

unesp  **UNIVERSIDADE ESTADUAL PAULISTA**
“JÚLIO DE MESQUITA FILHO”
Faculdade de Ciências
Campus de Bauru - SP

PEDRO HENRIQUE MENDES DE OLIVEIRA

SPOTTER: SISTEMA DE IDENTIFICAÇÃO DE MELANOMA EM
IMAGENS DE CELULAR

BAURU – S.P.
2023

PEDRO HENRIQUE MENDES DE OLIVEIRA

SPOTTER: Sistema de Identificação de Melanoma em Imagens de Celular

Trabalho de Conclusão de Curso (TCC) apresentado ao Conselho de Curso de Sistemas de Informação, da Faculdade de Ciências – Unesp/Bauru, como requisito para obtenção do título de Bacharel em Sistemas de Informação.

Orientador:

Co-orientador:

Bolsa:

BAURU – S.P.
2023

Ficha Catalográfica:

Oliveira, Pedro Henrique Mendes de
SPOTTER: Sistema de Identificação de Melanoma em
Imagens de Celular / Pedro Henrique Mendes de Oliveira. –
Bauru, 2023
34 p.

Trabalho de conclusão de curso (Bacharelado – Sistemas de
Informação) – Universidade Estadual Paulista (Unesp),
Faculdade de Ciências, Bauru

1 Identificação de Melanoma em Imagens de Celular

SPOTTER: Sistema de Identificação de Melanoma em Imagens de Celular

Trabalho de Conclusão de Curso (TCC) apresentado ao Conselho de Curso de Sistemas de Informação, da Faculdade de Ciências – Unesp/Bauru, como requisito para obtenção do título de Bacharel em Sistemas de Informação.

Orientador:
Co-orientadora:
Bolsa:

Data da defesa/entrega: 05/12/2023

MEMBROS COMPONENTES DA BANCA EXAMINADORA:

Presidente e Orientador: José Remo Ferreira Brega
Faculdade de Ciências - Unesp.

Membro Titular: Simone das Graças Domingues Prado
Faculdade de Ciências - Unesp.

Membro Titular: Douglas Rodrigues
Faculdade de Ciências - Unesp.

Local: Universidade Estadual Paulista
Faculdade de Ciências
UNESP – Campus de Bauru

Dedico este trabalho aos meus pais,
professores e Lorena meu grande amor.

AGRADECIMENTOS

Agradeço a Unesp, aos ensinamentos de meus professores, incentivo de meus pais e apoio do meu amor.

“Mas tudo ainda era muito maior quando a gente ouvia contada, a narração dos outros [...]”

João Guimarães Rosa (1994, p.35)

RESUMO

Este trabalho tem como principal objetivo desenvolver uma solução voltada para identificação precoce de possíveis características associadas ao câncer de pele, por meio da análise de sinais cutâneos, utilizando a telemedicina. O aplicativo foi desenvolvido para dispositivos móveis, melhorando a acessibilidade à avaliação dermatológica. Ele permite aos usuários identificarem sinais potencialmente preocupantes, democratizando o acesso a análises especializadas. Além de realizar análises, o aplicativo oferece informações sobre o tema, orientando os usuários sobre as próximas ações a serem tomadas ao identificar características que demandam atenção. Há também uma seção interativa para esclarecer dúvidas sobre o processo de avaliação, proporcionando aos usuários uma compreensão mais profunda. No desenvolvimento do algoritmo destinado a identificar com precisão os diferentes tipos de pintas e lesões cutâneas, conduziu-se um estudo envolvendo arquiteturas de aprendizado profundo. Nesse contexto, as redes neurais convolucionais destacaram-se como a escolha mais eficaz. A integração dessas redes, aliada a um tratamento dos dados e à utilização de um modelo previamente treinado, resultou em um resultado robusto. A proposta do trabalho não só se destaca por sua abordagem tecnológica inovadora, mas também pela amplitude informativa que oferece. O aplicativo representa uma ferramenta abrangente e confiável para identificação precoce de possíveis indicativos de câncer de pele, contribuindo significativamente para a promoção da saúde e bem-estar da comunidade.

Palavras – chave: CNN; câncer; telemedicina; IA.

ABSTRACT

This work aims to develop a solution focused on the early identification of possible characteristics associated with skin cancer through the analysis of cutaneous signals, using telemedicine. The mobile application was designed to enhance accessibility to dermatological assessments, allowing users to identify potentially concerning signs, democratizing access to specialized analyses. In addition to conducting analyses, the application provides information on the topic, guiding users on the next steps to take when identifying characteristics that require attention. There is also an interactive section to address doubts about the evaluation process, providing users with a deeper understanding. In the development of the algorithm intended to accurately identify different types of moles and skin lesions, a study involving deep learning architectures was conducted. In this context, convolutional neural networks stood out as the most effective choice. The integration of these networks, combined with data preprocessing and the use of a pre-trained model, resulted in a robust outcome. The proposal of the work not only stands out for its innovative technological approach but also for the informative breadth it offers. The application represents a comprehensive and reliable tool for the early identification of possible indicators of skin cancer, contributing significantly to the promotion of health and well-being within the community.

Keywords : CNN; cancer; telemedicine; AI.

LISTA DE FIGURAS

Foto 1	MiiSkin	15
Foto 2	MoleScope	16
Foto 3	UMSKinCheck	17
Foto 4	Diagrama de caso de uso	18
Foto 5	Tela Inicial	19
Foto 6	Informações Médicas	19
Foto 7	Tela de informações específicas	20
Foto 8	Menu de Informações do Aplicativo	20
Foto 9	Seleção de parte do corpo	21
Foto 10	Tela de Análises	21
Foto 11	Representação da Ligação entre Telas	22
Foto 12	Treinamento da CNN e Transformer	27
Foto 13	Evolução da Perda e Acurácia durante o treinamento da CNN por 30 épocas	29
Foto 14	Matriz de Confusão	30

LISTA DE ABREVIATURAS E SIGLAS

CNN	Redes Neurais Convolucionais
SUS	Sistema Único de Saúde
CFM	Conselho Federal de Medicina
SAPS	Secretaria de Atenção Primária à Saúde
UBS	Unidade Básica de Saúde
INCA	Instituto Nacional de Câncer
MS	Ministério da Saúde

SUMÁRIO

1 INTRODUÇÃO	13
2 SOLUÇÕES EXISTENTES	15
3 DESCRIÇÃO DO APLICATIVO	18
3.1 TELAS DO APLICATIVO	19
4 MODELO DE CLASSIFICAÇÃO	23
5 PROCEDIMENTO DE VALIDAÇÃO DO SISTEMA	26
6 CONCLUSÃO	32
REFERÊNCIA	33

1. INTRODUÇÃO

O acesso à medicina, atendimento médico e diagnósticos apresentam desafios em várias regiões do Brasil e do mundo, devido às disparidades geográficas e socioeconômicas.

