica utilizada no *Deep Learning* para avaliar a performance de um modelo de forma mais robusta. Em vez de apenas dividir os dados em conjuntos de treino e teste, a Validação Cruzada particiona o conjunto de dados em "k" grupos, ou *folds*, e treina o modelo "k" vezes. A cada iteração, um dos *folds* é utilizado para validação, enquanto os demais são usados para treino, garantindo uma avaliação mais robusta do desempenho do modelo, de acordo o site oficial Scikit-Learn (2024).

Figura 13 - Validação Cruzada.



Fonte: traduzida de Scikit-Learn (2024).

Analisando a Figura 13 conseguimos entender que essa abordagem oferece uma avaliação mais precisa da capacidade do modelo de generalizar para dados não vistos, pois todas as observações são utilizadas tanto para treino quanto para validação em diferentes momentos. No contexto de classificação de câncer de pele, onde o número de imagens pode ser limitado, a Validação Cruzada é fundamental para garantir que o modelo não esteja apenas memorizando o conjunto de treino.

Além disso, a técnica de Validação Cruzada pode ajudar a identificar problemas como o *overfitting*, em que o modelo performa bem nos dados de treino, mas falha em generalizar. Com isso, é possível ajustar melhor os hiperparâmetros e o tamanho da arquitetura do modelo, visando melhorar a acurácia e o F1-score do classificador, como foi explicado por Barreto Junior (2019).


Redes Neurais Convolucionais

As Redes Neurais Convolucionais (CNNs) são uma classe de redes neurais criadas especialmente para processar e analisar dados com uma estrutura em grade, como por exemplo imagens. Inspirada na arquitetura do córtex visual humano (parte do cérebro responsável pelo processamento de informações visuais), as CNNs são especialmente eficazes em tarefas de visão computacional devido a sua capacidade de capturar e aprender padrões com seu próprio processamento de dados, como explicado no trabalho de Costa (2017).

Sendo amplamente empregadas em tarefas de classificação de imagens, como reconhecimento facial, detecção de objetos e diagnósticos médicos. Essas redes são treinadas com extensos conjuntos de dados rotulados, permitindo a identificação automática de padrões e características visuais. Esse processo possibilita a classificação de imagens com elevado nível de precisão, tornando as CNNs uma ferramenta essencial para a análise e interpretação de dados visuais em diversas aplicações científicas e tecnológicas.

As CNNs funcionam por meio de uma série de camadas interconectadas que transformam a imagem de entrada em uma saída classificada. Segundo Falcão et al. (2019), as principais camadas de uma CNN incluem camadas convolucionais, camadas de *Pooling* e camadas totalmente conectadas. Sua vantagem sobre as redes neurais padrão é que elas são mais eficientes na detecção de relações complexas entre imagens, e isto é possível graças à aplicação de filtros que examinam a relação entre *pixels* adjacentes. A Figura 14 mostra as dimensões dos canais de cores definidos como matriz de três dimensões onde: a largura e altura determina o tamanho da imagem enquanto a profundidade determina os canais de cores *Red Green Blue* (RGB).

Figura 14 - Dimensões de canais de cores RGB.




Fonte: Oliveira et al. (2019).

Falcão et al. (2019), explica que as camadas convolucionais são responsáveis por detectar padrões locais na imagem de entrada, onde são aplicados filtros convolucionais que percorrem a imagem em pequenos blocos. Cada filtro gera um mapa de características que realça certas partes da imagem. As camadas de *Pooling*, são usadas para reduzir a resolução espacial dos mapas de características, estabelecendo a informação e reduzindo o número de parâmetros e a carga computacional.

Esse processo hierárquico permite que as CNNs aprendam representações cada vez mais abstratas e complexas das imagens classificadas, chegando na camada totalmente conectada, onde a decisão de classificação é feita. Para melhor aplicar uma estrutura de uma CNN podemos dividi-la em dois blocos, o primeiro é o de extração de características onde está a camada de convolução e as camadas de *Pooling*, já o segundo bloco é onde está as camadas totalmente conectadas que se comporta semelhante a uma *Multi Layer Perceptron*, como é visto na Figura 15.

Figura 15 - Estrutura de uma rede neural.




Fonte: modificada de Lacerda (2019).

