

UNIVERSIDADE PAULISTA

**ANA BEATRIZ MAIA RIBEIRO
ASH CELESTINE FERREIRA NANI
DÉBORA GUTIERRES DE ALCÂNTARA
KAWAN DE PAULA RODRIGUES
IAN FELIPE MATOS DE SOUZA
LEONARDO PICOLLI CARDOSO**

**DESENVOLVIMENTO DE UMA APLICAÇÃO MÓVEL PARA A IDENTIFICAÇÃO
DE CÂNCER DE PELE**

SÃO JOSÉ DOS CAMPOS

2025

**ANA BEATRIZ MAIA RIBEIRO
ASH CELESTINE FERREIRA NANI
DÉBORA GUTIERRES DE ALCÂNTARA
KAWAN DE PAULA RODRIGUES
IAN FELIPE MATOS DE SOUZA
LEONARDO PICOLLI CARDOSO**

**DESENVOLVIMENTO DE UMA APLICAÇÃO MÓVEL PARA A IDENTIFICAÇÃO
PRECOCE DE CÂNCER DE PELE**

Trabalho de Conclusão de Curso
apresentado ao Instituto de Ciências
Exatas e Tecnologia da Universidade
Paulista, como parte dos requisitos
necessários para a obtenção do
título de Bacharel em Ciência da
Computação.

Orientador: Prof. Dr. Elcio Hideiti
Shiguemori

**SÃO JOSÉ DOS CAMPOS
2025**

CIP - Catalogação na Publicação

DESENVOLVIMENTO DE UMA APLICAÇÃO MÓVEL PARA A
IDENTIFICAÇÃO PRECOCE DE CÂNCER DE PELE / Leonardo
Cardoso...[et al.]. - 2025.

110 f. : il. color

Trabalho de Conclusão de Curso (Graduação) apresentado ao Instituto
de Ciência Exatas e Tecnologia da Universidade Paulista, São José dos
Campos, 2025.

Área de Concentração: SJC -Dutra.

Orientador: Prof. Dr. Elcio Shiguemori.

Coorientador: Prof. Me. Fernando Souza.


1. Desenvolvimento . 2. Aplicativo. 3. Cancer. 4. Inteligência artificial .
I. Cardoso, Leonardo. II. Shiguemori , Elcio (orientador). III. Souza,
Fernando (coorientador).


ANA BEATRIZ MAIA RIBEIRO
ASH CELESTINE FERREIRA NANI
DÉBORA GUTIERRES DE ALCÂNTARA
KAWAN DE PAULA RODRIGUES
IAN FELIPE MATOS DE SOUZA
LEONARDO PICOLLI CARDOSO

**DESENVOLVIMENTO DE UMA APLICAÇÃO MÓVEL PARA A IDENTIFICAÇÃO
PRECOCE DE CÂNCER DE PELE**

Trabalho de Conclusão de Curso
apresentado ao Instituto de Ciências
Exatas e Tecnologia da Universidade
Paulista, como parte dos requisitos
necessários para a obtenção do
título de Bacharel em Ciência da
Computação.

O trabalho foi considerado Aprovado com a nota nove (9,0).
São José dos Campos, 19 de Novembro 2025.


Prof. Dr. Elcio Hideiti Shiguemori - Orientador
Universidade Paulista - UNIP


Prof. Msc. Stefano B. B. R. P. Mathias - Avaliador
Universidade Paulista - UNIP

RESUMO

Este trabalho tem como objetivo o desenvolvimento de uma aplicação móvel para identificação de lesões cutâneas potencialmente cancerígenas, utilizando técnicas de Inteligência Artificial (IA) e Visão Computacional em imagens capturadas por câmeras de smartphones. A proposta busca oferecer uma ferramenta complementar aos sistemas de exames preventivos, priorizando acessibilidade e alcance de comunidades vulneráveis. A pesquisa foi conduzida com abordagem aplicada, utilizando modelos publicamente disponíveis. O modelo de IA escolhido foi construído com base em uma Rede Neural Convolucional (CNN) da arquitetura EfficientNetB0, empregando *transfer learning* e implementada em Python, com uso da biblioteca TensorFlow. O treinamento foi realizado em ambiente de nuvem por meio da plataforma Google Colab, utilizando um conjunto editado da base de dados pública ISIC, alcançando acurácia média de aproximadamente 80%. A aplicação móvel foi desenvolvida com o *framework* React Native, integrada ao *back-end* em FastAPI, hospedada na plataforma Render e integrada a um banco de dados não relacional para o armazenamento de imagens e relatórios, através do serviço de armazenamento R2 da empresa Cloudflare. O protótipo demonstrou-se funcional, realizando análises em até cinco segundos, com interface intuitiva e responsiva. No entanto, ao ser testado com o conjunto de dados PAD-UFES-20, composto por imagens dermatológicas obtidas por câmeras de dispositivos móveis, a acurácia caiu para cerca de 60%. Conclui-se que a integração entre IA e dispositivos móveis representa um avanço promissor para o rastreamento não invasivo de doenças dermatológicas, podendo contribuir significativamente para a detecção precoce e o encaminhamento de pacientes aos serviços de saúde. Contudo, destaca-se que modelos públicos de IA para a detecção do câncer de pele não disponibilizam todos os elementos necessários para uso direto em aplicações médicas móveis, sendo recomendável, em trabalhos futuros, o desenvolvimento de um modelo próprio ou a formação de parcerias que proporcionem tal modelo.

Palavras-chave: Inteligência Artificial; Redes Neurais Convolucionais; Visão Computacional; Câncer de Pele; Aplicação Móvel.

ABSTRACT

This project aims to develop a mobile application for identifying potentially cancerous skin lesions, using Artificial Intelligence (AI) and Computer Vision techniques on images captured by smartphone cameras. The proposal seeks to offer a complementary tool to preventive screening systems, prioritizing accessibility and reach for vulnerable communities. The research was conducted using an applied approach, using public available models. The chosen AI model was built using a Convolutional Neural Network (CNN) with the EfficientNetB0 architecture, employing transfer learning and implemented in Python, using the TensorFlow library. Training was conducted in a cloud environment through the Google Colab platform, using an edited set from the ISIC public database, achieving an average accuracy of approximately 80%. The mobile application was developed with the React Native framework, integrated with the FastAPI backend, hosted on the Render platform, and integrated with a non-relational database for storing images and reports, through Cloudflare's R2 storage service. The prototype proved functional, performing analyses in up to five seconds, with an intuitive and responsive interface. However, when tested with the PAD-UFES-20 dataset, composed of dermatological images obtained by mobile device cameras, accuracy dropped to approximately 60%. The conclusion is that the integration of AI and mobile devices represents a promising advance for the non-invasive screening of dermatological diseases, potentially contributing significantly to early detection and referral of patients to healthcare services. However, it is noteworthy that public AI models for skin cancer detection do not provide all the necessary elements for direct use in mobile medical applications. It is recommended in future works to develop its own model or to form partnerships that can provide such a model.

Keywords: Artificial Intelligence; Convolutional Neural Networks; Computer Vision; Skin Cancer; Mobile Application.

LISTA DE ILUSTRAÇÕES

Imagem 1 - Risco Estimado de Câncer de Pele não Melanoma por Região.....	17
Imagem 2 - Subcampos da Inteligência Artificial.....	26
Imagem 3 - Relação do Aprendizado Profundo.....	28
Imagem 4 - Neurônio Artificial.....	29
Imagem 5 - Tipos de Arquitetura de Rede.....	31
Imagem 6 - Hierarquia de detecção de padrões em CNNs.....	32
Imagem 7 - Processo de Convolução.....	33
Imagem 8 - Camada de Pooling.....	34
Imagem 9 - Exemplo de CNN.....	35
Imagem 10 - Dispositivo Portátil para Imagens da Retina.....	42
Imagem 11 - Exemplo de Resultados do Algoritmo de Treinamento.....	58
Imagem 12 - Exemplo Benigno e Maligno da Base de Dados Skin Cancer.....	61
Imagem 13 - Amostra Generalizada da Base de Dados Skin Cancer.....	61
Imagem 14 - Exemplo Dataset PAD-UFES-20.....	62
Imagem 15 - Diagrama de Casos de Uso.....	67
Imagem 16 - Diagrama de Arquitetura do Projeto.....	71
Imagem 17 - Diagrama Entidade Relacionamento.....	72
Imagem 18 - Diagrama de Classes.....	73
Imagem 19 - Tela de Login.....	76
Imagem 20 - Tela de Cadastro.....	77
Imagem 21 - Tela de Carregamento.....	78
Imagem 22 - Tela Principal.....	79
Imagem 23 - Tela de Configurações.....	80
Imagem 24 - Tela de Histórico.....	81
Imagem 25 - Tela de Detalhes do Relatório.....	82
Imagem 26 - Download do Relatório.....	83
Imagem 27 - Tela de Instruções para Foto.....	84
Imagem 28 - Tela de Aviso para Procurar Opiniões Profissionais.....	85
Imagem 29 - Tela de Upload de Imagens.....	86
Imagem 30 - Tela de Opções de Captura/envio de Imagem.....	87
Imagem 31 - Tela de Captura de Imagem.....	88
Imagem 32 - Tela Carregamento Análise.....	89
Imagem 33 - Tela de Resultados.....	90
Imagem 34 - Saída Simples do Algoritmo de Teste.....	93
Imagem 35 - Exemplo de Saída do Algoritmo de Predição.....	94
Imagem 36 - Loss e Accuracy do Modelo “Skin Cancer”.....	95
Imagem 37 - Tabela de Resultados Positivos e Negativos por Classe.....	96
Imagem 38 - Comparação entre Falsos Negativos e Verdadeiros Positivos.....	97

LISTA DE TABELAS

Tabela 1 - Mortalidade por Câncer de Pele no Brasil Entre 2020 e 2023.....	16
Tabela 2 - Mortalidade por Câncer de Pele no Brasil Entre 2016 e 2019.....	16
Tabela 3 - Requisitos Funcionais.....	65
Tabela 4 - Requisitos Não Funcionais.....	65
Tabela 5 - Caso de uso 1.....	67
Tabela 6 - Caso de uso 2.....	68
Tabela 7 - Caso de uso 3.....	69

LISTA ABREVIATURAS E SIGLAS

ACK	Ceratose Actínica
ACS	American Cancer Society (ACS)
AI	Inteligência Artificial
API	Interface de Programação de Aplicações
ANN	Redes Neurais Artificiais
BCC	Carcinoma Basocelular
CDN	Rede de Entrega de Conteúdo
CNN	Redes Neurais Convolucionais
CSV	Valores Separados por Vírgula
CSS	Folha de Estilo em Cascatas
DNA	Ácido Desoxirribonucleico
DNS	Sistema de Nomes de Domínio
EPI	Equipamentos de Proteção Individual
ESRGAN	Enhanced Super-Resolution Generative Adversarial Network
FDA	Food and Drug Administration
FPS	Fator de Proteção Solar
GAN	Redes Neurais Generativas Adversárias
GPU	Unidade de Processamento Gráfico
HPV	Papilomavírus Humano
IDE	Ambiente de Desenvolvimento Integrado
INCA	Instituto Nacional do Câncer José Alencar Gomes da Silva
ISIC	International Skin Imaging Collaboration
KNN	Redes de Kohonen
MEL	Melanoma
NEV	Nevos
RD	Triagem da Retinopatia Diabética
RNA	Redes Neurais Artificiais
SCC	Carcinoma Espinocelular
SEK	Queratose Seborreica
SSL	Camada de Soquetes Seguros
SUS	Sistema Único de Saúde
SVM	Máquina de Vetores de Suporte
TPU	Unidades de Processamento de tensor
UI	Interface do Usuário
UV	Raios Ultravioleta
UVA	Ultravioleta A
UVB	Ultravioleta B

UX

Experiência do Usuário

SUMÁRIO

1 INTRODUÇÃO.....	12
1.1 Objetivo Geral.....	13
1.2 Objetivos Específicos.....	13
1.3 Justificativa.....	14
2 EMBASAMENTO TEÓRICO.....	15
2.1 O Câncer de Pele.....	15
2.1.1 Grupos de Risco.....	16
2.1.2 Tipos de Câncer de Pele e Outras Lesões Cutâneas Relacionadas.....	19
2.1.2.1 Não Melanoma.....	19
2.1.2.2 Melanoma.....	19
2.1.2.3 Lesões Cutâneas Relacionadas.....	20
2.1.3 Detecção e Diagnóstico.....	21
2.1.4 A Importância do Diagnóstico Precoces.....	21
2.1.5 Acompanhamento e Exames Preventivos em Grupos de Risco.....	22
2.1.6 Barreiras ao Diagnóstico Precoces.....	23
2.1.7 Sistemas de Controle ao Câncer de Pele.....	24
2.1.8 Ações de Prevenção Pessoais.....	25
2.2 A Inteligência Artificial.....	25
2.2.1 Aprendizado de Máquina.....	27
2.2.2 Redes Neurais Artificiais.....	29
2.2.3 Redes Neurais Convolucionais.....	31
2.2.4 Modelos de Inteligência Artificial, Algoritmos de Treinamento de Modelos de IA, e Aprendizado por Transferência.....	35
2.3 Tecnologias Relevantes na Medicina.....	37
2.3.1 Teledermatologia.....	37
2.3.2 Inteligência Artificial na Medicina.....	37
3 TRABALHOS RELACIONADOS.....	39
3.1 Estudos Acadêmicos Sobre Modelos de IA para a Detecção de Câncer de Pele.....	39
3.1.1 Comparação entre ANN, CNN, KNN e GAN — Dildar et al. (2021).....	39
3.1.2 Comparação entre CNN, SVM e ANN — Vijayalakshmi et al. (2019).....	40
3.1.3 Pré-processamento com ESRCAN e CNNs Pré-Treinadas — Gouda et al. (2022).....	40
3.1.4 Faster-RCNN e Segmentação Fuzzy K — Nawaz et al. (2021).....	41
3.1.5 CNN desenvolvida do zero — Zhang et al. (2021).....	41
3.2 Diagnóstico da RD por IA por Meio de Smartphone — Oliveira et al. (2024).....	41
3.3 FDA aprova 1º dispositivo portátil que ajuda a detectar o tumor (2024).....	43
3.4 Implicações para o Projeto.....	44
3.5 Métricas de Avaliação.....	44
4 METODOLOGIA.....	47
4.1 BACK-END.....	47
4.2 FRONT-END.....	48
4.3 INTELIGÊNCIA ARTIFICIAL.....	48

4.3.1 Algoritmos de Treinamento de Modelo de IA.....	49
4.3.2 Algoritmo de Manuseio de Dados.....	49
4.3.3 Algoritmos de Teste de Previsão em Lote.....	50
4.3.4 Algoritmo de Previsão.....	51
4.4 INTEGRAÇÃO.....	52
4.5 TESTES.....	52
4.5.1 Testes de Replicação.....	52
4.5.2 Testes com Algoritmos de Teste de Previsão em Lote.....	52
4.5.3 Testes da Aplicação.....	53
4.6 FERRAMENTAS.....	54
4.6.1 Linguagens de Programação.....	54
4.6.2 Segurança e Criptografia.....	54
4.6.3 Ambientes e Ferramentas de Desenvolvimento.....	55
4.6.4 Frameworks e Bibliotecas.....	56
4.6.5 Serviços em Nuvem e Infraestrutura.....	56
4.6.6 Inteligência Artificial.....	57
4.6.7 Algoritmo de Treinamento de Modelo de IA.....	57
4.6.8 EfficientNetB0.....	59
4.6.9 - Bases de Dados.....	59
4.6.9.1 - Base de Dados para o Treinamento do Modelo de Inteligência Artificial(IA): Skin Cancer: Malignant VS. Benign.....	60
4.6.9.2 - Base de Dados para o Testes com Algoritmos de Teste de Previsão em Lote: PAD-UFES-20.....	61
5 IMPLEMENTAÇÃO DO PROJETO.....	64
5.1 PROJETO.....	64
5.1.1 Análise de Requisitos.....	64
5.1.1.1 Requisitos Funcionais.....	64
5.1.1.2 Requisitos Não Funcionais.....	65
5.1.2 Diagrama de Caso de Uso.....	66
5.1.3 Diagrama de Arquitetura.....	70
5.1.4 Diagrama Entidade Relacionamento.....	71
5.1.4 Diagrama de Classes.....	72
5.2 BACK END.....	73
5.3 FRONT END.....	74
5.3.1 Funcionamento e Interfaces.....	76
5.4 INTEGRAÇÃO BACK-FRONT.....	90
5.5 INTELIGÊNCIA ARTIFICIAL.....	91
5.5.1 Processo de Pesquisa de Replicação de Resultado de Algoritmos.....	91
5.5.3 Implementação da Inteligência Artificial.....	92
5.5.3.1 Algoritmo de Manuseio de Dados.....	92
5.5.3.2 O Algoritmo de Treinamento do Modelo de IA.....	93
5.5.3.3 O Algoritmo de Teste de Previsão em Lote.....	93

5.5.3.4 O Algoritmo de Previsão.....	94
6 TESTES E RESULTADOS.....	95
3.1 Resultados da Replicação do Algoritmo de Treinamento de Modelo.....	95
3.2 Resultados do Algoritmo de Teste de Previsão em Lote.....	96
3.3 Resultados da Aplicação.....	97
7 CONCLUSÃO E TRABALHOS FUTUROS.....	99
8 REFERÊNCIAS.....	101

1 INTRODUÇÃO

De acordo com o relatório “Cancer Facts & Figures” da American Cancer Society (ACS) publicado em 2025, desde o início dos seus registros nos anos 70, observa-se um aumento constante das incidências de melanoma, que, apesar de representar uma proporção menor dos casos de câncer cutâneo, é considerado o mais agressivo, devido a sua mortalidade significativa quando diagnosticado em estágios avançados.

Contudo, o mesmo relatório denota que, graças a tratamentos modernos, como a evolução das técnicas de tratamentos de estágios avançados da doença, observa-se um declínio constante nos falecimentos causados por câncer de pele (AMERICAN CANCER SOCIETY, 2025). Graças a estes avanços, a taxa do sucesso no tratamento de estágios avançados de câncer de pele aumentou de 15% para 35% nas últimas décadas, contudo, se descoberto no início, a taxa de cura do câncer de pele ainda poder chegar a ser superior a 95% (INSTITUTO NACIONAL DE CÂNCER, 2023).

Portanto nota-se, mesmo nos tempos modernos, a importância do diagnóstico precoce para salvaguardar vidas, precavendo o agravamento dos sintomas do câncer cutâneo e aumentando as chances de cura do paciente. Com este intuito, a Unidade Um da publicação “Detecção Precoce do Câncer” do Instituto Nacional de Câncer José Alencar Gomes da Silva (INCA) de 2021 aborda os fundamentos da detecção precoce e do controle do câncer, especialmente no contexto brasileiro. Dentre os conceitos apresentados, a Unidade Um denota que o rastreamento das populações é uma estratégia válida, mas tal estratégia demanda, entre vários itens, o acesso a um sistema de exames de rotina.

O mesmo documento aponta diversos obstáculos ao rastreamento populacional e sugerido sistema de exames, como a necessidade de um processo não invasivo para garantir a adesão da população, e da disponibilidade de pessoal capacitado e infraestrutura especializada para atender a população local. O mesmo texto destaca como a falta dos itens supracitados, e o baixo nível de conscientização, são os principais fatores da falta de adesão do povo brasileiro a um sistema de pré diagnóstico.

Diante disso, viu-se a oportunidade de utilizar conceitos e ferramentas de Inteligência Artificial para criar um aplicativo móvel, no intuito de trazer melhorias para o cenário geral descrito acima.

A ideia de utilizar Inteligência Artificial (IA) surge por conta dos avanços e inovações que vêm acontecendo nos últimos anos, sendo divulgadas amplamente por muitos países.

Uma das vertentes de ferramentas de IA traz a possibilidade de analisar imagens, identificar padrões e objetos nelas, classificar os objetos encontrados, entre outras funcionalidades que se encaixam com a proposta deste projeto. Por isso, foi escolhida uma ferramenta dessa natureza, para que os usuários possam analisar imagens de lesões cutâneas em seus dispositivos e descobrir as chances de aquilo que aparece na imagem ser considerado uma lesão de câncer de pele.

Unindo este ponto à intenção de tornar essa aplicação mais acessível, os alunos decidiram transformá-la em um aplicativo móvel, já que desta maneira os usuários teriam mais liberdade geográfica para utilizar a ferramenta, sendo possível acessá-la em qualquer lugar onde haja acesso à internet (além de outros pontos positivos de ser uma aplicação móvel, que serão melhor detalhadas ao decorrer deste documento.

1.1 Objetivo Geral

Considerando os desafios listados anteriormente, este projeto propõe o desenvolvimento do protótipo de uma aplicação para celulares utilizando Inteligência Artificial, capaz de detectar sinais de lesões cutâneas cancerígenas utilizando o hardware disponível em celulares populares.

1.2 Objetivos Específicos

Procura-se ainda que a aplicação seja acessível e informativa, e não substituir profissionais, mas auxiliando como ferramenta de triagem inicial.

E que possa servir como ferramenta complementar a um sistema de prevenção público.

1.3 Justificativa

Uma ferramenta acessível e de fácil uso poderia incentivar o povo a participar das iniciativas públicas, burlando a barreira inicial de adesão, se tornando um canal direto de conscientização, facilitando a consistência de exames, acompanhamento de lesões, e priorização de pacientes com maior risco, direcionando-os para atendimento médico adequado.