Durante a pandemia de COVID-19 em 2020, o Conselho Federal de Medicina (CFM) regulamentou a telemedicina no Brasil como medida emergencial (BRASIL, 2020). Em 2022, o CFM oficializou e estabeleceu diretrizes mais abrangentes por meio da Resolução CFM nº 2.314, consolidando a prática da telemedicina no país (BRASIL, 2022).

Essa evolução normativa reflete o reconhecimento permanente da telemedicina como uma ferramenta essencial para o acesso e eficiência nos serviços de saúde. Iniciativas como o TeleSUS promovido na época da COVID-19, UBS Digital e outros, desempenham um papel fundamental ao fornecer atendimento médico gratuito e à distância. Até 2022, o Ministério da Saúde já havia investido mais de R\$126 milhões em 50 projetos em 22 estados brasileiros (SAPS, 2022).

A identificação de pintas potencialmente malignas, em geral, requer a consulta presencial com um dermatologista (INCA, 2022), para realização de exames clínicos, dificultada pela escassez de especialistas em algumas regiões. Essa limitação geográfica e a necessidade de consultas presenciais motivam a busca por soluções que possibilitem análises iniciais remotas e eficientes.

O presente trabalho visa facilitar a vida dos cidadãos, proporcionando um método de identificação inicial que não dependa da presença física em consultórios médicos. Inspirado no projeto 'PRICKI' (Journal of Immunological Methods, v. 487.), desenvolvido na UNESP de Botucatu, o qual utilizou técnicas de aprendizado de máquina para criar um aplicativo de diagnóstico de alergias, este trabalho busca aplicar abordagens similares para identificação precoce de possíveis casos de câncer de pele.

O desafio central consiste em incorporar tecnologia de maneira ética, levando em consideração a sensibilidade associada à identificação da possibilidade de um caso de câncer. Equilibrando a necessidade de evitar falsos positivos, que poderiam causar impactos na saúde física ou emocional, com a importância de evitar falsos negativos, que poderiam criar uma falsa sensação de segurança e desencorajar a busca por orientação especializada.

Em 2019 foram registrados 185.380 casos relacionados a algum tipo de câncer de pele (MS, 2021). A detecção rápida é crucial, especialmente no melanoma, o tipo mais grave, onde um mês de atraso no tratamento inicial aumenta a taxa de mortalidade em 5%.

Este contexto reforça a importância do projeto de possibilitar uma identificação precoce das características do câncer de pele, que é crucial para um tratamento eficaz. O tempo é um fator crítico, como evidenciado pelo aumento significativo na taxa de mortalidade quando o tratamento é adiado. Além disso, a população mais idosa enfrenta um risco mais elevado de desenvolver câncer de pele devido à exposição acumulada ao sol ao longo da vida.

Os custos associados ao tratamento tardio ressaltam a importância econômica do diagnóstico precoce. O Serviço Único de Saúde (SUS) enfrenta despesas substanciais no tratamento de pacientes com melanoma, e a detecção inicial pode representar uma economia significativa para o sistema de saúde, ao mesmo tempo que melhora as perspectivas de tratamento para os pacientes.

O SUS gasta em média R\$4,4 milhões por ano no Estado de São Paulo com o tratamento de pacientes com melanoma, segundo um estudo que analisou os 2.920 casos da doença entre os paulistas, de 2000 a 2007. Se fossem detectados em sua fase inicial, os 2.920 casos custam R\$1,15 milhões, ou seja, os gastos atuais são 282% maiores. Este estudo indica que um paciente que está com melanoma ainda na fase inicial custa R\$382 por mês, enquanto o custo para tratar um paciente com melanoma disseminado, no estágio 4, fica em média R\$2.600 por mês (SOUZA, 2009).

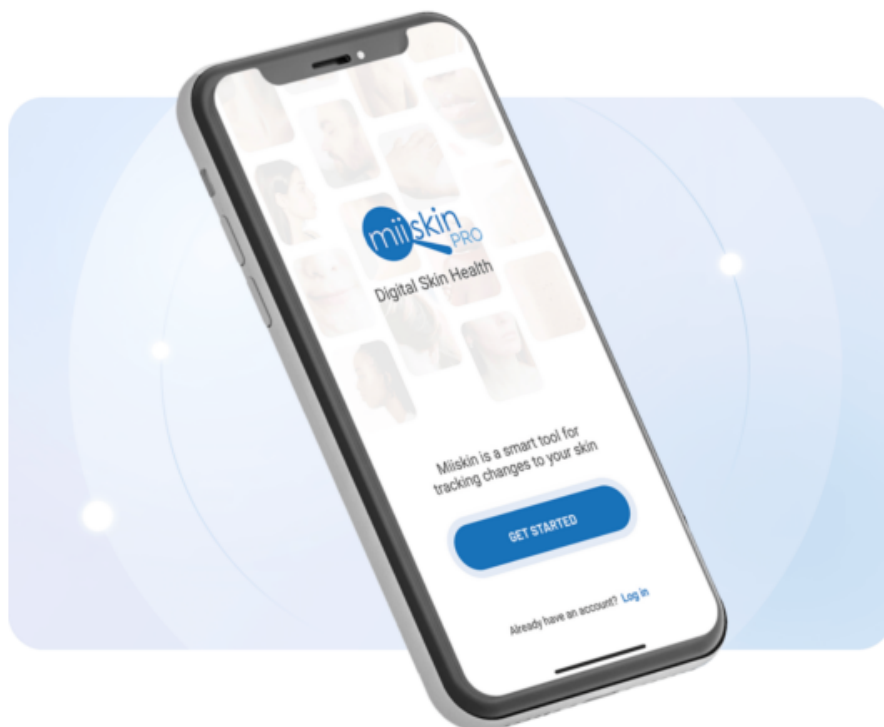
A versão inicial do aplicativo foi desenvolvida sem custos, utilizando ferramentas de código aberto e um banco de dados de imagens disponíveis gratuitamente na internet. Isso reforça o compromisso de tornar a tecnologia acessível e amplamente disponível. O contexto delineado destaca a necessidade urgente de soluções inovadoras para enfrentar os desafios no diagnóstico de câncer de pele, contribuindo assim para a melhoria da saúde pública.

