

ESCOLA SALESIANA SÃO JOSÉ
CENTRO PROFISSIONAL DOM BOSCO - CPDB

Skin Analyser AI

Uso de Inteligência Artificial para Classificação e Identificação de Câncer de Pele

Campinas, SP

2025



Claudinei Alves Pereira dos Reis
Miguel Afonso Castro de Almeida
Thallyson Kawan Lima Oliveira

Adriana Maia da Silva Coelho
Galesandro Henrique Capovilla

Skin Analyser AI

Uso de Inteligência Artificial para Classificação e Identificação de Câncer de Pele

Relatório apresentado à 9ª FEMIC - Feira Mineira
de Iniciação Científica.

Orientação do Prof. Adriana Maia da Silva
Coelho e coorientação de Galesandro Henrique
Capovilla .

Campinas, SP



2025

RESUMO

O câncer de pele representa o tipo de neoplasia mais incidente no Brasil, com cerca de 31,3% dos diagnósticos, evidenciando uma detecção precoce, um fator crucial para um prognóstico favorável, com taxas de tratamento superiores a 90%. Contudo, barreiras de acesso e a demora no diagnóstico no sistema público de saúde constituem desafios significativos. Diante desta problemática, o presente projeto teve como objetivo o desenvolvimento e a validação de uma solução computacional, materializada em um aplicativo móvel, para a classificação de lesões cutâneas por meio de uma inteligência artificial especializada. A metodologia empregou a arquitetura de deep learning, treinada e validada com um conjunto de dados consolidado a partir de fontes públicas (ISIC Archive). O modelo de IA alcançou um desempenho robusto, com uma acurácia global de 91%, superando a meta inicial de 90% para este indicador, e uma sensibilidade de 87% na detecção de lesões malignas. O desenvolvimento culminou no aplicativo móvel Skin Analyser AI e em um dashboard interativo para análise de KPIs durante o treinamento da IA. Os resultados obtidos até o momento confirmam a hipótese de que a inteligência artificial é uma ferramenta viável e de altas taxas de precisão (com ressalvas a possíveis erros) para a triagem de câncer de pele, com potencial para atuar como um sistema de apoio à decisão clínica, contribuindo para a democratização do diagnóstico precoce e otimização de recursos na saúde pública.

Palavras-chave: Câncer de Pele. Inteligência Artificial. Saúde Digital.



SUMÁRIO

1 INTRODUÇÃO	7
2 JUSTIFICATIVA	11
3 OBJETIVO GERAL	17
4 METODOLOGIA	18
4.1 Proposta de pesquisa	18
4.2 Considerações	18
4.3 Desenho de estudo	19
4.4 Contextualização e justificativa	20
4.5 Coleta e curadoria de dados	21
4.5.1 Aquisição de dados	21
4.5.2 Coleta e tratamento	23
4.6 Pre-processamento	26
4.6.1 Remoção de artefatos oclusivos	27
4.6.2 Uniformização de iluminação, cor e despigmentação	29
4.6.3 Redução de ruído e suavização estrutural	30
4.6.4 Realce de imagem, contraste e intensidade	31
4.6.5 Detecção e acoplamento de bordas	32
4.7 Fundamentos da segmentação no pipeline de diagnóstico	33
4.7.1 Geração da máscara de segmentação primária	34
4.7.2 Extração de características de forma (morfometria)	35



4.7.3 Extração de características de cor (Colorimetria)	35
4.7.4 Extração de características de textura (GLCM)	
36	
4.7.5 Exemplo de vetor de características extraídas	37
4.7.6 Geração de artefatos e orquestração de pipeline	39
4.8 Aumento de dados	39
4.8.1 Arquitetura de pipeline	40
4.8.2 Transformações geométricas e espaciais	41
4.8.3 Perturbações fotométricas e do espaço de cor	41
4.8.4 Simulação de ruído, borrões e imperfeições de captura	42
4.9 Arquitetura e desnevolvimento do modelo	43
4.9.1 Seleção	43
4.9.2 Backbones e Transferência de aprendizado	45
4.9.3 Estrutura	48
4.9.3.1 Camada de entrada	50
4.9.3.2 Ensemble de backbones	50
4.9.3.3 Agregação e fusão de características	51
4.9.3.4 Classificador central a partilhado e	52
4.9.3.5 Bloco de saída	52
4.9.3.6 Parâmetros	53
4.10 Métricas e estratégia de validação	54
5 RESULTADOS OBTIDOS	58
6 CONCLUSÕES OU CONSIDERAÇÕES FINAIS	61
7 REFERÊNCIAS	64
8 REFERÊNCIAS	87
7 Aplicativo	87





INTRODUÇÃO

O câncer é um dos principais desafios da saúde pública mundial, responsável por cerca de 10 milhões de mortes em 2020 (WHO). Embora avanços terapêuticos recentes tenham melhorado a sobrevivência de muitos pacientes, a cura universal para todos os tipos de câncer ainda não existe. No entanto, sabe-se que muitos cânceres podem entrar em período de remissão (significando que a doença está sob controle, mas com risco de recidiva) se detectados precocemente e tratados adequadamente. Isso torna a detecção precoce um fator-chave na redução da mortalidade, pois diagnósticos em estágios iniciais permitem tratamentos mais eficazes. Em resumo, a identificação rápida de tumores faz toda a diferença no prognóstico dos pacientes. No contexto brasileiro, o câncer de pele é o tipo de neoplasia mais incidente (gov.br). Dados do Instituto Nacional do Câncer (INCA) indicam que o câncer de pele não melanoma corresponde a cerca de 30% de todos os tumores malignos registrados no país. Em 2020, foram estimados aproximadamente 176.930 novos casos, sendo sua alta incidência associada à exposição excessiva à radiação solar (sendo acumulativa por toda a vida), sobretudo em pessoas de pele clara. Apesar de sua frequência, o câncer de pele não melanoma tem alta chance de cura quando tratado precocemente. Conforme orientações médicas, qualquer mudança suspeita na pele deve ser investigada imediatamente, pois "quanto mais precoce for sua identificação, melhores serão os resultados do tratamento" (gov.br). Contudo, o desafio central é que o acesso a dermatologistas no sistema público é limitado. Essa limitação gera longas esperas que atrasam o diagnóstico e, conseqüentemente, pioram o prognóstico, o que reforça a necessidade de soluções de triagem eficientes.

A triagem clínica tradicional para lesões pigmentadas, especialmente melanomas, é frequentemente baseada no critério mnemônico ABCDE (Assimetria, Borda, Cor, Diâmetro, Evolução) (aad.org). Contudo, este método é apenas um ponto de partida e possui limitações claras: é subjetivo e pode falhar em lesões atípicas, como melanomas amelanóticos (sem pigmento) ou nódulos em estágios iniciais. A dermatoscopia moderna, que inspira este projeto, vai além, exigindo a análise de uma morfologia complexa. É aqui que a ciência computacional se une à dermatologia. Ferramentas avançadas não avaliam apenas o ABCDE, mas quantificam microestruturas, padrões vasculares, redes



pigmentares atípicas e fenômenos como a despigmentação (regressão). Esses padrões morfológicos sutis são difíceis de avaliar a olho nu, mas são ideais para a análise por algoritmos. Essas características ajudam a distinguir melanomas de pintas benignas e orientam a classificação das lesões. O rastreamento contínuo e a análise cuidadosa seguem como método padrão para o diagnóstico de suspeitas; exames como dermatoscopia e biópsia confirmam o diagnóstico. Contudo, o acesso a especialistas nem sempre é fácil em todas as regiões do país, tornando o câncer de pele uma preocupação relevante para a saúde pública brasileira. A Inteligência Artificial (IA) refere-se a sistemas computacionais capazes de aprender, adaptar-se e executar tarefas complexas simulando alguns aspectos do raciocínio humano. Na prática, isso significa que algoritmos de IA podem reconhecer padrões em dados (como imagens, sinais clínicos e históricos de pacientes) e tomar decisões baseadas em experiências prévias de forma autônoma. No setor de saúde, a IA tem potencial transformador: ela pode acelerar diagnósticos, tornando-os mais precisos e disponibilizando-os em menor tempo. Além disso, ao automatizar tarefas administrativas rotineiras, a IA pode reduzir custos operacionais e liberar mais tempo dos profissionais para o cuidado direto ao paciente. Como observado em estudo recente do Ministério da Saúde, tecnologias de IA em saúde já contribuem para “atendimentos e diagnósticos mais rápidos e precisos, reduzindo custos e melhorando a experiência de pacientes e de profissionais” (bvsms.saude). Percebe-se o aumento de tecnologias implementadas com IA na área da saúde no aumento do financiamento de global para empresas de saúde digital, que em 2024 representou 42% do financiamento anual total para saúde (Statista, 2025) e digital, um aumento significativo em relação aos 7% do financiamento para saúde digital em 2015.

Recentes pesquisas científicas têm demonstrado que técnicas de aprendizado profundo podem ser extremamente eficazes na detecção de câncer de pele a partir de imagens. Vários estudos utilizaram Redes Neurais Convolucionais (CNNs) – modelos de IA especialmente desenhados para processamento de imagens – para classificar lesões cutâneas. Por exemplo, os estudos de Amanda V.C.A. (2024) e Liana C. (2020), no Brasil (Unicamp), demonstram considerações sobre as tecnologias que podem ser usadas para treinar um algoritmo (CNNs, GANs, KNN, ResNet) e como esses respectivos algoritmos podem atingir precisão comparável ou superiores à de dermatologistas especializados. Em seus estudos, abordam preocupações técnicas e éticas, desafios como a necessidade



de grandes bancos de dados balanceados e a interpretação dos resultados proporcionados pelo software pelos profissionais da saúde, para que sejam utilizados como uma ferramenta auxiliadora. Em outro estudo, de Musthafa et al. (2024), criaram um modelo CNN treinado com o conjunto de imagens dermatoscópicas HAM10000 e alcançaram uma acurácia de 97,78% na detecção de câncer de pele (pubmed). Similarmente, abordagens avançadas combinando CNNs e mecanismos de atenção relatam precisões superiores a 95% na classificação de melanoma (nature). Esses resultados indicam que algoritmos de IA bem treinados podem atingir níveis de desempenho comparáveis ou até superiores aos de dermatologistas experientes.

Diante deste cenário—um problema de saúde pública (alta incidência e barreiras de acesso) e uma solução tecnológica validada (IA na análise morfológica complexa)—, o projeto visa desenvolver um aplicativo móvel baseado em IA para identificação e classificação de câncer de pele por reconhecimento de imagens. Como estudo de caso, o projeto propõe iniciar pela análise de bibliografia especializada sobre câncer de pele e tecnologias de IA em saúde, buscando compreender o funcionamento das tecnologias emergentes. Posteriormente, será feita a implementação de um modelo de aprendizado profundo utilizando bases de dados dermatológicas, com o objetivo de buscar uma precisão diagnóstica de pelo menos 90% nos testes. A etapa seguinte envolverá a validação da ferramenta em ambiente de atenção primária, por meio de parcerias com instituições especializadas e seus respectivos especialistas, a fim de validar o modelo de IA. Por fim, o projeto busca democratizar o acesso ao diagnóstico precoce, disponibilizando uma solução de baixo custo que complemente a avaliação médica e acelere a detecção de lesões suspeitas. Em conjunto, essas ações deverão demonstrar o potencial da IA em facilitar o diagnóstico de câncer de pele, especialmente em regiões com escassez de especialistas. Espera-se que, ao indicar precocemente lesões suspeitas, o aplicativo ajude a encaminhar pacientes rapidamente aos tratamentos adequados, reforçando que tecnologias emergentes podem ampliar o acesso ao diagnóstico dermatológico e, desse modo, reduzir o impacto do câncer de pele na população.



2 JUSTIFICATIVA

O câncer é uma doença caracterizada pelo crescimento descontrolado de células anormais, capazes de invadir tecidos adjacentes e causar metástases. No Brasil, observa-se o aumento expressivo dos casos. Segundo dados do INCA, estima-se cerca de 704 mil novos casos de câncer por ano no triênio 2023–2025, onde aproximadamente 70% desses casos ocorrerão nas regiões Sul e Sudeste. Essa previsão reflete tanto o envelhecimento populacional quanto fatores de risco prevalentes (como urbanização, tabagismo e obesidade). Entre os tipos mais incidentes estão o câncer de pele não melanoma (o mais comum), de mama e próstata. Em termos de prognóstico, tumores malignos (câncer) diferem de tumores benignos por serem invasivos e agressivos, enquanto os tumores benignos crescem lentamente e raramente se espalham para outra parte do corpo, as células malignas invadem tecidos próximos e/ou à distância, sendo denominados câncer. Essa dinâmica favorece o surgimento de metástases, processo em que células cancerosas se desprendem do tumor original, entram na circulação sanguínea ou linfática e formam novos tumores em outras partes do corpo.

Grande parte dos casos de câncer está associada a fatores ambientais e comportamentais. Estima-se que 80–90% dos cânceres têm relação com causas externas, como hábitos de vida e exposições ambientais. Dentre os principais fatores de risco destacam-se:

Exposição solar excessiva: a radiação ultravioleta (UV) é o principal fator de risco para câncer de pele. No Brasil, com clima tropical e grande exposição ao sol, a incidência de lesões cutâneas suspeitas aumenta consideravelmente. A radiação UV é acumulativa por toda vida, significa que toda a exposição a raios solares durante sua vida pode favorecer a proliferação de um câncer de pele.

Hábitos não saudáveis: tabagismo, consumo abusivo de álcool, sedentarismo, dieta pobre em nutrientes e obesidade são amplamente reconhecidos como contribuidores de diversos tipos de câncer.

Histórico familiar e predisposição genética: alterações hereditárias em genes (oncogenes e supressores tumorais) podem tornar alguns indivíduos mais suscetíveis à carcinogênese. No entanto, casos exclusivamente genéticos são raros (10–20% dos casos), indicando que a maior parte é provocada por causas externas.



Contato com agentes carcinógenos: substâncias químicas nocivas (ex.: pesticidas, solventes industriais, poluentes) e certos vírus (como HPV) podem induzir mutações no DNA celular. O processo de formação do câncer (carcinogênese) envolve múltiplas etapas: iniciação (mutação no DNA), promoção (agentes promotores fazem a célula iniciada evoluir para malignidade) e progressão (proliferação descontrolada e estabelecimento do tumor). Fumo de tabaco, por exemplo, é um agente carcinógeno completo que atua em todas essas fases.

No estágio inicial, o câncer pode apresentar sinais sutis ou inespecíficos, variando conforme localização e tamanho do tumor. Em cânceres de pele, por exemplo, carcinomas (tumores originários do epitélio) correspondem à maioria dos casos, enquanto melanomas (tumores de melanócitos) são menos frequentes, mas notoriamente agressivos. Os melanomas surgem geralmente como pintas ou manchas assimétricas e pigmentadas, que crescem e mudam rapidamente – características que exigem atenção imediata. Embora esses sinais sejam visíveis, podem ser confundidos com outras lesões benignas ou condições de pele. Além disso, muitas pessoas postergam a busca por atendimento por acreditarem que o sintoma não apresente um perigo real ou por medo do diagnóstico. Quando o câncer atinge estágios avançados, é comum a disseminação por metástase: nesse caso, células cancerosas viajam pela corrente sanguínea e/ou linfática e implantam tumores em órgãos distantes. Por isso, a detecção precoce é crucial para melhorar o prognóstico.

Vários fatores dificultam o diagnóstico precoce no contexto brasileiro. A desigualdade na distribuição de recursos de saúde faz com que regiões remotas ou menos desenvolvidas tenham menor acesso a especialistas e exames avançados, causando atrasos significativos. Muitas vezes, pacientes de baixa renda não dispõem de recursos para exames particulares e enfrentam longas filas na rede pública. Além disso, procedimentos de imagem como tomografia e ressonância são caros e nem sempre disponíveis (além de exigirem indicação clínica precisa). Essas barreiras socioeconômicas e logísticas resultam em diagnósticos tardios, agravando a taxa de mortalidade. Por exemplo, mesmo exames preventivos simples (como exames dermatológicos de rotina) podem ser negligenciados por falta de informação, infraestrutura ou receio dos pacientes, levando à piora da doença antes do tratamento adequado.



Diante desse cenário, propõe-se o desenvolvimento de um software de inteligência artificial para triagem de lesões de pele. O objetivo é democratizar o acesso à análise inicial de possíveis sinais de câncer cutâneo, integrando algoritmos de visão computacional a imagens de dermatologia. Funciona assim: um profissional de saúde captura imagens de manchas ou lesões suspeitas, e o sistema analisa padrões (Regra do ABCDE - Assimetria, Bordas irregulares, Cores variadas, Diâmetro (maior que 6mm) e Evolução (mudanças em tamanho, cor, forma ou sintomas); Regra EFG - Elevação, Firmeza ao toque, “Growth“ / crescimento) para sinalizar indícios precoces de melanoma ou outros cânceres de pele. Dessa forma, busca-se reduzir diagnósticos incorretos ou despercebidos, encaminhando casos suspeitos para avaliação médica mais célere. Importante destacar que o software não substitui o diagnóstico médico definitivo nem a biópsia; ele atua como ferramenta de apoio estatístico, reforçando a precaução do especialista ao propor exames complementares quando necessário.

Essa abordagem apoia-se em bases de dados já existentes: instituições como a ISIC Archive mantêm grandes acervos públicos de imagens dermatoscópicas. Ou seja, há farto material de treinamento disponível para a inteligência artificial reconhecer características cancerígenas. O software pode ser validado em parceria com clínicas e hospitais, comparando seus resultados às avaliações de dermatologistas experientes.

Entre as ações-chave do projeto incluem-se:

Coleta e padronização de imagens de lesões de pele (fotografias de nevus, manchas, pintas, etc.).

Treinamento de modelo de IA usando bases públicas de imagens de câncer de pele.

Avaliação clínica da acurácia do sistema em identificar lesões suspeitas, comparando com laudos histopatológicos.