Analisando a estrutura da ilustrada acima nota-se a presença de camadas convolucionais que aplicam filtros para extrair características locais da imagem, como bordas e texturas, enquanto as camadas de *Pooling* reduzem a dimensionalidade dos dados, preservando as características mais importantes. Por fim, as camadas totalmente conectadas utilizam essas características para realizar a classificação final.

Entendendo como ocorre as dimensões dos canais de cores RGB como é mostrado na Figura 14 e, além disso, analisando a estrutura de uma CNN como mostra a Figura 15, podemos entender que a camada de convolução é composta por diversos neurônios. Cada neurônio aplica um filtro chamado de *kernel* que é uma matriz de convolução responsável pela detecção de bordas, características e traços relevantes na imagem.

Figura 16 - Processo de convolução.



Fonte: Lacerda (2019).

A Figura 16 mostra que cada matriz possui valores dos pesos sinápticos (parâmetros que determinam a forma como os dados de entrada são processados pela rede neural), onde ao percorrer toda a imagem é gerado uma nova imagem com o nome de mapa de características, como foi demonstrado em Falcão et al. (2019).

Na prática, a função de ativação *Rectified Linear Unit* (ReLU) é aplicada individualmente a cada *pixel* do mapa de ativação gerado após a convolução de acordo com Pereira et al. (2016). Esse processo elimina valores negativos, garantindo que apenas os padrões relevantes sejam propagados para as próximas camadas.

A Equação 1 ilustra esse comportamento, onde os valores negativos são

substituídos por zero, resultando em um mapa de ativação sem *pixels* negativos. Esse mapa final, livre de informações irrelevantes, é então encaminhado para as camadas subsequentes da Rede Neural Convolucional, contribuindo para a extração de características mais relevantes e aprimorando a capacidade do modelo de reconhecer padrões visuais complexos.

$$f(x) = \max(0, x) \quad (\text{Equação 1})$$

- $f(x)$ - Saída da função ReLU:
 - Representa o valor de ativação que será passado para a próxima camada da rede neural.
 - Depende diretamente da entrada x .
- x - Entrada da função ReLU:
 - Corresponde ao valor resultante da combinação linear das entradas da camada anterior, incluindo os pesos sinápticos e o termo de viés (bias).
 - Pode assumir valores positivos ou negativos.
- $\max(0, x)$ - Operação matemática de máximo:
 - Retorna o maior valor entre 0 e x , o que significa que:
 - Se $x \geq 0$, então $f(x) = x$ (a saída mantém o valor da entrada).
 - Se $x < 0$, então $f(x) = 0$ (a saída é zerada).

Na última camada de uma CNN usada para classificação, a função *Softmax* transforma os valores de saída (*logits*) em probabilidades. Para cada entrada, essa função gera uma distribuição de probabilidades entre as classes, fazendo com que a soma das probabilidades seja sempre igual a 1. Esse comportamento permite interpretar o valor de cada neurônio de saída como probabilidade de pertencer a uma determinada classe, facilitando a classificação final. Como mostra a Equação (2).

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \quad (\text{Equação 2})$$

- $\sigma(z)_j$ - Saída da função *Softmax* para a classe j :
 - Representa o valor de ativação que será passado para a próxima camada da rede neural.
 - Depende diretamente da entrada x .
- e^{z_j} - Exponencial do valor z_j :
 - A função exponencial (base e , aproximadamente, 2,718) é aplicada ao valor z_j .
 - Isso garante que todos os valores fiquem positivos e amplifica as diferenças entre eles.
- $\sum_{k=1}^K e^{z_k}$ - Soma das exponenciais de todas as classes:
 - O denominador é a soma dos exponenciais de todos os K valores z_k .

- Essa soma normaliza os valores, garantindo que as saídas da função formem uma distribuição de probabilidades.
- K - Número total de classes:
 - Indica a quantidade total de categorias possíveis para a classificação.
 - Cada z_k corresponde a um valor antes da ativação para uma classe específica.
- j e k - Índices das classes:
 - j representa a classe específica para qual a função está calculando a probabilidade.
 - k é um índice usado na soma do denominador, percorrendo todas as classes K .