2. SOLUÇÕES EXISTENTES

Existem diversas soluções inovadoras no mercado que visam auxiliar na detecção e monitoramento de sinais de pele. A seguir, serão apresentadas algumas delas, destacando suas características, vantagens e desvantagens.

O Miiskin (<https://miiskin.com/>) cria uma biblioteca com fotos e um histórico das mudanças nos sinais de pele. Especialmente eficaz para sinais que estão crescendo, o Miiskin recomenda a inclusão de uma moeda ao lado da pinta para garantir uma referência de medida constante entre as fotos. Além disso, sua funcionalidade inclui filtros de correção de borrões, favorecendo uma análise mais precisa. No entanto, sua desvantagem reside na barreira monetária para acesso total às funcionalidades, com um modelo de negócios voltado principalmente para consultórios e organizações, com planos a partir de trezentos dólares ao mês.

Figura 1 — MiiSkin (Imagem do aplicativo)



Fonte: site do Miiskin. Disponível em: <https://miiskin.com>.

O MoleScope (<https://www.molescope.com/>) apresenta uma solução baseada em uma câmera de alta resolução que se conecta ao celular, melhorando a qualidade das imagens. Esta solução simula o olhar próximo de um médico durante uma consulta ao vivo. O paciente pode realizar um autoexame seguindo um guia fornecido pela MoleScope ou encaminhar as fotos

para seu dermatologista. Ele também conta com conectividade com a plataforma DermEngine que possui seus próprios especialistas caso o usuário não tenha acesso a um médico.

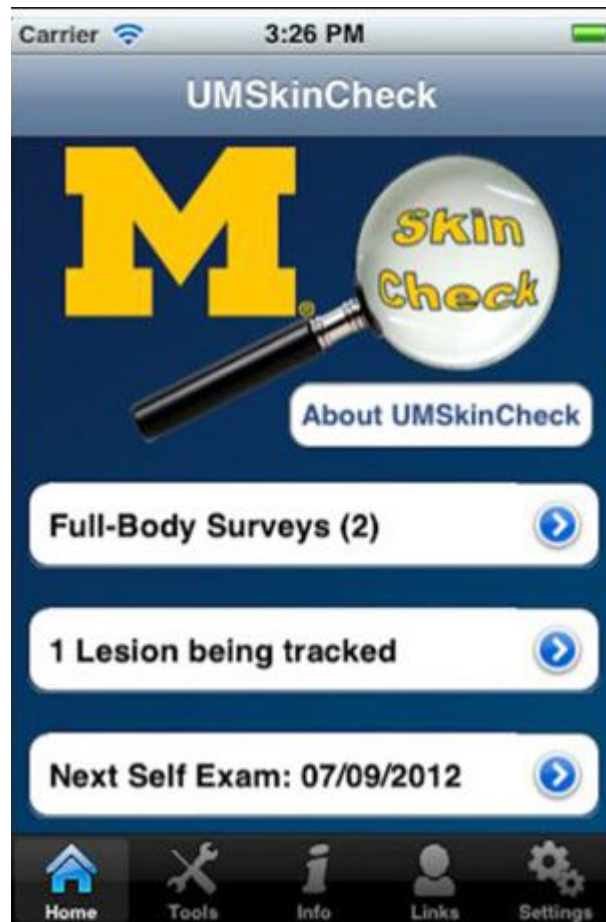
É disponibilizado em dois modelos, por 49 dólares e 299 dólares, o MoleScope não é compatível com certos modelos Android, apesar de sua compatibilidade com a linha de aparelhos da Apple.



Figura 2 — MoleScope

A universidade de Michigan, nos Estados Unidos, desenvolveu o aplicativo UMSkinCheck (<https://www.med.umich.edu/cancer/files/skin-check-app-flyer.pdf>), com foco em fornecer informações sobre riscos, prevenção e saúde da pele. Ele oferece um guia para a realização de autodiagnósticos e envia notificações para lembrar o usuário de realizar exames de rotina. Similar ao Miiskin, o UMSkinCheck permite a gravação de fotos para a comparação de alterações.

Figura 3 — UMSkinCheck

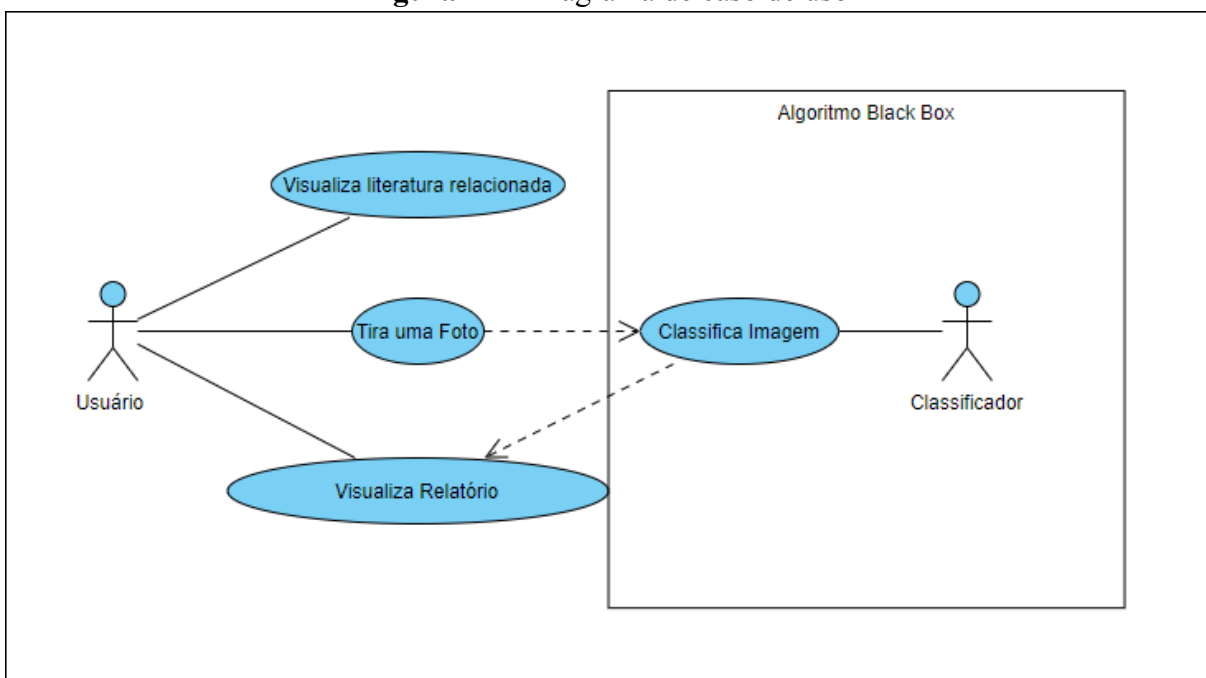


Todas as soluções apresentadas possuem limitações, como a disponibilidade apenas em inglês, o que os tornam menos acessíveis para o público brasileiro. O Spotter busca superar essas limitações integrando as melhores características de cada solução em um produto final voltado para o público brasileiro, sem custos aos usuários.