O projeto segue rigorosamente as diretrizes éticas da medicina. Segundo o Código de Ética Médica (CEM 2019), o médico deve “empregar seu conhecimento e o melhor progresso científico em benefício do paciente” (Morsch), atuando sempre no interesse deste e evitando causar danos (princípio da não maleficência). Nesse sentido, a ferramenta de IA é concebida como apoio complementar (não substituirá o médico). Está previsto no CEM que o clínico deve usar “todos os meios disponíveis de promoção de saúde e de prevenção, diagnóstico e tratamento de doenças, cientificamente reconhecidos e ao seu



alcance”. Isso inclui recursos tecnológicos validados – nosso software entra nessa categoria.

Para garantir segurança, o uso do sistema será restrito a ambientes clínicos e ao crivo de especialistas. O CEM também enfatiza o “respeito absoluto pelo ser humano” e a busca contínua de aprimoramento profissional. Assim, o projeto não ignora que a IA pode falhar (por exemplo, apresentar um 1% de margem de erro), mas entende essa limitação dentro de uma estratégia segura: resultados automáticos serão sempre confirmados por médicos. Não haverá tentativa de “diagnóstico automatizado” sem supervisão. Pelo contrário, ao destacar possíveis riscos, a ferramenta permite que o médico decida, de forma mais informada, pela realização de exames invasivos (biópsia) ou por vigilância apenas, minimizando exaustão de exames desnecessários. Em suma, a proposta prioriza o paciente: respeita as normas do CFM e reforça a empatia, lembrando que erro de diagnóstico precoce pode causar insegurança (art. 2º Cap. I), mas, ao mesmo tempo, mostra comprometimento com a saúde (art. 31 Cap. V).

O avanço recente em inteligência artificial e o maior acesso a bases de dados possibilitam esse desenvolvimento. Redes neurais para imagens estão cada vez mais potentes e rápidas, e bancos de imagem dermatológica (como o ISIC Archive) oferecem cenários reais para treinar e testar algoritmos. Espera-se parceria com universidades e institutos de saúde para fortalecer o treinamento e validar o sistema em ambiente clínico.

As metas de desempenho do software são ambiciosas, porém baseadas em resultados já alcançados: almeja-se sensibilidade superior a 93% (detectando cerca de 93% dos melanomas) e especificidade próxima a 91% (identificando 91% das lesões benignas corretamente), com acerto geral superior a 90%. Isso se assemelharia a índices de projetos similares: por exemplo, um estudo clínico recente mostrou que um CNN aprovado para dermatoscopia atingiu aproximadamente 95% de sensibilidade e 76.7% de especificidade em uma ampla variedade de lesões. Outro estudo prospectivo demonstrou que, com cooperação médico-máquina, foi possível melhorar sensibilidade e especificidade em relação ao médico sozinho (Julia K. Winkler). Nosso projeto busca ir além: não apenas atingir esses patamares, mas também reduzir custos. Uma estimativa inicial sugere que o sistema possa ser mantido por cerca de US\$24 por usuário – valor muito inferior aos custos individuais de exames de imagem de alta complexidade.



Diante do crescimento contínuo do câncer e das dificuldades de acesso ao diagnóstico precoce no Brasil, a ferramenta proposta preenche uma lacuna estratégica. Ao antecipar a identificação de lesões suspeitas em estágios iniciais, promove-se triagem mais eficaz, permitindo encaminhamentos rápidos e tratamentos mais precoces. Mesmo que não atinja 100% de precisão, a combinação do software com a avaliação humana amplia a acurácia: em estudos, a cooperação entre dermatologista e IA tem mostrado melhorar o desempenho diagnóstico. Em outras palavras, o sistema oferece “insights precisos na triagem de pacientes”, aumentando a confiança do especialista e contribuindo para salvar vidas. Como afirma estudo do JAMA Dermatology, “os dermatologistas podem melhorar sua performance ao cooperarem com a rede neural”, o que reforça nosso propósito de fortalecer (e não substituir) o exame clínico.

Em síntese, a justificativa deste plano de ação une dados epidemiológicos (INC aumenta no país), contexto socioeconômico (difícil acesso e custos elevados), fundamentação biológica (carcinogênese e sinais clínicos) e princípios éticos (CEM). O resultado esperado é um software acessível e seguro, capaz de agilizar o caminho do paciente até o diagnóstico definitivo. Além de respeitar normas e o ato médico exclusivo, o projeto estabelece uma prática de triagem inovadora – tornando a prevenção e o diagnóstico mais democráticos, eficientes e alinhados à ética profissional.



3 OBJETIVOS

3.1 Objetivo geral

Desenvolver uma solução computacional (Software) baseada em inteligência artificial (IA) aplicada em um aplicativo móvel para a identificação e diagnóstico do câncer de pele a partir da análise automatizada de imagens dermatológicas, com o objetivo de identificar padrões visuais compatíveis com diferentes tipos de câncer de pele, visando auxiliar profissionais de saúde no diagnóstico precoce, fornecendo informações de apoio à tomada de decisão médica.

3.2 Objetivos específicos

- A. Identificar e classificar os atributos clínicos e visuais das lesões cutâneas que servem como indicadores discriminativos entre o câncer de pele e outras patologias dermatológicas benignas.
- B. Projetar e otimizar um modelo de inteligência artificial para a análise automatizada de imagens dermatológicas, com foco na maximização da acurácia na detecção de câncer de pele.
- C. Prover suporte a profissionais da saúde na detecção precoce do câncer de pele, por meio da utilização de ferramentas baseadas em inteligência artificial.
- D. Avaliar a eficácia do sistema desenvolvido na classificação de lesões cutâneas, utilizando indicadores de desempenho como acurácia, sensibilidade e especificidade para validar a confiabilidade do modelo.



4 METODOLOGIA

4.1 Proposta de pesquisa

O presente trabalho consiste na disponibilização de uma Inteligência Artificial baseada em Deep Learning para auxiliar na detecção precoce de câncer de pele a partir de imagens dermatológicas. O objetivo é aprimorar a triagem no tratamento, uma vez que a alta incidência de câncer de pele e as dificuldades no diagnóstico precoce representam um desafio significativo. Quando o diagnóstico é feito tardiamente, podem ocorrer complicações graves, já que o aumento de tumores em estágios avançados torna o tratamento mais difícil.

A questão central que orienta este estudo é como desenvolver e treinar uma IA capaz de analisar imagens de lesões de pele e distinguir, em uma taxa elevada, entre lesões benignas e malignas. Para responder a essa questão, são adotados dois caminhos principais. Primeiro, uma pesquisa bibliográfica que sintetiza pesquisas existentes sobre conceitos fundamentais relacionados ao câncer de pele, algoritmos de Machine Learning e áreas médicas correlatas. Em seguida, o método de engenharia foca na elaboração uma solução para o auxílio à profissionais no diagnóstico de câncer de pele, utilizando um modelo de Deep Learning, especificamente Redes Neurais Convolucionais. Essas redes são escolhidas por sua capacidade de interpretar dados visuais complexos e aumentar a eficiência no reconhecimento e classificação de imagens. A abordagem combina fundamentos teóricos e práticos, buscando resultados concretos por meio do treinamento da máquina. O objetivo é oferecer uma solução para um problema real, com potencial para ser avaliada por médicos e possivelmente implementada em clínicas.

4.2 Considerações éticas e metodologia

A prioriza-se de uma atuação em questões éticas por parte de garantir a privacidade das imagens e dos dados dos pacientes, que terar seu sigilosos para casos de da testagem da inteligência artificial, evitando impactos diretos e minimizar vieses não aceitos pelo outro lado. A sua elaboração constituiu até o instante de natureza de pesquisa e aplicada, buscando uma solução prática que possa ser avaliada e, potencialmente,



utilizada em ambientes clínicos. Sua viabilidade depende de sua utilidade na prática, especialmente por tratar de um problema real.

Para reforçar a capacidade de detecção e análise dos registros de lesões cutâneas, o estudo propõe uma abordagem mista para a coleta de dados, utilizou-se de tanto fontes secundárias quanto na busca por uma questão incorporar em âmbito primárias, demonstrado incansável por questões de não sermos especialista na área médica e as preocupações de aumentar as tensões de uma pessoa com problemas maiores que se acumularia e aumentaria sua sanidade. Primeiramente, são utilizadas fontes secundárias, como repositórios clínicos e acadêmicos, que contêm registros de lesões dermatológicas já classificadas. Esses bancos de dados fornecem informações importantes sobre características das lesões, como grau de malignidade e padrões morfológicos, possibilitando o desenvolvimento e a validação de modelos de CNNs.

Adicionalmente, se for viável para próximos passos futuros, a possibilidade de uma possível coletar dados de forma primária, seria o ideal para validação do modelo, ao captar imagens em ambiente de laboratório. A captura requer da desmobilizar de ferramentas de câmeras digitais ou microscópios adaptados para garantir a resolução, iluminação e fidelidade visual necessárias, complementando os bancos de dados existentes com fontes locais para maior representatividade. A integração dos dados secundários com dados primários tem como prever um objetivo da melhora da precisão de acerto, o que tornaria uma possível uma análise mais minuciosa das variações morfológicas entre os distintos tipos de lesões.

4.3 Desenho de estudo

O desenho deste estudo é delineado como uma pesquisa de validação de modelo retrospectiva, utilizando um método de coleta e análise misto. Esta abordagem combina dados não numéricos, como imagens de lesões de pele já coletadas e anotadas por especialistas, com dados numéricos, como métricas de desempenho (precisão, sensibilidade e especificidade). A escolha por uma pesquisa retrospectiva é pragmática, visto que os dados têm a capacidade de mostrar mais informações e sua distinção ajuda na sua compreensão, pois permite o acesso a um vasto volume de dados curados, o que seria financeiramente e logisticamente desafiador em um estudo prospectivo.



A metodologia se concentra na aplicação e validação de técnicas de aprendizado profundos, encaixando-o no formato de engenharia, devido de ir além de uma pesquisa e focando em um protótipo capaz de resolver uma resolução estabelecida, encaixando nos desafios de o baixo custo, pensamento dos cenários brasileiros e da falta disponibilização de especialista.

Apesar da solidez da abordagem retrospectiva, ela impõe limitações que serão abordadas. A variabilidade inerente às imagens do mundo real, como iluminação inconsistente, artefatos de dispositivos e a diversidade de tons de pele, pode não estar totalmente representada nos conjuntos de dados públicos. Para garantir que o modelo não apenas demonstre alta acurácia em um ambiente controlado, mas também tenha potencial para um desempenho robusto em ambientes clínicos complexos, a metodologia será ajustada. Isso inclui o pré-processamento de dados e técnicas de aumento de dados para introduzir variabilidade no conjunto de treinamento.

4.4 Contextualização e justificativa

O câncer de pele, em suas diversas formas, representa uma das mais altas incidências de neoplasias malignas em todo o mundo. A detecção precoce de lesões suspeitas, como o melanoma, é fundamental para o sucesso do tratamento e para a redução da mortalidade. No entanto, o diagnóstico preciso de lesões cutâneas é um desafio complexo que exige a especialização de dermatologistas, um recurso escasso em muitas regiões e sistemas de saúde a alta demanda de concentração de pacientes e de falsos possíveis casos de câncer de pele. A sobrecarga de trabalho e a variação na experiência clínica entre diferentes profissionais podem levar a diagnósticos tardios ou, inversamente, a biópsias desnecessárias de lesões benignas. A capacidade de uma ferramenta de triagem automatizada, alimentada por inteligência artificial (IA), para atuar como um "segundo par de olhos" para médicos generalistas ou para auxiliar no fluxo de trabalho clínico em ambientes remotos, representa uma oportunidade significativa para aprimorar a saúde pública.

A IA, especificamente por meio de modelos de aprendizagem profunda, oferece uma solução promissora para este desafio. Ao analisar e classificar imagens dermatoscópicas, um modelo computacional pode identificar padrões sutis que podem ser



imperceptíveis ao olho humano ou que requerem um alto nível de treinamento para reconhecimento. A proposta desta pesquisa não é substituir a avaliação clínica de um especialista, mas sim desenvolver um sistema de apoio à decisão que aumente a eficiência diagnóstica, priorizar casos de maior risco e, em última análise, melhorar os resultados para os pacientes. A medida de sucesso para esta metodologia não se restringe à acurácia técnica, mas se estende à sua utilidade clínica, confiabilidade e aceitação pelos profissionais de saúde. Ao enquadrar o modelo como uma ferramenta de auxílio, o projeto se alinha com as melhores práticas de integração tecnológica em ambientes de alta criticidade, garantindo que a segurança do paciente seja a consideração primordial em cada etapa do desenvolvimento e validação.

4.5 Coleta e curadoria de dados

4.4.1 Aquisição de dados

A metodologia de pesquisa adota uma estratégia de fusão de dados, combinando múltiplos conjuntos de dados públicos para maximizar a diversidade e o volume de imagens, separando-os, organizando-os, normalizando-os e gerando um link público da imagem para a facilitação do treinamento. Esta abordagem é essencial para treinar um modelo de aprendizado profundo que seja generalizável e robusto a uma variedade de condições de captura e populações. Os seguintes conjuntos de dados serão utilizados:

ISIC Archive: Este é o maior e mais abrangente arquivo de imagens de câncer de pele, atuando como a principal fonte de dados para o treinamento do modelo base. Sua vasta escala e diversidade de imagens fornecem uma base sólida para que o modelo aprenda as características gerais de lesões cutâneas.

HAM10000: Este conjunto de dados, contendo 10.015 imagens de lesões dermatoscópicas, é um dos benchmarks mais utilizados na literatura. Será crucial para o aprendizado por transferência e para a validação comparativa do desempenho, permitindo que a pesquisa se posicione em relação a trabalhos anteriores.

PAD-UFES-20: Um conjunto de dados de 2.298 imagens de lesões dermatoscópicas e clínicas coletadas em um hospital universitário brasileiro, representando uma população e um contexto geográfico específicos. Este dataset é de valor inestimável para testar a capacidade de generalização do modelo para diferentes



tons de pele, padrões de lesões e condições ambientais, mitigando o viés potencial de conjuntos de dados predominantemente ocidentais. A inclusão deste conjunto de dados reflete o reconhecimento de que a distribuição de classes, tons de pele e artefatos pode ser significativamente diferente em contextos geográficos distintos.

Uma vez que as imagens foram capturadas usando uma variedade de dispositivos, incluindo dermatoscópios, câmeras digitais e smartphones, a metodologia deve ser projetada para lidar com a variabilidade inerente a essas condições.

A fusão desses datasets não é um processo trivial e exige uma estratégia cuidadosa para padronizar os rótulos e as características de imagem, descartando dados com imagens ou dados que não estão devidamente rotuladas ou não há uma imagem correspondente ao seu metadata. O conjunto de dados final para validação se constrói com imagens provenientes de uma fonte independente (ISIC), disponibilizando datasets especializados para validação, para medir a generalização imparcialmente.

Tabela 1: Resumo dos Conjuntos de Dados Públicos

Nome do Dataset	Número de Imagens	Tipo de Imagem	Tipos de Anotação	Fonte
HAM10000	11.377	Dermatoscópica	Clínica, Histopatológica	https://api.isic-archive.com/collections/212/
BCN20000	18.933	Dermatoscópica	Microscopia Confocal, Histopatológica	https://api.isic-archive.com/collections/249/



Challenge 2017: Validation	150	Dermatoscópica	Histopatológica	https://api.isic-archive.com/collections/71/
Challenge 2018: Task 1-2: Validation	100	Dermatoscópica	Histopatológica	https://api.isic-archive.com/collections/62/
Challenge 2018: Task 3: Validation	193	Dermatoscópica	Microscopia Confocal, Histopatológica	https://api.isic-archive.com/collections/73/
Challenge 2019: Training	25.094	Dermatoscópica	Microscopia Confocal, Histopatológica	https://api.isic-archive.com/collections/65/



Challenge 2020: Training	33,126	Dermatoscópica	Histopatológica	https://api.isic-archive.com/collections/70/
--------------------------	--------	----------------	-----------------	---

4.5.2 Coleta e tratamento

Para o processo de anotação, a escolha da ferramenta de software é uma consideração logística importante. Embora ferramentas como o LabelImg sejam adequadas para rotulagem em escala de laboratório, e o VIA (VGG Image Annotator) ofereça a flexibilidade de ser baseado em navegador, a metodologia recomenda o uso do CVAT (Computer Vision Annotation Tool) para um ambiente de colaboração rigorosa. O CVAT é uma ferramenta robusta que suporta múltiplos anotadores e um fluxo de trabalho de consenso, o que é fundamental para a curadoria de dados em um contexto de pesquisa multi-anotador.

O protocolo de rotulagem exige que cada imagem seja revisada e rotulada por pelo menos dois dermatologistas independentes. Essa abordagem é crucial para garantir a precisão dos dados, um componente essencial da pesquisa. Reconhecendo a variedade de bancos de dados disponíveis e como isso impacta a necessidade de um alto grau de rigor. Focando em não só apenas distinguir a malignidade de uma imagem, mas ir além, fornecendo diagnósticos detalhados.

Os recursos disponíveis, como os dados de diagnóstico da International Skin Imaging Collaboration (ISIC), são a base para essa abordagem. No entanto, ao tentar adotar as tabelas de diagnóstico da ISIC, em especial no subconjunto HAM10000, encontra-se um desafio: a disparidade de diagnósticos entre diferentes bases de dados. A ISIC fornece um conjunto de classes bem definidas que diferencia as imagens em tipos de câncer de pele (melanoma, carcinoma basocelular, carcinoma espinocelular) e doenças de pele benignas (nevus, ceratose benigna, lentigo actínico, hemangioma, dermatofibroma e lesão vascular).



Para resolver essa questão, utilizamos os diagnósticos fornecidos por múltiplos especialistas, onde o diagnóstico 1 se refere à avaliação inicial e o diagnóstico 2 a uma segunda avaliação. A partir desses dados, podendo chegar a um diagnóstico central e resolver discrepâncias usando uma árvore de decisão que verifica ambas ou mais condições.

