

# Desenvolvimento de uma Aplicação Móvel Multiplataforma para Detecção e Avaliação de Risco de Lesões Cutâneas

Guilherme Hermes<sup>1</sup>, Francisco Willem R. Moreira<sup>1</sup>, Jean Mário M. de Lima<sup>1</sup>

<sup>1</sup>Instituto Metr pole Digital – Universidade Federal do Rio Grande do Norte (UFRN)  
Caixa Postal 1524 – Natal – RN – Brasil

{guilherme.hermes.053,willem.romao.707}@ufrn.edu.br, jean.lima@imd.ufrn.br

**Abstract.** *This study looks at the practical application of machine learning techniques in the detection of skin lesions, combining the InceptionV3 neural network with the development of a multiplatform architecture for a mobile application. The model achieved an accuracy of 88%. The architecture of the mobile application, based on Flutter, provided accessibility and intuitive interaction, integrating with the model via an API. The discussions highlight the need for improvements and explore the possibility of incorporating other integration strategies. This project represents steps forward in the application of emerging technologies in information systems to improve the early detection of skin cancer, promoting accessibility in the health sector.*

**Resumo.** *Este estudo aborda a aplica o pr tica de t cnicas de aprendizado de m quina na detec o de les es cut neas, combinando a rede neural InceptionV3 com o desenvolvimento de uma arquitetura multiplataforma para uma aplica o m vel. O modelo atingiu uma acur cia de 88%. A arquitetura da aplica o m vel, baseada no Flutter, proporcionou um f cil acesso e intera o intuitiva, integrando-se com o modelo atrav s de uma API. As discuss es destacam a necessidade de melhorias e exploram a possibilidade de incorporar outras estrat gias de integra o. Este projeto representa passos adiantes na aplica o de tecnologias emergentes em sistemas de informa o para melhorar a detec o precoce de c ncer de pele, promovendo avan os no setor da sa de.*

## 1. Introdu o

A integra o da intelig ncia artificial (IA) com a computa o m vel destaca-se no avan o das ci ncias da sa de, oferecendo novas solu es para a detec o e classifica o de les es cut neas, incluindo o c ncer de pele, uma quest o cr tica de sa de p blica devido   import ncia do diagn stico precoce [Escudiero 2018]. Este artigo explora como a computa o m vel pode ajudar na detec o precoce de les es de pele, beneficiando a sa de p blica [Lobo 2017]. Considerando que o c ncer de pele representa cerca de 30% dos tumores malignos no Brasil, a aplica o da IA associada   computa o m vel emerge como uma op o vi vel para o diagn stico precoce [Fiocruz 2020].

A metodologia foi composta pela sele o do conjuntos de dados com imagens de les es de pele de fontes m dicas confi veis, pr -processamento dos dados, escolha do algoritmo de Machine Learning (ML), treinamento do modelo, avalia o, integra o com o aplicativo e testes em imagens reais.

Os objetivos deste trabalho incluem o desenvolvimento de um aplicativo móvel multiplataforma capaz de detectar lesões de pele e avaliar seu risco usando técnicas de ML, desta forma, oferecendo contribuição ao unir técnicas de aprendizado de máquina em um aplicativo móvel multiplataforma para detectar lesões de pele. A integração do modelo com o aplicativo não só permite uma detecção das lesões, mas também uma interação intuitiva para os usuários, representando uma abordagem para fornecer uma solução prática para profissionais de saúde e pacientes, validando o potencial da inteligência artificial e da computação móvel para melhorar a disponibilidade de ferramentas na área da saúde.

## 2. Fundamentação Teórica

### 2.1. Informação das ciências médicas

Atualmente, o Ministério da Saúde do Brasil não recomenda o rastreamento populacional para o câncer de pele devido à falta de consenso e evidências suficientes para essa prática. Em vez disso, enfatiza a importância da conscientização e educação da população sobre a observação de lesões cutâneas e a busca por avaliação médica quando necessário.

Nesse contexto, aplicativos de detecção e classificação de lesões de pele podem ser vistos como ferramentas complementares, ajudando médicos e pacientes na identificação precoce do câncer de pele [Ministério da Saúde]. Esses aplicativos podem contribuir para a conscientização e monitoramento das lesões de pele, incentivando as pessoas a buscar avaliação médica conforme as diretrizes do Ministério da Saúde e orientações internacionais.