Dessa forma, é possível otimizar o uso da infraestrutura e do pessoal capacitado, além de ampliar a detecção precoce em grupos de risco, contribuindo para a redução da mortalidade por câncer de pele e para o fortalecimento do controle populacional da doença.

2 EMBASAMENTO TEÓRICO

Neste capítulo, serão apresentados os principais conceitos necessários para fundamentar o desenvolvimento deste trabalho. Serão abordados aspectos gerais sobre o câncer de pele como tipos, índices e fatores de risco, e o processo de diagnóstico e de prevenção, contextualizando o ambiente em que a aplicação seria introduzida. Também serão introduzidos os conceitos fundamentais de Inteligência Artificial (IA), com ênfase em sua aplicação no diagnóstico médico por imagem, justificando sua relevância para o desenvolvimento de soluções tecnológicas voltadas aos problemas de saúde apresentados.

2.1 O Câncer de Pele

O câncer, de acordo com o Instituto Nacional de Câncer (INCA) (2012), é definido como um conjunto de mais de cem doenças que têm, como característica em comum, o crescimento anormal e desordenado das células, que disseminam-se pelos tecidos e pelos órgãos do corpo humano e causando tumores ou neoplasias prejudiciais à saúde. É um processo gradual e lento, que pode ser causado ou agravado por fatores cancerígenos e que começa com a mutação genética em uma célula, quando os genes chamados proto-oncogenes são ativados, iniciando o processo de carcinogênese (a formação do câncer) (INCA, 2012).

Em geral o câncer pode surgir em diversas partes do corpo humano, seja na pele, em órgãos internos e até mesmo no sangue devido ao surgimento de células defeituosas (cancerígenas) (INCA, 2012).

Neste trabalho, atenta-se ao câncer cutâneo, também conhecido como o câncer de pele, que é o mais comum de todos os tipos de câncer (AMERICAN CANCER SOCIETY, 2019).

No contexto brasileiro, o câncer de pele se mantém como o tipo de câncer mais comum, representando 30% de todos os tumores malignos registrados no país (INCA, 2022). O INCA, no relatório “Estimativa: Incidência de Câncer no Brasil”, publicado em 2022, estimou que, a cada ano no Brasil, entre 2023 e 2025, haveriam 220.490 casos novos de câncer de pele não melanoma e 8.980 casos novos de

câncer de pele melanoma, o que corresponde a um risco estimado de 102 por 100 mil habitantes e de 4 por 100 mil habitantes respectivamente. Ainda segundo o INCA, e seu Atlas de Mortalidade Online, entre os anos de 2020 e 2023, foram registrados 20.101 óbitos por câncer de pele, demonstrando uma porcentagem, não ajustada, de 1,26% de falecimentos por câncer de pele em relação aos óbitos totais registrados Brasil, como mostra a Tabela 1.

Tabela 1 - Mortalidade por Câncer de Pele no Brasil Entre 2020 e 2023

ANO	TOTAL DE ÓBITOS	ÓBITOS POR CÂNCER	%
2020	1.556.824	4.576	0,29%
2021	1.832.649	4.814	0,26%
2022	1.544.266	5.123	0,33%
2023	1.465.610	5.588	0,38%

Fonte: Atlas On-line de Mortalidade do INCA, 2025.

Para comparação, pré pandemia, entre os anos de 2016 e 2019, foram registrados 16.684 óbitos por câncer de pele, registrando-se uma porcentagem, não ajustada, de 1,16% de falecimentos por câncer de pele em relação aos óbitos totais registrados no Brasil, como mostra a Tabela 2.

Tabela 2 - Mortalidade por Câncer de Pele no Brasil Entre 2016 e 2019

ANO	TOTAL DE ÓBITOS	ÓBITOS POR CÂNCER	%
2016	1.309.774	3.885	0,30%
2017	1.312.663	4.085	0,21%
2018	1.316.719	4.120	0,31%
2019	1.349.801	4.594	0,34%


Fonte: Atlas On-line de Mortalidade do INCA, 2025.

2.1.1 Grupos de Risco

O artigo Estimativa 2023: incidência de câncer no Brasil publicado pelo INCA em 2022, aborda, ainda, índices distintos de acordo com as regiões do país. O documento aponta uma estimativa de que, entre homens, ocorram 135,86 casos no Sul, 121,40 no Sudeste, 77,45 no Centro-Oeste, 68,97 no Nordeste e 17,69 no Norte, para cada 100 mil habitantes. Com estes dados, a Imagem 1 foi elaborada para obter-se uma melhor visualização da distribuição do risco entre as regiões brasileiras.

Entre as mulheres, os valores são de 164,79 no Sul, 123,33 no Sudeste, 107,52 no Centro-Oeste, 77,84 no Nordeste e 26,90 no Norte — igualmente por 100 mil habitantes.

Imagem 1 - Risco Estimado de Câncer de Pele não Melanoma por Região



Fonte: Adaptado do INCA, 2022

Sobre o câncer de pele melanoma, a incidência na Região Sul é maior quando comparado com as demais regiões (INCA, 2022).

Nota-se, então, uma maior incidência nas regiões Sul, Sudeste e Centro-Oeste.

Isto talvez ocorra pelo principal fator de risco à doença, sendo ele, a radiação

ultravioleta, que induz a lesões no Ácido Desoxirribonucleico (DNA), sendo ele cumulativo (INCA, 2022). Assim sendo, os grupos de risco são: indivíduos de pele mais clara, aqueles que se expõem desprotegidos ao Sol, que se expõem frequentemente ao Sol, seja por ocupação ou lazer, usuários de camas solares, idade avançada, com a estimativa de risco se iniciando para aqueles acima dos 40 anos, pele com presença de pintas, e aqueles com histórico familiar. Há uma predominância de aparecimento dessas lesões nas partes do corpo que costumam permanecer mais expostas, como o rosto, braços e mãos (DILDAR et al., 2021).

Contudo, é importante destacar outros fatores que também podem induzir à patologia, como descrito no artigo “Estimativa 2023: incidência de câncer no Brasil” publicado pelo INCA, em 2022:

(...) merecem destaque ainda as radiações ultravioletas não naturais, como lâmpadas e camas solares, e a exposição aos bifenilos policlorados (...) trabalho em fabricação de vidros, indústria de eletrônicos, produção e manuseio de óleo mineral não tratado, metalurgia, produção e manuseio de alcatrão de carvão, refinamento do petróleo, limpeza de chaminés e brigadas de incêndio. Por fim, o uso de medicamentos imunossupressores, como ciclosporina e azatioprina, antifúngicos, como voriconazol, e diuréticos, como hidroclorotiazida, associados à exposição solar, também aumenta o risco.

No geral, com relação às atividades laborais, é mais comum que pessoas que trabalham em contato com o sol e ao ar livre, em atividades como pesca, agricultura, limpeza urbana, entre outros, tenham ocorrência de câncer de pele, por conta da maior exposição à Radiação Ultravioleta (UV) (BONFIM, 2023).

Por fim, como apontado nas pesquisas de SIMÕES (2023), em casos como os da doença de Bowen, a doença tende a agravar-se e tem maiores chances de aparecer em pessoas que sofrem com imunossupressão, geralmente ligada com o vírus do Papilomavírus Humano (HPV), tornando a vacinação em uma ferramenta de prevenção.

2.1.2 Tipos de Câncer de Pele e Outras Lesões Cutâneas Relacionadas

Os tipos de câncer de pele são classificados de acordo com as células que lhe deram origem, criando duas categorias principais: o melanoma, e o não melanoma, este último dividido entre o câncer que surge nas células basais e aquele que surge nas células escamosas (Vazquez, 2021)

2.1.2.1 Não Melanoma

O não melanoma engloba a maioria dos casos de pele, com os mais comuns sendo o Carcinoma Basocelular e o Carcinoma Espinocelular (AMERICAN CANCER SOCIETY, 2019).

O Carcinoma Basocelular ou Carcinoma de Células Basais se origina na camada basal da epiderme e é o tipo mais comum de câncer de pele e é maligno, contudo, é lento e não tende a metástase (disseminação do câncer para outros órgãos) (Vazquez, 2021).

Já o Carcinoma de Células Escamosas, Carcinoma Espinocelular ou Epidermóide se desenvolve em células queratinócitas na epiderme da pele e é o segundo câncer de pele mais comum, também é maligno, mas envolve metástase. (Vazquez, 2021). Quando o câncer já estabeleceu-se mas ainda não desenvolveu a metástase, a lesão é chamada de carcinoma Espinocelular in Situ ou Doença de Bowen (Vazquez, 2021).

2.1.2.2 Melanoma

Já o melanoma, é o câncer que se forma nos melanócitos, e que cresce e se espalha mais rapidamente e possui alta possibilidade de provocar metástase (INCA, 2022). Apesar de ser menos comum, por exemplo, representando apenas 4% das neoplasias malignas do órgão no Brasil (INCA, 2022), o melanoma é a causa de cerca de 90% das mortes por câncer de pele (GUARNIER et al. 2024).

2.1.2.3 Lesões Cutâneas Relacionadas

Neste contexto, existem também lesões cutâneas não cancerígenas que merecem atenção, sejam elas pré-cancerosas ou benignas, tanto para fins de prevenção quanto para diferenciar corretamente lesões com potencial maligno daquelas sem risco de câncer, como a Queratose Actínica, a Queratose Seborreica, e o Nevo ou Pinta.

A lesão pré-maligna do Carcinoma Espinocelular é conhecida como Queratoses Actínicas, e pode evoluir para a Doença de Bowen (Vazquez, 2021). No Brasil, um estudo feito em 2006 apontou que a Queratose Actínica estava entre os diagnósticos mais comuns nas consultas mensuradas, onde de 57.343 delas, uma média de 5,1% das vezes resultava em um diagnóstico de Queratoses Actínicas (SCHMITT; MIOT, 2012)

A Queratose Seborreica é considerada um tumor benigno, e se forma majoritariamente pela proliferação de células basalóides que aparece com mais frequência a partir dos 50 anos de idade (YORADJIAN, 2011). Geralmente o diagnóstico da queratose seborreica não apresenta complicações, e em muitos casos o tratamento se torna até mesmo opcional (por conta de ser benigno) (YORADJIAN, 2011). Porém, em certas vezes esses tumores podem simular a aparência de melanomas, e nesses casos é necessária uma investigação mais aprofundada e exames histológicos para eliminar falsas suspeitas (YORADJIAN, 2011).

O Nevo ou Nevo Melanocítico, popularmente chamado de pinta ou sinal, é uma lesão de pele formada por um agregado de melanócitos, que são células responsáveis pela produção de melanina (pigmento da pele) e pode ser congênito (presente ao nascer) ou adquirido (aparecendo ao longo da vida) (DAMSKY, BOSENBERG, 2017). A maioria dos nevos é benigna, mas alguns, especialmente nevos displásicos (pintas que têm um aspecto atípico, com bordas irregulares, mais de uma cor e tamanho superior a 5 mm), podem ter risco aumentado de evoluir para melanoma (DAMSKY, BOSENBERG, 2017). Aproximadamente 33% dos melanomas são derivados diretamente de nevos melanocíticos (DAMSKY, BOSENBERG, 2017).

2.1.3 Detecção e Diagnóstico

Visualmente, no geral, de acordo com o Ministério da Saúde Brasileiro, as lesões causadas pelo câncer de pele podem ser identificadas pelas seguintes características: pequenas manchas ou feridas na pele de um indivíduo, que podem variar de cor, tamanho e forma; causando incômodos como coceira, dor e sangramento. Essas lesões não se cicatrizam, sendo, muitas vezes, indistinguível de um machucado comum sem um diagnóstico por imagem ou procedimento clínico de detecção como dermatoscopia ou biópsia (MINISTÉRIO DA SAÚDE).

Para o público, este conhecimento está retido em uma técnica conhecida como ABCD, recomendada pelo Ministério da Saúde Brasileiro (2024) para a análise de possíveis melanomas e nevos suspeitos. A sigla refere-se aos principais aspectos a serem observados: Assimetria, Bordas irregulares, Cores variadas em uma mesma lesão e Diâmetro aumentado (MINISTÉRIO DA SAÚDE).

Clinicamente, o diagnóstico de câncer de pele é feito, tradicionalmente, por exames na pele do paciente, utilizando-se de biópsia, que é um processo invasivo para a coleta do tecido afetado, e análise histopatológica das amostras colhidas, que é a análise visual do tecido sob o microscópio (FRANGE, 2009). Atualmente, há também a presença de técnicas de dermatoscopia e microscopia onde, na dermatoscopia, é utilizado um instrumento chamado dermatoscópio, que ajuda na observação das estruturas da pele e exame de lesões pigmentadas, sendo então um método não invasivo e um complemento para as formas de diagnóstico já utilizadas (FRANGE, 2009)(25); enquanto que a microscopia focalizada é feita pela avaliação das lesões por meio de imagens de microscópio, assim possibilitando um estudo mais aprofundado das condições suspeitas (MANNHEIMER, 2002).

Em todos os casos supracitados, utiliza-se análises visuais da área afetada para o diagnóstico.

2.1.4 A Importância do Diagnóstico Precoce

O diagnóstico precoce é essencial para identificar o câncer de pele ainda em seus estágios iniciais, aumentando significativamente as chances de cura (INCA,

2023). Isso ocorre pois uma das maiores influências sobre o sucesso do tratamento é o estado de avanço em que a doença encontra-se quando o tratamento é iniciado, com a taxa de sucesso de tratamentos do câncer de pele podendo variar entre 35% a até mais de 99%, dependendo do estágio da doença (ACS, 2025).

O diagnóstico precoce também diminui o risco de deformidades, comprometimento funcional, e a necessidade de tratamentos mais agressivos necessários em estados avançados (SIMÕES, 2023).

Os tratamentos mais utilizados incluem cirurgias de remoção das lesões, radioterapia e quimioterapia, escolhidos conforme o tipo e o estágio de evolução do câncer de pele (SIMÕES, 2023).

2.1.5 Acompanhamento e Exames Preventivos em Grupos de Risco

O acompanhamento regular e a realização de exames de rotina são fundamentais tanto para pacientes que já foram diagnosticados com câncer de pele quanto para indivíduos pertencentes a grupos de risco (INCA 2023).

Entre esses grupos estão pessoas de pele clara, com histórico familiar da doença, que apresentam grande exposição solar sem proteção adequada ou que possuem múltiplas pintas e lesões cutâneas (INCA 2023).

Para pacientes que já passaram pelo tratamento, o acompanhamento médico contínuo é uma etapa essencial na prevenção de recidivas e no monitoramento de novas lesões (ZINK, 2024). Estudos indicam que indivíduos com histórico de câncer de pele não melanoma apresentam cerca de 35% de chance de recorrência em até três anos após a última ocorrência, percentual que pode chegar a 50% em cinco anos (ZINK, 2024). Dessa forma, consultas dermatológicas periódicas e o autoexame da pele são estratégias importantes para detectar precocemente alterações suspeitas (INCA 2023).

A adoção de exames preventivos também se mostra relevante para pessoas sem histórico da doença, especialmente aquelas com fatores de risco conhecidos, pois permite o diagnóstico em estágios iniciais e reduz a necessidade de tratamentos invasivos (INCA 2023).

2.1.6 Barreiras ao Diagnóstico Precoce

De acordo com o Instituto Nacional de Câncer José Alencar Gomes da Silva (INCA, 2021), as barreiras ao diagnóstico precoce no Brasil envolvem múltiplos fatores interligados.

Destaca-se a desinformação da população, que resulta na falta de conhecimento sobre os sinais e sintomas iniciais da doença e sobre os processos de rastreamento e diagnóstico disponíveis no sistema público de saúde, além do estigma social associado à doença, que provoca medo, negação e resistência à realização de exames preventivos, sobretudo em comunidades com menor nível educacional ou com crenças culturais enraizadas (INCA, 2021)

Soma-se a defasagem na capacitação de profissionais de saúde, que muitas vezes não reconhecem precocemente as manifestações clínicas do câncer, comprometendo a identificação e o encaminhamento adequado dos casos suspeitos (INCA, 2021).

Também há limitações estruturais e tecnológicas, especialmente em regiões mais afastadas dos grandes centros urbanos, o que acarreta longos períodos de espera para consultas, exames e resultados (INCA, 2021).

O difícil acesso aos serviços de saúde, seja por fatores geográficos, econômicos ou pela ineficiência da rede de atenção (INCA, 2021).

E por fim, questões socioeconômicas, como baixa renda, baixa escolaridade e desigualdade regional, também influenciam o comportamento preventivo e a adesão aos programas de rastreamento (INCA, 2021).

Assim sendo, o Instituto Nacional de Câncer José Alencar Gomes da Silva (INCA, 2021) reforça a importância da implementação de políticas públicas integradas e contínuas voltadas à conscientização da população, à capacitação dos profissionais de saúde e à ampliação do acesso aos serviços especializados (INCA, 2021).

Ademais, no geral, não exclusivamente para o Brasil, o INCA também aponta que qualquer programa de acompanhamento ou de exames preventivos deve evitar ser invasivo, já que sistemas de rotina tendem a falhar caso sejam inconvenientes

(INCA, 2021).

2.1.7 Sistemas de Controle ao Câncer de Pele

No Brasil, a prevenção, diagnóstico, tratamento e acompanhamento do câncer podem ser realizados através do Sistema de Saúde Único (SUS) (INCA, 2021), e, desde 1999, a Campanha Nacional de Prevenção ao Câncer de Pele (CNPCCP), organizada pela Sociedade Brasileira de Dermatologia (SBD), possui diversos dermatologistas providenciando orientação sobre o câncer de pele e exames gratuitos, em cidades por todo o país (LAGES et al., 2012).

Ambos sistemas se encaixam no que, de acordo com LIMA JÚNIOR (2024) são as etapas de um sistema de controle do câncer populacional: informação da população, identificação precoce com exames e triagem, e tratamento de casos avançados para evitar complicações e mortes.

Para tal, o INCA (2021) ressalta a necessidade de sistemas de controle de câncer, estes que funcionam através de um tripé de classes de ações que podem ser aplicadas a população, sendo estes: população informada, profissional capacitado e acesso aos serviços de saúde.

Ressalta-se a importância das campanhas oficiais promovidas por governos e mídias grandes para a disseminação do conhecimento acerca do tema para a população (LIMA JUNIOR, 2024), uma vez que são a base, o início da prevenção ou tratamento em ambos os sistemas.

O INCA (2021) também reforça a necessidade de programas que focam na prevenção do câncer, onde exames de rotinas e acompanhamento profissional tornar-se-iam parte da vida da população brasileira. O INCA (2021) ressalta que este seria o próximo passo para a saúde pública brasileira, e também reforça a falta de conveniência e acesso à infraestrutura como as principais barreiras para a adoção popular.

Na omissão de estrutura, profissionais ou adesão do público a um sistema, existem várias práticas de prevenção primária que não requerem equipamento ou conhecimento avançado na área da saúde, e podem ser executadas pelas próprias pessoas em sua vida cotidiana. (LIMA JUNIOR, 2024).

2.1.8 Ações de Prevenção Pessoais

Um exemplo é o autoexame, uma prática preventiva simples e acessível, que consiste em observar regularmente a própria pele com auxílio de um espelho ou, quando possível, com a ajuda de outra pessoa para examinar áreas de difícil acesso (MINISTÉRIO DA SAÚDE). Para a educação popular, normalmente o auto exame é recomendado junto com a técnica ABCD descrita na seção 2.1.3. Essa ação permite identificar precocemente o surgimento de pintas ou lesões desconhecidas, possibilitando uma busca médica antecipada e aumentando as chances de tratamento eficaz (MINISTÉRIO DA SAÚDE).

Além da observação pessoal, outras medidas preventivas que indivíduos podem aplicar em sua vida são o uso correto de filtro solar com proteção UVA (ultravioleta A) e UVB (ultravioleta B) e Fator de Proteção Solar (FPS) mínimo de 30, aplicado 20 minutos antes da exposição solar direta e reaplicado a cada duas horas (SIMÕES et al., 2023). O uso de bonés, chapéus, óculos escuros e roupas com proteção térmica também contribui para reduzir a exposição à radiação ultravioleta (SIMÕES et al., 2023). Da mesma forma, o bronzamento artificial deve ser evitado, uma vez que aumenta o risco de lesões cutâneas (SIMÕES et al., 2023).

No âmbito ocupacional, é essencial que trabalhadores expostos ao sol recebam Equipamentos de Proteção Individual (EPI) adequados, juntamente com instruções e incentivo ao uso correto (BONFIM, 2023).

2.2 A Inteligência Artificial

A Inteligência Artificial (IA) é uma área relativamente recente da computação, desenvolvida a partir de contribuições de diversas disciplinas (RUSSEL, 2004). Seu surgimento como conceito estruturado remonta a 1950, quando Alan Turing publicou o artigo *“Computing Machinery and Intelligence”*, no qual propôs o famoso Teste de Turing — um experimento idealizado para avaliar se uma máquina seria capaz de se passar por um humano em uma conversa (RUSSEL, 2004; VALDATI, 2020).