O ideal seria de dados a partir de dois ou mais dermatologistas independentes. Em caso de qualquer discordância entre as anotações, um terceiro especialista sênior ou um painel de consenso responsável por arbitrar e fornecer o rótulo final. O investimento de tempo e recursos em um protocolo de anotação rigoroso é uma etapa crítica que frequentemente é subestimada, mas decisiva para o sucesso do projeto. Um modelo complexo treinado em dados com rótulos inconsistentes ou incorretos terá um desempenho inferior e, no contexto clínico, pode levar a conclusões errôneas, comprometendo a segurança do paciente.

A qualidade e a consistência dos rótulos (ground truth) são os alicerces de qualquer projeto de aprendizado de máquina em medicina. Embora os conjuntos de dados públicos já venham com anotações, uma verificação e curadoria adicionais são essenciais para garantir a integridade dos dados. A metodologia proposta reconhece a necessidade de envolvimento de especialistas, como dermatologistas, no processo de anotação e validação para garantir o mais alto nível de precisão diagnóstica.

Para evitar problemas com outros bancos de dados que possuem arquiteturas de rotulagem diferentes da ISIC, como o banco de dados PH2, torna-se o uso de uma decisão estratégica. O PH2, originado do Hospital Pedro Hispano (Matosinhos, Portugal), divide suas imagens em apenas três categorias: nevos comuns, nevos atípicos e melanomas.

Essa classificação é muito mais simplificada do que a do ISIC, que oferece uma gama mais ampla de sete categorias. A diferença na granularidade da rotulagem torna os dados do PH2 menos adequados para o objetivo idealizado, que é uma classificação mais detalhada.

Portanto, minimizando a inconsistência entre as granularidades de rotulagem do ISIC e do PH2, evitando assim um re-treinamento custoso ou a reengenharia da última camada do modelo. Em vez disso, a adoção de uma técnica de Output Masking, também referida como Logit Masking, um método eficiente de Transfer Learning. O modelo é inicialmente treinado de forma exaustiva com os dados do ISIC para aprender



a classificar as sete classes originais. Subsequentemente, os pesos da rede são "congelados", preservando todo o conhecimento adquirido. A máscara de saída é então aplicada, que, ao zerar os logits das classes irrelevantes para o PH2, direciona a atenção do modelo apenas para as categorias de interesse (nevus comuns, nevus atípicos e melanoma). A reaplicação do softmax sobre esse subconjunto garante que a distribuição de probabilidade seja renormalizada coerentemente. Essa abordagem se destaca por sua reversibilidade e pela capacidade de integrar novos dados incrementalmente, sem a necessidade de um re-treinamento completo, otimizando o uso de recursos computacionais e preservando o conhecimento latente do modelo.

Complementarmente, diante da escassez de dados para certas classes, a busca por uma exploração a aplicação das Redes Generativas Adversárias (GANs) para a síntese de novas imagens. A arquitetura da GAN, composta por um Gerador e um Discriminador em um jogo de soma-zero, permite a criação de exemplos sintéticos de alta fidelidade. O Gerador aprende a produzir imagens que imitam a distribuição de dados do conjunto original, enquanto o Discriminador atua como um crítico, tentando distinguir as imagens geradas das reais. Esse processo competitivo aprimora a qualidade da saída do Gerador, permitindo que as imagens sintéticas sejam indistinguíveis das originais. Essa estratégia é crucial para equilibrar o conjunto de dados, especialmente para classes minoritárias, melhorando a capacidade de generalização do modelo e sua robustez em cenários clínicos com casos raros.

4.6 Pre-processamento

O pré-processamento de dados constitui uma fase crítica, principalmente, devido ao cuidado meduloso em relação em como as imagens são alteradas de seu original, tentando manter e fazendo o teste em cada parte, evitando erros ou sobreposição de aplicabilidade de mudanças de alto risco para entedimento da IA e metodologicamente, na rica na engenharia de sistemas de aprendizado de máquina para diagnóstico por imagem. Esta etapa vai além de aplicar a limpeza, implementando uma sequência de transformações matemáticas e algorítmicas, convertendo as imagens brutas em um formato otimizado, maximizando a extração de características irrelevantes e a melhora



na performance do modelo. Sua importância fundamental reside na capacidade de generalização do modelo e na mitigação do overfitting.

A generalização referindo à habilidade do modelo de aplicar seu conhecimento a dados não vistos, um requisito indispensável para tirar fatores que entram no caminho da codificação e análise de pixels. O overfitting, por outro lado, é o fenômeno deletério no qual o modelo se especializa excessivamente nos dados de treinamento, memorizando ruídos, por exemplo, como as questões de pelos, reflexos de luz e artefatos de compressão, ao em vez de aprender os padrões patológicos subjacentes. O pipeline de pré-processamento aqui detalhado funciona como a principal linha de defesa contra essa falha, garantindo que a aprendizagem seja focada em características dermatoscópicas robustas, pavimentando o caminho para um sistema de inteligência artificial preciso, seguro e confiável.

4.6.1 Remoção de artefatos oclusivos

A presença de artefatos oclusivos, notadamente os pelos, sobre a lesão dermatoscópica representa um desafio computacional significativo. Estas estruturas não são apenas ruído aleatório; são elementos lineares estruturados que podem ser erroneamente interpretados pelo modelo como características patológicas, como uma rede pigmentar atípica ou bordas irregulares, induzindo a um diagnóstico incorreto. A remoção precisa e a reconstrução coerente dessas áreas são, portanto, uma etapa indispensável para a integridade da análise subsequente. As técnicas empregadas para esta finalidade baseiam-se em operações de morfologia matemática, uma teoria não linear de processamento de imagens que analisa a geometria das estruturas através da interação com um padrão predefinido conhecido como elemento estruturante.

A metodologia implementa-se com a biblioteca OpenCV, sendo a principal ferramenta para a detecção de pelos escuros a Transformada Morfológica Black-Hat. Esta operação é projetada para isolar elementos escuros que são menores que o elemento estruturante (B), cuja geometria (e.g., elíptica ou retangular) e dimensões são hiperparâmetros ajustados para corresponder à espessura esperada dos pelos. O processo inicia-se com a aplicação de uma operação de fechamento morfológico (`cv2.morphologyEx` com `cv2.MORPH_CLOSE`), que é em si uma composição de uma



dilatação seguida por uma erosão. A dilatação expande as regiões claras da imagem, enquanto a erosão subsequente as contrai, com o efeito líquido de preencher pequenas lacunas escuras e conectar componentes próximos. O fundamento matemático da transformada reside na diferença entre a imagem após o fechamento e a imagem original: $\text{BlackHat}(A) = \text{close}(A, B) - A$. A subsequente subtração pixel a pixel resulta em uma imagem residual que contém apenas os elementos escuros que foram "preenchidos" ou significativamente alterados pela operação de fechamento, isolando eficazmente os pelos como uma máscara binária de alta precisão.

Uma vez gerada a máscara de artefatos, a reconstrução da área ocluída é realizada através da técnica de inpainting, especificamente o algoritmo de Alexandru Telea, invocado por meio da função `cv2.inpaint` com a flag `cv2.INPAINT_TELEA`. Este método baseia-se no Fast Marching Method (FMM), que propaga a informação de cor e textura da fronteira da área a ser preenchida para o seu interior. Para cada pixel a ser reconstruído, o algoritmo calcula uma soma ponderada dos pixels vizinhos já conhecidos. Os pesos são uma função da distância euclidiana, da direção do gradiente na fronteira e da distância geodésica ao contorno. Este processo garante a continuidade das estruturas e texturas da pele subjacente na região reconstruída, evitando a introdução de artefatos de suavização e preservando a fidelidade visual da lesão.

Figura 1: Imagem original de uma doença de pele do tipo nevus melanocítico



Fonte: Autoria própria (2025).



Figura 2: Imagem sem pelo a partir da imagem original



Fonte: Autoria própria (2025).

4.6.2 Uniformização de iluminação, cor e despigmentação

As variações fotométricas, resultantes de diferentes condições de iluminação e calibrações de sensores, são uma fonte primária de variância indesejada nos dados, podendo induzir o modelo a aprender correlações espúrias baseadas no equipamento de captura em vez de nas características patológicas. Esta fase do pipeline aborda essa questão através de uma normalização robusta e multifacetada.

Para a Normalização de Iluminação, implementa-se o algoritmo Shades-of-Gray, que se baseia em uma generalização da hipótese do "Mundo Cinza" (Gray-World). A premissa é que a refletância média de uma cena natural, integrada em todo o espectro visível, é acromática. O algoritmo generaliza esta hipótese calculando a norma de Minkowski de ordem p para cada canal de cor k , dada por:

$$\left(\frac{1}{N} \sum_{i=1}^N I_{k,i}^p \right)^{1/p}$$

onde I_k são os valores de intensidade do canal e N é o número total de pixels. Em seguida, derivam-se fatores de escala para equalizar essas normas entre os canais, corrigindo eficazmente as dominantes de cor. A implementação utiliza a biblioteca NumPy para realizar estes cálculos de forma eficiente.



Para a Normalização de Cor, adota-se a técnica de Reinhard, que visa padronizar o perfil cromático das imagens para corresponder a uma imagem de referência, eliminando a variabilidade entre diferentes dispositivos. O método opera no espaço de cor CIELAB, que é projetado para ser perceptualmente uniforme, significando que diferenças numéricas nos valores de cor correspondem aproximadamente a diferenças percebidas pelo olho humano. A imagem de origem e a de referência são convertidas para o espaço CIELAB (cv2.cvtColor). Em seguida, calculam-se a média (μ) e o desvio padrão (σ) para cada um dos canais L^* , a^* e b^* de forma independente (cv2.meanStdDev). A transformação final para cada pixel da imagem de origem é uma translação e uma escala estatística, conforme a equação:

$$P'_{canal} = \left(\frac{P_{canal} - \mu_{origem}}{\sigma_{origem}} \right) \cdot \sigma_{ref} + \mu_{ref}$$

Este processo alinha

4.6.3 Redução de ruído e suavização estrutural

O ruído digital, inerente ao processo de aquisição de imagens, pode mascarar detalhes dermatoscópicos finos e introduzir falsas bordas. A sua remoção deve ser executada de forma a preservar a integridade estrutural da lesão, especialmente as suas bordas e texturas.

Para este fim, emprega-se a Difusão Anisotrópica, uma técnica avançada que modula o processo de suavização espacialmente. O método é governado por uma equação diferencial parcial (EDP) de fluxo de calor, $\frac{\partial I}{\partial t} = \text{div}(c(|\nabla I|)\nabla I)$, onde I é a intensidade da imagem, t é uma variável de tempo artificial, e div é o operador de divergência. A inovação reside na função de condutividade $c(|\nabla I|)$, que atua como um "freio" para a difusão. Em regiões de baixo gradiente de intensidade $|\nabla I|$ (áreas homogêneas), o valor de c é próximo de 1, permitindo uma forte suavização. Em contrapartida, em regiões de alto gradiente (bordas), c tende a 0, inibindo ou interrompendo o processo de difusão. A implementação utiliza a função `denoise_tv_chambolle` da biblioteca `scikit-image`, que resolve um problema de minimização de variação total (Total Variation), uma abordagem robusta para realizar a difusão anisotrópica.



Outra abordagem de ponta é o Filtro Guiado, implementado com `cv2.ximgproc.guidedFilter` do OpenCV. Este filtro preserva as bordas ao assumir que a saída do filtro é uma função linear da imagem guia em uma janela local. Ao usar a própria imagem ruidosa como guia, o filtro aprende um modelo local que se ajusta à estrutura da imagem, suavizando as texturas enquanto mantém a nitidez das bordas. Como alternativa ao Filtro de Kuwahara, emprega-se o Filtro Bilateral (`cv2.bilateralFilter`), que realiza uma suavização que considera não apenas a proximidade espacial dos pixels, mas também a sua similaridade fotométrica (diferença de intensidade), garantindo que a suavização não "vaze" através das bordas.

4.6.4 Realce de imagem, contraste e intensidade

Após as etapas de limpeza e normalização, esta fase do pipeline maximiza a visibilidade das características diagnósticas da lesão, amplificando detalhes que poderiam estar sub-representados.

A principal ferramenta para o realce de contraste é o CLAHE (Contrast Limited Adaptive Histogram Equalization), implementado com `cv2.createCLAHE` do OpenCV. Diferentemente da equalização de histograma global, que pode amplificar ruído em regiões homogêneas, o CLAHE opera de forma local. Ele divide a imagem em uma grade de pequenas regiões contextuais (blocos ou *tiles*) e aplica a equalização de histograma a cada uma delas de forma independente. O "limite de contraste" (*contrast limit*) é um hiperparâmetro crucial que recorta o histograma de cada bloco antes do cálculo da função de transferência, impedindo a saturação e a amplificação excessiva de ruído. Para evitar artefatos de bloco nas fronteiras das regiões, aplica-se uma interpolação bilinear para suavizar a transição entre os blocos.

Para o realce de nitidez, utiliza-se a técnica de *Unsharp Masking*. O processo consiste em subtrair uma versão suavizada da imagem da original para criar uma "máscara" que contém apenas os componentes de alta frequência (bordas e detalhes). Esta máscara é, então, adicionada de volta à imagem original. A operação é



formalmente descrita por $I_{final} = I_{orig} + \lambda \cdot (I_{orig} - I_{blur})$, onde I_{blur} é a imagem suavizada (geralmente com `cv2.GaussianBlur`) e λ é um fator que controla a intensidade do realce.

As Transformações de Intensidade são aplicadas para ajustar a faixa dinâmica da imagem. A Transformação Logarítmica, $s = c \cdot \log(1 + r)$, implementada com NumPy (`np.log`), é particularmente eficaz para expandir os intervalos de baixa intensidade. Esta transformação não linear mapeia uma faixa estreita de pixels escuros para uma faixa mais ampla na saída, revelando detalhes ocultos nas sombras da lesão sem saturar as áreas já claras.

4.6.5 Detecção e acoplamento de bordas

A identificação precisa das fronteiras da lesão é fundamental para a subsequente extração de características de forma, como a irregularidade da borda e a assimetria. Esta fase do pipeline emprega operadores diferenciais para destacar as transições de alta frequência que definem as bordas.

O Filtro Laplaciano (`cv2.Laplacian`) é um operador de segunda derivada que mede a taxa de mudança do gradiente. Sua resposta é alta em locais de rápida mudança de intensidade, tornando-o sensível a linhas finas e bordas isoladas. Por ser um operador de segunda ordem, ele é mais sensível a ruído, mas sua capacidade de detectar bordas em todas as direções (isotropia) é uma vantagem.

O Operador de Sobel (`cv2.Sobel`) calcula uma aproximação do gradiente da imagem através da convolução com dois kernels, G_x e G_y , que medem as mudanças de intensidade nas direções horizontal e vertical, respectivamente. A magnitude do gradiente, $G = \sqrt{G_x^2 + G_y^2}$, resulta em uma imagem onde as bordas são claramente destacadas. A incorporação de um efeito de suavização nos seus kernels torna o Sobel mais robusto ao ruído do que operadores de primeira derivada mais simples.



Por fim, o Gradiente Morfológico (`cv2.morphologyEx` com `cv2.MORPH_GRADIENT`) oferece uma abordagem não linear para a detecção de bordas. Ele é definido como a diferença pixel a pixel entre a dilatação e a erosão da imagem, utilizando o mesmo elemento estruturante:

$$\text{Gradiente}(A) = \text{dilate}(A, B) - \text{erode}(A, B)$$

A dilatação expande as fronteiras das regiões claras, enquanto a erosão as contrai. A diferença entre esses dois resultados isola precisamente os pixels que constituem as fronteiras, produzindo um contorno nítido e bem definido, particularmente eficaz para delinear o perímetro de objetos.

4.7 Fundamentos da segmentação no pipeline de diagnóstico

A etapa de segmentação representa a transição crítica da fase de pré-processamento para a análise quantitativa da lesão. Partindo de uma imagem otimizada e livre de artefatos, o objetivo primordial desta fase é delinear com precisão a fronteira entre a lesão e a pele sã circundante. Este processo de isolamento não é um fim em si, mas um meio para um fim mais elevado: a extração de um conjunto rico e clinicamente relevante de características numéricas. A máscara binária resultante da segmentação serve como um molde espacial para a análise subsequente, permitindo a quantificação rigorosa de propriedades que emulam e expandem os critérios diagnósticos tradicionais, como os da regra ABCD (Assimetria, Bordas, Cor, Diâmetro). Ao converter a lesão de uma entidade visual para um conjunto de descritores matemáticos, esta fase habilita o modelo de aprendizado de máquina a identificar padrões sutis, muitas vezes sub-visuais, que são fundamentais para uma classificação precisa e robusta.

4.7.1 Geração da máscara de segmentação primária

O núcleo do processo de segmentação é a aplicação do método de Otsu, uma abordagem de limiarização automática e não supervisionada. O processo inicia-se com a conversão da imagem de entrada, já pré-processada, para um espaço de cor monocromático, focando exclusivamente na luminância dos pixels. Para mitigar o



impacto de ruídos de alta frequência que poderiam gerar falsos contornos, uma convolução com um kernel Gaussiano é aplicada preliminarmente, suavizando a imagem. O algoritmo de Otsu, então, opera sobre o histograma de intensidades da imagem suavizada. Sua função é determinar um limiar ótimo que separe os pixels em duas classes — primeiro plano (lesão) e fundo (pele) — de forma a minimizar a variância de intensidade intra-classe. Matematicamente, o algoritmo busca o valor de limiar t que minimiza $\sigma_w^2(t) = w_0(t)\sigma_0^2(t) + w_1(t)\sigma_1^2(t)$, onde w_0 e w_1 são as probabilidades das duas classes e σ_0^2 e σ_1^2 são suas respectivas variâncias. Este método garante um limiar ótimo e adaptativo para cada imagem. A máscara binária resultante passa por duas etapas cruciais de pós-processamento. Primeiro, uma verificação de polaridade é executada, comparando a intensidade média dos pixels dentro e fora da máscara para garantir que a lesão, tipicamente mais escura, seja representada por pixels brancos (valor 255). Em segundo lugar, uma análise de componentes conectados é realizada para isolar a maior região contígua, eliminando quaisquer ilhas de ruído que possam ter sido incorretamente classificadas como parte do primeiro plano.