A *Global Average Pooling* também conhecida como *GlobalAveragePooling2D*, é uma técnica de redução de dimensionalidade utilizada em CNNs para simplificar a saída antes da camada de classificação calculando a média das ativações para cada canal como é mostrado na Equação 3. Em vez de aplicar filtros de *Pooling* padrão em uma janela de tamanhos menores, essa técnica calcula a média de toda a área de cada mapa de características. Dessa forma, ele gera um único valor por mapa de características, resultando em um vetor compacto.

$$x_{pool} = \frac{1}{N} \sum_{i=1}^N x_i \quad (\text{Equação 3})$$

- x_{pool} - Valor resultante do *Pooling*:
 - Representa a saída da operação de média *Pooling*, que reduz o tamanho da matriz de ativação.
 - É o valor médio dos elementos dentro de uma determinada região da entrada.
- N - Número total de elementos considerados na média:
 - Indica quantas vezes x_i , estão sendo somados.
 - Depende do tamanho da janela (*kernel*) utilizada para o *Pooling*.
- $\frac{1}{N}$ - Fator de normalização:
 - Indica que está calculando uma média aritmética, dividindo a soma total pelo número de elementos.
- $\sum_{i=1}^N x_i$ - Soma de todos os valores na região de *Pooling*:
 - A notação do somatório (Σ) significa que soma todos os x_i da região analisada.
 - O índice i varia de 1 a N , percorrendo todos os elementos da região.
- x_i - Valores individuais dentro da janela de *Pooling*:

- Representam os valores da matriz de ativação dentro da região considerada.

A Entropia Cruzada Categorical mede a diferença entre a distribuição real das classes e a distribuição de probabilidade predita pelo modelo, indicando o quão bem o modelo consegue prever a classe correta. Além disso, compara a probabilidade atribuída pelo modelo à classe correta com a probabilidade esperada (que é 1 para a classe correta e 0 para as demais classes). A função penaliza previsões distantes da classe correta com valores maiores, incentivando o modelo a ajustar seus pesos para minimizar essa distância. Pode ser entendida da seguinte forma:

$$H(p, q) = - \sum_{i=1}^C p(i) \log(q) \quad (\text{Equação 4})$$


- $H(p, q)$ - Entropia Cruzada:
 - Mede a discrepância entre as distribuições verdadeiras p (rótulos reais) e predita q (saída do modelo).
 - Quanto menor o valor de $H(p, q)$, mais próximas estão as distribuições, indicando uma melhor predição do modelo.
- $p(i)$ - Probabilidade real da classe i :
 - Representa a distribuição real (dos dados, ou seja, a verdadeira probabilidade associada à classe i).
 - No caso de um rótulo *One-Hot* (exemplo: classificação supervisionada), apenas uma classe terá $p(i) = 1$, enquanto todas as outras 0.
- $q(i)$ - Probabilidade predita pelo modelo para a classe i :
 - Refere-se à saída da função *Softmax*, que gera probabilidade para cada classe.
 - Essa probabilidade representa a confiança do modelo em cada possível categoria.
- $\sum_{i=1}^C$ - Somatório sobre todas as C classes:
 - A Entropia Cruzada é calculada considerando todas as possíveis classes C , somando as contribuições individuais de cada classe.
- $\log q(i)$ - Logaritmo da probabilidade predita:
 - Utiliza o logaritmo natural (base e) para penalizar previsões incorretas.
 - Quanto menor for $q(i)$ para a classe correta, maior será o impacto negativo no cálculo da perda.
- Sinal negativo (-):
 - A soma dos termos $p(i) \log q(i)$ geralmente resulta em um valor negativo, então o sinal de menor é utilizado para garantir que a Entropia Cruzada seja um valor positivo.

- Além disso, valores menores indicam predições mais precisas.

Transferência de Aprendizado

A Transferência de Aprendizado (ou *Transfer Learning*) é um método de aprendizado de máquina que visa a reutilização de conhecimento de uma tarefa para outra tarefa diferente, mas relacionada, aproveitando os padrões pré-treinados em uma situação para melhorar o desempenho em outra. Sua utilização tem como finalidade diminuir o tempo de treinamento, reduzir a necessidade de uma grande base de dados, melhorar a precisão do modelo e aplicação em diferentes domínios. A Figura 17 ilustra como ocorre a Aprendizagem de Máquina Tradicional com a Transferência de Aprendizado.

Figura 17 - Comparativo entre Aprendizagem de Máquina Tradicional com Transferência de Aprendizagem.



Fonte: modificada e traduzida de Sarkar (2018).