### 2.2. IA no campo da saúde

A IA desempenha um papel importante na saúde, um estudo recente na Radiologia Brasileira explora conceitos como imagem digital e redes neurais para melhorar o diagnóstico assistido por computador em áreas como dermatologia. Essas aplicações têm potencial para melhorar a triagem e a detecção precoce de câncer de pele, assim como em outras áreas médicas, como radiologia, patologia e oftalmologia, onde o aprendizado profundo com redes neurais promete diagnósticos mais precisos [Leite 2019].

### 2.3. Base de dados

Os dados foram retirados do dataset *Human Against Machine with 10.000 training images* (HAM10000) [Tschandl et al. 2018]. Foram coletadas imagens dermatoscópicas de diferentes populações, adquiridas e armazenadas por diferentes modalidades. O conjunto de dados final consiste em 10.015 imagens dermatoscópicas. Os casos incluem uma coleção representativa de todas as categorias diagnósticas importantes no domínio das lesões de pele. Segue as classificações nesta base de dados: *Queratoses actínicas e carcinoma intraepitelial / doença de Bowen, carcinoma basocelular, lesões benignas semelhantes a queratose, dermatofibroma, melanoma, nevos melanocíticos e lesões vasculares*.

### 2.4. Aprendizado de máquina

O desenvolvimento de modelos de aprendizado de máquina, especialmente Redes Neurais Convolucionais (CNNs), é reconhecido por aprender padrões em imagens e consequentemente ajudar na detecção e classificação de doenças. As CNNs desempenham um papel importante nesse quesito, permitindo a extração automática de características relevantes. [Li et al. 2022]

## 2.5. Aplicativo móvel multiplataforma

A escolha do Flutter como plataforma de desenvolvimento se baseia na sua eficácia e produtividade para criar aplicativos multiplataforma. Destacando-se por seus recursos, como um único código-fonte para várias plataformas, uma interface do usuário atraente e responsiva, e amplo suporte da comunidade e documentação [Jermaine and Subramaniam 2021].

O aplicativo requer acesso à câmera do dispositivo móvel e envio de informações via API para um modelo de ML. O site pub.dev e a comunidade do Flutter auxiliam na escolha da arquitetura e melhores práticas de desenvolvimento. Testes foram realizados para desenvolver uma arquitetura clara, limpa e de alta qualidade, seguindo os princípios da *Clean Architecture*, considerando desde o início a escalabilidade para futuras mudanças.

Além disso, a segurança é uma preocupação chave, e hospedar o modelo em um servidor oferece maior controle e segurança dos dados. A integração via API é altamente compatível com várias plataformas, como Android, iOS e a web, tornando-a uma abordagem versátil e eficaz para integrar modelos de ML em aplicativos Flutter, garantindo segurança, eficiência e compatibilidade multiplataforma.

## 3. Metodologia

Inicialmente, foi realizada uma pesquisa para identificar conjuntos de dados com imagens de lesões de pele de fontes médicas confiáveis, resultando na seleção do conjunto HAM10000. Em seguida, foi realizado o pré-processamento dos dados, incluindo limpeza e transformação redimensionando as imagens e normalizando valores de pixels.

Para melhorar a robustez do modelo e a eficiência do tempo de treinamento, foram aplicadas técnicas de pré-processamento como aumento de dados e equilíbrio dos pesos das classes. Redes neurais pré-treinadas usando *Transfer Learning* foram testadas para a tarefa de classificação, entre elas, *ResNet*, *MobileNet* e *Inception*. A *InceptionV3* se destacou como a escolha mais promissora, e foi treinado com um conjunto de hiperparâmetros ajustados. Afim de avaliar o modelo, métricas como acurácia, juntamente com a análise da matriz de confusão foram utilizadas.

Além disso, o modelo foi testado em imagens reais para avaliar sua capacidade de generalização e aplicabilidade prática. A metodologia também incluiu estudo da literatura para orientar o desenvolvimento da arquitetura do aplicativo móvel, utilizando práticas modernas de desenvolvimento multiplataforma e integração de modelos de ML.