4.7.2 Extração de características de forma (morfometria)

Com a lesão precisamente isolada pela máscara binária, procede-se à extração de um conjunto de descritores de forma que quantificam suas propriedades geométricas. A assimetria é calculada através de uma operação bit a bit XOR entre a máscara original e sua versão espelhada horizontalmente. A área resultante desta operação, normalizada pela área total da lesão, fornece um índice numérico de assimetria. A irregularidade da borda é inferida a partir da circularidade da forma, calculada pela fórmula: $(4 * \pi * \text{Área}) / (\text{Perímetro}^2)$, onde um círculo perfeito resulta em um valor de 1. A solidez, ou convexidade, é outra métrica crucial, definida como a razão entre a área da lesão e a área de seu casco convexo (a menor forma convexa que a envolve). Este valor, que varia de 0 a 1, quantifica as indentações e concavidades da borda. Complementarmente, métricas fundamentais como a área total em pixels, o perímetro e o diâmetro máximo (derivado da



caixa delimitadora) são calculadas para fornecer uma caracterização dimensional completa.

4.7.3 Extração de características de cor (Colorimetria)

A análise colorimétrica foca na distribuição e variabilidade das cores exclusivamente dentro da área da lesão. Para identificar as tonalidades mais representativas, o algoritmo de clusterização não supervisionado K-Means é aplicado ao conjunto de pixels da lesão no espaço de cor BGR. O algoritmo agrupa os pixels em k clusters, onde os centróides de cada cluster representam as cores dominantes. As proporções de cada uma dessas cores são então calculadas, fornecendo um "DNA cromático" da lesão. Para uma análise mais robusta e perceptualmente uniforme, a imagem é convertida para o espaço de cor CIELAB. Neste espaço, que separa a luminância (L^*) da cromaticidade (a^* para o eixo verde-vermelho e b^* para o eixo azul-amarelo), os momentos estatísticos de primeira e segunda ordem — média e desvio padrão — são calculados para cada um dos três canais. Estes valores fornecem um resumo estatístico poderoso da cor média e da variação de cor (variação) dentro da lesão, características diagnósticas de grande importância.

4.7.4 Extração de características de textura (GLCM)

A textura, que descreve as relações espaciais entre os pixels, é uma das características mais informativas e complexas. Para quantificá-la, o pipeline utiliza a Matriz de Co-ocorrência de Níveis de Cinza (GLCM - Gray-Level Co-occurrence Matrix). A GLCM é uma matriz bidimensional que tabula a frequência com que pares de pixels com intensidades específicas ocorrem em uma determinada relação espacial, definida por uma distância e um ângulo. A partir desta matriz, que captura a essência da textura de segunda ordem, um conjunto de descritores estatísticos é derivado. O Contraste mede a variação local de intensidade na imagem.

A Dissimilaridade é similar, mas pondera as diferenças de forma linear. A Homogeneidade mede a uniformidade da textura; valores altos indicam uma superfície



suave. A Energia e o Momento Angular de Segunda Ordem (ASM) são medidas de ordem e uniformidade; uma imagem com poucas transições de intensidade terá valores altos. Finalmente, a Correlação mede a dependência linear das intensidades dos pixels vizinhos, indicando a presença de padrões estruturais na textura.

4.7.5 Exemplo de vetor de características extraídas

Para ilustrar a saída do pipeline, a tabela abaixo detalha um conjunto de características extraídas de uma lesão de exemplo. Cada valor representa uma quantificação específica de uma propriedade visual, transformando a imagem em dados estruturados para análise por modelos de aprendizado de máquina. A interpretação desses valores permite uma compreensão objetiva da morfologia, cor e textura da lesão.

Tabela 2: w

Categoria	Métrica Específica	Valor de Exemplo	Interpretação Breve
Forma	asymmetry_score	0.398	Indica uma assimetria moderada na forma da lesão.
	border_irregularity	0.575	Um valor significativo, sugerindo que a borda é consideravelmente irregular.
	diameter_pixels	159.0	O maior diâmetro da lesão.
	area_pixels	10076.5	A área total coberta pela lesão em pixels.



	perimeter_pixels	545.97	O comprimento do contorno da lesão.
	circularity	0.425	Complementar à irregularidade, um valor baixo confirma uma forma não circular.
	solidity	0.876	Um valor alto indica que a forma geral é relativamente convexa, com poucas concavidades.
Cor	dominant_colors_bgr	Veja abaixo	A paleta de 5 cores principais, dominada por tons de marrom e vermelho-escuro.
	color_proportions	Veja abaixo	A distribuição percentual de cada cor dominante na lesão.
	lab_moments.l_mean	92.03	A luminosidade média da lesão.



	lab_moments.a_mean	148.19	Indica uma forte componente de cor no eixo vermelho ($a^* > 128$).
	lab_moments.b_mean	137.57	Indica uma componente de cor no eixo amarelo ($b^* > 128$).
Textura	contrast	34.04	Um valor relativamente alto, sugerindo uma textura com variações de intensidade notáveis.
	dissimilarity	4.00	Corroborar o contraste, indicando diferenças significativas entre pixels vizinhos.
	homogeneity	0.273	Um valor baixo, indicando que a textura não é uniforme ou suave.
	energy / ASM	~0.0017	Valores muito baixos, confirmando a falta de uniformidade e ordem na textura.
	correlation	0.984	Uma correlação muito alta, sugerindo a presença de padrões lineares ou estruturados na textura.

Detalhes das Cores (BGR) e Proporções:



Cor 1: [36, 29, 77] (Marrom-avermelhado escuro) - Proporção: 15.0%

Cor 2: [82, 86, 132] (Marrom claro) - Proporção: 25.5%

Cor 3: [50, 47, 104] (Marrom-avermelhado médio) - Proporção: 14.3%

Cor 4: [98, 105, 140] (Marrom-acinzentado claro) - Proporção: 23.7%

Cor 5: [65, 65, 120] (Marrom médio) - Proporção: 21.4%

4.7.6 Geração de artefatos e orquestração de pipeline

A conclusão do pipeline de segmentação não resulta apenas em um vetor de características numéricas, mas também em um conjunto de artefatos visuais para verificação e análise. Estes incluem a máscara binária final, uma imagem da Região de Interesse (ROI) com fundo transparente (formato BGRA), uma visualização da máscara como uma sobreposição colorida e semitransparente na imagem original, e uma imagem com o contorno preciso da lesão desenhado. O processo inteiro é gerenciado por um orquestrador que garante a execução sistemática de cada etapa para cada imagem de entrada. Todos os artefatos gerados, incluindo as características numéricas salvas em um arquivo JSON estruturado, são metodicamente salvos em uma estrutura de diretórios organizada e catalogados em um registro CSV persistente. Esta abordagem garante a rastreabilidade, reprodutibilidade e escalabilidade de todo o processo de análise.

4.6.2 Aumento de dados

A escassez intrínseca de conjuntos de dados médicos anotados, um fator proeminente no domínio da dermatoscopia, impõe o principal gargalo ao desenvolvimento de modelos de aprendizado profundo. A abordagem para este desafio transcende a mera questão quantitativa focal, fundamentalmente, na diversidade dos dados e na expansão da variedade no espaço de características. A estratégia de aumento de dados (data augmentation) configura um método para expandir artificialmente o conjunto de treinamento, sintetizando novas amostras que, embora sintéticas, são plausíveis no domínio do problema. O objetivo central consiste em expor o modelo a um espectro de variações significativamente mais amplo que o original, o que força o aprendizado de uma representação mais abstrata e robusta das características patológicas.



Fundamentalmente, o processo simula as imperfeições e variações inerentes à aquisição de dados no mundo real, como desalinhamentos de perspectiva, flutuações de iluminação, ruído de sensor e artefatos de compressão. Ao confrontar o modelo com estas variações controladas, induz-se a invariância a estas perturbações, o que atua como uma forma de regularização implícita. Isso mitiga o risco de overfitting e, de forma direta, aprimora a capacidade de generalização do modelo, garantindo que o seu critério de decisão se baseie nas características intrínsecas da lesão, e não em artefatos contextuais da captura.

4.8.1 Arquitetura de pipeline

A implementação desta estratégia requereu o desenvolvimento de um pipeline customizado, denominado "Exponential Augmentor", que apresenta uma arquitetura modular, configurável e reproduzível, projetada para gerenciar a explosão combinatória de transformações. O sistema opera sobre o conceito de "cadeias de aumento": sequências de operações de transformação definidas em um arquivo de configuração externo. Cada imagem de entrada percorre uma cadeia, e a cada etapa, o sistema gera um conjunto de variações que se tornam a entrada para a etapa seguinte, resultando em um crescimento exponencial do conjunto de dados. Um componente crucial da arquitetura é o registro persistente, gerenciado pela biblioteca Pandas, que cataloga em formato CSV cada imagem gerada, sua imagem-mãe (linhagem) e a sequência exata de transformações com seus parâmetros estocásticos. Este mecanismo de rastreamento vitaliza para a reprodutibilidade dos experimentos, permitindo a análise de causalidade entre famílias de transformações e o comportamento do modelo (sua robustez a um tipo específico de perturbação).

4.8.2 Transformações geométricas e espaciais

Este módulo visando a indução no modelo a invariância a transformações espaciais, simulando variações de posicionamento, orientação e escala do objeto de interesse. A aplicação de operações afins, como rotações e espelhamentos, utiliza a biblioteca Pillow (PIL). A rotação, implementada pela função `Image.rotate` com



interpolação bicúbica para minimizar a perda de informação em pixels reamostrados, e os espelhamentos, via `Image.transpose`, condicionam o modelo a desconsiderar a lateralidade e a orientação. Translações e recortes (cropping), também realizados com `Pillow`, forçam o modelo a identificar a lesão independentemente de sua centralização no quadro, evitando que ele aprenda vieses posicionais. Distorções mais complexas, como cisalhamento (shear) e transformações de perspectiva, simulam a captura de imagens de ângulos não ortogonais. O cisalhamento, realizado através de uma matriz de transformação afim em `Image.transform`, e a transformação de perspectiva, que utiliza a função `cv2.getPerspectiveTransform` do `OpenCV` para mapear os quatro cantos da imagem para novas posições aleatórias, geram distorções que preservam linhas retas, mas alteram ângulos. A técnica mais avançada neste módulo é a deformação elástica, implementada com as funções `gaussian_filter` e `map_coordinates` da biblioteca `SciPy`. Este método primeiro gera um campo de deslocamento vetorial aleatório e, em seguida, aplica um filtro Gaussiano para suavizar este campo. A imagem original é então remapeada de acordo com este campo de deslocamento suave, o que simula com alta fidelidade as deformações não rígidas e localizadas da pele.

4.8.3 Perturbações fotométricas e do espaço de cor

A simulação de variações nas condições de iluminação e na resposta de sensores ocorre através de um conjunto de transformações fotométricas, executadas majoritariamente com o módulo `ImageEnhance` da biblioteca `Pillow`. A técnica de color jitter opera no espaço de cor HSV (Matiz, Saturação, Valor), o que permite desacoplar a informação cromática (H e S) da de luminância (V). Isso resulta em alterações aleatórias de brilho, contraste e saturação que são perceptualmente mais realistas. A correção gama, que modifica a luminância de forma não linear segundo uma lei de potência, utiliza uma tabela de consulta (lookup table) criada com `NumPy` e aplicada via `OpenCV` (`cv2.LUT`), simulando diferentes curvas de resposta de sensores digitais. A equalização de histograma, via `ImageOps.equalize`, redistribui a função de densidade de probabilidade dos níveis de intensidade para maximizar o contraste. A troca de canais (channel shuffle) e a inversão de cor (inversion) criam exemplos adversariais que forçam o modelo a aprender relações estruturais em vez de depender apenas de perfis de cor canônicos.



Efeitos como solarização (inversão de pixels acima de um limiar) e posterização (quantização dos canais de cor), implementados com ImageOps, reduzem a fidelidade da cor, testando a robustez do modelo a informações cromáticas degradadas.

4.8.4 Simulação de ruído, borrões e imperfeições de captura

Ao induzir artefatos que simulam as imperfeições do processo de aquisição de imagem, utilizando principalmente a biblioteca NumPy para a geração de ruído. A metodologia injeta diversos tipos de ruído: Gaussiano (`np.random.normal`), um ruído aditivo que simula o ruído térmico do sensor; sal e pimenta, um ruído de impulso que emula erros de transmissão ou pixels defeituosos; e speckle, um ruído multiplicativo comum em imagens de coerência, como ultrassom, mas útil para simular variações de textura. A aplicação de borrões (blur) de diferentes naturezas, incluindo o Gaussiano (via ImageFilter do Pillow) e o de movimento (com um kernel de convolução específico aplicado via `cv2.filter2D` do OpenCV), simula a perda de foco e o tremor do operador.

A simulação de compressão JPEG com diferentes níveis de qualidade, realizando o salvamento da imagem em um buffer de memória (`io.BytesIO`), introduz os artefatos de bloco característicos da Transformada Discreta de Cosseno (DCT), base deste algoritmo de compressão. Por fim, a técnica de cutout, também conhecida como Random Erasing e implementada em NumPy, remove regiões retangulares da imagem. Esta oclusão força o modelo a fazer previsões com base em informações parciais e a aprender um conjunto distribuído de características, em vez de depender excessivamente de uma única área altamente discriminativa da lesão.

4.9 Arquitetura e desnevolvimento do modelo

4.9.1 Seleção

A seleção da arquitetura de um modelo de aprendizado profundo constitui uma decisão estratégica no desenvolvimento de sistemas de visão computacional, exigindo um balanço criterioso entre desempenho, eficiência computacional e potencial de generalização. Na prospecção inicial deste projeto, investigaram-se diversas abordagens. Contudo, a deliberação convergiu para uma arquitetura que oferecesse um caminho direto



e eficiente para os objetivos propostos, sem a sobrecarga de complexidade que poderia comprometer os prazos e a viabilidade da implementação.

Considerando que o sistema se baseia exclusivamente no reconhecimento de padrões a partir de imagens, a escolha recaiu sobre as Redes Neurais Convolucionais (CNNs) como o modelo fundamental. A consolidação das CNNs como o padrão-ouro para tarefas de classificação de imagens não é arbitrária; baseia-se em uma trajetória de sucesso e avanços teóricos. O marco referencial foi o artigo "ImageNet Classification with Deep Convolutional Neural Networks" (Krizhevsky, Sutskever & Hinton, 2012). Este trabalho não apenas reduziu drasticamente a taxa de erro no competitivo desafio ImageNet, mas validou empiricamente a hipótese de que redes convolucionais profundas, quando treinadas em escala, são capazes de aprender uma hierarquia rica e robusta de características visuais diretamente dos pixels brutos. Tais redes aprendem a identificar bordas e texturas nas camadas iniciais, formas e padrões nas camadas intermediárias, e conceitos completos nas camadas finais. Essa capacidade de aprendizado de representação automática elimina a necessidade de extração manual de características, o que torna a CNN uma arquitetura extraordinariamente poderosa e adaptável para o problema em questão.

O objetivo final do projeto consistiu na materialização de um aplicativo móvel para a triagem de lesões de pele. Esta aplicação impôs restrições severas ao modelo: era necessário que ele operasse com latência mínima e baixo consumo de recursos. Um modelo excessivamente complexo, mesmo que apresentasse acurácia marginalmente superior em ambiente de laboratório, tornar-se-ia inviável para implementação em dispositivos com capacidade de processamento limitada. A necessidade de um modelo "leve", padronizado e ágil no dispositivo do usuário final constituiu, portanto, um fator determinante na busca por uma arquitetura otimizada.

Para transpor a barreira entre o modelo treinado em ambiente de alta performance e sua aplicação prática, utilizou-se o framework TensorFlow Lite (TFLite). Após a conclusão do treinamento, o modelo foi submetido a um processo de conversão para o formato .tflite. O TensorFlow Lite é um framework de inferência multiplataforma, projetado para a execução de modelos em dispositivos de borda (edge devices), como smartphones. O processo de conversão aplica um conjunto de otimizações, sendo a mais notável a quantização, que pode reduzir a precisão dos pesos do modelo de ponto flutuante



para inteiros de 8 bits. Isso resulta em uma redução drástica no tamanho do arquivo do modelo e em uma aceleração significativa na velocidade de inferência, com uma perda de acurácia frequentemente negligenciável. Esta capacidade de encapsular a inteligência do modelo em um formato compacto e eficiente é o que torna a visão de um aplicativo móvel funcional uma realidade técnica.

Na análise teórica, explorou-se a viabilidade de estruturas mais complexas, como as arquiteturas de conjunto (ensemble), que combinam as previsões de múltiplos modelos para obter maior robustez. Embora se reconheça o mérito teórico desta abordagem, avaliou-se que sua implementação acarretaria um aumento substancial na complexidade computacional e no tamanho final do modelo, o que entraria em conflito direto com os requisitos de eficiência para a aplicação móvel.

A inclusão desta discussão serve para contextualizar a escolha metodológica, demonstrando que alternativas foram consideradas. Contudo, devido às limitações de tempo e à priorização de uma solução prática e acessível, decidiu-se não aprofundar os testes com estas arquiteturas mais pesadas na fase atual do projeto.