Esse fluxo de aprendizado mostrado na Figura 17 acelera significativamente o treinamento de modelos ao reutilizar redes neurais previamente treinadas em grandes bases de dados. Diferentemente da Aprendizagem de Máquina Tradicional, onde o modelo precisa aprender todas as características do zero, a Transferência de Aprendizado aproveita representações já extraídas, exigindo apenas pequenos ajustes nas camadas finais. Isso reduz drasticamente o tempo de treinamento e o uso de recursos computacionais, tornando viável a aplicação de redes neurais profundas mesmo em cenários com limitações de *hardware*.

Pan et al. (2010), explica que essa abordagem é particularmente útil em situações onde os dados de treinamento são limitados ou quando o custo de coletar novos é alto. O objetivo principal é aprender como um domínio de origem (dados de entrada) enquanto o domínio de destino (dados de saída) já são conhecidos. Além disso, essa técnica utiliza a tendência indutiva da tarefa fonte para auxiliar a tarefa alvo, podendo ser feita da seguinte forma: ajustando o viés indutivo da tarefa alvo, limitando o espaço do modelo, estreitando o espaço de hipóteses ou fazendo ajustes finos no próprio processo de busca com a ajuda do conhecimento da tarefa fonte.

MobileNetV2

O *MobileNetV2* é uma arquitetura de Rede Neural Convolutacional desenvolvida para tarefas de visão computacional em dispositivos móveis ou sistemas embarcados e com recursos de computação limitados. Sua principal característica é a eficiência, alcançada através do uso de camadas convolucionais profundas e estratégias de otimização, o que resulta em um modelo mais compacto e mais leve, ideais para implementação em *smartphones*, *tablets* e outros dispositivos móveis.

Uma das principais inovações do *MobileNetV2* é a utilização de blocos residuais e conexão linear entre camadas, o que permite um treinamento mais eficiente, mais rápido e estável, além de uma melhor preservação dos gradientes durante a retropropagação, aplicada quando se experimenta maus resultados no aprendizado ou na extração de dados como foi explicado por Gulartt et al. (2020).

Além disso, Gulartt et al. (2020), explica que sua arquitetura permite adaptar a diferentes requisitos de desempenho e recursos computacionais, ou seja, a arquitetura oferece uma variedade de hiperparâmetros e configurações que podem ser ajustados para equilibrar a precisão do modelo com a eficiência computacional, permitindo que os desenvolvedores personalizem a rede de acordo com as necessidades específicas de seus aplicativos e dispositivos.

APÊNDICE B - MÉTRICAS DE AVALIAÇÃO

A acurácia como sendo uma das métricas mais simples e amplamente mais utilizada para medir o desempenho de um modelo de classificação, ela representa a proporção de previsões corretas feitas pelo modelo em relação ao total de previsões realizadas. A fórmula para calcular a acurácia é dada pela Equação (5).

$$acurácia = \frac{\text{número de previsões corretas}}{\text{total de previsões}} \quad (\text{Equação 5})$$

A precisão é uma métrica que mede a proporção de verdadeiros positivos em relação ao total de verdadeiros previstos. Essa métrica é importante em situações onde o custo de falsos positivos é elevado. A precisão é calculada de acordo com a Equação (6).

$$precisão = \frac{\text{verdadeiros positivos}}{\text{verdadeiros positivos} + \text{falsos positivos}} \quad (\text{Equação 6})$$

O *recall*, também conhecido como sensibilidade ou taxa de verdadeiro positivo, mede a proporção de verdadeiros positivos em relação ao total de positivos reais. Essa métrica é fundamental em situações em que o custo de falsos negativos é alto.

$$recall = \frac{\text{verdadeiros positivos}}{\text{verdadeiros positivos} + \text{falsos negativos}} \quad (\text{Equação 7})$$


Avaliação do modelo com os dados de treinamento e teste

Como forma de avaliar o desempenho do modelo nos dados de treinamento e teste utilizou-se métricas como acurácia média e desvio padrão, curva *Receiver Operating Characteristic* (ROC) e a matriz de confusão para ajudar a entender se o modelo é confiável e realmente eficaz na detecção de câncer de pele em imagens dermatoscópicas.

A Figura 18 ilustra a análise da acurácia média e do desvio padrão em cada fold do processo de Validação Cruzada realizado no trabalho. Cada ponto no gráfico representa a acurácia média alcançada pelo modelo em um determinado *fold*, enquanto a área sombreada ao redor da linha reflete o intervalo de variação baseado no desvio padrão da acurácia.