O termo “Inteligência Artificial” foi oficialmente criado em 1956 por John

McCarthy, durante a Conferência de Dartmouth, evento que marcou a fundação da IA como campo científico (VALDATI, 2020). Nessa época, definiu-se IA como a construção de máquinas inteligentes capazes de simular comportamentos humanos, incluindo aprendizagem e resolução de problemas (VALDATI, 2020). A partir daí, o conceito ramificou-se em duas principais abordagens: uma voltada à imitação do pensamento e comportamento humanos e outra focada na racionalidade lógica, buscando soluções sem necessariamente copiar processos mentais humanos (RUSSELL, 2004).

A Inteligência Artificial é ainda dividida em diversos subcampos, cada qual com objetivos e métodos próprios (VALDATI, 2020).

Imagem 2 - Subcampos da Inteligência Artificial



Fonte: Valdati (2020)

A Imagem 2 apresenta alguns dos principais subcampos da Inteligência Artificial (VALDATI, 2020).

São eles: 1) a resolução de problemas, que busca soluções automáticas para desafios complexos por meio de planejamento, raciocínio e heurísticas — como ocorre no Google Maps, que utiliza algoritmos de busca e otimização para calcular rotas mais eficientes (RUSSELL, 2013); 2) o processamento de linguagem natural, que permite a compreensão e geração de textos e fala, exemplificado por assistentes virtuais como Alexa e Google Assistant (JURAFSKY, 2023); 3) a robótica, que aplica IA para controlar máquinas físicas, como os robôs industriais utilizados em linhas de montagem automotivas (SICILIANO, 2016); 4) os sistemas especialistas, que simulam a tomada de decisão humana em áreas específicas, como o MYCIN, desenvolvido para auxiliar no diagnóstico de infecções bacterianas

(SHORTLIFFE, 1976); 5) o processamento de imagem, também conhecido como visão computacional, responsável por interpretar imagens e vídeos, como nos sistemas de reconhecimento facial (SZELISKI, 2022); 6) o aprendizado de máquina, que permite que sistemas aprendam padrões a partir de dados, sendo amplamente utilizado por plataformas de recomendação como Netflix e Spotify (MURPHY, 2012); 7) a computação evolutiva, que possui algoritmos genéticos inspirados em processos naturais de seleção e adaptação, aplicados, por exemplo, na otimização de rotas logísticas (GOLDBERG, 1989); e, por fim, 8) o aprendizado profundo, que utiliza redes neurais profundas capazes de extrair características complexas, como ocorre em sistemas de detecção automática de tumores em exames médicos (GOODFELLOW, 2016);

Cada subcampo contribui de maneira distinta para o desenvolvimento da IA e pode ser explorado conforme a aplicação desejada, sendo que neste trabalho o foco será principalmente no aprendizado de máquina, aprendizado profundo e visão computacional, essenciais para o diagnóstico automatizado de lesões dermatológicas (VALDATI, 2020).

De forma geral, a IA pode ser entendida como a capacidade de dispositivos e sistemas computacionais de realizar tarefas que normalmente exigiriam inteligência humana, como tomada de decisão, raciocínio lógico, aprendizado com base em dados e adaptação por meio de repetição e testes (BARBOSA, 2023). Essa definição ampla permite que a IA seja aplicada em múltiplos campos, incluindo saúde, educação, indústria e segurança, consolidando-se como uma das áreas mais promissoras e transformadoras da tecnologia contemporânea.

2.2.1 Aprendizado de Máquina

O Aprendizado de Máquina é um dos subcampo supracitados da Inteligência Artificial, este focado em desenvolver algoritmos capazes de realizar tarefas específicas a partir de dados, sem precisar de programação explícita para cada situação (FERREIRA, 2024). Seu objetivo é identificar padrões nos dados e utilizá-los para fazer previsões ou classificações em novos conjuntos de informações (FERREIRA, 2024). Para isso, os dados são geralmente divididos em conjunto de

treino, para o modelo aprender e ajustar parâmetros; conjunto de validação, usado para otimização de hiperparâmetros e controle de “*overfitting*”; e conjunto de teste, formado por dados inéditos para avaliar a capacidade de generalização do modelo (FERREIRA, 2024).

A base do aprendizado de máquina é a inferência indutiva, que permite generalizar conceitos a partir de exemplos observados (MONARD, 2003). Hipóteses são construídas a partir dos dados, mas sua precisão depende da qualidade e diversidade desses exemplos (MONARD, 2003). Uma das abordagens mais comuns é o aprendizado supervisionado, que utiliza dados rotulados para ensinar o modelo a relacionar características de entrada com resultados esperados, formando modelos preditivos capazes de classificar ou prever eventos futuros (MONARD, 2003).

Imagem 3 - Relação do Aprendizado Profundo



Fonte: Adaptado de Ferreira (2024)

O aprendizado profundo, como demonstra a Imagem 3, é também uma subárea do aprendizado de máquina. De acordo com Kelleher (2019) ela difere dos métodos tradicionais, os quais muitas vezes exigem engenharia manual de


características relevantes, pois as as redes neurais profundas, utilizadas no aprendizado profundo, podem extrair padrões automaticamente a partir de grandes volumes de dados, sendo particularmente eficientes em tarefas de classificação e reconhecimento de imagens, como imagens médicas, identificando padrões sutis que poderiam passar despercebidos por métodos tradicionais ou pelo olhar humano (KELLEHER, 2019).

2.2.2 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA), conforme descrito por HAYKIN (2001), são sistemas computacionais, compostos por unidades chamadas neurônios artificiais, onde o manejo, processamento e interpretação de informações se dão através da conexão e interação entre um ou mais neurônios artificiais, em uma simplificação de o que acontece organicamente dentro de um cérebro humano – a inspiração deste modelo.

Cada neurônio artificial possui um estado de ativação que é propagado para outros neurônios por meio dos pesos sinápticos (HAYKIN, 2001). A Imagem 4 representa um neurônio artificial e suas principais partes de funcionamento.

Imagem 4 - Neurônio Artificial



Fonte: Haykin (2001)

Para determinar sua saída, cada entrada x passa por uma sinapse associada a um neurônio k , e é multiplicada pelo peso sináptico w , que define a influência dessa entrada na saída y (HAYKIN, 2001; OSÓRIO, 2000). Em seguida, as entradas

ponderadas são somadas, e ao resultado é adicionado o valor do viés b , ajustando a ativação do neurônio (HAYKIN, 2001; OSÓRIO, 2000). Por fim, o valor resultante é processado através de uma função de ativação, que determina a saída final do neurônio (HAYKIN, 2001; OSÓRIO, 2000).

Durante o treinamento, os pesos e os vieses são ajustados de forma que a rede aprenda padrões e produza respostas precisas frente aos dados apresentados (OSÓRIO, 2000).

Matematicamente, este modelo pode ser representado da seguinte forma:

$U_k = \sum_{j=1}^m W_{kj} X_j$, e: $y_k = \varphi(U_k + b_k)$ onde U_k realiza a soma ponderada das entradas, b_k representa o viés, φ é a função de ativação que gera a saída final y_k do neurônio (HAYKIN, 2001).

Durante a construção de uma rede neural artificial, um deve atentar-se a escolher uma função de ativação adequada para o problema em que ela será aplicado, pois existem diversas funções, que levam a interpretações e saídas diferentes, como a função linear, onde a saída cresce proporcionalmente à entrada, sem limites, e um deve usá-la quando um deseja que a saída seja diretamente proporcional à entrada, ou a função binária, que só possui dois valores de saída possíveis, e deve ser usadas em sistemas de classificação binários (RAUBER, 2005).

Para problemas de classificação multiclasse, a função softmax é geralmente recomendada, pois converte os valores de saída do modelo em probabilidades que somam 1, permitindo identificar a classe correta para cada amostra (SATHYA, 2018).


Sua fórmula é dada por: $softmax(z_i) = \frac{e^{z_i}}{\sum_j e^{z_j}}$

Apesar de ser amplamente utilizada, alguns estudos recentes discutem alternativas e questionam sua eficácia em certas situações (PEREYRA, 2020).

Um também deve atentar-se à estrutura de como os neurônios da rede serão conectados, já que as redes neurais artificiais podem variar em arquitetura, desde redes de camada única até redes profundas com múltiplas camadas uni-direcionais ou recorrentes, cada uma adequada a tipos específicos de problemas (HAYKIN,

2001) a Imagem 4 ilustra algumas destas abordagens (HAYKIN, 2001; OSÓRIO, 2000).

Imagem 5 - Tipos de Arquitetura de Rede




Fonte: Osório (2000)

São estas as redes ilustradas na Imagem 5: redes com três camadas, que possuem uma camada de entrada, uma camada oculta e uma camada de saída, permitindo modelar relações não lineares básicas; redes com atalhos, que permitem que sinais “pulem” uma ou mais camadas, evitando o desvanecimento do gradiente em estruturas de redes muito profundas; redes multicamadas, que incluem uma ou mais camadas ocultas adicionais, aumentando sua capacidade de capturar padrões complexos; redes recorrentes, utilizadas quando os dados têm dependência temporal ou sequencial, pois reciclam informações do estado anterior para processar sequências; e redes de ordem superior, que incorporam interações multiplicativas entre entradas ou neurônios, possibilitando modelar relações ainda mais complexas e sutis nos dados.

2.2.3 Redes Neurais Convolucionais

As Redes Neurais Convolucionais (CNNs) são um tipo especializado de RNA projetado para processar dados com estrutura espacial, como imagens ou vídeos (SILVA, 2018). De acordo com CHOLLET (2017), o aprendizado de padrões nas CNNs é hierárquico, onde a cada camada convolucional aumenta a complexibilidade dos padrões que se organizam até se tornarem uma forma consistente que pode ser detectada em outras imagens futuramente, que é o que permite o aprendizado de padrões complexos. A Imagem 6 representa o processo supracitado.

Imagem 6 - Hierarquia de detecção de padrões em CNNs




Fonte: Chollet (2017)

Ademais, as CNNs, de acordo com O'SHEA (2015), se diferenciam por utilizar elementos como camadas convolucionais, camadas de *"pooling"* e camadas totalmente conectadas.

A entrada consiste de uma matriz de 3 dimensões representando parte da imagem que foi inserida, contendo dois fatores espaciais (x , y) e um fator de profundidade — por exemplo: se é uma imagem colorida o fator de profundidade será 3, representando os 3 canais de cor RGB (CHOLLET, 2017).

As camadas convolucionais utilizam filtros, também chamados de “*kernels*” são matrizes de peso, que deslizam pela matriz de entrada, com o parâmetro “*strides*” determinando como será esse deslocamento, gerando mapas de características que representam padrões detectados (PEREIRA, 2025). A convolução do nome CNN vem da multiplicação entre as matrizes de entrada com os “*kernels*” (SILVA, 2018). A Imagem 7 demonstra como é feita a multiplicação de matrizes entre a entrada e o filtro numa camada convolucional.


Imagem 7 - Processo de Convolução



Fonte: Rawat, Wang (2017)

As camadas de “*pooling*” diminuem a dimensionalidade desses mapas de características mantendo apenas as informações relevantes (RAWAT, 2017). Isto pode ocorrer de duas maneiras: com “*average pooling*”, onde calcula-se a média dos valores do setor analisado, ou com “*max pooling*”, onde seleciona-se apenas os maiores valores de cada setor analisado (RAWAT, 2017). A Imagem 8 representa visualmente ambas.

Imagem 8 - Camada de Pooling




Fonte: Rawat, Wang (2017)

As camadas totalmente conectadas têm uma disposição parecida com o que vemos em outros tipos de rede neural, onde todos os neurônios de uma camada estão conectados com todos os neurônios da camada seguinte; assim a informação que essa camada recebe como entrada é o resultado da intercalação das camadas anteriores (O'SHEA, 2015; SILVA, 2018).

A camada de saída tem o propósito de classificar as imagens com base nas características e informações obtidas durante todo o processo realizado anteriormente, onde então é aplicada a função de ativação sobre os dados, possibilitando a classificação da imagem; o número de neurônios em sua composição equivale ao número de classes possíveis para as imagens de entrada iniciais (PEREIRA, 2025).

A Imagem 9 ilustra a estrutura completa de uma CNN e das camadas descritas anteriormente. Nota-se como: A imagem de é conectada a cada camada convolucional, que utilizando "*kernels*", geram os mapas de características C1; em seguida, as camadas de "*pooling*" diminuem as dimensões dos mapas mantendo apenas as informações mais relevantes, resultando no mapa C2; essas duas ações

se repetem intercalando entre camadas convolucionais e de *pooling*, resultando na extração hierárquica de características, e em S_x ; que são encaminhadas para as camadas totalmente conectadas N_1 ; e então para a camada de saída N_2 , onde será passado pela função de ativação, resultando na saída (CORPORAAL, 2011)



2.2.4 Modelos de Inteligência Artificial, Algoritmos de Treinamento de Modelos de IA, e Aprendizado por Transferência

Modelos de Inteligência Artificial (IA) e algoritmos de treinamento são termos que por vezes são usados como sinônimos, contudo, oficialmente representam conceitos distintos (IBM, 2024b). Modelos de IA são programas de aprendizado de máquina que foram treinados em uma coleção de dados tornando-os capazes de reconhecer certos padrões e realizar decisões sem intervenção humana (IBM, 2024a). Já os algoritmos de treinamento são conjuntos de instruções que realizam este treinamento (IBM, 2024b). Em outras palavras, o modelo é a aplicação prática, enquanto o algoritmo configura o modelo, auxiliando ou até realizando todo o processo de treinamento (IBM, 2024b).

Este treinamento do modelo consiste em: 1) separação dos dados utilizados para o aprendizado em três conjuntos: i. treino, que serão usados para treinar o modelo; ii. validação, usado para avaliar o desempenho do modelo durante o treinamento, ajustes internos serão realizados no modelo de acordo com estes

resultados para dar seguimento aos próximos ciclos de treinamento; e iii. teste, dados complementamente inéditos, não utilizados durante o treinamento, para realizar um teste final e imparcial do aprendizado do modelo; 2) preparação dos dados, ou seja, a organização de informações, e ou a realização de pré processamentos como recortes, mudanças de cor, tratamentos, seja para o tratamento dos dados em busca de melhores análises, ou para a aumento da quantidade de dados disponível para o modelo; 3) o modelo é então treinado de forma iterativa, cada iteração denominada época, onde o modelo aprende com os dados de treinamento, as previsões do modelo treinado são comparados com os dados de validação, os resultados são monitorados por meio de métricas como a função de perda e acurácia que indicam numericamente a capacidade do modelo, e então procura-se ajustar os parâmetros internos do modelo para reduzir o erro entre as previsões e os resultados esperados na próxima iteração de acordo com estas métricas, estas métricas que também podem proporcionar a visualização da evolução ou regressão do modelo a cada época para o humano responsável pelo treinamento, que pode então optar por utilizar o modelo treinado até apenas a época com os melhores resultados, e ignorar épocas subsequentes onde houve um decaimento da qualidade do modelo (IBM, 2024b).

Assim sendo, um único algoritmo de treinamento pode treinar diversos modelos, mas cada modelo pode finalizar o treinamento com resultados diferentes, dependendo dos dados utilizados como entrada do algoritmo de treinamento (IBM, 2024b).

Pode-se ainda ajustar um modelo já treinado por meio da técnica conhecida como aprendizado por transferência (transfer learning), onde utiliza-se um modelo previamente treinado em uma base de dados ampla e diversificada, o que lhe proporciona um aprendizado genérico sobre diferentes padrões (IBM, 2024b). Nesta abordagem, esse modelo é refinado com dados específicos de um novo conjunto, permitindo que ele aprenda características particulares relacionadas a uma tarefa ou domínio específico, e, como o modelo já possui conhecimento prévio adquirido do banco de dados inicial, o novo treinamento pode ser realizado com um volume menor de dados, menos épocas e tempo reduzido de processamento, possibilitando uma especialização eficiente para um problema específico (IBM, 2024b).

2.3 Tecnologias Relevantes na Medicina

O avanço das tecnologias digitais traz consigo uma série de vantagens na área da saúde, permitindo novas formas de diagnóstico, acompanhamento e tratamento de pacientes, além de ampliar o alcance e a eficiência dos serviços médicos (DO NASCIMENTO NETO et al, 2020).

Entre essas inovações, destacam-se a telemedicina, que viabiliza o atendimento remoto e a inteligência artificial médica, que auxilia na análise de grandes volumes de dados e na identificação de padrões em exames e imagens (HORSHAM et al., 2020).

2.3.1 Tele dermatologia

Anteriormente à pandemia do coronavírus em 2020, a telemedicina já era aplicada em situações pontuais, contudo, as idiossincrasias forçadas sobre a sociedade durante a pandemia foram precisas para que a telemedicina fosse rapidamente adotada e testada em situações reais nas mais diversas áreas, e pós pandemia, os avanços se consolidaram (HORSHAM, et al. 2020).

Durante a mesma pandemia em 2020, Horsham C, et al. (2020) realizou um estudo sobre a tele dermatologia. Neste estudo, pacientes mandaram fotos para os dermatologistas das clínicas e estabelecimentos de saúde que frequentavam, e isso ajudou na triagem, diminuindo os encaminhamentos presenciais em até 88%, o que foi de grande utilidade no cenário em que encontravam-se na época. O estudo de Horsham et al. (2020) conclui que a virtualização do atendimento ajudou diversos pacientes na identificação precoces de condições alarmantes.

2.3.2 Inteligência Artificial na Medicina

No contexto da saúde, pertinente para este projeto, a inteligência artificial tem aplicações significativas, como na análise de imagens médicas (radiografias, tomografias e fotos dermatológicas). Sistemas baseados em Inteligência

Artificial(IA) podem analisar grandes volumes de dados clínicos e imagens médicas de forma rápida, precisa e consistente, e são capazes de identificar padrões sutis que muitas vezes passam despercebidos pelo olhar humano, permitindo diagnósticos mais rápidos e precisos, aumentando a detecção precoce patógenos, otimizando o tempo de resposta e aumentando a efetividade dos tratamentos reduzindo a incidência de erros humanos (COMISSÃO EUROPEIA; DO NASCIMENTO NETO et al, 2020; JABOUR, 2022).

Assim sendo, estes sistemas são, em suma, ferramentas de apoio aos profissionais de saúde capazes de exceder limites humanos e de otimizar o atendimento clínico e a tomada de decisões, sem substituí-los (COMISSÃO EUROPEIA; GOOGLE CLOUD; JABOUR, 2022).

3 TRABALHOS RELACIONADOS

A revisão de trabalhos relacionados tem como objetivo apresentar pesquisas e soluções já existentes, destacando as principais práticas, triunfos e lacunas que servem de base para o desenvolvimento deste projeto. Com isso, busca-se compreender as abordagens mais eficazes, suas limitações e potencial de adaptação para novos contextos.

Este capítulo aborda três eixos principais: (i) estudos acadêmicos sobre modelos de Inteligência Artificial (IA) para a detecção de câncer de pele, (ii) aplicações acadêmicas com objetivos e ou técnicas semelhantes, e (iii) aplicações comerciais com objetivos e ou técnicas semelhantes.

3.1 Estudos Acadêmicos Sobre Modelos de IA para a Detecção de Câncer de Pele

Existem diversos trabalhos acadêmicos que abordam a eficiência do uso de técnicas de inteligência artificial para a detecção de câncer de pele a partir de imagens de lesões cutâneas. A seguir, este projeto lista algumas destas pesquisas e as principais técnicas utilizadas.

3.1.1 Comparação entre ANN, CNN, KNN e GAN — Dildar et al. (2021)

No artigo científico de Dildar et al. (2021), foram comparadas redes neurais comumente utilizadas para a análise de dados, no contexto da detecção de câncer de pele, sendo estas: Redes Neurais Artificiais (ANN), Redes Neurais Convolucionais (CNN), Redes de Kohonen (KNN) e Redes Neurais Generativas Adversárias (GANs).

ANN é uma das formas mais usadas de rede neural, com uma camada de entrada, uma ou mais camadas ocultas, e uma camada de saída (DILDAR, 2021). KNN destaca-se por ser capaz de aprendizado não supervisionado, e por ser capaz de reduzir entradas de múltiplas dimensões para um mapa bidimensional enquanto preservam a topologia, permitindo que análises de objetos complexos e não lineares

possam ser realizadas em duas dimensões (DILDAR, 2021; KOHONEN). GANs operam em uma estrutura competitiva entre agentes, onde um gerador cria dados falsos, enquanto o discriminador tenta distinguir o que é real ou falso (DILDAR, 2021; GOODFELLOW et al., 2014).

A conclusão da pesquisa foi que *“CNNs fornecem melhores resultados do que outros tipos de redes neurais ao classificar dados de imagem porque está mais intimamente relacionada à visão computacional do que outras”* (DILDAR, 2021).

3.1.2 Comparação entre CNN, SVM e ANN — Vijayalakshmi et al. (2019)

No trabalho de Vijayalakshmi, et al. (2019), são comparadas três abordagens — ANN, SVM e CNN — para classificação de lesões cutâneas à procura de sinais de melanoma. Uma Máquina de Vetores de Suporte (SVM) é um modelo de aprendizado de máquina que separa dados em classes por meio de um hiperplano, e que classifica novos dados com base em qual lado do hiperplano eles caem (VIJAYALAKSHMI, et al. 2019). O artigo enfatiza a necessidade de pré-processamento ao destacar como os principais obstáculos para uma classificação precisa: (i) pelos, (ii) sombras e (ii) a baixa resolução. Vijayalakshmi, et al. (2019), chega a conclusão que, embora ANN e SVM tenham apresentado resultados satisfatórios, a CNN obteve o melhor desempenho.