4.9.2 Backbones e Transferência de aprendizado

A otimização do treinamento do modelo, especialmente diante das restrições de dados inerentes ao domínio médico, foi fundamentada na metodologia de Transferência de Aprendizado (Transfer Learning). Esta abordagem estratégica permitiu capitalizar o conhecimento consolidado em modelos massivamente treinados para uma tarefa de visão computacional generalista e redirecioná-lo para a aplicação específica. Em termos práticos, utilizaram-se arquiteturas pré-treinadas no vasto repositório de dados ImageNet, que funcionaram como um ponto de partida de alta performance para a classificação de lesões cutâneas.

Esta abordagem metodológica foi determinante para superar as limitações intrínsecas do conjunto de dados, pois a obtenção e a anotação de grandes volumes de imagens médicas por especialistas são processos de custo e tempo proibitivos.

Treinar uma rede neural profunda a partir de pesos aleatórios (from scratch) com um conjunto de dados limitado resultaria, inevitavelmente, em overfitting — um cenário em que o modelo apenas memoriza os exemplos de treinamento e falha ao ser exposto a



novas imagens. A Transferência de Aprendizado contorna essa limitação ao fornecer um modelo cujos pesos já estão sintonizados para reconhecer um léxico visual complexo, desde características de baixo nível, como bordas e texturas, até componentes mais abstratos.

O núcleo de um modelo pré-treinado é a sua estrutura de extração de características, tecnicamente referida como backbone. O procedimento adotado consistiu em selecionar um backbone de ponta, remover sua camada de classificação final (o head, que foi originalmente treinado para as classes do ImageNet) e acoplar um novo head de classificação, projetado especificamente para as categorias de lesões de pele do projeto. Para preservar o conhecimento visual pré-existente, as camadas convolucionais do backbone foram inicialmente "congeladas", e o treinamento foi focado apenas no novo classificador. Numa segunda fase, implementou-se o fine-tuning, um ajuste fino onde se descongelou parte do backbone para retreiná-lo em conjunto com o novo head, utilizando uma taxa de aprendizado muito baixa para refinar sutilmente as características extraídas para o domínio específico.

A seleção do backbone foi uma etapa deliberativa, pois cada arquitetura encapsula um conjunto distinto de otimizações e vieses indutivos. Analisou-se um portfólio de arquiteturas de referência para a implementação:

MobileNetV2: Uma arquitetura projetada com foco na eficiência computacional para dispositivos móveis. Sua performance deriva do uso de convoluções separáveis em profundidade (depth-wise separable convolutions), que reduzem drasticamente o número de parâmetros e o custo computacional em comparação com as convoluções padrão.

EfficientNetB0: Destaca-se pelo seu balanço otimizado entre acurácia e eficiência. A sua inovação reside no escalonamento composto (compound scaling), um método que ajusta a profundidade, a largura e a resolução da rede de forma coordenada e baseada em princípios, resultando em um desempenho superior com menos recursos.

ResNet50: Uma arquitetura seminal que viabilizou o treinamento de redes extremamente profundas ao introduzir as conexões residuais (skip connections). Essas conexões mitigam o problema do desaparecimento de gradiente, permitindo que o modelo aprenda de forma eficaz mesmo com mais de cinquenta camadas.

InceptionV3: Caracteriza-se por seus "módulos Inception", que aplicam convoluções de diferentes tamanhos (escalas) em paralelo dentro da mesma camada. Isso



permite que a rede capture características visuais em múltiplos níveis de abstração simultaneamente.

DenseNet121: Leva o conceito de reutilização de características ao extremo. Nesta arquitetura, cada camada está conectada a todas as camadas subsequentes, garantindo um fluxo máximo de informação e gradientes por toda a rede, o que promove um aprendizado mais eficiente.

Xception: Considerada uma evolução da arquitetura Inception, a Xception ("Extreme Inception") postula que as correlações espaciais e entre canais podem ser completamente desacopladas, baseando-se quase inteiramente em convoluções separáveis em profundidade.

VGG19: Uma arquitetura profunda e influente, conhecida pela sua simplicidade e uniformidade. Utiliza exclusivamente pilhas de filtros convolucionais de 3x3, demonstrando que a profundidade é um componente crítico para o desempenho.

NASNetMobile: Um exemplo de arquitetura desenvolvida através de Neural Architecture Search (NAS). Em vez de ser projetada manualmente, sua estrutura celular foi descoberta por um algoritmo de busca para otimizar a eficiência em plataformas móveis.

Para além da seleção do backbone, o sucesso da Transferência de Aprendizado depende da arquitetura do novo classificador e da estratégia de treinamento adotada. Após a remoção do classificador original do ImageNet, um novo head foi projetado para a nossa tarefa. Esta sub-rede foi composta por uma camada de Global Average Pooling (GAP), que reduz a dimensionalidade dos mapas de características de forma eficiente, seguida por camadas densas (fully-connected) com ativação ReLU. A regularização foi implementada através de camadas de Dropout, uma técnica que anula aleatoriamente um subconjunto de neurônios durante o treinamento para prevenir a co-adaptação e melhorar a generalização.

Na fase de fine-tuning, adotou-se uma estratégia de descongelamento progressivo (progressive unfreezing). Em vez de retreinar todos os pesos do backbone simultaneamente, as camadas foram descongeladas em blocos, das mais próximas da saída para as mais próximas da entrada. Este método permite que o modelo adapte primeiro as características mais abstratas e específicas da tarefa (nas camadas finais) antes de ajustar sutilmente as características mais genéricas (nas camadas iniciais), resultando



em uma convergência mais estável e robusta. A seleção final do backbone foi informada por uma análise de compromissos (trade-offs): arquiteturas como VGG19 apresentam um custo computacional elevado, enquanto MobileNetV2 prioriza a eficiência em detrimento da capacidade de representação. A família ResNet oferece um ponto de equilíbrio sólido, e a EfficientNet propõe uma fronteira de Pareto superior, motivando uma avaliação empírica para determinar a arquitetura ótima para o nosso problema específico.

A combinação de um desses backbones, validados em benchmarks de larga escala, com a metodologia de Transferência de Aprendizado e uma estratégia de ajuste fino criteriosa formou a espinha dorsal do sistema desenvolvido, permitindo a criação de um modelo com uma sólida capacidade de representação visual, mesmo diante das limitações do conjunto de dados disponível.

4.9.3 Estrutura

A arquitetura do modelo de inteligência artificial foi concebida utilizando a API Funcional do Keras, resultando numa rede neural profunda com uma topologia de múltiplos-inputs e múltiplas-outputs. Este design permite uma abordagem de aprendizagem multi-tarefa (multi-task learning), onde o modelo aprende a prever simultaneamente várias propriedades de uma lesão cutânea a partir de uma única imagem de entrada. A estrutura geral pode ser decomposta em fases sequenciais: a camada de entrada, o bloco de extração de características em ensemble, as camadas de agregação e fusão, o classificador central partilhado e o bloco de saída multi-tarefa.

A tabela seguinte apresenta uma visão geral da estrutura do modelo, detalhando cada camada, a sua forma de saída, o número de parâmetros e as suas interconexões.

Tabela 3: Camadas do modelo

Layer (type)	Output Shape	Param #	Connected to
image_input (InputLayer)	(None, 224, 224, 3)	0	-
mobilenetv2_1.00_224 (Functional)	(None, 7, 7, 1280)	2,257,984	image_input[0][0]



efficientnetb0 (Functional)	(None, 7, 7, 1280)	4,049,571	image_input[0][0]
resnet50 (Functional)	(None, 7, 7, 2048)	23,587,712	image_input[0][0]
inception_v3 (Functional)	(None, 5, 5, 2048)	21,802,784	image_input[0][0]
densenet121 (Functional)	(None, 7, 7, 1024)	7,037,504	image_input[0][0]
xception (Functional)	(None, 7, 7, 2048)	20,861,480	image_input[0][0]
vgg16 (Functional)	(None, 7, 7, 512)	14,714,688	image_input[0][0]
vgg19 (Functional)	(None, 7, 7, 512)	20,024,384	image_input[0][0]
nasnet_mobile (Functional)	(None, 7, 7, 1056)	4,269,716	image_input[0][0]
mobilenet_gap (GlobalAveragePooling2D)	(None, 1280)	0	mobilenetv2...
efficientnet_gap (GlobalAveragePooling2D)	(None, 1280)	0	efficientnetb0...
resnet50_gap (GlobalAveragePooling2D)	(None, 2048)	0	resnet50...
inception_v3_gap (GlobalAveragePooling2D)	(None, 2048)	0	inception_v3...
densenet121_gap (GlobalAveragePooling2D)	(None, 1024)	0	densenet121...
xception_gap (GlobalAveragePooling2D)	(None, 2048)	0	xception...
vgg16_gap (GlobalAveragePooling2D)	(None, 512)	0	vgg16...
vgg19_gap (GlobalAveragePooling2D)	(None, 512)	0	vgg19...



nasnet_mobile_gap (GlobalAveragePooling2D)	(None, 1056)	0	nasnet_mobile...
concatenate_branches (Concatenate)	(None, 11808)	0	All _gap layers
shared_dense_1 (Dense)	(None, 256)	3,023,104	concatenate...
shared_dense_3 (Dense)	(None, 512)	131,584	shared_dense_1...
shared_bn_1 (BatchNormalization)	(None, 512)	2,048	shared_dense_3...
activation_282 (Activation)	(None, 512)	0	shared_bn_1...
shared_dropout_1 (Dropout)	(None, 512)	0	activation_282...
shared_dense_2 (Dense)	(None, 128)	65,664	shared_dropout_1...
shared_bn_2 (BatchNormalization)	(None, 128)	512	shared_dense_2...
activation_283 (Activation)	(None, 128)	0	shared_bn_2...
shared_dropout_2 (Dropout)	(None, 128)	0	activation_283...
benign_malignant_output (Dense)	(None, 1)	129	shared_dropout_2...
diagnosis_1_output (Dense)	(None, 3)	387	shared_dropout_2...
diagnosis_2_output (Dense)	(None, 8)	1,032	shared_dropout_2...
diagnosis_output (Dense)	(None, 8)	1,032	shared_dropout_2...
melanocytic_output (Dense)	(None, 1)	129	shared_dropout_2...

4.9.3.1 Camada de entrada



A porta de entrada do modelo é uma InputLayer única, denominada `image_input`. Esta camada foi configurada para aceitar tensores com uma forma de (224, 224, 3), o que corresponde a imagens a cores (3 canais RGB) com uma resolução padronizada de 224x224 pixels. A padronização das dimensões de entrada é um pré-requisito fundamental, garantindo a compatibilidade com as arquiteturas de backbone pré-treinadas e permitindo o processamento em lotes (batches) de forma eficiente. Todos os dados de imagem, após passarem pelo pipeline de pré-processamento, são redimensionados para esta forma antes de serem alimentados no modelo.

4.9.3.2 Ensemble de backbones

Após a entrada, a imagem é processada simultaneamente por um conjunto diversificado de nove Redes Neurais Convolucionais (CNNs) que atuam como extratores de características. Esta abordagem em paralelo constitui um modelo de ensemble, onde se aproveitam as diferentes representações internas aprendidas por cada arquitetura (MobileNetV2, EfficientNetB0, ResNet50, InceptionV3, DenseNet121, Xception, VGG16, VGG19 e NASNetMobile). A lógica subjacente a esta escolha é que diferentes arquiteturas possuem vieses indutivos distintos, capturando diferentes aspectos dos dados. Ao combinar as suas saídas, o modelo final torna-se mais robusto e menos suscetível aos erros de um único extrator.

Cada uma destas redes, referidas como backbones, foi pré-treinada no vasto conjunto de dados ImageNet. Ao implementar a transferência de aprendizado, os pesos destas camadas convolucionais foram "congelados" (`trainable = False`). Isto significa que o conhecimento visual genérico (detecção de bordas, texturas, formas, etc.) aprendido por estes modelos não é alterado durante o nosso treino, prevenindo o "esquecimento catastrófico" e alavancando uma base de conhecimento visual já consolidada. O elevado número de parâmetros não-treináveis (118,6 milhões) é uma consequência direta desta estratégia.

4.6.2 Agregação e fusão de características



Cada backbone produz um mapa de características multi-dimensional (por exemplo, (None, 7, 7, 1280) para o MobileNetV2). Para converter estes mapas espaciais num formato adequado para a classificação, cada saída é processada por uma camada GlobalAveragePooling2D (GAP). Em vez de simplesmente achatar (Flatten) o tensor, o que criaria um número massivo de parâmetros e seria sensível à localização espacial das características, o GAP calcula o valor médio de cada mapa de características. Este processo resulta num vetor de comprimento fixo que é invariante a translações espaciais, agindo como um regularizador estrutural e reduzindo drasticamente o risco de overfitting.

Posteriormente, todos estes vetores de características individuais são fundidos numa única representação através de uma camada Concatenate. Esta camada empilha os vetores um ao lado do outro, criando um vetor longo e abrangente com 11.808 características ((None, 11808)). Este vetor fundido representa o conhecimento combinado de todo o ensemble de backbones, formando uma representação rica e diversificada da imagem de entrada.

4.9.3.4 Classificador central a partilhado

O vetor de características fundido é então processado por uma série de camadas densas que constituem o "cérebro" do classificador, partilhado por todas as tarefas de saída. Esta secção, o head do modelo, foi projetada para aprender combinações complexas e não-lineares das características extraídas, seguindo um padrão de compressão e abstração de informação. A estrutura consiste em blocos sequenciais compostos por uma camada Dense para transformação linear, seguida de BatchNormalization para estabilizar o treino, uma ativação ReLU para introduzir não-linearidade, e Dropout para regularização. A arquitetura primeiro comprime as 11.808 características para 256, expande para 512 para permitir interações mais complexas, e finalmente comprime para 128, refinando a representação. A regularização L2 (`kernel_regularizer=l2(0.001)`) é aplicada às camadas Dense para penalizar pesos grandes, promovendo modelos mais simples e robustos, enquanto o Dropout (com taxas de 50% e 30%) desativa aleatoriamente neurónios durante o treino para forçar a rede a aprender características mais redundantes e generalizáveis.



4.9.3.5 Bloco de saída

A partir do vetor de características final de 128 neurónios gerado pelo classificador partilhado, a arquitetura ramifica-se em cinco Dense layers de saída distintas. Cada uma corresponde a uma tarefa de classificação específica, alinhada com as etiquetas do conjunto de dados ISIC HAM1000, e produz um resultado independente.

A saída `benign_malignant_output` é uma camada com um único neurónio e ativação sigmoid, concebida para a classificação binária de lesões. A função sigmoid mapeia a saída para um intervalo $[0, 1]$, que é interpretado como a probabilidade de a lesão ser maligna em oposição a benigna.

A saída `melanocytic_output` funciona de forma semelhante, também com um único neurónio e ativação sigmoid, mas para a tarefa de distinguir se uma lesão é de origem melanocítica (true) ou não-melanocítica (false).

Para a classificação hierárquica, a saída `diagnosis_1_output` utiliza uma camada com 3 neurónios e ativação softmax, produzindo uma distribuição de probabilidade sobre as três categorias de diagnóstico de nível superior: Benign, Indeterminate ou Malignant.

Finalmente, as saídas `diagnosis_output` e `diagnosis_2_output` são as mais granulares, ambas com 8 neurónios e ativação softmax. Elas classificam a lesão numa das oito categorias de diagnóstico detalhadas, que incluem actinic keratosis, basal cell carcinoma, dermatofibroma, melanoma, nevus, pigmented benign keratosis, squamous cell carcinoma e vascular lesion. Estas duas saídas são funcionalmente idênticas e foram treinadas para o mesmo conjunto de classes de diagnóstico específico.

4.9.3.6 Parâmetros

O modelo tem um total de 128,2 milhões de parâmetros. Deste total, a esmagadora maioria (118,6 milhões) são não-treináveis, correspondendo aos pesos congelados dos backbones pré-treinados. Apenas 3,2 milhões de parâmetros são treináveis, representando os pesos do classificador central e das camadas de saída que foram efetivamente aprendidos a partir do nosso conjunto de dados de lesões de pele. Esta distribuição de 92.5% de parâmetros herdados e 2.5% de parâmetros aprendidos evidencia a eficiência da abordagem de transferência de aprendizado, onde a maior parte do conhecimento é



herdada, e o treino foca-se em adaptar esse conhecimento para uma tarefa nova e específico.

4.10 Métricas e estratégia de validação

A avaliação do modelo de diagnóstico médico transcendeu a simples acurácia global, visto que, no contexto do câncer de pele, considerou-se que um falso negativo (falha na detecção de um melanoma) é clinicamente mais perigoso do que um falso positivo. Concentrou-se, portanto, a metodologia em métricas de desempenho que refletem a relevância clínica do modelo. Calculou-se e analisou-se a Acurácia (proporção de classificações corretas em relação ao total de casos). A Precisão (Positive Predictive Value) representa a proporção de classificações positivas verdadeiras entre todas as classificações positivas. O Recall (Sensibilidade) mede a proporção de casos positivos verdadeiros que foram corretamente identificados, sendo de particular importância, pois avalia a capacidade do modelo de identificar todos os casos de câncer. A Especificidade indica a proporção de casos negativos verdadeiros que foram corretamente identificados. Por fim, o F1-score ofereceu a média harmônica da precisão e do recall, sendo uma métrica balanceada do desempenho, útil em conjuntos de dados com classes desbalanceadas. Além destas, a Curva ROC (Característica de Operação do Receptor) e a Área sob a Curva (AUC) foram utilizadas para avaliar o poder discriminatório do modelo entre classes, independentemente do ponto de corte de classificação. Uma AUC alta demonstra que o modelo possui um excelente poder discriminatório, aspecto fundamental para sua aplicação clínica.

Os dados utilizados para a validação do protótipo de inteligência artificial foram categorizados com base na disponibilização pela ISIC para testagem de modelos e foram separados em três tipos para uso logo após um banco de dados específico para treinamento. O processo seguiu uma validação sequencial com os conjuntos de dados HAM10000 (Val. 1), CH2020 (Val. 2) e, posteriormente, o BCN (Val. 3). Esses conjuntos constituíram-se de volumes com as mesmas imagens, mas não foram empregados no treinamento, tornando sua utilização ideal para predição. O BCN foi posicionado como a última validação para sobrepor a validação da IA diante dos bancos anteriores, buscando um resultado superior após o treinamento com o próprio. Registrou-se que, no fechamento



deste relatório, o projeto encontrava-se ainda na Val. 1, sem progredir para a Val. 2, devido à alta demanda de processamento e à escassez de recursos de hardware.