3. DESCRIÇÃO DO APLICATIVO

O diagrama ilustrado na figura 4 tem como objetivo detalhar as funcionalidades do aplicativo móvel responsável pela interação com o usuário final. O protagonista é o usuário, que possui acesso à navegação da literatura relacionada, segmentada por categorias específicas e informações detalhadas do funcionamento do próprio *software*. Destaca-se a capacidade do aplicativo em proporcionar uma experiência informativa e educativa.

Figura 4 — Diagrama de caso de uso



Fonte: Elaborado pelo autor

Além disso, existe a funcionalidade de tirar uma foto que o usuário utiliza a câmera do celular para capturar uma imagem de um sinal em sua própria pele que deseja classificar. Essa ação serve como ponto de entrada, junto com a inserção de idade e região do corpo, para o algoritmo, que processará a imagem capturada.


Por fim, o sistema retorna a análise da classificação, e o usuário tem a opção de visualizar um relatório mais detalhado sobre como interpretar os resultados. O relatório inclui informações da probabilidade associada às classes, explicação dos resultados e formas de contato com especialistas médicos.

Esses casos de uso representam as interações possíveis entre o usuário e as funcionalidades do aplicativo "Spotter". O design desses casos de uso busca proporcionar uma experiência intuitiva, com as informações relevantes sempre presentes em tela e cuja usabilidade não requeira tutoriais, visando maior acessibilidade.

3.1 TELAS DO APLICATIVO

Ao abrir o aplicativo o sistema apresentará a tela inicial, figura 5, que contém três botões: “Iniciar uma nova análise”, representado por um ícone de uma câmera, “Como funciona?” e “Recomendações Médicas”. Ao clicar em “Recomendações Médicas” a tela de Menu de Informações Médicas é chamada. Nela é possível visualizar a tela, mostrada na figura 6, que contém cinco opções de informações para ajudar a informar o usuário sobre o que é um tumor maligno, os tipos, fatores de riscos, sinais e sintomas e também sobre prevenção. A tela também conta com um botão no canto superior esquerdo que retorna o usuário de volta à tela inicial.

Figura 5 — Tela Inicial



Fonte: Elaborado pelo autor.

Figura 6 — Informações Médicas

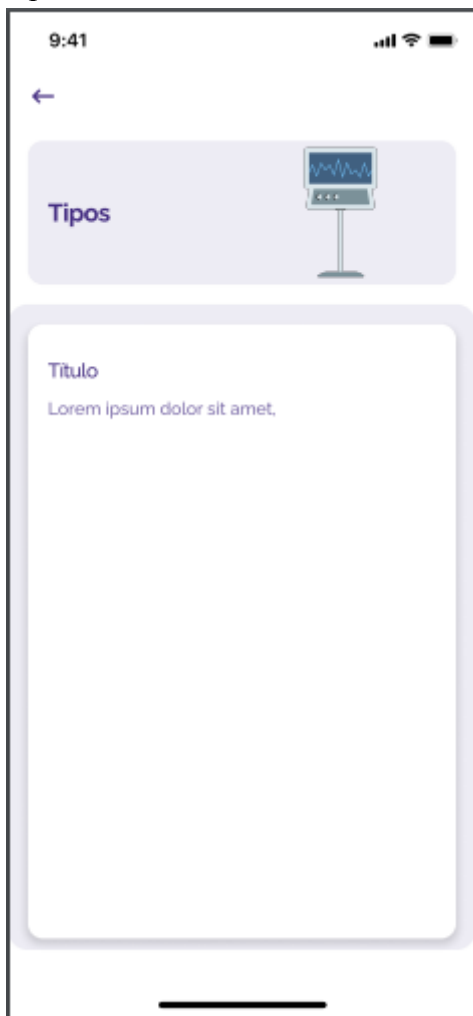


Fonte: Elaborado pelo autor.

Após o usuário selecionar uma das opções na tela de Informações Médicas (Figura 6), uma nova tela é aberta, exibindo textos referentes ao tópico escolhido, conforme ilustrado na

Figura 7. As informações apresentadas têm origem em fontes oficiais do governo, como o Ministério da Saúde ou o Instituto Nacional de Câncer (INCA). Caso o usuário tenha optado pelo Menu de Informações do Aplicativo (Figura 8) na tela inicial, ele será direcionado para essa seção. Nela, são disponibilizadas informações sobre o funcionamento do algoritmo de classificação de imagens, as probabilidades associadas a cada tipo de câncer de pele, um manual para interpretar a análise e detalhes de contato com o SUS.

Figura 7 — Tela de informações específicas.



Fonte: Elaborado pelo autor.

Figura 8 — Menu de Informações do Aplicativo

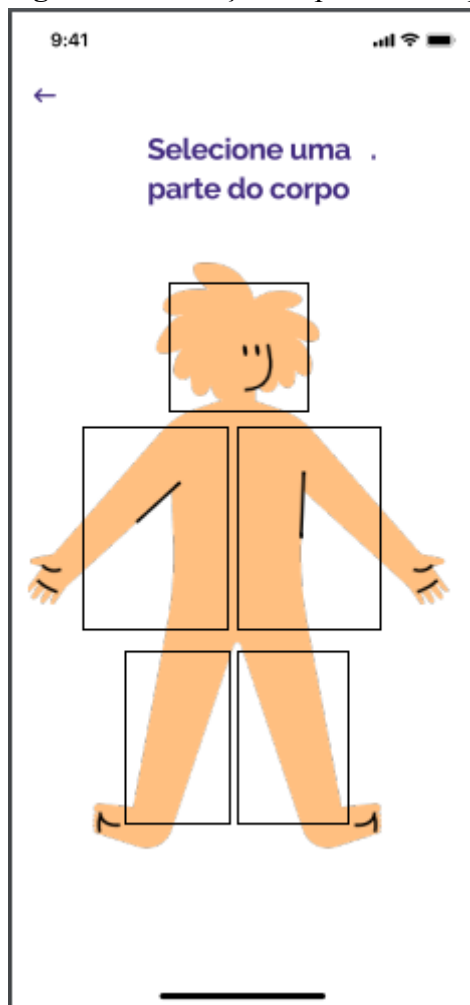


Fonte: Elaborado pelo autor.