3.1.3 Pré-processamento com ESRGAN e CNNs Pré-Treinadas — Gouda et al. (2022)

Gouda et al. (2022), é um projeto binário que utiliza o “*dataset*” SIC2018, e que apresenta uma solução de pré-processamento que utiliza Enhanced Super-Resolution Generative Adversarial Network (ESRGAN), uma variação de GAN, sendo esta responsável por aumentar a qualidade das imagens de baixa resolução (GOUDA, et al. 2022; WANG, 2018). O projeto de Gouda et al. (2022) também realiza testes de três CNNs pré-treinadas, utilizando técnicas de “*transfer learning*” e “*fine-tuning*”, sendo elas: InceptionV3, ResNet50 e Inception ResNet. além da CNN criada para o projeto. Os resultados apresentados por Gouda et al.

(2022) indicam que a abordagem proposta pelos autores alcançou precisão superior às demais estratégias testadas, que, entre os modelos pré-treinados avaliados, a InceptionV3 apresentou desempenho superior, e que fine-tuning elevou a acurácia em todos os modelos, com destaque novamente para a InceptionV3, sugerindo que redes profundas têm maior probabilidade de adquirir características relevantes quando ajustadas em um conjunto de dados menor do que redes rasas.

3.1.4 Faster-RCNN e Segmentação Fuzzy K — Nawaz et al. (2021)

No trabalho de Nawaz et al. (2021), é proposta a utilização do *framework* denominado Faster-RCNN, buscando aprimorar o método Fast-CNN, utilizando o conceito de “regiões propostas”. Este conceito de “regiões propostas” acarreta na imagem de entrada ser recortada em regiões retangulares, que são classificados e processados pelo algoritmo, reduzindo a carga computacional e aumentando a velocidade de análise (REN et al., 2015). Além disso, os autores integraram um método de segmentação Fuzzy K, que permite que diferentes regiões pertençam a múltiplos agrupamentos, melhorando a precisão da segmentação. Os resultados apresentados demonstraram uma melhora pequena, mas significativa, comparada com outros métodos analisados (REN et al., 2015).

3.1.5 CNN desenvolvida do zero — Zhang et al. (2021)

Zhang et al. (2021) descreveram a construção e treinamento de uma Rede Neural Convolucional(CNN) para detecção de lesões de pele, apresentando detalhadamente as camadas da rede e seu funcionamento. O modelo alcançou acurácia de 95%, demonstrando o alto potencial da técnica.

3.2 Diagnóstico da RD por IA por Meio de Smartphone — Oliveira et al. (2024)

Publicado na Revista de Oftalmologia Brasileira em 2024, o objetivo deste estudo foi o de desenvolver e testar uma estratégia de triagem da retinopatia diabética (RD), usando imagens de fundoscopia obtidas com um dispositivo portátil e

de baixo custo (smartphone acoplado à lente 20D), avaliando essas imagens com algoritmos de Inteligência Artificial (IA) para identificar a presença ou ausência da doença. Foi realizado um estudo transversal, observacional, com pacientes diabéticos que passaram por exame oftalmológico.

Neste estudo, uma lente 20D (lente oftálmica de diagnóstico, geralmente esférica, usada para a oftalmoscopia indireta, um exame que permite visualizar a retina, o nervo óptico e os vasos sanguíneos) foi acoplada a um smartphone através de um adaptador criado pelos pesquisadores e impresso em 3D, de modo a capturar imagens do fundo de olho (retinografia) durante midríase medicamentosa (a dilatação pupilar). A Imagem 10 foi retirada do artigo de Oliveira (2024), e ilustra o modelo 3D do adaptador e o adaptador em uso com o smartphone.

Imagem 10 - Dispositivo Portátil para Imagens da Retina.



Fonte: OLIVEIRA (2024)

As imagens foram classificadas por um algoritmo de IA em modo binário: presença ou ausência de retinopatia diabética, e foram usados diferentes métodos de aprendizado de máquina (como Support Vector Machines, Random Forest, KNN, Bayes, Multilayer Perceptron) combinados com extratores de características e arquiteturas de CNNs. A base de dados usada para treino foi criada por uma mistura de um “dataset público” (MESSIDOR) e imagens capturadas com o dispositivo portátil. Foram avaliadas 97 imagens retinianas no total: 45 imagens consideradas “normais” (sem RD) e 52 com RD.

Os modelos de IA obtiveram acurácia variando de cerca de 70 % até 100 % na classificação binária de presença ou ausência de retinopatia. As abordagens

baseadas em redes neurais profundas e combinações com classificadores como Random Forest ou SVM foram as que apresentaram os melhores resultados.

O estudo demonstrou que uma abordagem de triagem com dispositivo portátil de baixo custo é viável e apresenta eficácia satisfatória para identificar pacientes diabéticos com ou sem retinopatia diabética, especialmente em locais com infraestrutura limitada. O uso desse método pode ajudar na detecção precoce de lesões retinianas, encaminhando pacientes que necessitam de atenção especializada e possivelmente reduzindo a progressão para cegueira evitável.

Os autores destacam limitações, como o tamanho pequeno da amostra, a possível dificuldade em imagem de pacientes com pupila pequena ou opacidades (ex: cataratas) e o fato de o estudo estar restrito a um hospital. Eles sugerem que versões futuras do sistema podem evoluir para classificação multiclases, identificando níveis de gravidade da retinopatia, em vez de apenas presença/ausência

3.3 FDA aprova 1º dispositivo portátil que ajuda a detectar o tumor (2024)

De acordo com a publicação de janeiro de 2024 do Instituto Oncoguia, a agência regulatória dos Estados Unidos, a Food and Drug Administration (FDA), aprovou o primeiro dispositivo portátil com auxílio de algoritmo de IA para auxiliar na detecção de câncer de pele.

Esse dispositivo é capaz de identificar lesões de câncer de pele de três tipos: melanoma, carcinoma basocelular e carcinoma espinocelular, contudo, devem ser usadas apenas em lesões que já foram identificadas como suspeitas, e não para diagnóstico.

O aparelho, quando encostado na pele, emite luz e capta os comprimentos de onda refletidos pelas estruturas celulares abaixo da pele, que são analisados pelo para estimar se há indicativo de câncer. Os resultados são categorizados como: “Investigar mais” indicando a necessidade de uma avaliação mais completa, ou “Monitorar” indicando que não há urgência imediata no encaminhamento do paciente

O fabricante informa que, em estudo, o dispositivo alcançou 96% positivos verdadeiros e 97% de negativos verdadeiros.

A FDA exige que a empresa realize testes adicionais de validação clínica pós-comercialização, inclusive em populações demográficas diversas.

3.4 Implicações para o Projeto

Os estudos apresentados de modelos baseados em Inteligência Artificial(IA) para classificação evidenciam a predominância das Redes Neurais Convolucionais(CNNs) como abordagem mais eficiente para a classificação automática de lesões cutâneas relacionadas a câncer, e a possibilidade de esperar resultados acima de 95%, além do ênfase na importância de técnicas avançadas de pré-processamento graças a grande possibilidade de artefatos em imagens dermatológicas para garantir tais resultados. O projeto irá atentar-se a utilizar modelos com ênfase nas características supracitadas.

A pesquisa de projetos acadêmicos de aplicações similares como o “Diagnóstico da Retinopatia Diabética por Inteligência Artificial por Meio de Smartphone” por Oliveira et al. de 2024, demonstra que a triagem inicial por ferramentas de baixo custo, especialmente frente a falta de profissionais, pode vir resultar em diagnósticos mais precoces.

E a pesquisa de aplicações comerciais demonstra que aplicativos similares já estão em circulação, e enquanto não implementados na íntegra, são referências de metodologia, soluções e casos de uso.

No caso de ambos os tipos de aplicações, eles demonstram, seja com o uso da luz do smartphone, ou do adaptador impresso em 3D, que o uso do smartphone não precisa ser limitado a apenas a câmera do hardware disponível.

3.5 Métricas de Avaliação

Durante o treinamento de um modelo de inteligência artificial, uma parte importante é a avaliação de desempenho, e para que ela possa ser feita de forma mensurável, existem métricas e gráficos gerados ao final da etapa de treinamento que podem situar o programador no cenário atual de seus resultados, indicando se

devem ser feitos mais ajustes nas configurações do modelo, ou se ele atingiu um resultado satisfatório.

Neste projeto o grupo utilizou essas métricas durante os testes de algoritmos, para definir qual deles seria a melhor escolha, e entender como se comportavam nas situações propostas. Algumas das métricas consideradas, que serão detalhadas de forma sucinta nos parágrafos seguintes, foram: função de perda, matriz de confusão, acurácia, precisão, recall, entre outras.

A função de perda mede o quão distantes as previsões do modelo estão dos rótulos verdadeiros, penaliza mais severamente previsões incorretas que se afastam muito dos rótulos verdadeiros (ATWANY, 2022).

A matriz de confusão faz uma comparação entre os rótulos verdadeiros e os rótulos previstos pelo modelo. Nesta representação é usada uma lógica que se baseia em: falsos negativos (falhar em reconhecer uma lesão cancerosa), falsos positivos (identificar falsamente uma lesão como câncer), verdadeiros negativos (acusar corretamente que em certa imagem não há lesão cancerosa), e verdadeiros positivos (classificar corretamente como câncer uma imagem em que há de fato uma lesão cancerosa) e ter um bom controle disso é de extrema importância em aplicações de saúde (POWERS, 2020).

A acurácia é a precisão de acertos do modelo, isto indica, quantas imagens o modelo classificou corretamente em relação ao total (Classificação: precisão, recall, precisão e métricas relacionadas, 2024).

Precisão, por exemplo, mede quantos dos casos previstos como positivos realmente eram positivos (POWERS, 2020).

Recall mede quantos casos positivos reais o modelo conseguiu encontrar entre todos os disponíveis, ou seja, mede se o modelo conseguiu identificar todas as lesões cancerosas presentes na imagem (POWERS, 2020).

A métrica de recall é uma das mais importantes para o desempenho deste projeto, pois em situações onde há risco à saúde humana, deve-se ter certeza de que o algoritmo será capaz de identificar todas as lesões malignas presentes na imagem, pois em casos como este é muito menos prejudicial que o modelo apresente um falso positivo (indicar que a lesão tem altas chances de ser câncer,

mas não ser) do que um falso negativo (o modelo apontar que aquela lesão é benigna, e na verdade aquilo ser câncer).

4 METODOLOGIA

Este capítulo tem como objetivo definir e descrever todos os métodos utilizados na elaboração deste trabalho com o objetivo de documentar o desenvolvimento e orientar a reprodutibilidade da pesquisa.

4.1 BACK-END

Para o *back end*, primeiro serão estipuladas as funcionalidades necessárias para atender os requisitos do projeto, definindo as funcionalidades essenciais, como processamento de imagens, geração de relatórios e persistência de dados.

Em seguida, serão conduzidas pesquisas para a escolha de frameworks e bibliotecas, garantindo a utilização de ferramentas adequadas para a construção da aplicação, processamento de imagens e integração com inteligência artificial.

Após a definição destas ferramentas, iniciar-se-á a criação da aplicação, procurando atender todas as funcionalidades.

Para controle de versão e documentação do código, será criado um repositório no GitHub, permitindo a gestão de alterações e a colaboração eficiente durante o desenvolvimento.

Será então criada a integração do modelo através de um modelo teste para entender como conectar a aplicação ao modelo.

Para disponibilizar os resultados aos usuários, será então criado um endpoint na Interface de Programação de Aplicações (API), responsável por receber as requisições e disparar o processamento.

Por fim, o projeto será disponibilizado na nuvem através do upload no Render, possibilitando o acesso remoto à aplicação, e serão realizados testes para verificar o correto funcionamento de todas as funcionalidades, assegurando que a aplicação atenda aos requisitos definidos.

Quando o processo de treinamento e teste do modelo estiver pronto, ele será integrado ao projeto.

E novos testes serão realizados.

4.2 FRONT-END

Primeiro, definida a estrutura de diretórios e arquivos, buscando seguir uma lógica na estruturação dos arquivos e documentos, que não perdesse sentido conforme implementação de novas telas e funcionalidades, desde a estrutura inicial mantida do projeto, com os arquivos de configuração e arquivo principal, até o diretório (tabs), contendo todas as telas em que o usuário pode ter acesso quando logado, e (auth), telas de autenticação para login e cadastro de usuário no sistema.

Para manter o conjunto organizacional em coerência, também foi criado uma pasta hooks, onde estão salvos todos os webhooks, juntamente com requisições de APIs pré-padronizadas, mantendo uniformidade e assim buscando criar uma aplicação escalável e com baixa redundância, também favorecendo nos processos de manutenção dos códigos.

Um arquivo muito importante, que foi configurado após a codificação inicial para que se iniciasse o processo de integração de interface visual com o servidor, se trata do app.json, pois dentro dele foram configuradas todas as propriedades da aplicação, como seu nome, versão, orientação exibida na tela, ícone, entre outros mais.

Complementando a documentação de requisições, também foi utilizado o framework storybook, para que em cada componente presente na interface da aplicação pudessem ser feitos testes, implementações e atualizações de maneira isolada, sem perder a uniformidade e harmonia presente no código, evitando assim comprometimento com a identidade visual desenvolvida na aplicação.

4.3 INTELIGÊNCIA ARTIFICIAL

O uso da Inteligência Artificial(IA) neste projeto dar-se-á a partir do uso de um modelo de Rede Neural Convolucional(CNN), treinado em imagens médicas, capacitando-o a detectar sinais de câncer em imagens de lesões cutâneas capturadas por câmeras de dispositivos móveis.

Assim sendo, a metodologia da IA neste projeto engloba o processo de pesquisa, análise, teste, adaptação e integração, de modelos capazes de identificar

lesões cutâneas malignas e benignas, a partir de imagens capturadas por câmeras de dispositivos móveis, já disponíveis publicamente, integrando o com melhores resultados ao projeto, uma vez que o desenvolvimento de um modelo de IA capaz de realizar a classificação supramencionada vai além do escopo deste trabalho; e, de acordo com a literatura pesquisada, modelos de IA capazes de realizar a tarefa mencionada, com acurácia, já foram desenvolvidos.

Os passos que tomados serão os seguintes:

4.3.1 Algoritmos de Treinamento de Modelo de IA

Inicialmente, serão pesquisados em sites como “Kaggle”, “Hugging Face”, “Roboflow” e “GitHub”, por Algoritmos de Treinamento para Modelos de Inteligência Artificial (IA) capazes de classificar lesões cutâneas como cancerígenas ou não.

Algoritmos sem permissão para reprodução acadêmica serão descartados.

Em seguida, os Algoritmos de Treinamento serão tabulados em tabelas contendo informações como: confirmação de qualidade por terceiros, resultados documentados, qualidade da documentação, data de publicação, classificação binária ou multiclasse, banco de dados utilizado, e autor. Os itens anteriores foram descritos em ordem de importância.

Em seguida, os três Algoritmos de Treinamento com maior potencial de atender as necessidades do projeto, de acordo com as informações tabuladas, serão escolhidos.

Haverá então tentativas de reproduzir os resultados de treinamento de Modelos de IA documentados por estes três algoritmos de treinamento com maior potencial. Caso os resultados sejam similares e satisfatórios, dar-se-á progresso ao projeto, caso contrário, uma nova coleção de algoritmos de treinamento será testada, até o escopo de tempo do projeto ser exaurido, ou não sobrar mais opções de modelos disponíveis para teste.

4.3.2 Algoritmo de Manuseio de Dados

Será então desenvolvido um Algoritmo de Manuseio de Dados, responsável pela preparação e organização das informações utilizadas nos testes dos Algoritmos de Treinamento.

Esta etapa possui grande influência na eficiência dos experimentos, pois o algoritmo tem como função principal selecionar e separar conjuntos de dados com características específicas a partir de um banco de dados original.

Sem esse mecanismo, cada novo teste exigiria a organização e separação manual dos dados conforme as necessidades do experimento, tornando o processo mais demorado e propenso a erros. Com a implementação do Algoritmo de Manuseio de Dados, essa preparação será automatizada, a partir de entradas fornecidas pelo usuário, como número total de imagens, número de imagens por classe ou porcentagem de divisão, além da divisão automática de conjuntos de treino, validação e teste. Assim, o sistema poderá gerar automaticamente uma nova coleção de dados personalizada para cada teste.

O algoritmo deverá ainda seguir boas práticas de manipulação de dados, como: 1) estratificação, garantindo que a proporção das classes da base original seja mantida nas subdivisões (treino, validação e teste); 2) eficiência no manuseio, priorizando abordagens leves, como a criação de arquivos de referência (listas de identificadores) em vez de mover fisicamente as imagens; e 3) padronização entre bancos de dados, permitindo a integração de diferentes fontes que possuam métodos distintos de rotulação.

Este sistema possibilitará a criação rápida e eficiente de múltiplos subconjuntos de dados, favorecendo a realização de diversos testes e combinações experimentais ao longo do projeto.

4.3.3 Algoritmos de Teste de Previsão em Lote

Em seguida, para cada modelo de sucesso, serão desenvolvidos Algoritmos de Teste de Previsão em Lote.

Esses algoritmos representarão o funcionamento do código responsável por utilizar o modelo treinado dentro da aplicação, simulando todo o processo ao qual

uma imagem enviada pelo usuário será submetida até a geração da previsão final do modelo.

Para fins experimentais, o formato desses algoritmos será adaptado para testes em lote com validação: em vez de receber apenas uma imagem, como ocorrerá na aplicação final e utilizar o modelo, o algoritmo de teste utilizará o modelo, receberá o modelo um conjunto de imagens e um arquivo contendo os diagnósticos oficiais de cada imagem, fornecidos por profissionais.

O algoritmo executará o mesmo fluxo de pré-processamento e encaminhamento de imagem que será utilizado na aplicação real, processando todas as imagens, submetendo-as ao modelo, obtendo as previsões correspondentes e, em seguida, irá comparar estas previsões com os diagnósticos oficiais.

Dessa forma, será possível realizar um teste final representando o uso real do modelo dentro da aplicação, avaliando sua performance em um ambiente de execução semelhante ao sistema final.

Existe a necessidade de desenvolver um algoritmo de teste específico para cada modelo treinado, pois é fundamental utilizar o mesmo processo de pré-processamento de imagens aplicado durante o treinamento às imagens inéditas a serem analisadas. Essa correspondência garante que as condições sob as quais o modelo realizará previsões sejam compatíveis com aquelas em que ele aprendeu, preservando a coerência e a validade dos resultados obtidos.

4.3.4 Algoritmo de Previsão

Em seguida, o Algoritmo de Teste do modelo de IA com melhores resultados será adaptado como um Algoritmo de Previsão.

O Algoritmo de Previsão será usado para o back end da aplicação, e será responsável por conter o modelo treinado, receber a imagem a ser analisada, submetê-la aos tratamentos necessários, submetê-la a análise do modelo, e devolver a previsão do modelo sobre aquela imagem junto do nível de confiança do modelo sobre este resultado.

4.4 INTEGRAÇÃO

Após a conclusão do desenvolvimento dos três elementos principais do projeto, *back end*, *front end* e Inteligência Artificial (IA), utilizar-se-á a biblioteca *axios*, que torna mais prática e consistente toda a parte abrangente em relação a requisições *http* e *https* para o servidor, garantindo assim com que novamente, a aplicação se mantenha consistente e sem divergências demasiadamente discrepantes.

Durante essa etapa serão configuradas todas as rotas e endpoints que deveriam ser integrados via Interface de Programação de Aplicações (API), para realizar requisições de *GET*, *POST*, *PUT* e *DELETE* para o servidor. Juntamente com essa etapa de desenvolvimento, também será utilizado o *framework swagger*, para que seja possível manter uma documentação clara e objetiva em relação às rotas, endpoints e descrição detalhada sobre cada uma.

4.5 TESTES

Existem três fases de teste neste projeto.

4.5.1 Testes de Replicação

Esta seção de testes é realizada durante as tentativas de replicação dos algoritmos de treinamento disponíveis na internet, esperando-se obter resultados finais similares aos documentados. Os testes de replicação serão simples, já que grande parte dos algoritmos disponíveis possuem, ao fim de seus algoritmos, os códigos que produzem os resultados com as métricas usadas em sua documentação. Caso o algoritmo não possua esta etapa ao fim do seu treinamento, algoritmos capazes de criar visualizações gráficas de métricas como perda e acurácia ao longo do treinamento, serão criados.

4.5.2 Testes com Algoritmos de Teste de Previsão em Lote

Os modelos treinados a partir de algoritmos de treino reproduzidos com sucesso serão avaliados por meio dos Algoritmos de Teste de Previsão em Lote, com o objetivo de verificar sua performance em conjunto com o Algoritmo de Previsão, reproduzindo, o mais fielmente possível, o funcionamento do modelo dentro do sistema final.

Para garantir uma avaliação realista, o banco de dados utilizado nestes testes será completamente diferente daquele empregado no processo de treinamento do modelo.

A métrica principal de avaliação será a comparação entre as previsões geradas pelo modelo e os diagnósticos oficiais das mesmas imagens, realizados por profissionais especializados. Espera-se que a proporção de previsões corretas mantenha-se próxima à acurácia obtida durante o treinamento, podendo ocorrer uma leve queda natural em função das diferenças entre os conjuntos de dados.