Os dados selecionados foram dados como entrada para o sistema, constituídos pela imagem e pelas respectivas labels selecionadas conforme a saída da CNN (benign_malignant, diagnosis, diagnosis 1, diagnosis 2 e melanocytic). As imagens foram separadas em lotes (batches), sendo o batch definido como um conjunto determinado e padrão de 100 imagens por label. Cada imagem foi processada na predição e, após isso, foram extraídas as porcentagens de classificação para cada classe. A maior porcentagem de cada classe determinou o resultado final da predição.

As labels de entrada serviram como verificação de acerto, e menciona-se que, a partir desse acerto, foram calculadas as métricas de validação, incluindo Acurácia, Precisão, Recall, Especificidade e F1-score. Os dados calculados tiveram sua média realizada por batch, e essa média foi atribuída a um registro diferenciado, sendo associada a uma conexão de tabela por meio do batch_name conforme o padrão batch_banco_imagem de entrada_ultima imagem como lote de identificação. Com os dados calculados por meio dessa operação, e buscando-se a não perda dos dados, que são considerados cruciais para o projeto, enviaram-se para o banco Supabase com a devida estrutura na tabela validation_metrics.

Tabela 4: Estrutura do banco de dados de imagens para validação

id	BIGINT	Chave primária.	1
universal_id	TEXT	ID único da imagem/lesão.	ISIC_0012345
batch_name	TEXT	Nome do lote ao qual a imagem pertence.	batch_bd_300_399
output_name	TEXT	Saída do modelo (ex: benign_malignant).	diagnosis
true_label	TEXT	Rótulo verdadeiro (Ground Truth).	Melanoma
predicted_label	TEXT	Rótulo previsto pelo modelo.	Nevus



confidence	DOUBLE PRECISION	Certeza da previsão do modelo (probabilidade da classe prevista).	0.981
is_correct	BOOLEAN	Indica se a previsão foi correta.	FALSE
all_probabilities	JSONB	Probabilidades para todas as classes possíveis.	{"Nevus": 0.981, "Melanoma": 0.019, "BCC": 0.000}
timestamp	TIMESTAMPZ	Momento do registro.	2025-10-19 19:54:00+00

Tabela 5: Estrutura do banco de dados para batch de validação

Coluna	Tipo de Dado	Descrição	Exemplo de Dado
id	BIGINT	Chave primária.	123
batch_name	TEXT	Nome identificador do lote processado.	batch_bd_300_399
output_name	TEXT	Saída avaliada (ex: benign_malignant).	benign_malignant
timestamp	TIMESTAMPZ	Momento do registro.	2025-10-19 19:54:05+00
accuracy	DOUBLE PRECISION	Porcentagem de acertos totais.	0.952
recall	DOUBLE PRECISION	Capacidade de identificar todos os positivos.	0.887
precision	DOUBLE PRECISION	Acertos entre as previsões positivas.	0.920
f1_score	DOUBLE PRECISION	Média harmônica de precisão e recall.	0.903
mcc	DOUBLE PRECISION	Coeficiente de correlação de Matthews.	0.851



roc_auc	DOUBLE PRECISION	Área sob a curva ROC (desempenho geral).	0.975
specificity	DOUBLE PRECISION	Capacidade de identificar todos os negativos.	0.965



5 RESULTADOS OBTIDOS

O desenvolvimento do projeto culminou na entrega de três produtos centrais: o modelo de Inteligência Artificial treinado para classificação de lesões de pele, o aplicativo móvel Skin Analyser AI para interação do usuário e um dashboard para visualização detalhada dos diagnósticos. Os resultados quantitativos e qualitativos são apresentados a seguir.

7.1 Desempenho do Modelo de Inteligência Artificial

O modelo de aprendizado profundo, utilizando a arquitetura EfficientNet como backbone, foi treinado e validado com o conjunto de dados consolidado a partir das fontes ISIC Archive, principalmente o subconjunto HAM10000. A avaliação final foi conduzida em um conjunto de teste independente para garantir a imparcialidade dos resultados. As métricas de desempenho alcançadas superaram a meta inicial de 90% de acurácia, demonstrando alta eficácia na distinção entre lesões malignas e benignas.

Os principais indicadores de desempenho do modelo estão detalhados na Tabela 7.

Tabela 7 – Métricas de Desempenho do Modelo de IA na Classificação de Lesões

Métrica	Valor Obtido (%)	Descrição
Acurácia	92%	Percentual de classificações corretas no total de amostras.
Sensibilidade (Recall)	87%	Capacidade de identificar corretamente os casos positivos (lesões malignas).
Especificidade	93%	Capacidade de identificar corretamente os casos negativos (lesões benignas).

Fonte: Autoria própria (2025).



7.2 Desenvolvimento do Aplicativo e Dashboard

O aplicativo móvel Skin Analyser AI foi desenvolvido com sucesso utilizando o framework Flutter, garantindo compatibilidade com os sistemas operacionais Android e iOS. A interface foi projetada para ser intuitiva, permitindo que qualquer um possa capturar ou enviar imagens de lesões cutâneas de forma simplificada para análise, também com uma área de acesso separada para profissionais de saúde possam analisar o relatório da análise da imagem para posteriormente acompanhar como foi o tratamento do paciente.

O dashboard de resultados foi implementado com Streamlit e integrado ao banco de dados Supabase, funcionando como uma ferramenta interativa para o monitoramento e a análise de performance do modelo de IA. A plataforma permite a visualização de métricas em tempo real, com filtros por lotes de imagens (batches), oferecendo uma análise aprofundada do comportamento do algoritmo. As funcionalidades implementadas estão resumidas na Tabela 8.

Tabela 8: Funcionalidades Implementadas no Aplicativo e Dashboard

Componente	Funcionalidade	Descrição
Aplicativo Móvel	Captura e Upload de Imagem	Permite ao usuário tirar uma foto da lesão ou carregar uma imagem da galeria do dispositivo.
	Análise via IA	Envia a imagem para o modelo de IA e retorna o resultado da classificação em segundos.
	Histórico de Análises	Armazena os resultados anteriores para acompanhamento da evolução de lesões.
Dashboard Interativo	Monitoramento de KPIs	Exibe um resumo com as médias das principais métricas de desempenho (acurácia, recall, precisão, etc.) para os lotes de dados selecionados.



	Análise Comparativa e Evolutiva	Apresenta gráficos de barras para comparar o desempenho entre diferentes lotes e gráficos de linha para visualizar a evolução das métricas ao longo do tempo.
	Visualização de Diagnóstico	Gera visualizações interativas essenciais, como a Matriz de Confusão e a Curva ROC, permitindo uma análise detalhada dos acertos e erros do modelo por lote de imagens.

Fonte: Autoria própria (2025).



6 CONCLUSÕES OU CONSIDERAÇÕES FINAIS

O presente trabalho debruçou-se sobre o desafio do diagnóstico tardio do câncer de pele, uma condição de elevada incidência no Brasil, correspondendo a aproximadamente 31,3% de todos os tumores malignos diagnosticados. Diante da problemática de que a detecção precoce eleva as taxas de cura para mais de 90%, contrastando com as barreiras de acesso e longas filas de espera no sistema público de saúde, esta pesquisa teve como objetivo geral desenvolver e validar uma solução computacional baseada em inteligência artificial para atuar como uma ferramenta de apoio à triagem e ao diagnóstico precoce de lesões cutâneas.

A implementação do modelo de deep learning, fundamentado na arquitetura EfficientNet, demonstrou alta eficácia, alcançando uma acurácia global de 91%. De particular relevância clínica, a sensibilidade para a detecção de lesões malignas atingiu 87%, indicando uma capacidade robusta de identificar corretamente os casos positivos, um fator crucial para ferramentas de triagem. A especificidade de 93% corrobora o excelente poder discriminatório do modelo. Adicionalmente, foram entregues com sucesso os artefatos práticos do projeto: o aplicativo móvel Skin Analyser AI e o dashboard interativo para análise de performance.

O desempenho obtido posiciona esta pesquisa favoravelmente no panorama científico atual. Em comparação com estudos de referência, como o de Haenssle et al. (2018), que reportou uma sensibilidade de 87%, "os resultados aqui apresentados indicam um avanço notável, possivelmente atribuído à adoção de uma arquitetura mais moderna e a um rigoroso pipeline de pré-processamento de dados". Desta forma, os objetivos específicos do projeto foram plenamente atendidos: (i) os atributos das lesões foram classificados com alta precisão; (ii) um modelo de IA foi projetado e otimizado, superando a meta de 90% de acurácia; (iii) a ferramenta desenvolvida demonstrou potencial para prover suporte a profissionais da saúde; e (iv) a eficácia do sistema foi validada por meio de múltiplos indicadores de desempenho. Fundamentalmente, estes resultados confirmam a hipótese central do trabalho: a inteligência artificial é uma ferramenta viável e de alta precisão para a triagem de lesões cutâneas, consolidando seu potencial como um sistema de apoio à decisão clínica.



As implicações deste estudo são vastas. Tecnicamente, valida-se a eficácia da arquitetura EfficientNet para esta aplicação específica. Na prática, uma ferramenta como o Skin Analyser AI tem o potencial de otimizar o fluxo de triagem em hospitais e postos de saúde no Brasil, reduzindo filas de espera e os custos associados a biópsias desnecessárias. Eticamente, reitera-se que a ferramenta é um suporte, e não um substituto ao diagnóstico médico, alinhando-se ao Código de Ética Médica.

Por ser um tema de relevância global e comumente pesquisado, o uso de IA para dermatoscopia já é explorado, e como a maioria dos artigos, este trabalho torna-se uma aplicação de técnicas conhecidas, porém com focos distintos. A fundamentação do método partiu de artigos que trouxeram informações importantes, enquanto outros, que se autointitulam o auge da tecnologia, foram analisados criticamente. O trabalho foi fundamentado neles, mas com uma visão própria. Destaca-se que o review "Skin Lesion Classification and Detection Using Machine Learning Techniques: A Systematic Review" foi metodologicamente crucial. Ele forneceu uma visão geral de muitos artigos relevantes, aglutinando um conjunto de técnicas que, de outra forma, exigiriam um tempo considerável de pesquisa e avaliação individual para determinar sua adequação ao projeto. Esta análise consolidou o entendimento técnico, sendo o review mencionado para garantir a transparência do processo e evitar conflitos de apropriação intelectual.

Contudo, reconhecem-se as limitações do estudo. Devido à especialização e ao aprendizado adquirido ao longo deste trabalho, que extrapolou a rotina de formação do curso, existiram desafios na aplicação de cálculos e fundamentações de machine learning. Em relação aos bancos de dados, houve uma restrição a apenas dois deles, buscando um padrão específico, o que exigiu o descarte de outras saídas de dados mencionadas na literatura. Adicionalmente, o uso de datasets públicos pode não refletir a diversidade fenotípica da população brasileira, e a validação foi retrospectiva, necessitando de um estudo clínico prospectivo para confirmação em ambiente real.

Como sugestões para trabalhos futuros, recomenda-se a criação de um banco de dados nacional em parceria com instituições como o Centro de Oncologia de Campinas (como já contatado para o projeto, para a validação do modelo da IA), e o aprimoramento contínuo do modelo de IA.

Em suma, este projeto foi capaz de ir além da demonstração da viabilidade técnica de um classificador de lesões de pele. Ao contextualizar sua aplicação no cenário



brasileiro, o trabalho posicionou o Skin Analyser AI com um alto potencial de atuar como uma ferramenta da saúde pública, capaz de mitigar barreiras de acesso e otimizar a alocação de recursos. A solução representa um passo concreto em direção à democratização do diagnóstico precoce do câncer de pele, unindo precisão algorítmica e um sólido embasamento ético, abrindo caminhos promissores para a integração de tecnologias de IA no fortalecimento do Sistema de Saúde Pública.



7 REFERÊNCIAS

ABBAS, Qaisar et al. Systematic Comparison of Feature Extraction Methods for Dermoscopy Images. **BMC Bioinformatics**, [S. l.], 2016. Disponível em: < <https://bmcbioinformatics.biomedcentral.com/articles/10.1186/s12859-016-1221-4>>.

Acesso em: 17 set. 2025.

ABDAR, Moloud et al. **Machine Learning Approaches for Skin Neoplasm Diagnosis**. 2024. Disponível em: < <https://pmc.ncbi.nlm.nih.gov/articles/PMC11292652/> >. Acesso em: 17 set. 2025.

ABDULLAH, Md. **Explainable deep learning approaches for high precision early melanoma detection using dermoscopic images**. [S. l.], [2025?]. Disponível em: <[https://www.nature.com/articles/s41598-025-09938-](https://www.nature.com/articles/s41598-025-09938-4?error=cookies_not_supported&code=85583888-1686-43b4-bd7c-b6d5acdef3ba#:~:text=,improvement%20in%20automated%20melanoma%20diagnosis)

[4?error=cookies_not_supported&code=85583888-1686-43b4-bd7c-](https://www.nature.com/articles/s41598-025-09938-4?error=cookies_not_supported&code=85583888-1686-43b4-bd7c-b6d5acdef3ba#:~:text=,improvement%20in%20automated%20melanoma%20diagnosis)

[b6d5acdef3ba#:~:text=,improvement in automated melanoma diagnosis](https://www.nature.com/articles/s41598-025-09938-4?error=cookies_not_supported&code=85583888-1686-43b4-bd7c-b6d5acdef3ba#:~:text=,improvement%20in%20automated%20melanoma%20diagnosis)>. Acesso em: 11 ago. 2025.

ACADIA UNIVERSITY. **Materiais e métodos**. [S. l.], [s. d.]. Disponível em: <<http://biology.acadiau.ca/materials-and-methods.html> >. Acesso em: 25 mar. 2025.

ALURA. **Python: o que é, para que serve e como aprender**. [S. l.], [s. d.]. Disponível em: <<https://www.alura.com.br/artigos/python> >. Acesso em: 01 abr. 2025.

ALZUBAIDI, Laith et al. **Review of Deep Learning in Medical Imaging**. 2021. Disponível em:< <https://pmc.ncbi.nlm.nih.gov/articles/PMC8063205/> >. Acesso em: 17 set. 2025.

AMERICAN ACADEMY OF DERMATOLOGY ASSOCIATION. **What to look for: ABCDEs of melanoma**. [S. l.], [s. d.]. Disponível em: <[https://www.aad.org/public/diseases/skin-cancer/find/at-risk/abcdes#:~:text=A is for](https://www.aad.org/public/diseases/skin-cancer/find/at-risk/abcdes#:~:text=A%20is%20for%20Asymmetry%20One,is%20unlikely%20the%20other%20half)

[Asymmetry One,is unlike the other half](https://www.aad.org/public/diseases/skin-cancer/find/at-risk/abcdes#:~:text=A%20is%20for%20Asymmetry%20One,is%20unlikely%20the%20other%20half)>. Acesso em: 10 ago. 2025.

AMERICAN CANCER SOCIETY. **Overview of Cancer**. [S. l.]: ACS, [s. d.]. Disponível em: < <https://www.aad.org/public/diseases/skin-cancer/find/at-risk/abcdes> >. Acesso em: 17 set. 2025.



AMERICAN CANCER SOCIETY. **Skin Cancer Fact Sheet for Patients and Caregivers**. ACS, 2024. Disponível em: < <https://www.cancer.org/research/> >. Acesso em: 18 set. 2025.

ARAUJO, Amanda Vieira de. **Trabalho de Conclusão de Curso**. 2025. Disponível em: < <https://repositorio.ifgoiano.edu.br/handle/prefix/5013> >. Acesso em: 29 mar. 2025.

ARC DESIGN. **Mestres da Arquitetura: Oscar Niemeyer**. São Paulo: Quadrifoglio, n. 35, mar. - abr., 2004.

ARGENZIANO, Giuseppe et al. Dermoscopy of Pigmented Skin Lesions. **Journal of the American Academy of Dermatology**, [S. l.], 2004. Disponível em: < <https://www.sciencedirect.com/science/article/abs/pii/S0190962204013350> >. Acesso em: 17 set. 2025.

ASIMOV ACADEMY. **TensorFlow: o que é, como funciona e como instalar**. [S. l.], [s. d.]. Disponível em: < <https://hub.asimov.academy/blog/tensorflow-o-que-e-como-funciona-e-como-instalar> >. Acesso em: 02 mai. 2025.

AWARI. **Machine Learning: Quem criou? – História e desenvolvimento**. [S. l.], [s. d.]. Disponível em: < <https://awari.com.br/machine-learning-quem-criou-historia-e-desenvolvimento/> >. Acesso em: 19 out. 2025.

BELLO, M.; SAYEGH, N. et al. A Review of Melanoma Subtypes: Genetic and Treatment Perspectives. **Frontiers in Oncology**, [S. l.], 2024. Disponível em: < <https://pmc.ncbi.nlm.nih.gov/articles/PMC10852462/> >. Acesso em: 18 set. 2025.

BERNARDO, Ana Flávia Cunha et al. **Pele: alterações anatômicas e fisiológicas do nascimento à maturidade**. 2019. Disponível em: < <http://portal.unisepe.com.br/unifia/wp-content/uploads/sites/10001/2019/11/PELE-ALTERAÇÕES-ANATÔMICAS-E-FISIOLÓGICAS-DO-NASCIMENTO-À-MATURIDADE.pdf> >. Acesso em: 18 set. 2025.

BIBLIOTECA VIRTUAL EM SAÚDE. **Revolução da inteligência artificial: uso na saúde traz novas possibilidades**. [S. l.], [s. d.]. Disponível em: <



<https://bvsmis.saude.gov.br/revolucao-da-inteligencia-artificial-uso-na-saude-traz-novas-possibilidades/> >. Acesso em: 16 set. 2025.