Para iniciar uma análise, é necessário clicar no ícone da câmera e, em seguida, informar a idade. Posteriormente, a tela de Seleção de Parte do Corpo (Figura 9) é acionada, onde uma figura representa as opções compatíveis com o classificador. Essas informações são utilizadas como métrica durante a classificação da imagem. O sistema, então, solicita permissão ao usuário para acessar a câmera do dispositivo, e caso seja concedida, abre-a para


que o usuário tire uma foto. Os três dados - idade, região e foto - são parâmetros de entrada no algoritmo de classificação de imagem, que retorna as probabilidades associadas a cada tipo de possível resultado. Com a classificação concluída, é chamada a Tela de Análises (Figura 10), que elabora um relatório usando as informações obtidas via o algoritmo. Nessa tela, há também um botão que direciona o usuário para a tela do Menu de Informações do Aplicativo (Figura 8), com a opção "Como Interpretar os Resultados" selecionada.

Figura 9 — Seleção de parte do corpo



Fonte: Elaborado pelo autor.

Figura 10 — Tela de Análises

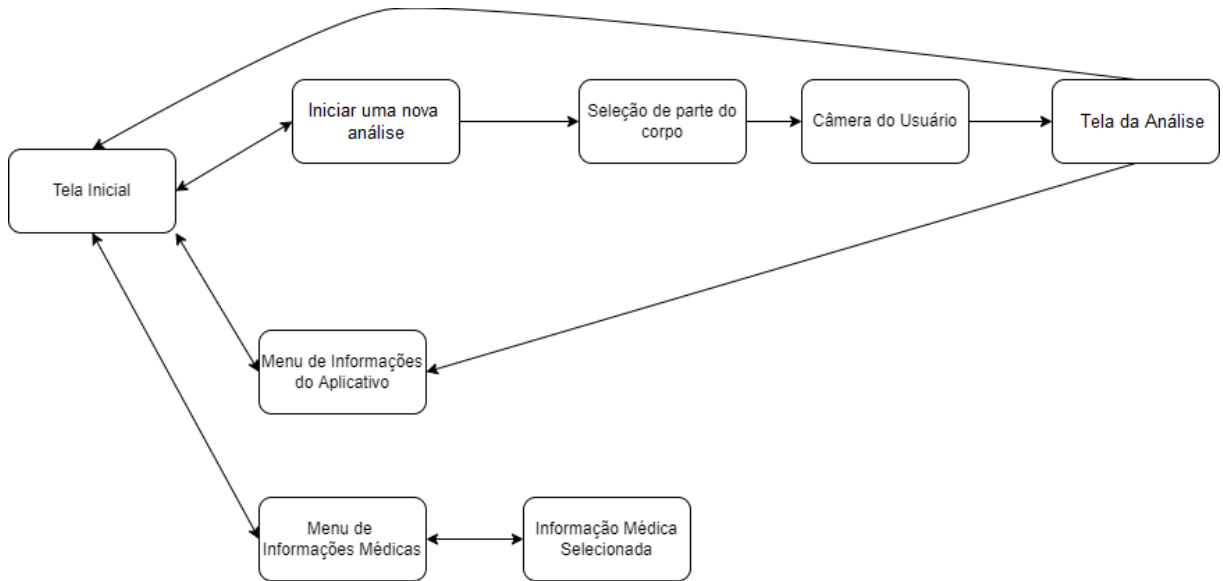


Fonte: Elaborado pelo autor.

Aqui está uma representação visual das conexões e transições entre as diferentes telas do aplicativo Spotter, proporcionando um melhor entendimento do fluxo de interação do usuário. Ao abrir o aplicativo, ele sempre começa pela Tela Inicial, oferecendo três opções: Iniciar uma nova análise, Menu de Informações do Aplicativo e Menu de Informações

Médicas. O fluxo de análise segue pelas telas de inserção de dados até a conclusão da análise, onde o usuário tem a opção de retornar à Tela Inicial ou ir diretamente para o Menu de Informações do Aplicativo. O Menu de Informações Médicas dá acesso a categorias específicas de informações.

Figura 11 — Representação da Ligação entre Telas



Fonte: Elaborado pelo autor.

4. MODELO DE CLASSIFICAÇÃO

A implementação de um modelo de classificação robusto representa a essência deste projeto, visando superar desafios associados à análise remota de sinais de pele. Nesse contexto, foram exploradas duas abordagens distintas: a arquitetura de transformers e redes neurais convolucionais (CNNs) para a tarefa de classificação de pintas cutâneas.

Inicialmente, foi considerada a arquitetura de redes neurais convolucionais (CNNs). Conhecidas por sua eficácia em tarefas de visão computacional, as CNNs são especialmente adequadas para lidar com imagens médicas devido à sua capacidade de capturar padrões locais.

Entretanto, durante o desenvolvimento do projeto, optou-se por incorporar uma segunda abordagem utilizando transformers devido à sua capacidade de capturar padrões complexos e contextuais em dados sequenciais, o que se mostrava promissor para a análise de imagens médicas. Os transformers operam com um mecanismo de atenção, permitindo ao modelo ponderar dinamicamente diferentes partes da entrada, o que é crucial para lidar com dados sequenciais complexos, como as características presentes em imagens médicas.

Além disso, a utilização destes modelos permitiu explorar o potencial de transferência de aprendizado por meio de modelos pré-treinados em grandes conjuntos de dados. Essa abordagem visa acelerar o treinamento e melhorar a capacidade do modelo de generalizar padrões relevantes a partir das imagens de pintas, contribuindo para a eficiência da análise.

A validação cruzada foi incorporada para verificar a robustez dos modelos em diferentes subconjuntos de dados. Para isso foi realizada uma separação 70/30 entre dados de treinamento e dados de validação. Essa abordagem busca assegurar que os modelos possam generalizar suas habilidades de classificação para uma variedade de casos, e não somente aos dados com os quais eles foram treinados.