4.5.3 Testes da Aplicação

Os testes da aplicação devem consistir em comprovar sua capacidade operacional, mediante os requisitos funcionais e não-funcionais prospectados durante o levantamento de requisitos, com o objetivo de avaliar as métricas de desempenho, usabilidade e confiabilidade do sistema.

Inicialmente serão conduzidos testes das funcionalidades propostas, abrangendo todo o conjunto técnico da parte de negócios e integração e funcionamento, tanto da aplicação cliente quanto do servidor.

Testes de precisão também serão realizados, baseando-se nas métricas de resultados falsos negativos e positivos, possibilitando assim uma verificação de acurácia com base no contexto em que foram realizados em questão.

Por fim, serão realizados testes de usabilidade com um dos integrantes do grupo, a fim de detectar possíveis bugs e incoerências, com foco em obter uma aplicação em fase de produção consistente e que forneça boa experiência ao usuário, atendendo seus objetivos.

4.6 FERRAMENTAS

Para o desenvolvimento deste projeto, foi utilizado um conjunto de linguagens de programação, *frameworks*, ferramentas de desenvolvimento e serviços em nuvem que possibilitaram a construção, segurança e disponibilização da aplicação.

4.6.1 Linguagens de Programação

Python — linguagem de programação open source, muito utilizada em segmentos como IAs, infraestrutura de rede e desenvolvimento web, permitindo a integração com diversas bibliotecas e linguagens de programação (PYTHON, 2025). Foi escolhida devido ao seu maior ecossistema em relação à visão computacional e inteligência artificial,

Kotlin — linguagem multiplataforma que pode ser utilizada em conjunto com Java e JavaScript, facilitando a criação de *softwares* para diferentes ambientes. (KOTLIN, 2025).

Java – Linguagem consolidada desde 1995, bastante utilizada no desenvolvimento de aplicativos *desktop e mobile* (JAVA, 2025).

React-Native – Foi escolhida por se tratar de um desenvolvimento com foco primário em dispositivos Android, porém com intenção de possibilitar a utilização da aplicação para usuários de sistemas operacionais IOs.

4.6.2 Segurança e Criptografia

Quando tratamos da segurança de um sistema, os principais conceitos trabalhados são: confiabilidade (envolvendo disponibilidade de informação, capacidade de informação e outros pontos), confidencialidade (as informações devem ser acessadas apenas pelas pessoas autorizadas) e integridade (alterações no sistemas em si só podem ser realizadas mediante autorização, fazendo com que cada alteração seja identificável e recuperável) (TANENBAUM, 2007). Assim sendo, para assegurar, principalmente, a confidencialidade das informações dentro do aplicativo, pois dentro de um projeto como este, que lida com dados sensíveis e

peçoais, a segurança é um aspecto importante de se considerar, foi utilizado o AES-256 — Algoritmo de criptografia com chave de 256 bits, garantindo alto nível de segurança e tornando a descriptografia praticamente inviável sem a chave correta (KANANDA, 2022).

4.6.3 Ambientes e Ferramentas de Desenvolvimento

No projeto, foram utilizadas diferentes ferramentas que possibilitaram sua implementação. Como Ambiente de Desenvolvimento Integrado (IDE) para codificação e desenvolvimento, foi utilizado o Visual Studio Code, pois além de se tratar de uma IDE já consolidada, possui suporte a múltiplas linguagens, além de também possibilitar a instalação de extensões, possibilitando uma maior eficiência quanto ao uso de snippets e outras funcionalidades que tornam o desenvolvimento mais ágil e organizado.

Para também ser possível realizar todo o controle e gerenciamento de versionamento da aplicação, foi utilizado o GitHub, plataforma pública que possibilita a colaboração dos desenvolvedores podendo realizar commits, até um local seguro em nuvem para manter um sistema de backup de todos os arquivos.

Já se tratando diretamente da parte de projeto da Interface do Usuário (UI) e Experiência do Usuário (UX) da aplicação, foi utilizado o figma, pois além de ser uma plataforma em que também é possível realizar a criação dos protótipos das telas de maneira conjunta e simultânea, possibilita a obtenção da estilização dos componentes em formato Folha de Estilos em Cascatas (CSS), que também pode ser reaproveitada no desenvolvimento da aplicação.

Para os testes de algoritmos e modelos de treinamento, foi utilizada a plataforma Google Colab, pois também se trata de uma ferramenta gratuita, que permite ao desenvolvedor, criar, executar e compartilhar Jupyter Notebooks diretamente no navegador, se estendendo à possibilidade de acesso opcional a unidade de processamento gráfico (GPU) e Unidade de Processamento de tensor (TPU) para um processamento mais rápido e robusto.

4.6.4 Frameworks e Bibliotecas

Na construção da parte de servidor da aplicação, foi optado a utilização do framework na linguagem “python” FastAPI, pois além de possuir uma alta performance, também possibilita o desenvolvimento de Interfaces de Programação de Aplicações (APIs) baseado em notações de tipo (FASTAPI, 2025).

Para que também fosse possível disponibilizar uma aplicação multiplataforma, optou-se por utilizar o *framework* react-native, além de também utilizar componentes nativos do sistema operacional, e possuir recursos como por exemplo o Hot Reload, que permite visualizar qualquer tipo de alteração da página em tempo real.

Para realizar a comunicação entre a interface visual da aplicação com o servidor, foi utilizado o *framework* Axios, desenvolvido com o propósito de tornar mais eficiente requisições “http” e “https”, possibilitando que a Interface do Usuário (UI) envie a requisição e receba resposta de maneira eficiente.

Para gerar uma visão dinâmica de diagramas diretamente da aplicação, também foi utilizado o mermaid, o qual realiza a geração desses diagramas em um arquivo markdown, possibilitando uma visão mais objetiva da aplicação de fato.

Complementarmente a isso, a lib storybook foi utilizada para realizar testes e documentar os componentes da aplicação de forma isolada, criando uma facilidade relacionada a manutenção de uma identidade visual padronizada e consistente.

4.6.5 Serviços em Nuvem e Infraestrutura

Foram utilizadas plataformas de serviços em nuvem neste projeto, com o intuito de diminuir a carga de processamento e armazenamento sobre o dispositivo móvel, onde o aplicativo está instalado. Com isso foram designadas as seguintes ferramentas.

Render.com – Plataforma que fornece estrutura para hospedagem da aplicação, monitoramento de tráfego e acesso ao banco de dados (RENDER, 2025)

Cloudflare R2 – Serviço de Sistema de Nomes de Domínio(DNS), Rede de Entrega de Conteúdo (CDN) e proteção de Camada de Soquetes Seguros (SSL),

permitindo o funcionamento da aplicação de forma segura na nuvem (CLOUDFLARE, 2025)

4.6.6 Inteligência Artificial

Gemini AI – Ferramenta de Inteligência Artificial (IA) utilizada na criação de imagens e ilustrações originais para a aplicação, evitando problemas com direitos autorais (GOOGLE, 2025).

4.6.7 Algoritmo de Treinamento de Modelo de IA

O algoritmo selecionado para a implementação deste projeto está disponível na plataforma Kaggle sob o nome de “Skin Cancer”, desenvolvido por Abdallah Wagih Ibrahim e publicado em 2023.

Foi escolhido pois apresentou os melhores resultados de reprodução.

É um algoritmo de classificação binária, ou seja, o resultado apresentado por ele é dividido em duas classes, sendo estas, benigno (para lesões e marcas identificadas como sendo de uma categoria que não apresenta câncer) e malignas (para lesões que apresentam as características indicadoras de possível câncer).

O algoritmo é feito em linguagem de programação Python, e utiliza as seguintes bibliotecas e ferramentas: Tensorflow, uma biblioteca utilizada para *Machine Learning*, segundo o site da própria biblioteca (TENSORFLOW, 2025); módulos padrão do Python (os, time, shutil, pathlib e itertools) (GLOSSARY, PYTHON, 2025); Numpy, ideal para computação científica em Python (NUMPY, 2025); Pandas, usada frequentemente para análise de dados (PANDAS, 2025); e também o Seaborn, que cria gráficos estatísticos, e pode ser interligada facilmente ao pandas (Waskom, M. L., 2021), entre outros.

Primeiramente, no código, são importadas todas as bibliotecas e ferramentas necessárias para o funcionamento dele. Após isso, inicia-se a etapa de preparação dos arquivos. Essa etapa começa definindo o endereço da pasta onde estão os dados a serem usados no treinamento, e cria listas para armazenar a localização de cada imagem e sua devida classificação (rótulo de maligno ou benigno). Depois,

coloca as informações dessas listas em um data frame para que os dados fiquem estruturados e o processamento deles seja mais eficiente.

A etapa seguinte é a de pré processamento de dados, onde são definidas informações como tamanho de batch e dimensões das imagens analisadas (altura, largura e número de canais de cores), assim como são feitas as conexões necessárias com o “dataframe” e a divisão dos conjuntos de imagens para treinamento e teste, para que eles sejam utilizados nos próximos passos.

A partir disso, com as imagens já com as dimensões e rótulos corretos, inicia a parte de criação do modelo de análise em si. Neste algoritmo foi utilizada a técnica de *transfer learning*, que tem como base um modelo já treinado anteriormente (a fim de utilizar os pesos já refinados que vêm com ele) e que está sendo adaptado para os requisitos das análises deste projeto. O modelo relacionado ao *transfer learning* aqui é o EfficientNetB0, e a partir dele são adicionadas camadas específicas e novas configurações considerando as intenções deste projeto.

O modelo é então treinado, e ao terminar, o código gera gráficos de avaliação de desempenho e faz previsões sobre o conjunto de teste. Ao fim deste processo, são gerados gráficos e reportes para a avaliação de performance do modelo, com métricas como: loss, acurácia e o gráfico de matriz de confusão. Neste ponto os programadores podem entender se as configurações de treinamento estão boas ou se devem ser ajustadas, com base nos gráficos e resultados deles. A Imagem 11 mostra um exemplo de resultados advindos desta etapa.

Imagem 11 - Exemplo de Resultados do Algoritmo de Treinamento

	precision	recall	f1-score	support
benign	0.94	0.89	0.92	360
malignant	0.88	0.94	0.91	300
accuracy			0.91	660
macro avg	0.91	0.91	0.91	660
weighted avg	0.91	0.91	0.91	660

Fonte: Wagih (2023)

Uma vez satisfeito com o desempenho do modelo, o programador pode salvá-lo como um arquivo e utilizá-lo para fazer novas inferências com outras fontes de dados e conectar este modelo a outros projetos ou partes do sistema.

4.6.8 EfficientNetB0

EfficientNet caracteriza uma “família” de modelos, variando de B0 até B7, com cada modelo possuindo particularidades e casos de uso mais adequados, devido principalmente à diferença nos ajustes dos parâmetros de profundidade, largura e resolução no modelo (ALI et al, 2025). Por exemplo, para que a entrada possa ser uma imagem com maior resolução, os outros parâmetros (profundidade e largura) devem ser aumentados proporcionalmente, sendo esta uma das características principais desse tipo de modelo (ALI et al, 2025). A EfficientNet-B0 é a base para as outras versões presentes nesta família, e apresenta um certo equilíbrio entre seu desempenho e complexidade (ALI et al, 2025).

Pode-se citar que a EfficientNet-B0 tem como componentes importantes em sua estrutura diversos módulos MBConv (Mobile Inverted Bottleneck Convolution). Estes módulos funcionam da seguinte forma: ao receber uma entrada de imagem nova, o módulo realiza uma convolução 1x1 e aumenta o número de canais daquela imagem (cada canal aqui representando um tipo de característica diferente a ser identificada) após isso, é feita uma convolução depthwise (na qual são aplicados filtros sobre os vários canais simultaneamente) que torna o modelo mais eficiente; então, depois da convolução, volta-se ao número original de canais daquela imagem, durante uma última convolução 1x1, assim seguindo para as próximas etapas até o output desejado (CHING et al, 2024; HOANG et al, 2021).

4.6.9 - Bases de Dados

Neste projeto, durante as tentativas de replicação de algoritmos de treinamento de modelos de Inteligência Artificial (IA), foram utilizados diversos

bancos de dados públicos para o treinamento dos modelos, buscando empregar as mesmas bases mencionadas nas publicações originais de cada projeto, a fim de reproduzir os resultados documentados.

Contudo, Entretanto, para o modelo que apresentou os melhores resultados, foram utilizadas duas bases de dados principais: 1) uma modificação do ISIC-Archive, utilizada no treinamento do modelo selecionado para este projeto, pois foi o banco de dados utilizado pelo algoritmo “Skin Cancer” supracitado; e 2) o PAD-UFES-20, utilizado durante a fase de testes com o algoritmo de previsão, com o objetivo de avaliar o desempenho do modelo já treinado frente a imagens inéditas dentro do sistema, o PAD-UFES-20 foi escolhido por conter fotografias de lesões cutâneas capturadas com câmeras de smartphones, o que a torna especialmente adequada ao contexto de uso proposto pela aplicação.


4.6.9.1 - Base de Dados para o Treinamento do Modelo de Inteligência Artificial(IA): Skin Cancer: Malignant VS. Benign

O dataset “*Skin Cancer: Malignant vs. Benign*” está disponível na plataforma Kaggle, publicado por Claudio Fanconi em 2019.

Este dataset consiste em 1800 imagens de dimensão 224x224 advindas do repositório ISIC-Archive (The International Skin Imaging Collaboration), que disponibiliza conteúdos dermatológicos voltados à pesquisa e inovação na área.

É um dataset balanceado, contendo duas classes similarmente populares, sendo uma com amostras de imagens de marcas cutâneas benignas, e a outra com amostras de imagens de câncer de pele (maligno). A Imagem 12 apresenta exemplos de uma amostra de cada classe.


Imagem 12 - Exemplo Benigno e Maligno da Base de Dados Skin Cancer



Fonte: Adaptado de Fanconi (2019)

Já a Imagem 13 ilustra uma amostra aleatória da mesma base de dados

Imagem 13 - Amostra Generalizada da Base de Dados Skin Cancer




Fonte: WAGIH (2023)

4.6.9.2 - Base de Dados para o Testes com Algoritmos de Teste de Previsão em Lote: PAD-UFES-20

O dataset PAD-UFES-20 foi desenvolvido na Universidade Federal do Espírito Santo (UFES, 2020) pelo Programa de Assistência Dermatológica e Cirúrgica (PAD), e é composto por 2298 imagens capturadas por câmeras de celular e um arquivo de metadados com informações sobre os 1373 pacientes que colaboraram com a coleta das imagens.

As imagens são separadas em seis classes, onde três delas apresentam amostras de lesões de câncer de pele: Carcinoma Basocelular (BCC), Carcinoma Espinocelular (SCC) e Melanoma (MEL); dois representam doenças de pele não cancerígenas: Nevos (NEV) e Queratose Seborreica (SEK); e uma não cancerígena, mas que pode vir a ser em certas circunstâncias: Ceratose Actínica (ACK). A Imagem 14 apresenta um exemplo de imagens presentes neste dataset e suas categorias.

Imagem 14 - Exemplo Dataset PAD-UFES-20



Fonte: Pacheco (2020)

Sobre o arquivo de metadados dos pacientes, ele é um “Comma-Separated Values”, ou CSV, que possui diversas características registradas sobre o caso de cada paciente, sendo estes: o diagnóstico comprovado sobre aquela lesão, detalhes sobre hábitos (se há o consumo de cigarros ou álcool, neste caso), um breve histórico de nacionalidade familiar, idade, gênero, histórico de câncer na família, entre outros fatores que podem ser úteis para análise e identificação de padrões para estudo, ou até mesmo como parâmetros para alguma aplicação tecnológica.

Em resumo, este dataset tem a proposta de ampliar os horizontes de pesquisa sobre câncer de pele e incentivar o desenvolvimento de ferramentas que consigam detectar essas lesões a partir de imagens captadas por celulares, tomando uma abordagem diferente de outros datasets que disponibilizam apenas

imagens profissionais feitas em ambientes médicos e controlados, segundo Pacheco (2020).

5 IMPLEMENTAÇÃO DO PROJETO

Os testes neste projeto serão divididos em três categorias: (i) testes durante do treinamento do modelo, onde procura-se recriar os resultados finais do treinamento; (ii) testes do sistema de Inteligência Artificial (IA), onde será testado o sistema de inteligência artificial como um todo dentro do sistema da aplicação; e (iii) teste da aplicação, onde a aplicação em si e suas funções serão testadas.

As métricas de avaliação serão, para (i) e (ii) métricas de avaliação de IA, como loss, acurácia, F1, neste projeto em especial, dando especial atenção ao recall e aos falsos negativos; e para o (iii) as métricas se baseiam nos requisitos funcionais e não funcionais descritos no projeto.

5.1 PROJETO

Um sistema é composto por diversos componentes em relacionamento, e por isso, antes de iniciar o desenvolvimento, um deve elaborar, baseando-se nas ferramentas disponíveis e objetivos do projeto, definições e ilustrações de como todo o sistema irá funcionar, do macro, para o micro.

5.1.1 Análise de Requisitos

A definição dos requisitos funcionais e não funcionais é um dos segmentos mais importantes durante o projeto de um sistema, pois ela delimita, de forma clara e qualitativa, as características do sistema e como estas características devem funcionar.

5.1.1.1 *Requisitos Funcionais*

Segundo Paula (2000), os requisitos funcionais são aqueles que determinam o funcionamento do sistema a partir de certa ação do usuário.

Assim sendo, a Tabela 3 foi elaborada para ilustrar os requisitos funcionais deste projeto.

Tabela 3 - Requisitos Funcionais

Requisitos Funcionais	
ID	Descrição
RF01	O aplicativo deve ser capaz de acessar a câmera do dispositivo móvel e guiar o usuário a capturar uma imagem da lesão de pele por meio de uma interface que oriente o processo, ou, alternativamente, o sistema deve primeiramente apresentar uma tela que descreva o tipo de imagem a ser retirada, ser capaz de acessar o sistema de arquivos do dispositivo móvel, e guiar o usuário através da seleção de uma imagem previamente retirada.
RF02	A imagem capturada ou selecionada deve ser processada por um modelo de Inteligência Artificial devidamente treinado para oferecer ao menos 95% de acurácia nos resultados.
RF03	Com base na análise realizada, o sistema deve gerar um relatório contendo o resultado. Tanto em casos analisados como altas chances de câncer, como em casos analisados como chance baixa de câncer, o relatório deve anexar recomendações e informações educativas que incentivem a procura de diagnóstico profissional e com foco na conscientização sobre o assunto.
RF04	O aplicativo deve então apresentar as informações deste relatório de forma sucinta e de fácil entendimento, visualização e consumo mesmo para os públicos mais leigos, evitando paredes de texto.

Fonte: Próprio Autor (2025)

5.1.1.2 Requisitos Não Funcionais

Ainda sob a ótica de Paula (2000), os requisitos não funcionais descrevem outros aspectos do sistema, que melhoram o funcionamento dele ou aumentam a qualidade da experiência do usuário, mas que não são tão cruciais para a aceitação como os requisitos funcionais. A tabela 4 apresenta os requisitos não funcionais deste projeto.

Tabela 4 - Requisitos Não Funcionais

(Continua)

Relação de Requisitos Não Funcionais	
ID	Descrição
RNF01	O aplicativo deve ser programado para funcionar em aparelhos Android.

(Conclusão)


ID	Descrição
RNF02	O algoritmo de inteligência artificial deve ser implementado em Python.
RNF03	O back-end deve ser desenvolvido utilizando Python.
RNF04	O aplicativo deve ser otimizado para alto desempenho, priorizando agilidade na análise das imagens, onde deve-se realizar a análise, geração de relatório e entrega de relatório em até 5 segundos.
RNF05	O aplicativo deve funcionar de forma estável, sem travamentos e manter as métricas supracitadas mesmo em dispositivos de hardware menos potentes nas mãos do povo brasileiro em 2025, garantindo acessibilidade (Por exemplo, lançados a partir de 2018, com Android 8.0 ou superior, e que possuam no mínimo 2 GB de memória RAM, estando conectados à internet).
RNF06	A interface deve ser intuitiva, simples e fácil de usar, para que mesmo usuários sem experiência prévia consigam completar o fluxo de: acesso à aplicação, envio e análise de imagem, e leitura do relatório sem instruções adicionais ou interrupções.
RNF07	O relatório deve ser apresentado de modo sucinto, com destaque aos pontos de interesse e evitando paredes de texto, de modo que a leitura do relatório não deve levar mais do que 1 minuto.
RNF08	O aplicativo não deve desincentivar aqueles que planejavam procurar ajuda médica, e deve incentivar aqueles que não planejavam.
RNF9	O tratamento de dados dos usuários deve estar de acordo com a LGPD (Lei Geral de Proteção de Dados) e diretrizes éticas da área da saúde, garantindo anonimização de dados sensíveis e solicitando consentimento explícito antes da coleta de qualquer informação pessoal.
RNF10	Todos os dados armazenados devem estar criptografados utilizando, no mínimo, o padrão AES-256. A comunicação entre cliente e servidor deve ocorrer via HTTPS com certificados atualizados, e o sistema deve ter autenticação segura para acesso a dados sensíveis.

Fonte: Próprio Autor (2025)

5.1.2 Diagrama de Caso de Uso

Outro planejamento de extrema importância pois dita todo o processo de projeto e desenvolvimento é o de casos de uso. De acordo com Paula (2000), os casos de uso fazem uma descrição dos requisitos funcionais de uma forma visual e estruturada em fluxos, com as ações que poderão ser realizadas dentro da aplicação. A Imagem 15 mostra a representação visual dos casos de uso deste projeto.