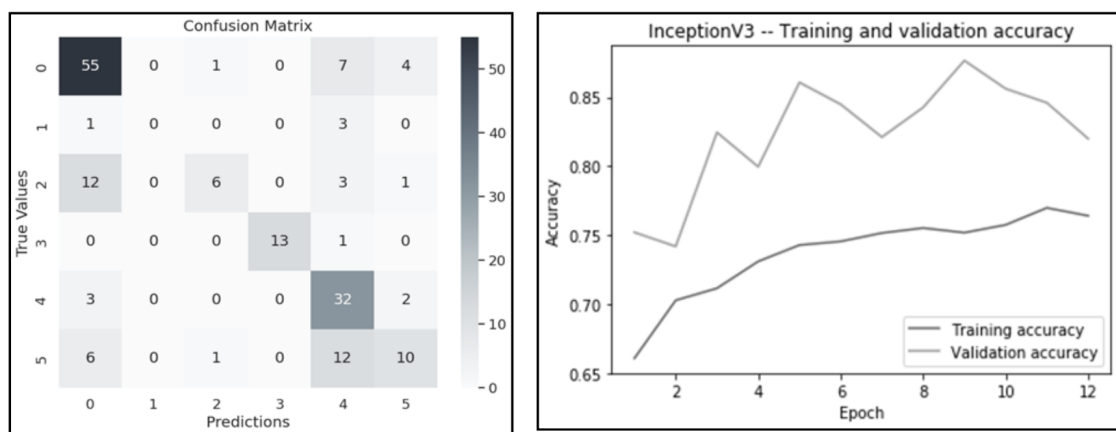
O desenvolvimento do aplicativo móvel foi guiado por requisitos previamente levantados, visando uma interface e experiência do usuário intuitivas e eficazes. A integração do modelo no aplicativo foi realizada utilizando requisições API, permitindo o diagnóstico de lesões de pele a partir de imagens enviadas pelo usuário [Dai et al. 2019].

## 4. Resultados e discussões

### 4.1. Modelo

Os resultados a seguir foram obtidos através do treinamento do modelo. Na Figura 1, podemos ver uma matriz de confusão, usada para descrever o desempenho de um modelo de classificação. Ela possui 6 linhas e 6 colunas, as linhas representam os valores

verdadeiros e as colunas, as previsões. Os valores diagonais indicam previsões corretas, enquanto os fora da diagonal, previsões incorretas. A cor das células representa o número de previsões, com cores mais escuras indicando números maiores. Os números nas células representam o número de previsões para cada combinação de valor verdadeiro e previsão.

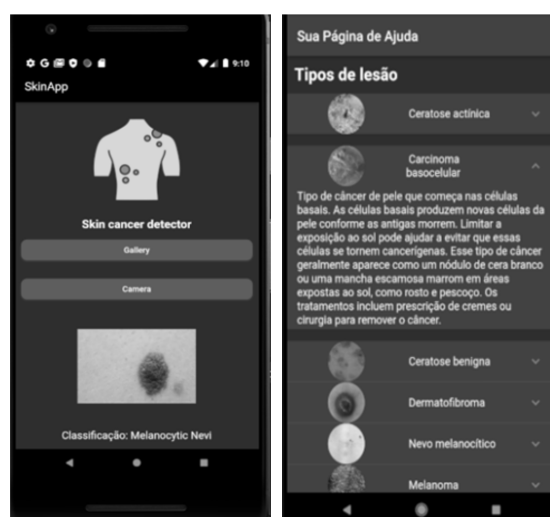


**Figura 1. Matriz de confusão e gráfico da curva de aprendizado do modelo.**

A avaliação do modelo de ML revelou uma acurácia de 88%. Essa métrica representa a proporção de previsões corretas em relação ao total de previsões, fornecendo uma visão geral do desempenho global do modelo (Figura 1).

#### 4.2. Arquitetura do aplicativo móvel

A arquitetura multiplataforma permite o pré-diagnóstico em tempo real em dispositivos Android e iOS para profissionais de saúde. Com uma interface amigável, a solução visa facilitar a interação usuário-modelo, promovendo a praticidade de uso.



**Figura 2. Telas do protótipo do aplicativo móvel multiplataforma.**

O uso de uma API para integrar o modelo ao aplicativo possibilita operações online e economiza recursos de memória. No entanto, é importante implementar avisos e

telas organizacionais para controlar os resultados do modelo e conscientizar o usuário sobre sua precisão.

Embora seja um protótipo, é comum que a arquitetura seja simples e minimalista, podendo não abranger todas as necessidades do aplicativo em uso real e em grande escala. Há espaço para melhoras, como fornecer avisos importantes e padronizar o envio de imagens para a API.

A solução multiplataforma oferece facilidade de acesso, permitindo avaliações em tempo real, principalmente como ferramenta de apoio à saúde. Com uma interface amigável e intuitiva, permite um rápido pré-diagnóstico. A arquitetura facilita a integração entre o modelo e o aplicativo, sendo necessário o acesso via internet, o que torna o aplicativo menos exigente em termos de memória e permite atualizações sem afetar o dispositivo do usuário.