O pré-processamento de imagens é uma fase essencial no desenvolvimento do processo de classificação de imagens. Essa etapa visa criar uma entrada coesa para o modelo, permitindo que ele aprenda padrões relevantes de maneira eficaz. Aqui, são apresentadas as diversas técnicas e considerações adotadas no processo de pré-processamento.

As imagens das pintas, inicialmente apresentando variabilidade nas resoluções, foram redimensionadas para um formato padrão. Todas as imagens foram ajustadas para uma resolução fixa de 224x224 pixels. Essa padronização na resolução facilitou significativamente o processamento eficiente durante o treinamento e a fase de inferência do modelo.

Para garantir que todas as imagens estivessem na mesma escala, as intensidades dos pixels foram normalizadas. Isso foi realizado convertendo as imagens em tensores e normalizando suas intensidades para o intervalo definitivo de $[0, 1]$, proporcionando um treinamento mais estável do modelo.

A estratégia de transferência de aprendizado desempenha um papel crucial na eficácia do modelo de classificação de pintas cutâneas. Essa abordagem envolve a utilização de um modelo pré-treinado, *ResNet-18* para a CNN e a *vit-base-patch16-224-in21k* para o Transformer, para inicializar os pesos da rede neural antes do treinamento específico para a tarefa em questão. Ambos os modelos foram implementados com seus pesos padrões, mas para se adequar a tarefa foi imputada a quantidade de classes como sendo sete. Tal prática se fundamenta na premissa de que um modelo previamente treinado em um amplo conjunto de dados visuais pode oferecer representações ricas e úteis para características visuais gerais.

Os pesos do modelo pré-treinado, ajustados para capturar padrões em imagens de domínios amplos, são empregados como ponto de partida para a tarefa específica de classificação de pintas cutâneas. Isso acelera significativamente o treinamento, uma vez que a rede já possui conhecimento sobre características visuais básicas, como bordas, texturas e formas, adquiridas durante o treinamento no conjunto de dados original.

A transferência de aprendizado permite que o modelo generalize padrões aprendidos em grandes conjuntos de dados de imagem para a tarefa específica de identificação de pintas cutâneas. Essa generalização é crucial, especialmente quando o conjunto de dados específico para a classificação de pintas pode ser relativamente pequeno em comparação com os conjuntos de dados utilizados para treinar modelos de grande escala.

Ao integrar um modelo pré-treinado, o modelo de classificação herda características visuais gerais e abstrações aprendidas em um contexto mais amplo. Isso é particularmente vantajoso em cenários médicos, onde os padrões podem ser sutis e a disponibilidade de dados rotulados pode ser limitada.

A transferência de aprendizado não apenas acelera o treinamento, mas também contribui para um modelo mais robusto, capaz de adaptar-se melhor às características específicas das pintas cutâneas. Essa abordagem representa um passo estratégico em direção ao desenvolvimento de um modelo preciso e eficiente para a detecção de possíveis casos de câncer de pele.

O treinamento do modelo de classificação de pintas cutâneas foi conduzido utilizando o framework PyTorch, que oferece recursos avançados, como otimizadores e funções de perda. Esses elementos desempenham um papel crucial no aprimoramento da eficácia do

modelo, ajustes de parâmetros e garantia da aprendizagem de representações significativas durante o processo de treinamento.

A utilização do PyTorch em conjunto com a API da FastAi simplificou consideravelmente o processo de treinamento, proporcionando um ambiente flexível e familiar para o desenvolvimento de modelos de aprendizado de máquina.

A incorporação desses recursos avançados do PyTorch estabeleceu um ambiente robusto para o treinamento do nosso modelo, permitindo adaptações dinâmicas e refinamento contínuo ao longo do processo de desenvolvimento. Essa abordagem contribuiu de forma significativa para a eficácia do modelo na tarefa específica de classificação de pintas cutâneas.

A fase de avaliação do modelo de classificação foi conduzida de forma direta, considerando a métrica de acurácia. Essas métricas desempenham um papel crucial ao proporcionar uma análise detalhada do desempenho do modelo em diferentes aspectos da tarefa de classificação. A avaliação não apenas valida a eficácia do modelo, mas também assegura que ele atenda a padrões éticos ao minimizar tanto os falsos positivos quanto os falsos negativos.

5. PROCEDIMENTO DE VALIDAÇÃO DO SISTEMA

Os dados utilizados vieram do dataset MNIST HAM10000, composto por 10015 fotos de alta resolução dermatoscópicas de sinais de pele, feito especialmente para fins de pesquisa em dermatologia e aprendizado de máquina. Ele conta com sete classes de imagens: melanomas, nevos melanocíticos, doença de Bowen, carcinoma, queratose benigna, dermatofibrose, e angioma. Todos os registros também contam com informações sobre a idade da pessoa e região do corpo onde o sinal se encontra. Ele está disponível publicamente e já foi usado em sites populares para a divulgação da ciência de dados como o Kaggle.

Infelizmente suas classes não são igualmente distribuídas, mais de 65% das imagens são de nevos melanocíticos, 10% de melanoma, 10% de queratose e os outros 15% são compostos pelas classes restantes. O mesmo acontece com a distribuição de região do corpo e a idade. Esse desbalanceamento nos dados pode impactar o resultado do modelo, que pode desenvolver tendências enviesadas as classes com maior ocorrência.

Para a escolha final de qual arquitetura seria usada foi feito estudo com uma comparação entre duas arquiteturas, Transformer e Redes Neurais Convolucionais (CNN). O treinamento de ambas as arquiteturas ao longo de 10 épocas proporcionou uma visão de seus desempenhos relativos, conforme evidenciado nos resultados apresentados graficamente na Figura 12. Para o treinamento os dados foram divididos entre duas partes, uma chamada de treinamento com setenta por cento dos dados e outra chamada de validação com os trinta por cento restantes.

Durante a avaliação foram consideradas duas métricas específicas para entender e comparar a eficácia de cada modelo: perda e acurácia. A acurácia é uma métrica fundamental que mensura a proporção de previsões corretas feitas pelo modelo em relação ao total de previsões. Ela fornece uma visão global do desempenho, destacando a eficácia geral do modelo em classificar corretamente as instâncias do conjunto de dados. A fórmula para calcular a acurácia é dada por:

$$(\text{Número de previsões corretas} / \text{Total de previsões}) \times 100\% = \text{Acurácia}$$


A perda é uma medida que quantifica o quão distantes as previsões do modelo estão dos rótulos reais durante o treinamento. A função de perda é utilizada para calcular o quanto o modelo precisa ajustar seus parâmetros a fim de minimizar a discrepância entre as previsões e os rótulos reais. Durante o treinamento, a entropia cruzada foi usada para esta função. A fórmula da função de perda (L) então é dada por:

$$- 1/N \sum_{j=1}^N \sum_i y_{j,i} \log(p_{j,i}) = L$$

Onde N é o número total de amostras no conjuntos de dados, $y_{j,i}$ é uma variável indicadora que é 1 se a amostra j pertencer à classe i e 0 caso contrário, e $p_{j,i}$ é a probabilidade prevista pelo modelo para a amostra j pertencer à classe i.