Imagem 15 - Diagrama de Casos de Uso



Fonte: Próprio Autor, 2025

A Tabela 5 representa o primeiro caso de uso, constando os passos para fazer um cadastro na aplicação.

Tabela 5 - Caso de uso 1

(Continua)

UC01 - Cadastro na Aplicação	
Objetivos	Criar uma conta no aplicativo para que o usuário possa avançar para a página principal da aplicação e utilizar suas funções.
Requisitos	Possuir o aplicativo instalado e estar conectado à Internet
Atores	Usuário
Pré-condições	O usuário em questão não pode possuir cadastro ainda.
Frequência de uso	Este caso só será utilizado quando o usuário criar uma conta.
Pós-Condições	A partir do cadastro, poderá acessar as outras telas do aplicativo e utilizar os recursos oferecidos

(Conclusão)

UC01 - Cadastro na Aplicação	
Fluxo Principal	1) Acesso ao aplicativo 2) Clicar na opção de cadastro na primeira tela do aplicativo 3) Preencher os campos necessários e completar as etapas de cadastro.
Fluxo Alternativo	Este caso de uso possui fluxo único.
Fluxo Exceção	1) Usuário já possui cadastro 2) Usuário é informado de que já possui uma conta e é instruído a fazer login
Validação	Não há validações neste caso.

Fonte: Próprio Autor

A Tabela 6, o segundo caso de uso, apresenta o fluxo de análise de fotos feita dentro da aplicação.

Tabela 6 - Caso de uso 2

(Continua)

UC02 - Analisar uma foto	
Objetivos	Carregar ou tirar uma foto para que ela passe pela análise da aplicação e retorne os resultados.
Requisitos	Possuir uma conta no aplicativo e acesso à Internet.
Atores	Usuário
Pré-condições	O usuário deve ter feito o cadastro no aplicativo e permitir o uso da câmera de seu dispositivo.
Frequência de uso	Este caso se aplica a todas as vezes em que o usuário buscar fazer uma nova análise de imagens pelo aplicativo, podendo ser um número ilimitado de vezes.
Pós-Condições	A análise retornará um relatório, que pode ser acessado a qualquer momento conforme a descrição do próximo caso de uso.

(Conclusão)

UC02 - Analisar uma foto	
Fluxo Principal	4) Na página inicial, o usuário deve fazer login em sua conta. 5) Selecionar a opção de Análise no menu. 6) Escolher entre carregar uma foto da galeria ou tirar uma nova foto 7) Após a análise, clicar em “Ver Relatório Completo” para acessar os resultados
Fluxo Alternativo	Neste caso, a única parte em que há uma decisão a ser tomada pelo usuário é a de carregar uma foto da galeria ou tirar uma nova, porém ambos os caminhos têm o mesmo fim e resultado, então podemos considerar como um único fluxo.
Fluxo Exceção	Não há um fluxo de exceção para este caso
Validação	Não há validações neste caso.

Fonte: Próprio Autor (2025)

A Tabela 7, por fim, representa o terceiro caso de uso, e mostra o processo para baixar relatórios anteriores pelo aplicativo.

Tabela 7 - Caso de uso 3

(Continua)

UC03 - Baixar Relatórios Anteriores	
Objetivos	Acessar o histórico de relatórios gerados pelo aplicativo em uma determinada conta, e baixá-los.
Requisitos	O usuário deve ter uma conta no aplicativo, acesso à Internet e análises feitas previamente.
Atores	Usuário
Pré-condições	O usuário deve ter uma conta no aplicativo.
Frequência de uso	Este caso se aplica a quantas vezes o usuário desejar consultar seus relatórios passados, sem limite de quantidade de vezes.

(Conclusão)


UC03 - Baixar Relatórios Anteriores	
Pós-Condições	O usuário terá um arquivo baixado em seu dispositivo contendo o relatório escolhido.
Fluxo Principal	1) O usuário deve fazer login em sua conta 2) Selecionar a opção “Histórico” no menu 3) Clicar no botão “Baixar como PDF”
Fluxo Alternativo	O relatório pode ser obtido automaticamente a partir de uma nova análise. Para isso, deve-se seguir o fluxo do caso de uso anterior.
Fluxo Exceção	Não há um fluxo de exceção para este caso.
Validação	A aplicação verifica se há relatórios relacionados àquele usuário no banco de dados.

Fonte: Próprio Autor (2025)

5.1.3 Diagrama de Arquitetura

Com as definições claras de necessidades de funcionalidades desenvolvidas anteriormente com a elaboração dos requisitos, e dos casos de uso, pode-se iniciar o projeto dos componentes necessários para o sistema, e como eles irão se relacionar.

Imagem 16 - Diagrama de Arquitetura do Projeto




Fonte: Próprio Autor (2025)

A Imagem 16, são os Diagramas de Arquitetura, representam como os elementos macro do sistema interagem entre si. Nela, a aplicação envia mensagens para o servidor, que processa essa mensagem e possivelmente recorre ao banco de dados para obter as informações necessárias para a resposta. Isso acontece quando o usuário interage com o aplicativo e realiza ações dentro dele, como fazer cadastro e login, solicitar relatórios, entre outros processos que serão explicados em próximos tópicos.

5.1.4 Diagrama Entidade Relacionamento

O diagrama entidade relacionamento que aparece na Imagem 17 exemplifica como as entidades presentes no sistema se relacionam entre si, simulando estruturas utilizadas em SGBDs (Sistemas de Gerenciamento de Banco de Dados).

Imagem 17 - Diagrama Entidade Relacionamento

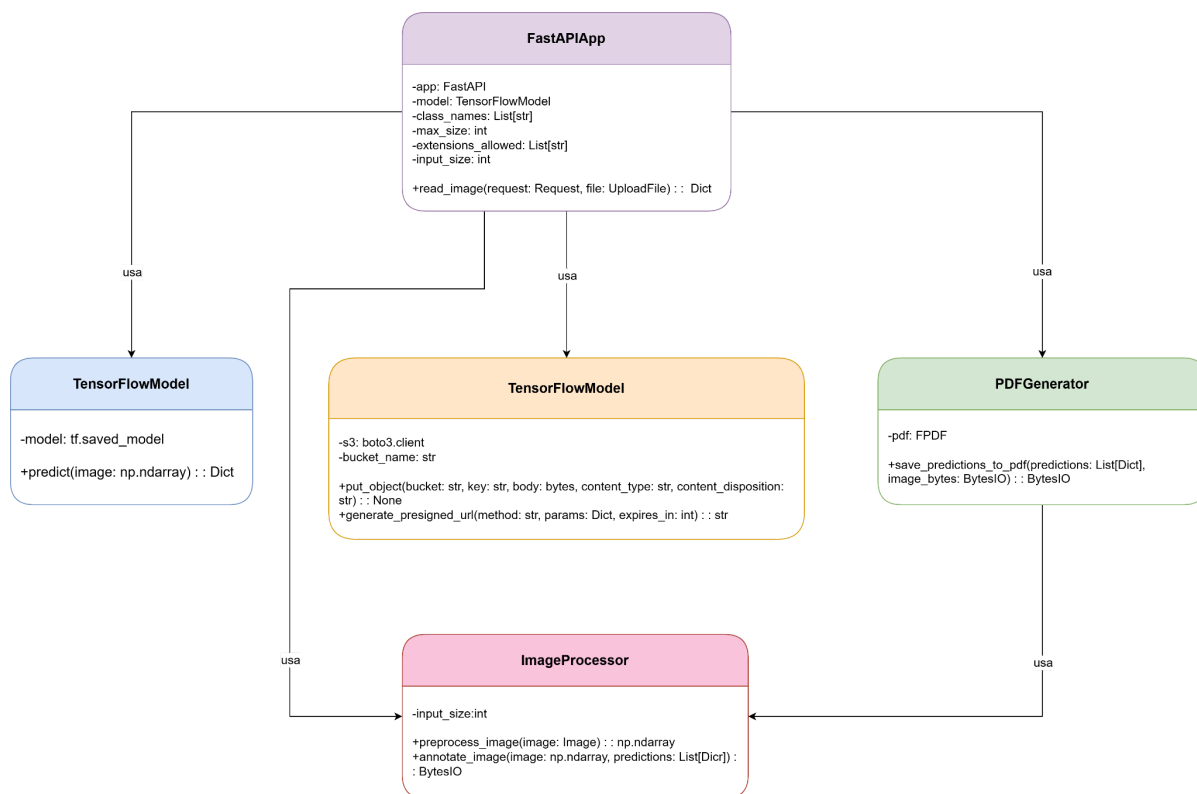


Fonte: Próprio Autor (2025)

5.1.4 Diagrama de Classes

Como o desenvolvimento desta aplicação foi feito com programação estruturada, e esse paradigma não permite a existência de classes, o diagrama que aparece na Imagem 18 é uma representação gerada pela ferramenta Mermaid que mostra como diferentes partes do código se conectam. Ou seja, funciona como uma “simulação” do que aconteceria com a representação das classes de uma aplicação orientada a objetos, por exemplo.

Imagem 18 - Diagrama de Classes



Fonte: Próprio Autor (2025)

5.2 BACK END

A aplicação foi desenvolvida em Python, utilizando do *framework* FastAPI para a criação da Interface de Programação de Aplicações (API), o *framework* TensorFlow para o desenvolvimento de uma rede neural, o serviço Render para a hospedagem da aplicação online e o serviços de armazenamento R2 para a persistência das informações determinadas necessárias durante o desenvolvimento.

Na função principal (`main.py`) são utilizadas as bibliotecas: Pillow para a manipulação de imagens, numpy para a manipulação de vetores, IO para a manipulação de bytes, Yaml para a leitura de arquivos deste tipo e datetime para a geração de timestamps.

A aplicação recebe uma requisição POST de um usuário e então realiza processos de verificação de tamanho e extensão, seguindo para uma conversão a um vetor e posterior análise pela rede neural.

A imagem é salva em um banco de dados não relacional utilizando a função `database.py`, que realiza uma conexão com sistema R2, fornecido pela Cloudflare.

A geração de um relatório é realizada pela função `pdfSaving.py` que escreve um arquivo contendo a imagem já analisada com a predição utilizando as classes definidas no arquivo `.yaml`

Após o processamento do relatório e da imagem, bem como a persistência de ambos no banco de dados, é gerado um link de *download* para que o usuário possa ter o arquivo para uso.

Junto com as funções Python há um arquivo `.docker` para que outros integrantes possam utilizar dos mesmos pacotes utilizados no desenvolvimento. Também há um arquivo de texto definido como “requirements” com as bibliotecas utilizadas na criação desta aplicação que serve tanto como um guia para outros desenvolvedores como um comando à aplicação de hospedagem que indica quais bibliotecas devem ser instaladas.

A Interface de Programação de Aplicações (API) já construída é executada no serviço de hospedagem Render. Este serviço lê diretamente do repositório presente no GitHub e executa o código ali inserido, também fazendo o *download* através do gerenciador de pacotes PIP das bibliotecas mencionadas na pasta requirements. O serviço também armazena as chaves e variáveis de conexão com o banco de dados, garantindo sua segurança e sua separação do ambiente em produção.

Após a execução com sucesso do código, os *endpoints* são acessíveis e abertos para os usuários utilizarem da aplicação.

5.3 FRONT END

Para a construção das telas presentes na aplicação, foi utilizada a tecnologia *framework* react-native, uma biblioteca de JavaScript/TypeScript, escolhida por possuir compatibilidade tanto com dispositivos android quanto IOS, além das suas linguagens core serem amplamente conhecidas e versáteis, possibilitando uma escalabilidade e manutenção de código mais ágil e consistente; também possui um grande ecossistema de bibliotecas e uma comunidade ativa, o que facilita o processo de integração de Interfaces de Programação de Aplicações (API's), por

exemplo, juntamente com a possibilidade de criação e reutilização de componentes visuais, Hot Reload, que permite a atualização da página sem a necessidade de recarregá-la, possibilitando maior agilidade e facilidade ao realizar testes e ajustes rápidos na interface lógica da aplicação.

Para a criação de interfaces e toda a parte de identidade visual, seguindo conceitos dos conteúdos aprendidos em aula para proporcionar uma boa integração de Experiência do Usuário/Interface do Usuário (UX/UI) na implementação do projeto, foi utilizada a ferramenta Figma, desde a criação do design individual de cada tela até mesmo a paleta de cores completa da aplicação, gerando uma identidade visual coerente de maneira com que se mantivesse simples e fluida, priorizando sempre a fácil utilização e entendimento do usuário.

Em relação à estrutura do código e arquitetura da aplicação, foram desenvolvidos alguns arquivos README responsáveis por documentar todo o processo de desenvolvimento de maneira detalhada, disponíveis na plataforma Github, detalhando todo o processo passo-a-passo desde a criação do projeto, até a parte de integração entre cliente-servidor, e como se aplicam alguns conceitos importantes da área de ciência da computação, como por exemplo componentes presentes nas disciplinas de engenharia de *software* e qualidade de *software*, visando sempre manter uma boa manutenção e estruturação do projeto, juntamente com um fácil entendimento.

Na parte de criação de imagens, foi usada a ferramenta Gemini AI para gerar imagens ilustrativas presentes dentro da aplicação, como por exemplo no tutorial de como enviar uma boa foto para a análise.

Juntamente com as ferramentas anteriores, foi utilizado o Mermaid, para acompanhar e visualizar de maneira gráfica e concreta toda a diagramação, estrutura de classes/objetos/ arquitetura geral e fluxograma do projeto, atualizados em tempo real.

Para complementar a documentação, foi usado o *framework* storybook, de maneira a documentar todos os componentes presentes na aplicação, permitindo que fosse possível trabalhar no desenvolvimento, testando e documentando todos os componentes e suas respectivas variações/alterações de maneira isolada.

Por fim, o Swagger API também foi utilizado, para documentar detalhadamente toda a parte de Interface de Programação de Aplicações (API), suas rotas com seus respectivos endpoints, juntamente com uma descrição detalhada sobre o funcionamento correto de cada uma, e como os parâmetros da requisição devem ser montados para seu envio.

5.3.1 Funcionamento e Interfaces

Levando em conta todos os conceitos abordados e o planejamento apresentado até agora, esta seção tem o objetivo de explicar em detalhes todas as telas presentes no aplicativo juntamente com suas funcionalidades.

Imagem 19 - Tela de Login



Fonte: Próprio Autor (2025)

A Imagem 19 mostra a primeira tela encontrada ao iniciar o aplicativo. Nela é possível entrar em sua conta através de e-mail e senha, assim como selecionar a opção de recuperação de senha, ou criar uma nova conta (que redireciona o usuário para a tela da Imagem 20).


Imagem 20 - Tela de Cadastro

A imagem mostra a tela de cadastro de uma nova conta em um aplicativo. No topo, há um botão de câmera em um círculo vermelho. O título principal é "Crie sua conta" em negrito. Abaixo dele, um subtítulo diz "Comece a monitorar sua saúde da pele hoje mesmo". A tela contém cinco campos de entrada: dois para nome (primeiro e sobrenome) com ícones de pessoa, um para e-mail com ícone de envelope, um para data de nascimento com ícone de calendário, e um para senha com ícone de cadeado e um botão para alternar visibilidade. Abaixo dos campos, há uma caixa de seleção vazia seguida pelo texto "Concordo com os Termos de Serviço e Políticas de Privacidade". Um botão azul com o texto "Criar conta" está centralizado. Na base, há o link "Já tem uma conta? Entre" em azul.

Fonte: Próprio Autor (2025)

A Imagem 20 apresenta a tela de cadastro de uma nova conta, com os campos que devem ser preenchidos. Também apresenta uma marcação para que o usuário possa ler e aceitar os Termos de Serviço e Políticas e Privacidade.


Imagem 21 - Tela de Carregamento



Fonte: Próprio Autor (2025)

A Imagem 21 é a tela de carregamento usada enquanto as conexões e processos da aplicação são realizados (conexão com servidor e banco de dados, validação da conta, entre outros) antes de levar o usuário até a tela principal.


Imagem 22 - Tela Principal



Fonte: Próprio Autor (2025)

A Imagem 22 mostra a tela principal do aplicativo, apresentando um menu principal na parte inferior, com as opções de fazer uma nova análise, ir para o histórico ou ir para a tela de configurações. Fora este menu, há um botão logo no topo com a opção de realizar uma nova análise. Abaixo deste botão, existem algumas informações sobre a atividade da conta, com dados de quantas análises foram feitas naquele mês, e a porcentagem de resultados analisados que foram categorizados com chances pequenas de apresentarem câncer. Após isso, são mostradas quais foram as análises recentes (essa sessão ficaria vazia em contas novas) e uma parte dedicada à exibição de conteúdos educativos sobre o tema de câncer de pele.

Imagem 23 - Tela de Configurações



Fonte: Próprio Autor (2025)

A Imagem 23 representa a tela de configurações, possível de ser acessada pelo menu, na qual o usuário pode acessar e alterar suas informações pessoais, ativar ou desativar notificações, alterar o tema, exportar seu histórico de análises, e acessar o controle de privacidade.

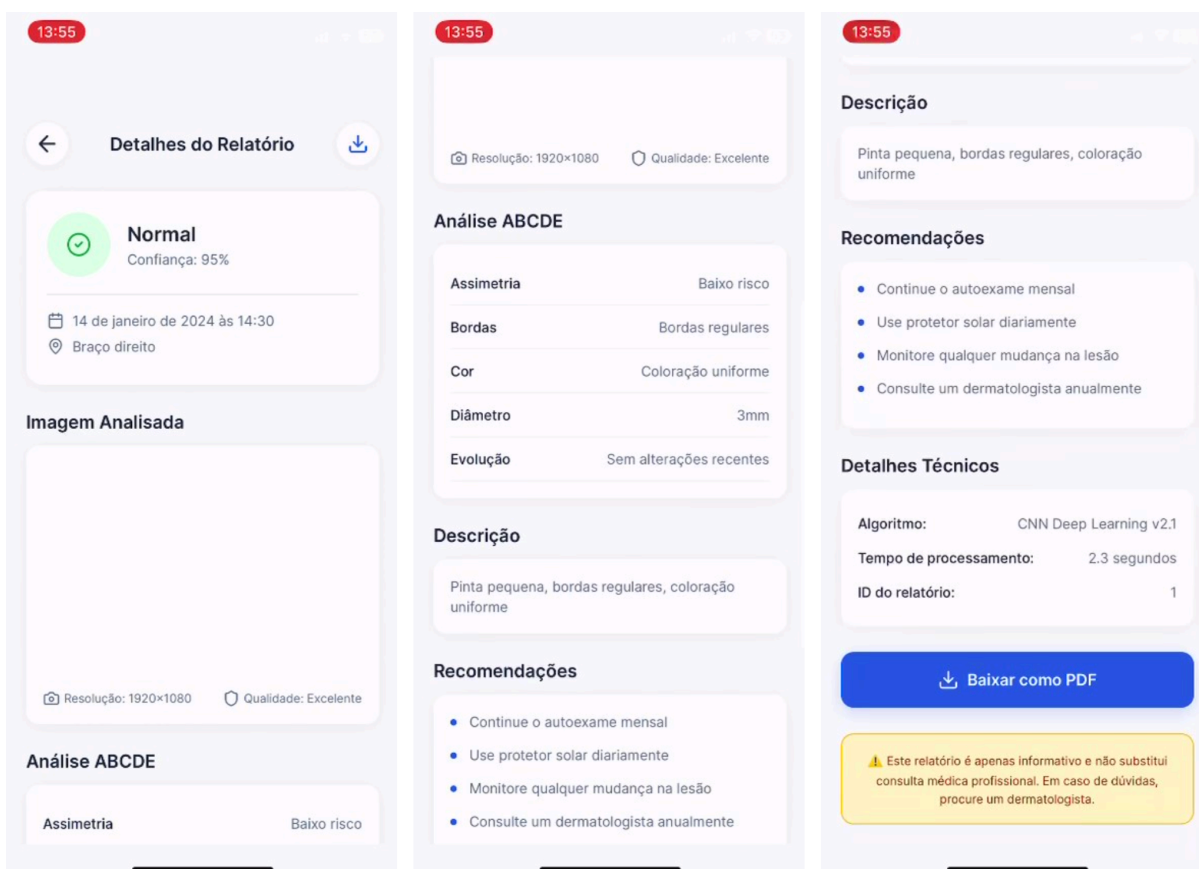
Imagem 24 - Tela de Histórico



Fonte: Próprio Autor (2025)

A Imagem 24 mostra a tela de histórico de análises, possível de ser acessada através do menu, na qual pode-se conferir informações como: total de análises feitas, estatísticas dos resultados, e seções que redirecionam o usuário para a tela de detalhes do relatório daquela análise.