Observa-se que, ao longo dos cinco *folds* (prática comum porque equilibra precisão estatística e eficiência computacional na Validação Cruzada), há flutuações no desempenho do modelo, com o *fold* 3 apresentando a maior acurácia média (em torno de 0.97) e o *fold* 2 exibindo a menor (próxima de 0.93). O desvio padrão, indicado pela largura da área sombreada, varia entre os *folds*, sendo mais amplo nos extremos (*folds* 2 e 5), o que indica maior variabilidade no desempenho nesses casos. Por outro lado, no *fold* 3, o desvio padrão é menor, sugerindo maior estabilidade nas previsões do modelo nesse conjunto.

Figura 18 - Acurácia média e desvio padrão por *fold*.




Fonte: gerada pelo autor utilizando o *Jupyter Lab* (2024).

Essas informações são importantes para avaliar a consistência do modelo, destacando possíveis limitações ou variações associadas à divisão dos dados entre treino e validação. Além disso, a análise evidencia que o modelo apresentou um desempenho geral satisfatório, mas com flutuações que podem ser aprimoradas.

A Figura 19 apresenta as curvas *Receiver Operating Characteristic* (ROC) para cada um dos cinco *folds* gerados durante a Validação Cruzada do modelo. A curva ROC avalia o desempenho do classificador em diferentes limiares de decisão, medindo a taxa de verdadeiros positivos (TPR) em relação à taxa de falsos positivos (FPR).

Em todos os *folds*, as curvas estão posicionadas próximas ao canto superior esquerdo do gráfico, indicando alta capacidade de separação entre as classes (Carcinoma Basocelular e Melanoma). Além disso, o valor médio da *Area Under the Curve* (AUC) sugere que o modelo tem alta capacidade de discriminação entre as classes.

Figura 19 - Curva ROC para cada *fold*.



Fonte: gerada pelo autor utilizando o *Jupyter Lab* (2024).

Esses resultados indicam que o modelo manteve um desempenho consistente em todos os *folds*, com AUC variando entre 0.98 e 0.99, demonstrando excelente capacidade discriminativa. A linha tracejada (AUC = 0.5) representa um classificador aleatório, servindo como referência para comparação. Como as curvas obtidas estão significativamente acima dessa linha, conclui-se que o modelo superou amplamente o desempenho de uma classificação aleatória.


A análise das curvas ROC complementa os resultados de métricas como acurácia, fornecendo uma visão detalhada da qualidade do modelo em termos de *trade-off*⁵ entre verdadeiros positivos e falsos positivos, essencial para problemas sensíveis como a detecção de câncer de pele.

Para apresentar uma comparação entre os valores reais e as previsões geradas pelo modelo, foram analisadas as matrizes de confusão dos dados de treinamento e dos dados de teste. Essa análise teve como objetivo compreender o comportamento do modelo em diferentes conjuntos de dados, permitindo identificar padrões de acerto e erro. Com essas informações, é possível otimizar o desempenho do modelo, ajustando seus parâmetros e estratégias para melhorar a precisão das previsões e garantir uma melhor generalização em dados não vistos.

⁵ Trade-off: significa um compromisso ou troca, ou seja, trata-se de um equilíbrio entre fatores conflitantes, onde melhorar um lado implica sacrificar, ao menos parcialmente, outro.

Figura 22 - Matriz de confusão *fold* 3.

Figura 20 - Matriz de confusão *fold* 1.




Fonte: gerada pelo autor utilizando o *Jupyter Lab* (2024).

A matriz de confusão do *fold* 1 representa o desempenho do modelo para a primeira subdivisão dos dados em um processo de Validação Cruzada. A Tabela 6 mostra os detalhes dos dados.

Tabela 6 - Detalhamento da matriz de confusão *fold* 1.

Rótulo verdadeiro (real)	Previsto: Carcinoma Basocelular	Previsto: Melanoma
Carcinoma Basocelular (0)	497 (VP - corretamente classificado como CBC)	37 (FP - erroneamente classificado como Melanoma)
Melanoma (1)	29 (FN - erroneamente classificado como CBC)	493 (VN - corretamente classificado como Melanoma)

Fonte: elaborada pelo autor (2024)



Fonte: gerada pelo autor utilizando o *Jupyter Lab* (2024).


A matriz de confusão do *fold 2* reflete o desempenho do modelo na segunda subdivisão dos dados durante o processo de Validação Cruzada. Os detalhes dessa análise estão apresentados na Tabela 7.