Essas duas métricas juntas proporcionam uma compreensão abrangente do desempenho do modelo. A acurácia oferece uma visão global da precisão das previsões, enquanto a perda reflete o processo de ajuste contínuo dos parâmetros do modelo para otimizar a correspondência entre previsões e rótulos reais durante o treinamento. Essa abordagem combinada é crucial para avaliar e selecionar a arquitetura mais eficaz para a tarefa.

Figura 12 — Treinamento da CNN e Transformer



Fonte: Elaborado pelo autor.

A partir da quarta época, torna-se notável que a CNN manifesta uma convergência mais acentuada em termos de redução de perda em comparação com a arquitetura Transformer. Esta tendência persiste ao longo das épocas subsequentes, sugerindo uma eficiência de aprendizado superior na CNN. Esta observação é corroborada pela análise da acurácia, indicando um desempenho consistente e superior desta arquitetura em todas as épocas consideradas. À luz destas considerações, a seleção da CNN como arquitetura final para o projeto se justifica.

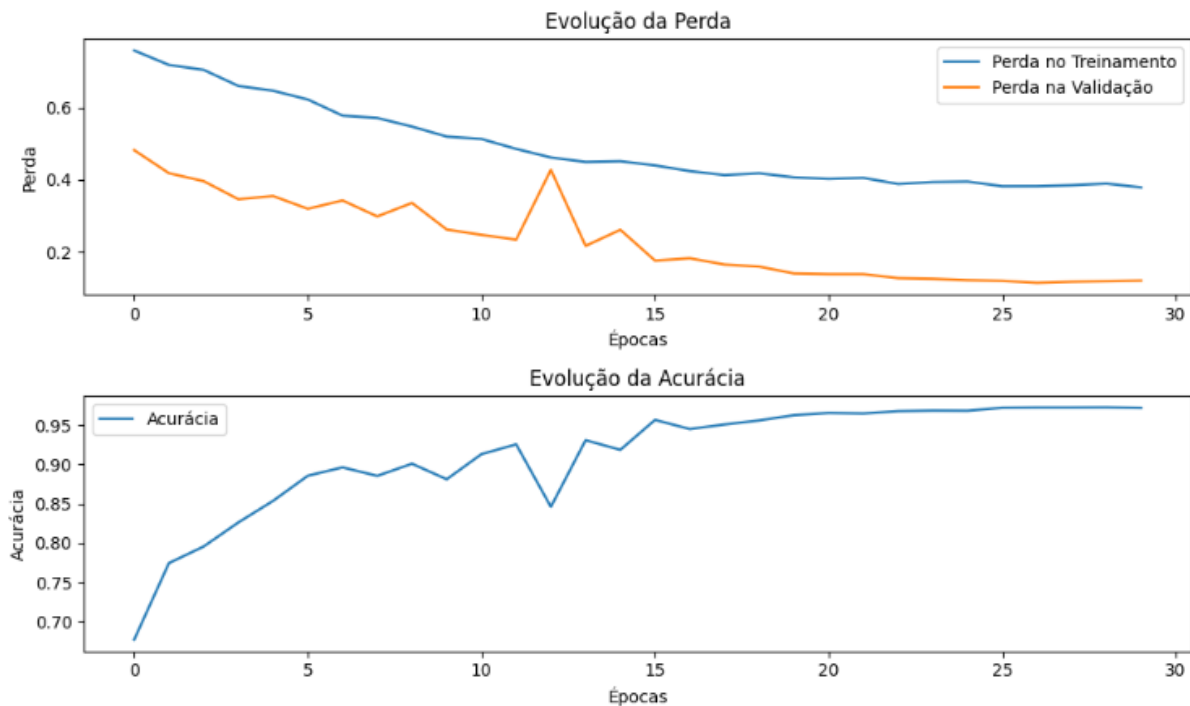
Com isto decidido a investigação foi aprofundada por meio de um treinamento estendido ao longo de 30 épocas, figura 13. Este prolongamento objetivou uma análise mais aprimorada da performance da CNN em relação às métricas cruciais de perda e acurácia, tanto no conjunto de treinamento quanto no conjunto de validação.

A extensão para 30 épocas permitiu uma observação mais detalhada da trajetória do treinamento da CNN. Os resultados indicam uma continuidade na tendência de redução da perda, sugerindo uma persistência na capacidade de aprendizado da CNN mesmo após um treinamento mais prolongado.

A métrica de acurácia, figura 13, por sua vez, foi monitorada para avaliar a consistência do desempenho da CNN ao longo do tempo. Uma performance estável ao longo das épocas adicionais indica a capacidade do modelo de generalizar sem sacrificar a precisão. O modelo chegou a mais de 97% de acurácia.

Os resultados apresentados fornecem uma base tangível para a compreensão da dinâmica do treinamento estendido da CNN. A análise destes resultados não apenas valida a escolha da CNN como arquitetura final, mas também oferece um entendimento maior sobre seu comportamento durante um período mais longo de aprendizado.

Figura 13 — Evolução da Perda e Acurácia durante o treinamento da CNN por 30 épocas



Fonte: Elaborado pelo autor.

A métrica de perda, figura 13, fornece uma medida quantitativa da discrepância entre as predições do modelo e as classes reais. Um valor de perda menor indica uma concordância mais próxima com as classes verdadeiras, sendo crucial para avaliar a precisão global do modelo em todas as imagens consideradas. Durante as épocas de treinamento, foi observada uma tendência de queda no valor da perda.

A probabilidade associada a cada predição oferece uma compreensão mais refinada do grau de confiança do modelo em suas próprias predições. Uma alta probabilidade em uma predição correta sugere uma confiança substancial do modelo na classificação. No entanto, é igualmente importante observar o comportamento em casos onde a probabilidade é mais equitativa, indicando uma maior incerteza na predição.