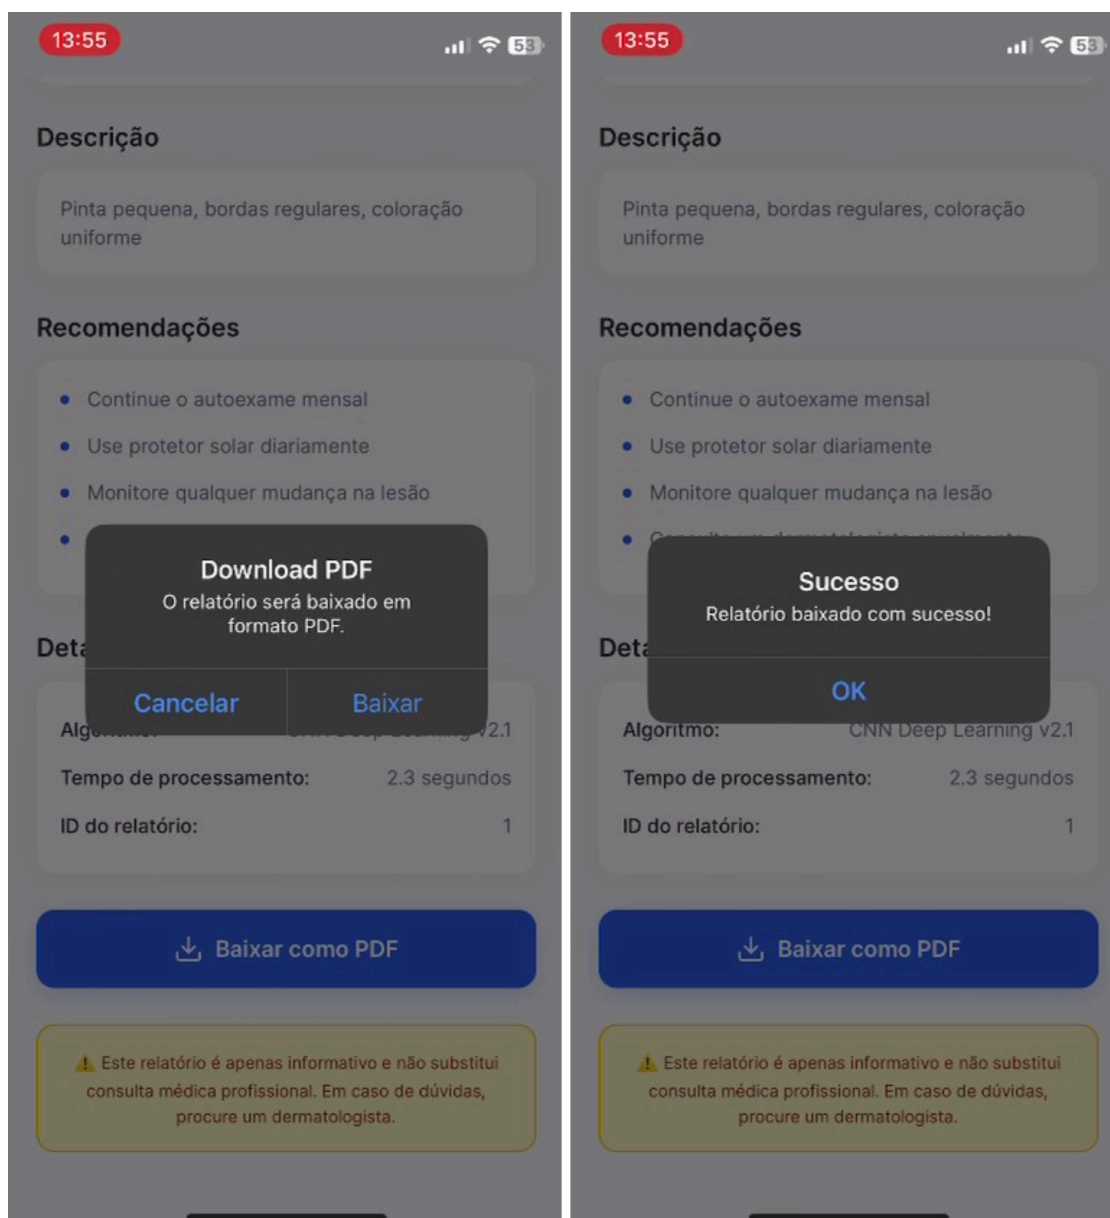
Imagem 25 - Tela de Detalhes do Relatório



Fonte: Próprio Autor (2025)

A Imagem 25 retrata a tela de detalhes do relatório, que pode ser acessada após a finalização de uma nova análise, ou por meio da tela de histórico. Nela, é possível ver o resultado da análise com o percentual de risco de apresentar uma lesão maligna, assim como a imagem que foi analisada, a análise ABCDE (que considera aspectos de assimetria, bordas irregulares ou com indicativos suspeitos, coloração da lesão, diâmetro e tempo de evolução dela), descrição do que foi detectado, algumas recomendações de atitudes preventivas, e por último uma breve descrição dos detalhes técnicos da análise (como qual o algoritmo usado, o tempo de processamento, e o ID daquele relatório) junto ao botão que permite baixar o relatório.


Imagem 26 - Download do Relatório



Fonte: Próprio Autor (2025)

A Imagem 26 mostra a tela que aparece ao clicar no botão para baixar o relatório, mostrando uma janela de confirmação e outra de sucesso caso o processo tenha sido finalizado sem problemas.

Imagem 27 - Tela de Instruções para Foto



Fonte: Próprio Autor (2025)

A Imagem 27 mostra a tela que aparece ao clicar na opção de “Análise” no menu, e mostra instruções para a captura de fotos para a análise, abordando aspectos como: iluminação, posicionamento adequado, foco e resolução, estabilidade da câmera e um botão para dar início ao processo de análise.


Imagem 28 - Tela de Aviso para Procurar Opiniões Profissionais



Fonte: Próprio Autor (2025)

A Imagem 28 é o aviso que aparece quando o usuário clica no botão “Continuar para Análise” da tela anterior, e reforça a importância de procurar ajuda profissional, pontuando que este aplicativo não substitui uma consulta médica.


Imagem 29 - Tela de Upload de Imagens



Fonte: Próprio Autor (2025)

A Imagem 29 representa a tela de upload de imagens para análise. Nela estão presentes as opções de usar a câmera para capturar uma nova imagem, ou carregar uma foto da galeria. Em sequência, aparecem alguns tópicos de detalhes da aplicação e um ponto de redirecionamento para uma seção com conteúdos informativos sobre câncer de pele.

Imagem 30 - Tela de Opções de Captura/envio de Imagem



Fonte: Próprio Autor (2025)

A Imagem 30 retrata a tela que dá ao usuário a opção de enviar para análise a foto que ele tirou no passo anterior, ou voltar à câmera para tirar outra.


Imagem 31 - Tela de Captura de Imagem



Fonte: Próprio Autor (2025)

A Imagem 31 é o que aparece ao escolher a opção de tirar uma nova foto, acessando a câmera do celular.

Imagem 32 - Tela Carregamento Análise



Fonte: Próprio Autor (2025)

A Imagem 32 mostra a tela de carregamento que aparece enquanto a análise está sendo feita, e mostra o progresso e a porcentagem completa até o momento. Quando o carregamento acaba, passa-se para a próxima tela.

Imagem 33 - Tela de Resultados



Fonte: Próprio Autor (2025)

Por fim, há a tela de resultados, com uma descrição breve do que foi descoberto durante a análise, representado na Imagem 33.

5.4 INTEGRAÇÃO BACK-FRONT

A comunicação entre as camadas *front* e *back* foi feita por meio de

requisições HTTP, juntamente com Axios, uma biblioteca escolhida para gerenciar essas requisições no frontend, substituindo o uso do fetch nativo, oferecendo mais recursos e facilidade de uso.

5.5 INTELIGÊNCIA ARTIFICIAL

5.5.1 Processo de Pesquisa de Replicação de Resultado de Algoritmos

Para localizar um algoritmo de treinamento de modelos Inteligência Artificial (IA) para o projeto, foram realizadas pesquisas em quatro sites: GitHub, Kaggle, Roboflow, e Hugging Face.

No site Hugging Face não foram localizados algoritmos apropriados para este projeto; no site Roboflow, foram localizados alguns algoritmos com potencial, contudo, pecavam em uma falta de documentação; no site GitHub foram encontrados uma amostra de projetos similares ao proposto, assim como no Kaggle. Dentre eles, os algoritmos no GitHub eram os mais bem documentados, enquanto no Kaggle existia uma mistura entre projetos bem e mal documentados, mas também projetos que participaram e foram revisados em competições organizadas por organizações de renome, como a “ISIC 2024 - Skin Cancer Detection with 3D-TBP”, organizada pela International Skin Imaging Collaboration (ISIC). Contudo, muitos projetos com alta classificação possuem códigos e ou bases de dados privadas.

Dentre os algoritmos de treinamento encontrados, houve a tentativa de reproduzir os resultados daqueles com maior potencial.

Foram realizados testes de replicação em algoritmos de treinamento como o “Skin Cancer Detection” por Abdallah Wagih Ibrahim em 2023, que, segundo sua documentação, é um algoritmo de treinamento de modelo de IA classificação e de multiclass, que utiliza o banco de dados “Skin Cancer MNIST: HAM10000” publicado por K Scott Mader em 2018, e apresenta acurácia acima de 90%, como mostrado na Imagem 36; ou o “HAM10000: Skin Disease Classification”, publicado por Dhruv Gangwani em 2021 na plataforma Kaggle, e que, de acordo com sua

documentação, também é um algoritmo de classificação de multiclass, com uma acuaría acima de 95%.

Contudo, entre problemas de versão de bibliotecas desatualizadas, exigência de máquinas capazes de alto processamento, ou erros estruturais no algoritmo que envenenaram os resultados apresentados na documentação, como a separação de dados após a aumentação de dados, muitos dos algoritmos replicados demonstraram-se não utilizáveis dentro do escopo do projeto.

No fim, o algoritmo que obteve os melhores resultados de replicação, foi o “Skin Cancer” publicado por Abdallah Wagih Ibrahim em 2023 na plataforma Kaggle, que utiliza o banco de dados “Skin Cancer: Malignant vs Benign” disponível na mesma plataforma, publicado por Claudio Fanconi em 2019.

Todos os testes foram realizados utilizando bibliotecas como sklearn para produzir métricas gerais de análise de modelos de Inteligência Artificial (IA) como acurácia, precisão, recall, F1-score e bibliotecas como o matplotlib para visualização clara de dados.

5.5.3 Implementação da Inteligência Artificial

A implementação da Inteligência Artificial no projeto se deu através da construção de quatro algoritmos distintos, desenvolvidos no ambiente do Google Colab e na linguagem Python: (i) algoritmo de manuseio de dados; (ii) algoritmo de treinamento de modelo; (iii) algoritmo de previsão; e (iv) algoritmo de teste.

5.5.3.1 Algoritmo de Manuseio de Dados

O Algoritmo de Manuseio de Dados é um algoritmo estrutural simples capaz de receber um arquivo CSV original, e criar novos arquivos CSVs, de maneira organizada, prontos para o algoritmo de treinamento ou teste, com opções de boas práticas como a estratificação, de acordo com a edição de variáveis no código.

Isto possibilitou a criação rápida de diversos CSVs ao longo do projeto, que funcionam como amostras com características específicas para testes ao longo do

desenvolvimento, sem necessidade de manipular as pastas de imagens dos bancos de dados.

5.5.3.2 O Algoritmo de Treinamento do Modelo de IA

A reprodução do Algoritmo de Treinamento “Skin Cancer” publicado por Abdallah Wagih Ibrahim em 2023 no site “Kaggle” foi realizada através do Google Colab em um ambiente de “GPUs: T4”.

As barreiras durante a reprodução foram duas, os conflitos de versões de bibliotecas, exigindo que o algoritmo fosse atualizado, e o principal, as limitações de 12 horas de execução por sessão do Google Colab, que impossibilitaram o treinamento completo do modelo, que chegou a ter apenas 35 épocas, e não as 50 estipuladas pelo autor original.

5.5.3.3 O Algoritmo de Teste de Previsão em Lote

O Algoritmo de Teste de Previsão em Lote é um algoritmo estruturado simples que recebe como entrada uma coleção de imagens, além de um CSV contendo o diagnóstico dessas imagens, e produz, como saída, as previsões realizadas pelo modelo, o grau de confiança, e o diagnóstico real, comparando os positivos falsos, negativos falsos, positivos verdadeiros e negativos verdadeiros, além da indicação das classes para uma análise da performance do modelo por lesão cutânea, em uma coleção simples de strings, como demonstra a Imagem 34.

Imagem 34 - Saída Simples do Algoritmo de Teste

	image	true_label	predicted_label	confidence
0	PAT_1401_1373_881.png	NEV	malignant	52.706402
1	PAT_72_110_647.png	NEV	benign	56.784554
2	PAT_1388_3513_146.png	NEV	benign	65.746735
3	PAT_244_374_726.png	NEV	benign	64.927818
4	PAT_205_311_255.png	NEV	benign	56.852184
5	PAT_658_1266_149.png	BCC	benign	54.929882
6	PAT_561_1068_909.png	BCC	malignant	63.246258
7	PAT_53_82_940.png	BCC	malignant	74.863091
8	PAT_330_696_894.png	BCC	malignant	62.204243
9	PAT_241_367_89.png	BCC	malignant	61.522900
10	PAT_522_3174_761.png	ACK	malignant	53.761299
11	PAT_2043_4308_681.png	ACK	malignant	67.974998

Fonte: Próprio Autor (2025)

Utilizando bibliotecas como matplotlib cria-se gráficos capazes de melhorar a visualização destes dados, comparando por exemplo, falsos positivos e negativos, e verdadeiros positivos e negativos, dando ênfase para os falsos negativos.

5.5.3.4 O Algoritmo de Previsão

O Algoritmo de Previsão é uma adaptação final do Algoritmo de Teste de Previsão em Lote, e foi implementado de maneira simples e estruturada, onde, recebe-se uma entrada de a imagem, passa essa entrada pelo pré-processamento que aplica na imagem todos os tratamentos que as imagens utilizadas para treinar o modelo sofreram, passa essa imagem pelo modelo treinado carregado no código, e recebe-se a previsão e a percentagem de confiança do modelo sobre esta previsão como saídas, como demonstra a Imagem 35.

Imagem 35 - Exemplo de Saída do Algoritmo de Predição

A imagem mostra um exemplo de saída de texto de um algoritmo de predição. O texto está em uma fonte de monoespaço, com a primeira linha em verde e a segunda em amarelo, ambas sobre um fundo escuro. O texto indica uma predição incerta e recomenda a reavaliação, além de fornecer o diagnóstico previsto e a percentagem de confiança.

```
Predição incerta, recomendar reavaliação  
Diagnóstico previsto: malignant (51.43% de confiança)
```

Fonte: Próprio Autor (2025)

Este é o único algoritmo dentre os quatro desta categoria que fazem parte da aplicação final — a aplicação, enviando a imagem para ser processada e analisadas, e tomando a saída deste algoritmo para basear as informações que passará ao usuário.

Contudo, as imagens do banco de dados “Skin Cancer: Malignant vs. Benign” publicado por Claudio Falconi no site “Kaggle” é uma coleção de imagens do banco de dados “ISIC” já processadas, e não foram encontradas informações sobre os exatos pré-processamentos realizados nesta coleção.

Assim o Algoritmo de Previsão realiza apenas os pré-processamentos visíveis no Algoritmo de Treinamento “Skin Cancer”, publicado por Abdallah Wagih Ibrahim em 2023.

6 TESTES E RESULTADOS

Este capítulo documenta os resultados obtidos, dividido em três seções principais: (i) Resultados do Modelo Treinado com o Algoritmo de Treinamento; (ii) Resultados do Algoritmo de Previsão; e (iii) Resultados

3.1 Resultados da Replicação do Algoritmo de Treinamento de Modelo

Os resultados obtidos ao final do treinamento utilizando o algoritmo escolhido, “Skin Cancer”, publicado por Abdallah Wagih Ibrahim em 2023 no site Kaggle, estão representados na Imagem 36.

Imagem 36 - Loss e Accuracy do Modelo “Skin Cancer”



Fonte: Próprio Autor (2025)

Como a Imagem 36 demonstra, este treinamento então chegou a um loss por volta de 0,4 e uma acurácia de mais de 0,85.

Comparados ao loss documentado no projeto original de 0.37 e um acurácia de 0.91 na época 24, enquanto os resultados do loss parecem ter sido reproduzidos, até em melhor eficiência com uma linha de treino menor, a acurácia obteve resultados piores, tanto finais quanto ao longo do treinamento, com uma clara incompetência pelas primeiras 30 épocas.

3.2 Resultados do Algoritmo de Teste de Previsão em Lote

Para um teste com dados externos, foi escolhido o banco de dados PAD-UFES-20 por se tratar de uma coleção de imagens de lesões cutâneas coletadas em território brasileiro através de smartphones

As classes são: Carcinoma Basocelular (BBC), Carcinoma Espinocelular (SCC), Ceratose Actínica (ACK), Ceratose Seborreica (SEK), Doença de Bowen (BOD), Melanoma (MEL) e Nevo (NEV), com BOD sendo considerado SCC, o que resulta em seis lesões cutâneas no conjunto de dados, quatro cancerígenas (ACK, , BBC, MEL e SCC) e duas não cancerígenas (NEV e SEK).

50 imagens de cada classe foram selecionadas, e processados pelo Algoritmo de Previsão, resultando no seguinte apresentando na Tabela 8.


Imagem 37 - Tabela de Resultados Positivos e Negativos por Classe

Tabela principal (cancerígenas):			
	Classe	Falso Negativo	Verdadeiro Positivo
0	ACK	19	31
1	BCC	22	28
2	MEL	31	19
4	SCC	15	35
Tabela NEV e SEK (benignas):			
	Classe	Falso Positivo	Verdadeiro Negativo
3	NEV	11	39
5	SEK	21	29

Fonte: Próprio Autor (2025)

Como é mostrado na Imagem 37, as previsões tiveram um maior índice de acerto em todas as classes, abstando o Melanoma.

Imagem 38 - Comparação entre Falsos Negativos e Verdadeiros Positivos



Fonte: Próprio Autor (2025)

Contudo, como ainda é possível visualizar tanto na Tabela 8 como na Imagem 38, o número de acertos e erros, especialmente entre aqueles pertinentes à lesões cancerígenas, se encontram próximos, com destaque ao Melanoma, com o pior caso, e ao Carcinoma Espinocelular como o melhor caso.

3.3 Resultados da Aplicação

A aplicação está apta a funcionar em aparelhos Android e IOs, assim como fazer análises de imagens dentro do intervalo de 5 segundos estipulado anteriormente. Além disso, o projeto segue boas práticas no front end para construir a UI, fazendo com que a aparência do aplicativo apresentasse apenas as informações necessárias e relevantes à ação que o usuário está atuando, e mantendo um design limpo.

Os relatórios são apresentados de forma sucinta e informativa ao usuário, de forma a não desincentivá-lo a procurar ajuda médica, sendo possível também baixar em formato PDF os relatórios de análises passadas.

Para o funcionamento completo da aplicação, é necessária uma conexão ativa com a *internet*, visto que os componentes de processamento (como servidor e banco de dados) estão conectados por meio do ambiente nuvem.

Contudo, isto implica no positivo de que a aplicação não depende do hardware do usuário.

Durante os testes, observou-se que a aplicação manteve estabilidade e tempo de resposta consistentes, mesmo em conexões móveis comuns, o que reforça sua viabilidade para uso cotidiano em contextos reais.

7 CONCLUSÃO E TRABALHOS FUTUROS

Do ponto de vista da inteligência artificial, o modelo não alcançou os resultados esperados, sendo estes, reproduzir de forma satisfatória o desempenho observado em trabalhos da literatura. Contudo, o estudo evidenciou os principais gargalos técnicos e apontou caminhos para aprimoramento.

Dentro do contexto do projeto, de uma aplicação, a principal limitação esteve relacionada à impossibilidade em replicar o mesmo processo de pré-processamento das imagens do banco de dados no algoritmo de previsão, o que, em hipótese, impactou diretamente a acurácia do modelo.

Como consequência de ambos, os resultados obtidos ficaram significativamente abaixo do esperado, ainda distantes das taxas de acerto de 80% ou mais normalmente reportadas em estudos semelhantes, e especialmente longe do nível de precisão necessário para uma aplicação real, que idealmente deveria aproximar-se de 100%.

Assim, como demonstrado nos testes, o número de falsos negativos ainda se apresenta em valores inaceitáveis, mesmo sendo inferior ao número de verdadeiros positivos, representando um perigo para os usuários.

Por outro lado, no aspecto da aplicação, os resultados foram satisfatórios. Os requisitos definidos foram atendidos e o protótipo desenvolvido mostrou-se funcional, comprovando a viabilidade do conceito proposto.

Conclui-se, portanto, que projetos públicos desse tipo exigem um maior investimento no desenvolvimento de modelos de inteligência artificial mais robustos, ou ainda, parcerias com indivíduos ou instituições que já possuam soluções consolidadas.

Como trabalhos futuros, sugere-se a continuação do desenvolvimento da aplicação, através a ampliação de sua acessibilidade o adaptando para funcionar sem a necessidade de internet, do investimento no desenvolvimento do modelo, da adaptação do modelo para outras doenças, ou através de parcerias com sistemas de saúde, permitindo o uso do protótipo em contextos reais — tanto para acompanhamento de pacientes quanto para realização de exames preventivos. Dessa forma, este tipo de ferramenta poderia contribuir para a ampliação do acesso

a diagnósticos e para o fortalecimento de estratégias de saúde preventiva, em um estudo de âmbito mais social.