Tabela 7 - Detalhamento da matriz de confusão *fold 2*.

Rótulo verdadeiro (real)	Previsto: Carcinoma Basocelular	Previsto: Melanoma
Carcinoma Basocelular (0)	482 (VP - corretamente classificado como CBC)	41 (FP - erroneamente classificado como Melanoma)
Melanoma (1)	27 (FN - erroneamente classificado como CBC)	506 (VN - corretamente classificado como Melanoma)

Fonte: elaborada pelo autor (2024)

Figura 22 - Matriz de confusão *fold* 3.



Fonte: gerada pelo autor utilizando o *Jupyter Lab* (2024).


A matriz de confusão do *fold* 3 representa o desempenho do modelo para a terceira subdivisão dos dados em um processo de Validação Cruzada. A Tabela 8 mostra os detalhes dos dados.

Tabela 8 - Detalhamento da matriz de confusão *fold* 3.

Rótulo verdadeiro (real)	Previsto: Carcinoma Basocelular	Previsto: Melanoma
Carcinoma Basocelular (0)	512 (VP - corretamente classificado como CBC)	27 (FP - erroneamente classificado como Melanoma)
Melanoma (1)	28 (FN - erroneamente classificado como CBC)	489 (VN - corretamente classificado como Melanoma)

Fonte: elaborada pelo autor (2024)

Figura 23 - Matriz de confusão *fold* 4.



Fonte: gerada pelo autor utilizando o *Jupyter Lab* (2024).


A matriz de confusão do *fold* 4 reflete o desempenho do modelo na quarta subdivisão dos dados durante o processo de Validação Cruzada. Os detalhes dessa análise estão apresentados na Tabela 9.

Tabela 9 - Detalhamento da matriz de confusão *fold* 4.

Rótulo verdadeiro (real)	Previsto: Carcinoma Basocelular	Previsto: Melanoma
Carcinoma Basocelular (0)	454 (VP - corretamente classificado como CBC)	54 (FP - erroneamente classificado como Melanoma)
Melanoma (1)	26 (FN - erroneamente classificado como CBC)	522 (VN - corretamente classificado como Melanoma)

Fonte: elaborada pelo autor (2024)

Figura 24 - Matriz de confusão *fold* 5.



Fonte: gerada pelo autor utilizando o *Jupyter Lab* (2024).

A matriz de confusão do *fold* 5 representa o desempenho do modelo para a quinta subdivisão dos dados em um processo de Validação Cruzada. A Tabela 10 mostra os detalhes dos dados.


Tabela 10 - Detalhamento da matriz de confusão *fold* 5.

Rótulo verdadeiro (real)	Previsto: Carcinoma Basocelular	Previsto: Melanoma
Carcinoma Basocelular (0)	496 (VP - corretamente classificado como CBC)	36 (FP - erroneamente classificado como Melanoma)
Melanoma (1)	18 (FN - erroneamente classificado como CBC)	504 (VN - corretamente classificado como Melanoma)

Fonte: elaborada pelo autor (2024)

A seguir, é apresentada a matriz de confusão que representa os dados do conjunto de teste, ou seja, dados que o modelo nunca viu antes. Características essenciais para avaliar a capacidade de generalização do modelo.

Figura 25 - Matriz de confusão do conjunto de teste.



Fonte: gerada pelo autor utilizando o *Jupyter Lab* (2024).

Podemos observar na matriz de confusão que o modelo está apresentando um desempenho satisfatório nos dados de teste, com uma distinção clara entre Carcinoma Basocelular e Melanoma.

Tabela 11 - Detalhamento da matriz de confusão do conjunto de teste.

Rótulo verdadeiro (real)	Previsto: Carcinoma Basocelular	Previsto: Melanoma
Carcinoma Basocelular (0)	614 (VP - corretamente classificado como CBC)	48 (FP - erroneamente classificado como Melanoma)
Melanoma (1)	28 (FN - erroneamente classificado como CBC)	630 (VN - corretamente classificado como Melanoma)

Fonte: elaborada pelo autor (2024)

A alta taxa de acertos em ambas as classes sugere que o modelo consegue identificar corretamente a maioria dos casos, minimizando erros de classificação. Além disso, a presença de poucos falsos positivos e falsos negativos indica que o modelo é capaz de generalizar bem para novos dados, tornando-se uma ferramenta confiável para auxiliar no diagnóstico dessas condições.