Como etapa final na avaliação do desempenho do classificador, foi mapeada a matriz de confusão (Figura 14) gerada a partir das predições do modelo. Esta matriz é uma ferramenta visual que permite uma avaliação detalhada da concordância entre as predições da CNN e as classes reais das pintas. A diagonal principal da matriz de confusão é de particular importância, pois representa os casos em que as predições da CNN coincidem exatamente com as categorias verdadeiras das pintas. Em outras palavras, a diagonal principal indica os resultados corretos obtidos pelo modelo e como é nela que a maior parte dos valores se

encontra então a acurácia do modelo é boa, apesar de que pelos dados de treinamento estarem desbalanceados esta métrica por si só pode ser insuficiente.



Figura 14 — Matriz de Confusão

Fonte: Elaborado pelo autor.

Nota-se também que o modelo realizou previsões preocupantes, como, por exemplo, classificar 6% das imagens de melanoma como nevos melanocíticos. As imagens relacionadas à doença de Bowen, carcinoma, dermatofibroma e angiomas apresentaram bons resultados, com baixas taxas de falsos positivos (valores na vertical) ou falsos negativos (valores na horizontal). A queratose benigna, por outro lado, apresentou mais falsos negativos do que

essas outras classes, principalmente para nevos melanocíticos e melanoma. Por fim, a classe com o maior número de registros no treinamento, nevos melanocíticos, apesar de proporcionalmente ainda contar com bons resultados, se destaca ao ter falsos positivos em todas as outras classes, sendo a única com esse comportamento.

6 CONCLUSÃO

O presente trabalho teve como objetivo principal a concepção e implementação de um aplicativo móvel voltado para a detecção precoce de câncer de pele. A abordagem adotada para a classificação das lesões cutâneas foi fundamentada na utilização de modelos de CNN.

Os resultados obtidos nos testes do classificador revelaram uma performance promissora, com taxas de acurácia que sustentam a viabilidade de uma versão comercial. A capacidade de distinguir entre pintas benignas e malignas com elevado grau de confiança representa um avanço crucial na detecção precoce do câncer de pele, permitindo intervenções médicas oportunas e, por conseguinte, aumentando as chances de tratamento bem-sucedido. Entretanto o desbalanceamento do conjunto de dados usado para o treinamento traz a necessidade de maior estudo, com outras métricas que possam trazer uma análise mais completa dos resultados.

Além disso, a facilidade de uso do aplicativo, aliada à sua acessibilidade por meio de dispositivos móveis, destaca-se como uma ferramenta potencialmente poderosa para a conscientização e monitoramento contínuo da saúde dermatológica pelos usuários. A inclusão de recursos educativos no aplicativo pode ampliar ainda mais seu impacto, capacitando os usuários a compreenderem melhor os sinais de alerta e a importância da detecção precoce.

Contudo, é imperativo ressaltar que este aplicativo não substitui a avaliação de um profissional de saúde qualificado. O objetivo é fornecer uma ferramenta complementar e de triagem, contribuindo para a conscientização e detecção precoce, mas a confirmação da análise deve ser realizada por um dermatologista.

Diante dos resultados promissores e do potencial impacto positivo na saúde pública, este trabalho destaca-se como um exemplo de como a convergência entre inteligência artificial e saúde pode gerar soluções inovadoras. As perspectivas futuras incluem melhorias contínuas no modelo de classificação, expansão da base de dados para aprimorar a diversidade das amostras, tratamento dos dados e a realização de estudos clínicos adicionais para validar a eficácia do aplicativo em ambientes do mundo real.

REFERÊNCIAS

BRASIL. CONSELHO FEDERAL DE MEDICINA - CFM. Ofício CFM nº 1756/2020 – CONJUR Brasília, DF, 19 mar. 2020. Disponível em: http://portal.cfm.org.br/images/PDF/2020_oficio_telemedicina.pdf. Acesso em: 8 dez. 2023.

BRASIL. CONSELHO FEDERAL DE MEDICINA. Resolução CFM nº 2.314, de 20 de abril de 2022. Define e regulamenta a telemedicina, como forma de serviços médicos mediados por tecnologias de comunicação. Diário Oficial da União, Brasília, DF, 22 abr. 2022.

SAPS. Governo Federal regulamenta Telessaúde e amplia acesso à saúde em áreas remotas do Brasil. 2 jul. 2022. Disponível em: <https://aps.saude.gov.br/noticia/17456>. Acesso em: 8 dez. 2023.

INCA. Câncer de pele não melanoma. Disponível em: <https://www.gov.br/inca/pt-br/assuntos/cancer/tipos/pele-nao-melanoma>. Acesso em: 8 dez. 2023.

Objective evaluation of immediate reading skin prick test applying image planimetric and reaction thermometry analyses. *Journal of Immunological Methods* (V. 487), 2020- . ISSN 0022-1759 versão *online*. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0022175920301642>. Acesso em: 8 dez. 2023.

SOUZA, R. J. P. de S. *et al.* Estimativa do custo do tratamento de câncer de pele tipo melanoma no Estado de São Paulo - Brasil. *Anais Brasileiros de Dermatologia*, v. 84, n. 3, p. 237-243, 2009. DOI: <https://doi.org/10.1590/S0365-05962009000300004>. Disponível em: <https://www.scielo.br/j/abd/a/pMrMjOdcTjQTspTLKjxyVhs/?lang=pt>. Acesso em: 8 dez. 2023.

UMSkinCheck. Universidade de Michigan, Estados Unidos. Disponível em: <https://www.uofmhealth.org/patient%20and%20visitor%20guide/my-skin-check-app>. Acesso em: 8 dez. 2023.

MoleScope. Vancouver, Canada: MetaOptima Technology Inc. 2023 Disponível em: <https://www.molescope.com/>. Acesso em: 8 dez. 2023

MiiSkin. Copenhagen, Dinamarca: MiiSkin Group Aps. 2023 Disponível em: <https://miiskin.com/>. Acesso em: 8 dez. 2023

GLOBAL COALITION FOR MELANOMA PATIENT ADVOCACY. Relatório sobre câncer de pele. <https://melanomapatients.org>. 2020. 16 p. Disponível em: https://melanomapatients.org.au/wp-content/uploads/2021/09/2020-campaign-report-GC-version-MPA_1.pdf. Acesso em: 9 set. 2023.

TSCHANDL, P. Dataset de imagens de pintas: The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions.. 5 ed. Chapecó: Argos, 2018. Disponível em: <https://dataverse.harvard.edu/dataset.xhtml?persistentId=doi:10.7910/DVN/DBW86T>. Acesso em: 5 fev. 2023.