8 REFERÊNCIAS

AMERICAN CANCER SOCIETY. *Cancer Facts & Figures 2025*. Atlanta: American Cancer Society, 2025. Disponível em: <https://www.cancer.org/content/dam/cancer-org/research/cancer-facts-and-statistics/annual-cancer-facts-and-figures/2025/2025-cancer-facts-and-figures-acf.pdf>. Acesso em: 9 out. 2025.

AXIOS. *Introdução | Axios Docs*. Disponível em: <https://axios-http.com/ptbr/docs/intro>. Acesso em: 18 out. 2025.

BARBOSA, Lucia Martins; PORTES, Luiza Alves Ferreira. *A inteligência artificial*. *Revista Tecnologia Educacional*, Rio de Janeiro, n. 236, p. 16-27, 2023.

BRASIL. *Lei Geral de Proteção de Dados Pessoais (LGPD)*. GOV.BR. Disponível em: <https://www.gov.br/esporte/pt-br/acao-a-informacao/lgpd>. Acesso em: 18 out. 2025.

BONFIM, Laiane Nunes. *Câncer de pele: medidas preventivas e perfil epidemiológico na região Nordeste do Brasil*. *Revista Ibero-Americana de Humanidades, Ciências e Educação*, v. 9, n. 1, p. 467-481, 2023. Disponível em: <https://periodicorease.pro.br/rease/article/view/8233>. Acesso em: 9 out. 2025.

CHOLLET, F. *Deep learning with python*. [S.l.]: Manning Publications Co., 2017.

CLOUDFLARE. *O que é HTTPS?*. 2025. Disponível em: <https://www.cloudflare.com/pt-br/learning/ssl/what-is-https/>. Acesso em: 18 out. 2025.

CLOUDFLARE. *Proteção na nuvem*. 2025. Disponível em: <https://developers.cloudflare.com/>. Acesso em: 18 out. 2025.

COMISSÃO EUROPEIA. *Inteligência artificial na saúde*. Disponível em: https://health.ec.europa.eu/ehealth-digital-health-and-care/artificial-intelligence-health-care_pt. Acesso em: 10 out. 2025.

CORPORAAL, H., PEEMEN, M.; MESMAN, B.; *Speed sign detection and recognition by convolutional neural networks*. In: *Proceedings of the 8th International Automotive Congress*. [S.l.: s.n.], 2011.

DAMSKY, William E.; BOSENBERG, Marcus. *Melanocytic nevi and melanoma: unraveling a complex relationship*. *Nature Reviews Cancer*, v. 17, n. 7, p. 315–327, 2017. DOI: <https://doi.org/10.1038/onc.2017.189>. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/28604751/>. Acesso em: 9 out. 2025.

DILDAR, M. et al. *Skin cancer detection: A review using deep learning techniques*. *International Journal of Environmental Research and Public Health*, v. 18, n. 10, p. 5479, 2021. Disponível em: <https://doi.org/10.3390/ijerph18105479>. Acesso em: 9 out. 2025.

DO NASCIMENTO NETO, Conrado Dias et al. Inteligência artificial e novas tecnologias em saúde: desafios e perspectivas. *Brazilian Journal of Development*, v. 6, n. 2, p. 9431-9445, 2020.

FANCONI C. *Skin Cancer: Malignant vs. Benign*. Kaggle, 2019. Disponível em: <https://www.kaggle.com/datasets/aryashah2k/skin-cancer-malignant-vs-benign>. Acesso em: 21 out. 2025.

FASTAPI. *FastAPI*. 2025. Disponível em: <https://fastapi.tiangolo.com/>. Acesso em: 9 out. 2025.

FERREIRA, Poliana N. *Aprendizado de máquina*. Editora Senac São Paulo, 2024.

FRANGE, V. M. N., Arruda, L. H. F., & Daldon, P. Érica C. (2009). *Dermatoscopia: importância para a prática clínica*. *Revista De Ciências Médicas*. <https://seer.sis.puc-campinas.edu.br/cienciasmedicas/article/view/637>. Acesso em: 9 out. 2025.

FIGMA. *Figma: a ferramenta de design de interface colaborativa e online*. Disponível em: <https://help.figma.com/hc/en-us>. Acesso em: 18 out. 2025.

GIL, A. C. *Como elaborar projetos de pesquisa*. Atlas São Paulo, 2002. v. 4.

GITHUB. *Crie e envie software em uma única plataforma de colaboração*. Disponível em: <https://docs.github.com/pt>. Acesso em: 18 out. 2025.

Glossary. Python. Disponível em: <<https://docs.python.org/3/glossary.html>>. Acesso em: 22 out. 2025.

GOLDBERG, D. E. *Genetic Algorithms in Search, Optimization, and Machine Learning*. Addison-Wesley, 1989.

GOODFELLOW, Ian J. et al. *Generative Adversarial Nets*. In: GHAMRANI, Z. et al. (org.). *Advances in Neural Information Processing Systems*, v. 27. Montreal, Canada: Neural Information Processing Systems Foundation; Curran Associates, 2014. Disponível em: <https://proceedings.neurips.cc/paper/2014/file/f033ed80deb0234979a61f95710dbe25-Paper.pdf>. Acesso em: 05 jul. 2025.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. MIT Press, 2016.

GOOGLE. *Conheça o Gemini, seu assistente de IA criado pelo Google para o dia a dia*. 2025a. Disponível em: <https://gemini.google/br/about/?hl=pt-BR>. Acesso em: 16 out. 2025.

GOOGLE. *Collaboratory FAQ*. 2025b. Disponível em: <https://research.google.com/colaboratory/intl/pt-BR/faq.html>. Acesso em: 21 out. 2025.

GOUDA, W. et al. *Detection of skin cancer based on skin lesion images using deep learning*. Healthcare, v. 10, n. 7, p. 1183, 2022. Disponível em: <https://doi.org/10.3390/healthcare10071183>. Acesso em: 19 mar. 2025.

GUARNIER, N. V.; VIEIRA, A. C. C.; GOUVÊA, G. M.; LIMA, L. H. C.; SANTOS, T. L. L. dos. *Manejo do câncer de pele do tipo melanoma: uma revisão narrativa*. Brazilian Journal of Implantology and Health Sciences, v. 6, n. 6, p. 2068–2084, 2024. DOI: <https://doi.org/10.36557/2674-8169.2024v6n6p2068-2084>. Disponível em: <https://bjih.emnuvens.com.br/bjih/article/view/2452>. Acesso em: 9 out. 2025.

HAYKIN, Simon. *Redes neurais: princípios e prática*. Bookman Editora, 2001.

HORSHAM C, et al. *A teledermoscopia está pronta para substituir os exames face a face na detecção precoce do câncer de pele? Visões do consumidor, aceitação da tecnologia e satisfação com o atendimento*. Dermatologia, 2020;

IBM. *What is an AI model?* IBM Think, 2024a. Disponível em: <https://www.ibm.com/think/topics/ai-model>. Acesso em: 5 nov. 2025.

IBM (). *What is model training?* IBM Think, 2024b. Disponível em: <https://www.ibm.com/think/topics/model-training>. Acesso em: 5 nov. 2025.

INSTITUTO NACIONAL DO CÂNCER JOSÉ ALENCAR GOMES DA SILVA (INCA). *Atlas On-line de Mortalidade*. Disponível em: <https://www.inca.gov.br/MortalidadeWeb/pages/Modelo01/consultar.xhtml>. Acesso em: 9 out. 2025.

INSTITUTO NACIONAL DO CÂNCER JOSÉ ALENCAR GOMES DA SILVA (INCA). *Coordenação Geral de Ações Estratégicas. Coordenação de Educação ABC do câncer: abordagens básicas para o controle do câncer*. 2a ed. rev. e atual. Rio de Janeiro: INCA; 2012. Disponível em: https://bvsms.saude.gov.br/bvs/publicacoes/inca/abc_do_cancer_2ed.pdf. Acesso em: 9 out. 2025.

INSTITUTO NACIONAL DO CÂNCER JOSÉ ALENCAR GOMES DA SILVA (INCA). *Deteção precoce do câncer*. Rio de Janeiro: INCA, 2021. Disponível em: <https://www.inca.gov.br/sites/ufu.sti.inca.local/files/media/document/deteccao-precoc-e-do-cancer.pdf>. Acesso em: 9 out. 2025.

INSTITUTO NACIONAL DO CÂNCER JOSÉ ALENCAR GOMES DA SILVA (INCA). *Estimativa | 2023: incidência de câncer no Brasil*. Rio de Janeiro: INCA, 2022. Disponível em: <https://www.inca.gov.br/sites/ufu.sti.inca.local/files/media/document/estimativa-2023.pdf>. Acesso em: 9 out. 2025.

JABOUR, F. G.; FIGUEIREDO, R. M. O.; MOURÃO-JÚNIOR, C.A. *Aprendizado de Máquinas Aplicado ao Diagnóstico por Imagem: Uma Revisão Integrativa*. Conjecturas, v. 22, n. 7, 2022. Disponível em: https://www.researchgate.net/publication/361731493_Aprendizado_de_Maquinas_ap

[licado_ao_diagnostico_por_imagem_uma_revisao_integrativa](#). Acesso em: 10 out. 2025

JAVA. *O que é Java e por que preciso dele?* 2025. Disponível em: https://www.java.com/pt-BR/download/help/whatis_java.html. Acesso em: 15 out. 2025.

JURAFSKY, D.; MARTIN, J. H. *Speech and Language Processing*. 3rd ed. Draft, Stanford University, 2023.

KANANDA, V. *Why You Should Use AES 256 Encryption to Secure Your Data*. 2022 Disponível em: https://www.progress-com.translate.goog/blogs/use-aes-256-encryption-secure-data?x_tr_sl=en&x_tr_tl=pt. Acesso em: 15 out. 2025.

KELLEHER, John D. *Deep learning*. MIT press, 2019.

KOHONEN, T.. *The Self-Organizing Map (SOM)*. CIS/HUT – Helsinki University of Technology. Disponível em: <http://www.cis.hut.fi/projects/somtoolbox/theory/somalgorithm.shtml>. Acesso em: 05 jul. 2025.

KOTLIN. *Kotlin docs*. 2025. Disponível em: <https://kotlinlang.org/docs/home.html>. Acesso em: 18 out. 2025..

LAGES, R. B.; BARBOSA, P. B.; ALMEIDA, I. P.; LOPES, L. R. S.; FILHO, L. L. L. *Deteção precoce do câncer de pele: experiência de campanha de prevenção no Piauí-Brasil* - doi: 10.5020/18061230.2012.p221. Revista Brasileira em Promoção da Saúde, [S. I.], v. 25, n. 2, p. 221–227, 2012. DOI: 10.5020/2233. Disponível em: <https://ojs.unifor.br/RBPS/article/view/2233>. Acesso em: 9 out. 2025.

LIMA JUNIOR. I.A., LISBOA A.V., FERREIRA M.G.G. et al. *Câncer de pele: uma revisão de literatura*. *Brazilian Journal of Implantology and Health Sciences*, v. 6, n. 4, p. 2493–2501, 2024. DOI: 10.36557/2674-8169.2024v6n4p2493-2501. Disponível em: <https://bjih.emnuvens.com.br/bjih/article/view/2017>. Acesso em: 24 ago. 2025.

MANNHEIMER, Walter A. *Microscopia dos materiais: uma introdução*. Editora E-papers, 2002.

MERMAID. *Diagramming and charting tool*. Disponível em: <https://mermaid.js.org/intro/>. Acesso em: 18 out. 2025.

MINISTÉRIO DA SAÚDE, *Câncer de pele*. Disponível em: <https://www.gov.br/saude/pt-br/assuntos/saude-de-a-a-z/c/cancer-de-pele>. Acesso em: 9 out. 2025.

MONARD, Maria Carolina; BARANAUSKAS, José Augusto. *Conceitos sobre aprendizado de máquina*. *Sistemas inteligentes-Fundamentos e aplicações*, v. 1, n. 1, p. 32, 2003.

MURPHY, K. P. *Machine Learning: A Probabilistic Perspective*. MIT Press, 2012.

NAWAZ, M. et al. *Skin cancer detection from dermoscopic images using deep learning and fuzzy k -means clustering*. *Microscopy Research and Technique*, 27 ago. 2021. Disponível em: <https://analyticalsciencejournals.onlinelibrary.wiley.com/doi/epdf/10.1002/jemt.23908>. Acesso: 19 mar. 2025.

NumPy. 2025. Disponível em: <https://numpy.org/>. Acesso em: 22 out. 2025.

O'SHEA, Keiron; NASH, Ryan. *An introduction to convolutional neural networks*. arXiv preprint arXiv:1511.08458, 2015.

OLIVEIRA, L. E. S. de; Silva, M. C. da; Santiago, R. V. C. de; Benevides, C. A.; Cunha, C. C. H.; Matos, A. G. *Diagnóstico da retinopatia diabética por inteligência artificial por meio de smartphone*. *Revista Brasileira de Oftalmologia*, v. 83, e0006, 2024. DOI: 10.37039/1982.8551.20240006. Disponível em: <https://www.rbojournal.org/article/diagnostico-da-retinopatia-diabetica-por-inteligencia-artificial-por-meio-de-smartphone/>. Acesso em: 18 out. 2025

ONCOGUIA. *Câncer de pele: FDA aprova 1º dispositivo portátil que ajuda a detectar o tumor*. 22 jan. 2024. Disponível em: <https://www.oncoquia.org.br/conteudo/cancer-de-pele-fda-aprova-1-dispositivo-portatil-que-ajuda-a-detectar-o-tumor/16934/7/>. Acesso em: 18 out. 2025.

OSÓRIO, Fernando; BITTENCOURT, João Ricardo *Sistema Inteligência baseados em Redes Neurais Artificiais aplicados ao Processamento de Imagens*. Universidade de Santa Cruz do Sul. 2000.

PACHECO, Andre GC et al. *PAD-UFES-20: A skin lesion dataset composed of patient data and clinical images collected from smartphones*. *Data in brief*, v. 32, p. 106221, 2020.

PANDAS. pandas documentation. 2025 — pandas 1.0.1 documentation. Disponível em: <<https://pandas.pydata.org/docs/>>.

PAULA FILHO, Wilson de Pádua. *Engenharia de software: fundamentos, métodos e padrões*. Rio de Janeiro: LTC, 2000.

PEREIRA, Adriano Diniz. *Redes neurais convolucionais para análise de mamografias*. 2025. Disponível em: <https://repositorio2.utfpr.edu.br/items/376b366a-3c29-436f-850d-cedda3315abe>. Acesso em: 9 out. 2025.

PEREYRA, G.; TUCKER, G.; CAI, W.; GIOVANNI, R.; HINTON, G.; CORTES, C. *Exploring Alternatives to Softmax Function*. arXiv preprint, 2020. Disponível em: <https://arxiv.org/abs/2011.11538>. Acesso em: 10 out. 2025.

PYTHON. *Welcome to Python.org*. 2025. Disponível em: <https://www.python.org/about/>. Acesso em: 18 out. 2025.

REACT NATIVE. React Native. *A framework for building native apps using React*. Disponível em: <https://reactnative.dev/>. Acesso em: 18 out. 2025.

RAUBER, Thomas Walter. *Redes neurais artificiais*. Universidade Federal do Espírito Santo, v. 29, p. 39, 2005.

RAWAT, W.; WANG, Z. *Deep convolutional neural networks for image classification: A comprehensive review*. Neural computation, MIT Press, v. 29, n. 9, 2017.

REN, Shaoqing. et al. *Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks*. arXiv, junho 2015. Disponível em: arXiv:1506.01497. Disponível em: <https://arxiv.org/abs/1506.01497>. Acesso em: 05 jul. 2025.

RENDER. *Cloud Application Hosting for Developers*. 2025. Disponível em: <https://render.com/docs>. Acesso em: 18 out. 2025.

RUSSEL, Stuart; NORVIG, Peter. *Inteligência artificial*. 2. ed. Rio de Janeiro: Campos, 2004.

RUSSELL, Stuart.; NORVIG, Peter. *Inteligência Artificial: Uma Abordagem Moderna*. 3. ed. Rio de Janeiro: Elsevier, 2013.

STORYBOOK. *Get started with Storybook | Storybook docs*. Disponível em: <https://storybook.js.org/docs>. Acesso em: 16 out. 2025.

SATHYA, P.; ABIRAMI, S.; RADHAKRISHNAN, K. *Soft-Max Activation Function For Neural Network Multi-Class Classifiers*. Karpagam Publications, 2018. Disponível em: <https://karpagampublications.com/wp-content/uploads/2018/09/Soft-Max-Activation-Function-For-Neural-Network-Multi-Class-Classifiers.pdf>. Acesso em: 10 out. 2025.

SCHERER, J. S. *Além da tecnologia: a inteligência artificial pode apoiar decisões clínicas na predição de sepse?* Revista Brasileira de Enfermagem, v. 75, n. 1, e20220204, 2022. Disponível em: <https://www.scielo.br/j/reben/a/pSqzrt33NQ3jCL6BHRHJ5XP>. Acesso em: 10 out. 2025.

SCHMITT, Juliano Vilaverde; MIOT, Hélio Amante. *Queratoses actínicas: revisão clínica e epidemiológica*. Anais Brasileiros de Dermatologia, v. 87, n. 3, p. 277–284, 2012. DOI: <https://doi.org/10.1590/S0365-05962012000300012>. Disponível em: <https://www.scielo.br/j/abd/a/PwJtf7XHVBpJSN9j7FVnLmH/?lang=pt>. Acesso em: 9 out. 2025.

SILVA, Rodrigo Emerson Valentim da. *Um estudo comparativo entre redes neurais convolucionais para a classificação de imagens*. 2018.

SIMÕES, Yanna Bosca Jezini et al. *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>. Acesso em: 9 out. 2025.

SHORTLIFFE, E. H. Computer-Based Medical Consultations: MYCIN. New York: Elsevier, 1976.

SICILIANO, B.; KHATIB, O. (eds.). Springer Handbook of Robotics. 2nd ed. Springer, 2016.

SZELISKI, R. Computer Vision: Algorithms and Applications. 2nd ed. Springer, 2022.

TANENBAUM, Andrew Stuart; STEEN, Marteen Van. *Sistemas distribuídos: princípios e paradigmas*. 2. ed. São Paulo, SP: Pearson, 2007. E-book. Disponível em: <https://plataforma.bvirtual.com.br>. Acesso em: 14 set 2025.

TensorFlow. Disponível em: <https://www.tensorflow.org/?hl=pt-br>. Acesso em: 22 out. 2025.

VALDATI, Aline de Brittos. *Inteligência artificial - IA*. 1. ed. São Paulo: Contentus, 2020. E-book.

VAZQUEZ, Vinicius de Lima. *Atlas de câncer de pele*. 1. ed. Barretos: Hospital de Amor, 2021. Disponível em: https://iep.hospitaldeamor.com.br/wp-content/uploads/2021/03/Atlas-de-Cancer-de-Pele_compressed.pdf. Acesso em: 9 out. 2025.

VIJAYALAKSHMI, M. M. et al. Melanoma Skin Cancer Detection using Image Processing and Machine Learning. International Journal of Trend in Scientific Research and Development (IJTSRD), v. 3, n. 4, p. 780–784, maio–jun. 2019. Disponível em: https://www.researchgate.net/publication/334123580_Melanoma_Skin_Cancer_Detection_using_Image_Processing_and_Machine_Learning. Acesso em: 06 jul. 2025.

VISUAL STUDIO CODE. Documentation for Visual Studio Code. Disponível em: <https://code.visualstudio.com/docs>. Acesso em: 18 out. 2025.

WANG, Xintao et al. *ESRGAN: Enhanced Super-Resolution Generative Adversarial Networks*. arXiv, 1 set. 2018. Última versão: 17 set. 2018. Disponível em: <https://arxiv.org/pdf/1809.00219>. Acesso em: 06 jul. 2025.

WAGIH, A. *Skin Cancer*. Kaggle. 2023a. Disponível em: <https://www.kaggle.com/code/abdallahwagih/skin-cancer/notebook>. Acesso em: 21 out. 2025.

WAGIH, A. *Skin Cancer Detection*. Kaggle. 2023b. Disponível em: <https://www.kaggle.com/code/abdallahwagih/skin-cancer-detection>. Acesso em: 21

out. 2025.

Waskom, M. L., (2021). seaborn: statistical data visualization. Journal of Open Source Software, 6(60), 3021, <https://doi.org/10.21105/joss.03021>. Acesso em: 13 Nov. 2025

YORADJIAN, Alessandra; CYMBALISTA, Natalia Cymrot; PASCHOAL, Francisco Macedo. *Queratose seborreica simuladora de melanoma. Surgical & Cosmetic Dermatology*, v. 3, n. 2, p. 169-171, 2011. Disponível em: <https://www.surgicalcosmetic.org.br/details/140/pt-BR>. Acesso em: 9 out. 2025.

ZHANG, Lei et al. *Edge-enhanced deep neural network for shaft surface defect detection*. Journal of Physics: Conference Series, v. 1911, n. 1, p. 012032, 2021. DOI: 10.1088/1742-6596/1911/1/012032. Disponível em: <https://iopscience.iop.org/article/10.1088/1742-6596/1911/1/012032/pdf>. Acesso em: 06 jul. 2025.

ZINK, Beatrix Sabóia. *Câncer de pele: a importância do seu diagnóstico, tratamento e prevenção*. Revista Hospital Universitário Pedro Ernesto, v. 13, 2014. Disponível em: <https://www.e-publicacoes.uerj.br/revistahupe/article/view/12256>. Acesso em: 9 out. 2025.