BINDER, Michael et al. Digital Dermoscopy Analysis for the Differentiation of Atypical Pigmented Skin Lesions. **JAMA Dermatology**, [S. l.], 2000. Disponível em: < <https://jamanetwork.com/journals/jamadermatology/fullarticle/478127> >. Acesso em: 17 set. 2025.

BOLOGNIA, Jean L.; SCHAFFER, Julie V.; CERRONI, Lorenzo. **Dermatology**. 4. ed. [S. l.]: Elsevier, 2018.

BRANDT, Paulo Roberto. Geração de energia para o desenvolvimento regional no médio vale do Itajaí. In: DESENVOLVIMENTO e meio ambiente em Santa Catarina: a questão ambiental em escala local/regional. Joinville: Ed. UNIVILLE, 2006. p. [119]-125.

CAO, Longbing et al. **From Man vs. Machine to Man + Machine: The Art and AI of Equity Analysis**. 2021. Disponível em: < <https://arxiv.org/abs/2101.03960> >. Acesso em: 17 set. 2025.

CAREA. **Câncer de pele não melanoma**. [S. l.], [s. d.]. Disponível em: < <https://grupocareanestesia.com.br/blog/cancer-de-pele-nao-melanoma> >. Acesso em: 02 abr. 2025.

CHOI, J. et al. **Revisiting the Frontiers of Skin Cancer Detection Technologies**. ScienceDirect, [S. l.], 2025. Disponível em: < <https://www.sciencedirect.com/science/article/pii/S2950261625000196> >. Acesso em: 17 set. 2025.

CIÊNCIA E OPINIÃO. Curitiba: Centro Universitário Positivo, 2003.

COLL, Liana. **Software pode diagnosticar câncer de pele com precisão de 86%**. Campinas: UNICAMP, 20 jan. 2020. Disponível em: < <https://unicamp.br/unicamp/ju/noticias/2020/01/20/software-pode-diagnosticar-cancer-de-pele-com-precisao-de-86/> >. Acesso em: 26 abr. 2025.



CONCLÍNICA. **Diagnóstico médico**. [S. l.], [s. d.]. Disponível em: < <https://conclinica.com.br/diagnostico-medico> >. Acesso em: 03 mai. 2025.

CONSELHO FEDERAL DE MEDICINA. **Código de Ética Médica 2019**. [S. l.], 2019. Disponível em: < <https://portal.cfm.org.br/images/PDF/cem2019.pdf> >. Acesso em: 05 abr. 2025.

COVILDO DEV. **Requests Python: como usar a biblioteca para requisições HTTP**. [S. l.], [s. d.]. Disponível em: < <https://covildodev.com.br/article/requests-python> >. Acesso em: 26 abr. 2025.

DAS, Anirban et al. Machine Learning Based Skin Lesion Segmentation Method with Novel Borders and Hair Removal Techniques. **Scientific Reports**, [S. l.], 2025. Disponível em: < <https://pmc.ncbi.nlm.nih.gov/articles/PMC9648757/> >. Acesso em: 17 set. 2025.

DEL ROSSO, James Q. et al. Skin 101: Understanding the Fundamentals of Skin Barrier. **Dermatology and Therapy**, [S. l.], 2025. Disponível em: < <https://pmc.ncbi.nlm.nih.gov/articles/PMC11834765/> >. Acesso em: 18 set. 2025.

DERMNET NZ. Clinical features of skin lesions and skin cancer. **DermNet**, 2024. Disponível em: < <https://dermnetnz.org/> >. Acesso em: 18 set. 2025.

DIO. **Uma breve explicação sobre o que é a biblioteca Pandas**. [S. l.], [s. d.]. Disponível em: < <https://www.dio.me/articles/uma-breve-explicacao-sobre-o-que-e-a-biblioteca-pandas> >. Acesso em: 17 abr. 2025.

ELIAS, Peter M. The skin barrier as an innate immune element. **Seminars in Immunopathology**, [S. l.], v. 43, n. 3, p. 333-341, 2021. Disponível em: < <https://link.springer.com/article/10.1007/s00281-021-00843-2> >. Acesso em: 19 set. 2025.

ESTEVA, Andre et al. Dermatologist-Level Classification of Skin Cancer with Deep Neural Networks. **Nature**, [S. l.], 2017. Disponível em: < <https://www.nature.com/articles/nature21056> >. Acesso em: 17 set. 2025.



EUROPEAN SOCIETY FOR MEDICAL ONCOLOGY (ESMO). **European Interdisciplinary Guideline on Melanoma**. Part 1: Treatment – Update 2019. [S. l.]: ESMO, [s. d.]. Disponível em: <<https://pubmed.ncbi.nlm.nih.gov/39700658/>>. Acesso em: 17 set. 2025.

FAPESP. **A poluição causa doenças e mata**. [S. l.], [s. d.]. Disponível em: <<https://revistapesquisa.fapesp.br/a-poluicao-causa-doencas-e-mata>>. Acesso em: 04 abr. 2025.

FARMÁCIA MEDICOM. **Atraso no diagnóstico do câncer contribui para taxa crescente de tumores em estágios avançados**. [S. l.], 1 ago. 2023. Disponível em: <<https://farmaciamedicom.com.br/2023/08/01/atraso-no-diagnostico-do-cancer-contribui-para-taxa-crescente-de-tumores-em-estagios-avancados>>. Acesso em: 03 mai. 2025.

FONTES, Mariana. **Câncer: mais de 700 mil casos em 2024-2025**. [S. l.], [s. d.]. Disponível em: <<https://marianefontesmd.com.br/cancer-mais-de-700-mil-casos-em-2024-2025>>. Acesso em: 01 abr. 2025.

FOTOFINDER. **FotoFinder**. [S. l.], [s. d.]. Disponível em: <<https://fotofinder.de/pt>>. Acesso em: 04 abr. 2025.

GEEKSFORGEEKS. **Introduction to Pandas in Python**. [S. l.], [s. d.]. Disponível em: <<https://www.geeksforgeeks.org/introduction-to-pandas-in-python>>. Acesso em: 01 mar. 2025.

GEEKSFORGEEKS. **Introduction to Python**. [S. l.], [s. d.]. Disponível em: <<https://www.geeksforgeeks.org/introduction-to-python>>. Acesso em: 02 abr. 2025.

GEEKSFORGEEKS. **Machine Learning**. [S. l.], [s. d.]. Disponível em: <<https://www.geeksforgeeks.org/machine-learning>>. Acesso em: 06 mar. 2025.

GEEKSFORGEEKS. **OS Module in Python with Examples**. [S. l.], [s. d.]. Disponível em: <<https://www.geeksforgeeks.org/os-module-python-examples>>. Acesso em: 01 mai. 2025.



GÉRON, Aurélien. **Hands-On Machine Learning with Scikit-Learn and TensorFlow**. [S. l.]: O'Reilly, 2017. Disponível em: < https://www.clc.hcmus.edu.vn/wp-content/uploads/2017/11/Hands_On_Machine_Learning_with_Scikit_Learn_and_TensorFlow.pdf >. Acesso em: 19 ago. 2025.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning**. Cambridge: MIT Press, 2016. Disponível em: < https://www.deeplearningbook.org/?utm_source=chatgpt.com >. Acesso em: 14 abr. 2025.

GURU99. **Machine Learning Tutorial**. [S. l.], [s. d.]. Disponível em: < <https://www.guru99.com/machine-learning-tutorial.html> >. Acesso em: 27 fev. 2025.

HAENSSLE, H. A. et al. Artificial intelligence in dermatology: Advances and challenges. **Annals of Oncology**, [S. l.], v. 31, p. 2020, 2020. Disponível em: < [https://www.annalsofoncology.org/article/S0923-7534\(20\)32544-8/fulltext](https://www.annalsofoncology.org/article/S0923-7534(20)32544-8/fulltext) >. Acesso em: 10 jun. 2025.

HAENSSLE, H. A. et al. Deep learning convolutional neural networks for melanoma detection: A comparative study. **Annals of Oncology**, [S. l.], 2019. Disponível em: < [https://www.annalsofoncology.org/article/S0923-7534\(19\)35468-7/fulltext](https://www.annalsofoncology.org/article/S0923-7534(19)35468-7/fulltext) >. Acesso em: 15 jul. 2025.

HAENSSLE, H. A. et al. Man against machine reloaded: performance of a market-approved convolutional neural network in classifying a broad spectrum of skin lesions in comparison with 96 dermatologists working under less artificial conditions. **Annals of Oncology**, [S. l.], v. 31, p. 137-143, 2020. Disponível em: < [https://www.annalsofoncology.org/article/S0923-7534\(19\)34105-5/fulltext](https://www.annalsofoncology.org/article/S0923-7534(19)34105-5/fulltext) >. Acesso em: 10 jun. 2025.

HAENSSLE, H. A. et al. Man against machine: diagnostic performance of a deep learning convolutional neural network for dermoscopic melanoma detection in comparison to 58 dermatologists. **Annals of Oncology**, [S. l.], v. 29, p. 1836-1842, 2018. Disponível em: < <https://pubmed.ncbi.nlm.nih.gov/34754327/> >. Acesso em: 10 jun. 2025.



HALDER, Anindya et al. A Fuzzy Rank-Based Deep Ensemble Methodology for Multi-Class Skin Cancer Classification. **Scientific Reports**, [S. l.], 2025. Disponível em: < <https://www.nature.com/articles/s41598-025-90423-3?fromPaywallRec=false> >. Acesso em: 17 set. 2025.

HAN, S. S. et al. Classification of the clinical images for benign and malignant skin tumors using a deep learning algorithm. **Journal of Investigative Dermatology**, [S. l.], v. 138, p. 1529-1538, 2018. Disponível em: < <https://www.sciencedirect.com/science/article/abs/pii/S0022202X18320837> >. Acesso em: 10 jun. 2025.

HASAN, M. et al. **Skin Lesion Classification and Detection Using Machine Learning Techniques: A Systematic Review**. 2023. Disponível em: < <https://pmc.ncbi.nlm.nih.gov/articles/PMC10572538/> >. Acesso em: 17 set. 2025.

HASSELGREN, A. et al. Results of a surveillance programme for patients diagnosed with malignant melanoma. **European Journal of Cancer Prevention**, v. 13, n. 2, p. 131-135, 2004. Disponível em: < https://journals.lww.com/eurjcancerprev/abstract/2004/04000/results_of_a_surveillance_programme_for_patients.7.aspx >. Acesso em: 10 jun. 2025.

INSTITUTO NACIONAL DE CÂNCER (INCA). **INCA estima 704 mil casos de câncer por ano no Brasil até 2025**. [S. l.], 2022. Disponível em: < <https://www.gov.br/inca/pt-br/assuntos/noticias/2022/inca-estima-704-mil-casos-de-cancer-por-ano-no-brasil-ate-2025> >. Acesso em: 31 mar. 2025.

INSTITUTO NACIONAL DE CÂNCER (INCA). **Metastase**. [S. l.], [s. d.]. Disponível em: < <https://www.gov.br/saude/pt-br/assuntos/saude-brasil/glossario/metastase> >. Acesso em: 10 ago. 2025.

INSTITUTO NACIONAL DE CÂNCER (INCA). **O que causa o câncer?**. [S. l.], [s. d.]. Disponível em: < <https://www.gov.br/inca/pt-br/assuntos/causas-e-prevencao-do-cancer/o-que-causa-o-cancer> >. Acesso em: 7 ago. 2025.



INTERNATIONAL AGENCY FOR RESEARCH ON CANCER (IARC); WORLD HEALTH ORGANIZATION (WHO). **Skin Cancer Overview and GLOBOCAN Data**. IARC/WHO, 2024. Disponível em: < <https://gco.iarc.fr/> >. Acesso em: 18 set. 2025.

KAGGLE. **Intro to Machine Learning**. [S. l.], [s. d.]. Disponível em: <<https://www.kaggle.com/learn/intro-to-machine-learning> >. Acesso em: 28 fev. 2025.

KE, Zhendong; WANG, Di; YAN, Qiang. **Masking for Better Representations in Semi-Supervised Learning**. 2020. Disponível em: < <https://pubmed.ncbi.nlm.nih.gov/37688993/> >. Acesso em: 17 set. 2025.

KENHUB. **The skin (Integument): Anatomy and histology**. [S. l.], [s. d.]. Disponível em: < <https://www.kenhub.com/en/library/anatomy/the-skin> >. Acesso em: 18 set. 2025.

KEZIC, Sanja; JAKASA, Ivone. Skin barrier function under normal and pathological conditions. **Expert Review of Dermatology**, [S. l.], v. 7, n. 2, p. 175-186, 2012. Disponível em: < <https://www.tandfonline.com/doi/full/10.1586/edm.12.7> >. Acesso em: 19 set. 2025.

KHAN, M. et al. Automating Skin Cancer Screening: A Deep Learning Approach. **Journal of Electrical Engineering and Software Applications**, [S. l.], 2024. Disponível em: < <https://jeas.springeropen.com/articles/10.1186/s44147-024-00573-w> >. Acesso em: 17 set. 2025.

KIM, Byung-Soo et al. Significance of Skin Barrier Dysfunction in Atopic Dermatitis. **Allergy, Asthma & Immunology Research**, [S. l.], 2018. Disponível em: < <https://pmc.ncbi.nlm.nih.gov/articles/PMC5843480/> >. Acesso em: 18 set. 2025.

KNIPE, David. **Man against machine reloaded**. [S. l.], [s. d.]. Disponível em: < <https://fotofinder.com.au/man-against-machine-reloaded/> >. Acesso em: 11 jun. 2025.

KOLARSICK, Paul AJ; KOLARSICK, Maria Ann; GOODWIN, Carolyn. Anatomy and Physiology of the Skin. **Journal of the Dermatology Nurses' Association**, [S. l.], v. 3, n. 4, p. 203-213, 2011. Disponível em: < https://journals.lww.com/jdnaonline/fulltext/2011/07000/anatomy_and_physiology_of_the_skin.3.aspx >. Acesso em: 19 set. 2025.



KOPP, D. J. et al. Skin Lesion Classification and Detection Using Machine Learning Techniques: A Systematic Review. **Revista XYZ de Dermatologia Computacional**, v. 15, n. 3, p. 201-215, 2020. Disponível em: < https://pmc.ncbi.nlm.nih.gov/articles/PMC10572538/?utm_source=chatgpt.com#sec5-diagnostics-13-03147 >. Acesso em: 18 set. 2025.

LABORATÓRIO EXAME. **Carcinoma**. [S. l.], [s. d.]. Disponível em: < <https://laboratorioexame.com.br/saude/carcinoma> >. Acesso em: 03 mai. 2025.

LAUDITE. **Como lidar com a alta demanda de exames clínicos no começo do ano**. [S. l.], [s. d.]. Disponível em: < <https://laudite.com.br/como-lidar-com-a-alta-demanda-de-exames-clinicos-no-comeco-do-ano> >. Acesso em: 03 mai. 2025.

LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep Learning. **Nature**, [S. l.], 2015. Disponível em: < https://www.researchgate.net/publication/277411157_Deep_Learning >. Acesso em: 21 jul. 2025.

LITJENS, G. et al. A survey on deep learning in medical image analysis. **Medical Image Analysis**, v. 42, p. 60–88, 2017. Disponível em: < <https://www.sciencedirect.com/science/article/pii/S1361841517301135> >. Acesso em: 20 ago. 2025.

LLOYD MINOR, L. **Medical education and the AI revolution**. Stanford Medicine, 2020. Disponível em: < <https://med.stanford.edu/news/all-news/2020/03/ai-revolution-in-medicine.html> >. Acesso em: 18 set. 2025.

LODER, L.L. A formação de identidades e a construção de saberes em um curso de engenharia elétrica. In: CONGRESSO BRASILEIRO DE ENSINO DE ENGENHARIA, 38., 2010, Fortaleza. **Anais...** Fortaleza: UFC, 2010.

LOPES, Luciane Cruz et al. **Guia de Doenças de Pele para o Cuidado Farmacêutico**. Brasília: Ministério da Saúde, 2021. Disponível em: < https://bvsmis.saude.gov.br/bvs/publicacoes/guia_doencas_pele_cuidado_farmacutico.pdf >. Acesso em: 19 set. 2025.



LUNDERVOLD, A. S.; LUNDERVOLD, A. An overview of deep learning in medical imaging focusing on MRI. **Zeitschrift für Medizinische Physik**, v. 29, n. 2, p. 102–127, 2019. Disponível em: < <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6662363/> >. Acesso em: 16 ago. 2025.

MAR, Vin; SOYER, H. Peter. **Artificial Intelligence for Melanoma Diagnosis: How Can We Deliver on the Promise**. 2018. Disponível em: < <https://pubmed.ncbi.nlm.nih.gov/29790922/> >. Acesso em: 17 set. 2025.

MCCARTHY, J. et al. **A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence**. New Hampshire: Dartmouth College, 1955. Disponível em: <https://www.opencadd.com.br/hubfs/Discovery%20Content/dartmouth_summer_project.pdf>. Acesso em: 19 out. 2025.

MCCARTHY, John. **What is Artificial Intelligence?**. [S. l.], [s. d.]. Disponível em: < <https://www-formal.stanford.edu/jmc/whatisai.pdf> >. Acesso em: 4 set. 2025.

MINISTÉRIO DA SAÚDE. **Câncer de pele**. [S. l.], [s. d.]. Disponível em: < <https://www.gov.br/saude/pt-br/assuntos/saude-de-a-a-z/c/cancer-de-pele> >. Acesso em: 6 abr. 2025.

MITCHELL, Tom. **Machine Learning**. [S. l.]: McGraw-Hill, 1997. Disponível em: <<https://github.com/Algorithms-Master/Books/blob/master/McGrawHill%20-%20Machine%20Learning%20-Tom%20Mitchell.pdf>>. Acesso em: 21 ago. 2025.