Dada a intenção de utilizar a IA para contribuir para a área médica, é de extrema importância implementar avisos e telas para controlar os resultados do modelo e conscientizar o usuário sobre sua precisão, além de organizar os resultados anteriores. Sendo assim, existe a possibilidade futura de incorporar o modelo no aplicativo usando TensorFlow Lite, tornando-o mais escalável e adequado para diferentes cenários.

## 5. Conclusão

Concluimos que a aplicação prática de técnicas de aprendizado de máquina é fundamental para o desenvolvimento da medicina moderna. A pesquisa abordou a integração do modelo com a arquitetura do aplicativo móvel.

No contexto dos trabalhos relacionados, destaca-se a crescente pesquisa em aplicativos móveis de saúde (mHealth) [Moungui et al. 2024] voltados para o diagnóstico e monitoramento de condições médicas. Alguns estudos exploram a utilização de aplicativos móveis e técnicas de aprendizado de máquina na detecção de lesões de pele, mas muitos ainda não foram amplamente consolidados ou adotados. Essas iniciativas enfrentam desafios como precisão limitada dos modelos, integração deficiente com aplicativos móveis e acessibilidade restrita para profissionais de saúde e pacientes [Yang et al. 2024] [Aziz 2024].

O modelo treinado com InceptionV3 foi beneficiado pela uso da técnica de Transfer Learning, economizando tempo de treinamento. A arquitetura do aplicativo móvel, baseada em Flutter e Dart, proporcionou acessibilidade e interação intuitiva, com integração bem-sucedida ao modelo via API. Resultados indicaram boa performance do modelo, com uma acurácia de 88% de desempenho. Sugestões para o futuro incluem a incorporação do modelo usando TensorFlow e Firebase, visando escalabilidade e adaptabilidade.

Embora haja esforços nessa área, há espaço para melhorias. Assim, a presente pesquisa contribui para essa lacuna, fornecendo uma solução prática em desenvolvimento que pode contribuir para a detecção precoce e o tratamento de condições dermatológicas. A contínua otimização da arquitetura do aplicativo e do modelo, juntamente com feedbacks de futuros usuários, promete aprimorar a utilidade e confiabilidade dessa ferramenta, representando passos adiantes nas aplicações de aprendizado de máquina na saúde.

## Referências

- Aziz (2024). Efficient skin lesion detection using yolov9 network. *Journal Medical Informatics Technology*, pages 11–15.
- Dai, X., Spasic, I., Meyer, B., Chapman, S., and Andres, F. (2019). Machine learning on mobile: An on-device inference app for skin cancer detection. In *2019 4th International Conference on Fog and Mobile Edge Computing, FMEC 2019*, pages 301–305.
- Escudiero, L. (2018). Esta inteligência artificial foi mais precisa do que dermatologistas na detecção de câncer de pele.
- Fiocruz (2020). *Aplicações de inteligência artificial em diagnósticos médicos: expectativas para os próximos dez anos (2020-2030)*. Fiocruz, Rio de Janeiro.
- Jermaine, C. J. and Subramaniam, V. (2021). *Building Cross-Platform Apps with Flutter and Dart: Build scalable apps for Android, iOS, and web from a single codebase (English Edition)*. Packt Publishing, Birmingham, UK.
- Leite, C. d. C. (2019). Inteligência artificial, radiologia, medicina de precisão e medicina personalizada. *Radiologia Brasileira*.
- Li, Z., Liu, F., Yang, W., Peng, S., and Zhou, J. (2022). A survey of convolutional neural networks: Analysis, applications, and prospects. *IEEE Transactions on Neural Networks and Learning Systems*, 33(12):6999–7019.
- Lobo, L. C. (2017). Inteligência artificial e medicina. *Revista Brasileira de Educação Médica*, 41(2):185–193.
- Ministério da Saúde. Câncer de pele.
- Moungui, H., Nana Djeunga, H. C., Anyiang, C., Cano, M., Postigo, J., and Carrion, C. (2024). Dissemination strategies for mhealth apps: Systematic review. *JMIR mHealth and uHealth*, 12:e50293.
- Tschandl, P., Rosendahl, C., and Kittler, H. (2018). The ham10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions. *Sci. Data*, 5.
- Yang, W., Gao, J., Chen, J., Yang, M., Ma, J., Chen, B., and Sun, H. (2024). *Deep Learning for Skin Lesion Segmentation: A Review and Outlook*, pages 175–185.