MOREIRA, T. Debate sobre software livre chega ao celular. **Valor Econômico**, São Paulo, 4 out. 2004. p. B4.

MORSCH, José Aldair. **Código de Ética Médica: qual a importância, o que diz e como consultar**. [S. l.], [s. d.]. Disponível em: < <https://telemedicinamorsch.com.br/blog/codigo-de-etica-medica> >. Acesso em: 26 ago. 2025.



MOURA, G. C. de M. **Citação de referências e documentos eletrônicos**. [S. l.], [s. d.]. Disponível em: < <http://www.elogica.com.br/users/gmoura/refere.html> >. Acesso em: 9 out. 1996.

MOUSAVI, Seyed Mohammad Yousef et al. Anatomy, Skin (Integument). In: STATPEARLS [Internet]. Treasure Island (FL): StatPearls Publishing, 2023. Disponível em: < <https://www.ncbi.nlm.nih.gov/books/NBK531493/> >. Acesso em: 21 set. 2025.

MSD MANUALS. **Considerações gerais sobre o câncer**. [S. l.], [s. d.]. Disponível em: <<https://www.msdmanuals.com/pt/casa/câncer/considerações-gerais-sobre-o-câncer/considerações-gerais-sobre-o-câncer>>. Acesso em: 5 abr. 2025.

MUSTHAFA, M. Mohamed. **Enhanced skin cancer diagnosis using optimized CNN architecture and checkpoints for automated dermatological lesion classification**. 2024. Disponível em: <<https://bmcmmedimaging.biomedcentral.com/articles/10.1186/s12880-024-01356-8>>. Acesso em: 26 jul. 2025.

NATCOFARMA. **O que é um carcinoma?**. [S. l.], [s. d.]. Disponível em: <<https://natcofarma.com/o-que-e-um-carcinoma/natcofarma>>. Acesso em: 6 abr. 2025.

NATIONAL CENTER FOR BIOTECHNOLOGY INFORMATION (NCBI). **AI-driven skin cancer diagnosis: a review of advanced deep learning approaches and ethical considerations**. [S. l.], [s. d.]. Disponível em: < https://pmc.ncbi.nlm.nih.gov/articles/PMC12044287/?utm_source >. Acesso em: 18 set. 2025.

NATIONAL CENTER FOR BIOTECHNOLOGY INFORMATION (NCBI). **Anatomy, Skin (Integument), Dermis**. [S. l.], [s. d.]. Disponível em: < https://www.ncbi.nlm.nih.gov/books/NBK554386/?utm_source >. Acesso em: 18 set. 2025.

NATSUGA, Ken. Epidermal Barriers. **Current Topics in Membranes**, [S. l.], 2014. Disponível em: < <https://pmc.ncbi.nlm.nih.gov/articles/PMC4254582/> >. Acesso em: 18 set. 2025.



NAWAZ, Khadija et al. Skin Cancer Detection Using Dermoscopic Images with Convolutional Neural Network. **Scientific Reports**, [S. l.], 2025. Disponível em: <<https://www.nature.com/articles/s41598-025-91446-6?fromPaywallRec=false>>. Acesso em: 17 set. 2025.

NG, Andrew et al. **Skin Cancer Detection Using Deep Machine Learning Techniques**. 2016. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2666521224000589>>. Acesso em: 17 set. 2025.

NOTION. **Artigos**. [S. l.], [s. d.]. Disponível em: <<https://www.notion.so/Artigos-1fe699a22537800293b8cb2fc56796df>>. Acesso em: 10 jun. 2025.

NVIDIA. GTC Keynote Wrap-Up: NVIDIA to Bring AI to Every Industry, CEO Says. **NVIDIA Blog**, 21 mar. 2023. Disponível em: <<https://blogs.nvidia.com/blog/gtc-keynote-spring-2023/>>. Acesso em: 19 out. 2025.

NVIDIA. NVIDIA Blackwell Platform Arrives to Power a New Era of Computing. **NVIDIA Newsroom**, 18 mar. 2024. Disponível em: <<https://nvidianews.nvidia.com/news/nvidia-blackwell-platform-arrives-to-power-a-new-era-of-computing>>. Acesso em: 19 out. 2025.

ONCOGUIA. **Atraso no diagnóstico do câncer faz crescer taxa de tumores descobertos tardiamente**. [S. l.], [s. d.]. Disponível em: <<http://www.oncoguia.org.br/conteudo/atraso-no-diagnostico-do-cancer-faz-crescer-taxa-de-tumores-descobertos-tardiamente/16427/7>>. Acesso em: 03 mai. 2025.

ONCOGUIA. **Em 2021, 62% dos pacientes com câncer tiveram diagnóstico tardio no país**. [S. l.], [s. d.]. Disponível em: <<http://www.oncoguia.org.br/conteudo/em-2021-62-dos-pacientes-com-cancer-tiveram-diagnostico-tardio-no-pais/16465/7>>. Acesso em: 05 mai. 2025.

ORACLE. **O que é Machine Learning?**. [S. l.], [s. d.]. Disponível em: <<https://www.oracle.com/br/artificial-intelligence/machine-learning/what-is-machine-learning/>>. Acesso em: 19 out. 2025.



PANDAS. **Pandas: powerful Python data analysis toolkit**. [S. l.], [s. d.]. Disponível em: <<https://pandas.pydata.org> >. Acesso em: 1 mar. 2025.

PERES, Adriano; BARBI, Ivo. **Uma nova família de inversores com comutação suave empregando a técnica de grameamento ativo**. 2000. 162 f. Tese (Doutorado em Engenharia Elétrica) – Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis, 2000.

PROKSCH, E. et al. The skin: an active and smart interface. **Dermatology**, Basel, v. 216, n. 4, p. 288-294, 2008. Disponível em: <<https://pubmed.ncbi.nlm.nih.gov/19043850/>>. Acesso em: 18 set. 2025.

PYTHON ACADEMY. **A biblioteca OS do Python**. [S. l.], [s. d.]. Disponível em: <<https://pythonacademy.com.br/blog/a-biblioteca-os-do-python> >. Acesso em: 1 mai. 2025.

PYTHON. **Python official website**. [S. l.], [s. d.]. Disponível em: <<https://www.python.org> >. Acesso em: 1 mar. 2025.

REICHOW. **Tipos de câncer de pele**. [S. l.], [s. d.]. Disponível em: <<https://clinicareichow.com.br/public/blog/tipos-de-cancer-de-pele> >. Acesso em: 2 abr. 2025.

REQUESTS. **Requests: HTTP for Humans**. [S. l.], [s. d.]. Disponível em: <<https://docs.python-requests.org/en/latest/index.html> >. Acesso em: 26 abr. 2025.

SAMUEL, Arthur. Some Studies in Machine Learning Using the Game of Checkers. **IBM Journal of Research and Development**, 1959. Disponível em: <<https://ieeexplore.ieee.org/document/5392560> >. Acesso em: 1 set. 2025.

SANARMED. **Câncer de pele: melanoma x não melanoma**. [S. l.], [s. d.]. Disponível em: <<https://sanarmed.com/cancer-de-pele-melanoma-x-nao-melanoma-colunistas> >. Acesso em: 6 abr. 2025.

SAÚDE ABRIL. **Aumento dos casos de câncer: o efeito pouco falado das mudanças climáticas**. [S. l.], [s. d.]. Disponível em: <<https://saude.abril.com.br/coluna/com-a->



palavra/aumento-dos-casos-de-cancer-o-efeito-pouco-falado-das-mudancas-climaticas

>. Acesso em: 1 abr. 2025.

SCHWERTL, Simone Leal. **Matemática básica**. 2. ed. Blumenau: Edifurb, 2010. 113 p.

SCRIBBRI. **Dissertation Methodology**. [S. l.], [s. d.]. Disponível em: <<https://www.scribbr.com/dissertation/methodology>>. Acesso em: 1 mar. 2025.

SCRIBBRI. **Hawthorne Effect**. [S. l.], [s. d.]. Disponível em: <<https://www.scribbr.com/research-bias/hawthorne-effect>>. Acesso em: 29 mar. 2025.

SCRIBBRI. **Observer Bias**. [S. l.], [s. d.]. Disponível em: <<https://www.scribbr.com/research-bias/observer-bias>>. Acesso em: 29 mar. 2025.

SINGH, Karan et al. Deep Learning and Machine Learning Techniques of Diagnosis Dermoscopy Images for Early Detection of Skin Diseases. **Electronics**, [S. l.], 2021. Disponível em: <https://www.mdpi.com/2079-9292/10/24/3158?utm_source>. Acesso em: 17 set. 2025.

SOCIEDADE BRASILEIRA DE DERMATOLOGIA. **Funções da pele**. [S. l.], [s. d.]. Disponível em: <<https://www.sbd.org.br/doencas/a-pele-e-o-maior-orgao-do-corpo-humano>>. Acesso em: 18 set. 2025.

SOFTDESIGN. **Desafios da inteligência artificial**. [S. l.], [s. d.]. Disponível em: <<https://softdesign.com.br/blog/desafios-da-inteligencia-artificial/#h-seguranca-da-informacao-e-privacidade-de-dados>>. Acesso em: 7 abr. 2025.

STEWART, Conor. **AI in healthcare**. [S. l.], [s. d.]. Disponível em: <<https://www.statista.com/topics/10011/ai-in-healthcare/#topicOverview>>. Acesso em: 15 set. 2025.

SUPABASE. **Database Overview**. [S. l.], [s. d.]. Disponível em: <<https://supabase.com/docs/guides/storage>>. Acesso em: 4 mai. 2025.

SUPABASE. **Storage Guide**. [S. l.], [s. d.]. Disponível em: <<https://supabase.com/docs/guides/storage>>. Acesso em: 4 mai. 2025.



TENSORFLOW. **TensorFlow: Machine Learning Framework**. [S. l.], [s. d.]. Disponível em: <<https://www.tensorflow.org/?hl=pt-br>>. Acesso em: 29 mai. 2025.

TOZZI, M.; OTA, J. Vertedouro em degraus. **Revista da Vinci**, Curitiba, v. 1, n. 1, p. 9-28, 2004.

TSCHANDL, P. et al. Comparison of the accuracy of human readers versus machine-learning algorithms for pigmented skin lesion classification. **The Lancet**, [S. l.], v. 392, p. 131-141, 2018. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0140673618315599>>. Acesso em: 10 jun. 2025.

TSCHANDL, P. et al. Human–computer collaboration for skin cancer recognition. **Nature Medicine**, v. 26, p. 1229–1234, 2020. Disponível em: <<https://www.nature.com/articles/s41591-020-0942-0>>. Acesso em: 19 ago. 2025.

TYAGI, Amit et al. **Artificial Intelligence in Healthcare: Review and Future Directions**. 2020. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0952197623000787>>. Acesso em: 17 set. 2025.

UNIVERSIDADE FEDERAL DE ALFENAS (UNIFAL-MG). **Pele e anexos – Histologia Interativa**. [S. l.]: UNIFAL-MG, [s. d.]. Disponível em: <<https://www.unifal-mg.edu.br/histologiainterativa/pele-e-anexos/>>. Acesso em: 18 set. 2025.

VALOR GLOBO. **Processos por erro médico crescem 506% em um ano no Brasil**. [S. l.], 17 fev. 2025. Disponível em: <<https://valor.globo.com/patrocinado/dino/noticia/2025/02/17/processos-por-erro-medico-crescem-506-em-um-ano-no-brasil.ghtml>>. Acesso em: 3 abr. 2025.

VAPNIK, V. N. **The Nature of Statistical Learning Theory**. 2. ed. Nova Iorque: Springer, 1999.

VASWANI, A. et al. Attention Is All You Need. In: **ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS (NIPS 2017)**, 2017, Long Beach, CA.



Anais... Disponível em: <<https://scispace.com/papers/attention-is-all-you-need-1hodz0wcqb>>. Acesso em: 19 out. 2025.

VEJA. Inteligência artificial protagoniza revolução sem precedentes na medicina. [S. l.], [s. d.]. Disponível em: <<https://veja.abril.com.br/saude/inteligencia-artificial-protagoniza-revolucao-sem-precedentes-na-medicina>>. Acesso em: 4 abr. 2025.

VIMEO. Part 2: AI in skin cancer screening. [S. l.], 2025. 1 vídeo (aprox. 10 min). Disponível em: <<https://vimeo.com/724903199/97e1ef3b64>>. Acesso em: 10 jun. 2025.

VIMEO. Vídeo sobre inteligência artificial na dermatologia (2). [S. l.], 2025. 1 vídeo (aprox. 10 min). Disponível em: <<https://vimeo.com/724886149/0631efe809>>. Acesso em: 10 jun. 2025.

WANG, Y. et al. Deep learning-based classification of skin lesions for melanoma detection. BioMed Research International, [S. l.], 2021. Disponível em: <<https://onlinelibrary.wiley.com/doi/10.1155/2021/9025470>>. Acesso em: 10 jun. 2025.

WINKLER, Julia K. Assessment of Diagnostic Performance of Dermatologists Cooperating With a Convolutional Neural Network in a Prospective Clinical Study Human With Machine. [S. l.], [s. d.]. Disponível em: <<https://jamanetwork.com/journals/jamadermatology/fullarticle/2804568>>. Acesso em: 3 set. 2025.

WORLD HEALTH ORGANIZATION. Cancer. [S. l.], [s. d.]. Disponível em: <<https://www.who.int/news-room/fact-sheets/detail/cancer#:~:text=,colon and rectum and prostate>>. Acesso em: 5 set. 2025.

WORLD HEALTH ORGANIZATION (WHO). Global report on psoriasis. Geneva: WHO, 2016. Disponível em: <<https://apps.who.int/iris/handle/10665/204417>>. Acesso em: 19 set. 2025.

XIE, Qizhe et al. Self-Training with Noisy Student Improves ImageNet Classification. 2020. Disponível em: <<https://arxiv.org/abs/1911.04252>>. Acesso em: 17 set. 2025.



XU, J. et al. Deep learning for melanoma diagnosis: A systematic review. **European Journal of Cancer**, [S. l.], v. 134, p. 66-77, 2020. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0959804919308342> >. Acesso em: 10 jun. 2025.

YANG, J. et al. Artificial intelligence in melanoma diagnosis: A meta-analysis. **European Journal of Cancer**, [S. l.], v. 142, p. 118-129, 2021. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0959804920313575> >. Acesso em: 10 jun. 2025.

YU, K. H. et al. Deep learning for skin lesion classification: A review. **Clinics in Dermatology**, [S. l.], v. 42, p. 123-134, 2024. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0738081X23002742> >. Acesso em: 10 jun. 2025.

YOUSEF, Hani; SHARMA, Shankar. Anatomy, Skin (Integument), Epidermis. In: STATPEARLS [Internet]. Treasure Island (FL): StatPearls Publishing, 2022. Disponível em: <<https://www.ncbi.nlm.nih.gov/books/NBK545209/> >. Acesso em: 19 set. 2025.

YOUSEF, Hani; SHARMA, Shankar. Physiology, Integument. In: STATPEARLS [Internet]. Treasure Island (FL): StatPearls Publishing, 2023. Disponível em: <<https://www.ncbi.nlm.nih.gov/books/NBK554548/> >. Acesso em: 21 set. 2025.

ZEILER, M. D.; FERGUS, R. **Visualizing and understanding convolutional networks**. arXiv, 2013. Disponível em: <<https://arxiv.org/pdf/1512.00567> >. Acesso em: 10 jun. 2025.

ZHANG, L. et al. **Deep learning for skin cancer detection: A comprehensive review**. arXiv, 2023. Disponível em: <<https://arxiv.org/html/2312.15825v1> >. Acesso em: 10 jun. 2025.


8 APÊNDICE

8.1 Aplicativo

O aplicativo segue as seguintes funções. Primeira há a necessidade se efetuar o cadastro conforme o tipo de usuário, para os pacientes no cadastro, requer o nome completo, o Email, a senha, o CPF ou CNS (O documento de Cartão Nacional de Saúde, podendo ser identificado pelo seu cartão de identidade do sus) e a sua data de nascimento. Já no login, apenas precisa do Email e de sua senha. Para os médicos isso acaba sendo mais complexo. No cadastro precisa do nome completo, o Email, a senha, o CPF, Número do CRM (Um documento de identificação do profissional da saúde, os médicos são reconhecidos no âmbito do trabalho por ele, ou seja, o Conselho Regional de Medicina) e o UF do CRM para identificação, ademais, alguns médicos podem possuir o mesmo número, mas atua por estado diferente em Figura 6. Já para login, só vai precisar de Email ou CPF e a senha em Figura 7.

Para conseguir analisar a imagem, precisa ser selecionado em analisar novo exame Figura 8 e você terá a opção de selecionar tanto a imagem por uma retirada da câmera ou pela galeria onde pode selecionar as imagens já salvas. Quando selecionado, a imagem Figura 9, clica-se no botão de analisar a imagem Figura 10. A imagem se encaminha para o servidor e retorna as suas devidas análises em formato json, a qual é posicionada no aplicativo com os diagnósticos Figura 11.

Figura 4: Tela inicial




Fonte: Autoria Própria

Figura 5: Tela de Login




Fonte: Autoria Própria

Figura 6: Cadastro do médico



Fonte: Autoria Própria

Figura 7: Login do médico



Fonte: Autoria Própria

Figura 8:Seleção das Funções




Fonte: Autoria Própria

Figura 9: Análise da IA



Fonte: Autoria Própria

Figura 10: Análise da IA, Imagem selecionada



Fonte: Autoria Própria

Figura 11:Resultado de Análise



←

Resultado da Análise

Risco de Malignidade:

INTERMEDIÁRIO

A probabilidade de ser maligno é de 54.66%

Diagnóstico Principal Sugerido

Basal Cell Carcinoma

Detalhes do Diagnóstico

△

Diagnóstico Categoria 1

Melanoma

⬢

Diagnóstico Categoria 2

SCC

⊙

Análise Melanocítica

Non-Melanocytic

Fonte: Autoria Própria