



**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE ENGENHARIA ELÉTRICA E INFORMÁTICA
CURSO DE BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO**

PEDRO HENRIQUE DE MORAES NÓBREGA

**CLASSIFICAÇÃO DE QUEIXAS DERMATOLÓGICAS USANDO
REDES NEURAIIS CONVOLUCIONAIS**

CAMPINA GRANDE - PB

2023

PEDRO HENRIQUE DE MORAES NÓBREGA

**CLASSIFICAÇÃO DE QUEIXAS DERMATOLÓGICAS USANDO
REDES NEURAS CONVOLUCIONAIS**

**Trabalho de Conclusão Curso
apresentado ao Curso Bacharelado em
Ciência da Computação do Centro de
Engenharia Elétrica e Informática da
Universidade Federal de Campina
Grande, como requisito parcial para
obtenção do título de Bacharel em
Ciência da Computação.**

Orientador : Prof. Eanes Torres Pereira

CAMPINA GRANDE - PB

2023

PEDRO HENRIQUE DE MORAES NÓBREGA

**CLASSIFICAÇÃO DE QUEIXAS DERMATOLÓGICAS USANDO
REDES NEURAIAS CONVOLUCIONAIS**

**Trabalho de Conclusão Curso
apresentado ao Curso Bacharelado em
Ciência da Computação do Centro de
Engenharia Elétrica e Informática da
Universidade Federal de Campina
Grande, como requisito parcial para
obtenção do título de Bacharel em
Ciência da Computação.**

BANCA EXAMINADORA:

**Prof. Eanes Torres Pereira
Orientador – UASC/CEEI/UFCG**

**Prof. Carlos Eduardo Santos Pires
Examinador – UASC/CEEI/UFCG**

**Francisco Vilar Brasileiro
Professor da Disciplina TCC – UASC/CEEI/UFCG**

Trabalho aprovado em: 29 de JUNHO de 2023.

CAMPINA GRANDE - PB

ABSTRACT

Cosmetic complaints, even though they do not pose life-threatening risks, can have a significant impact on people's self-esteem and consequently cause harm to their emotional well-being. In order to assist professionals in the field of aesthetics in identifying and treating these problems, the creation of an application has been proposed. This application includes functionalities such as the classification of cosmetic complaints, such as dehydration, acne, oiliness, blackheads, wrinkles, sagging, hyperpigmentation, and skin lesions. By using machine learning techniques, especially convolutional neural networks, image classification has become increasingly accurate. Based on this, the objective of this project is to use convolutional neural networks to create a model that can integrate with the aforementioned application, aiming to classify these cosmetic complaints. To achieve this, a model will be trained with a dataset containing images of each type of complaint, enabling the classification of images sent by the user and the identification of the complaints present in them.

Classificação de Queixas Dermatológicas Usando Redes Neurais Convolucionais

Pedro Henrique de Moraes Nóbrega
Unidade Acadêmica de Sistemas e Computação
Universidade Federal de Campina Grande
Campina Grande, Paraíba, Brasil

pedro.nobrega@ccc.ufcg.edu.br

Eanes Torres Pereira
Unidade Acadêmica de Sistemas e Computação
Universidade Federal de Campina Grande
Campina Grande, Paraíba, Brasil

eanes@computacao.ufcg.edu.br

RESUMO

Queixas dermatológicas estéticas, mesmo não representando riscos à vida, podem ter um impacto significativo na autoestima das pessoas e, conseqüentemente, causar danos à saúde emocional. Com o intuito de auxiliar profissionais da área de estética na identificação e tratamento desses problemas, foi proposta a criação de um aplicativo que possui, entre suas funcionalidades, a classificação de queixas dermatológicas, tais como desidratação, acne, oleosidade, comedões, rugas, flacidez, hiperpigmentação e lesões cutâneas. Com a utilização de técnicas de aprendizado de máquina, especialmente redes neurais convolucionais, a classificação de imagens tem se tornado cada vez mais precisa. Com base nisso, o objetivo deste projeto é utilizar redes neurais convolucionais para criar um modelo que possa integrar o aplicativo acima referido, visando a classificação dessas queixas dermatológicas. Para isso, será realizado o treinamento de um modelo com um conjunto de dados contendo imagens de cada tipo de queixa, possibilitando a classificação das imagens enviadas pelo usuário e a identificação das queixas presentes nelas.

Palavras-Chave

Redes neurais convolucionais, classificação de imagens, deep learning, queixas dermatológicas faciais, processamento de imagens médicas.

1. INTRODUÇÃO

As queixas dermatológicas são uma preocupação comum em pessoas de todas as faixas etárias. Entre os mais jovens, problemas como espinhas, acne e comedões são frequentes, enquanto os mais velhos geralmente se queixam de rugas, flacidez e lesões cutâneas. Além dos impactos físicos, essas questões estéticas também têm um efeito significativo na saúde psicológica dos pacientes, podendo afetar sua autoestima [1].

Embora o diagnóstico inicial dessas queixas muitas vezes seja feito pelos próprios pacientes, o tratamento adequado requer a intervenção de um especialista. Diante disso, este projeto visa auxiliar na identificação precisa dessas queixas, permitindo que os pacientes encontrem de maneira mais rápida o especialista adequado para seu problema.

A classificação de imagens utilizando Redes Neurais Convolucionais já é amplamente empregada na análise de imagens médicas [2], pois têm se mostrado eficazes na extração de características relevantes de imagens. Elas têm sido aplicadas com sucesso em inúmeras tarefas de diagnóstico e análise, como detecção de câncer, identificação de órgãos e classificação de

patologias [3]. No contexto da análise de câncer de pele, as redes neurais convolucionais têm apresentado um desempenho muito bom, até mesmo comparável ao de médicos dermatologistas [4].

Uma das estratégias utilizadas para o treinamento de modelos de classificação de imagens médicas é o uso de aprendizado por transferência, onde um modelo existente, previamente treinado, é utilizado como ponto de partida. Essa abordagem permite o uso de conjuntos de dados menores, economizando tempo e recursos computacionais, enquanto se aproveita do conhecimento prévio do modelo base, aprimorando-o para a nova tarefa.

Existem vários modelos de redes neurais artificiais que podem ser utilizados na classificação de imagens médicas, como *VGG16*, *DenseNet201*, *InceptionV3* e *InceptionResNetV2*. Todos esses modelos obtiveram excelentes resultados na classificação do conjunto de dados do *ImageNet*, um extenso banco de dados com mais de 14 milhões de imagens e 20 mil categorias, sendo amplamente utilizado no treinamento de modelos de classificação de imagens.

Neste trabalho, será implementada uma rede neural convolucional, utilizando aprendizado por transferência a partir do modelo pré-treinado *VGG16*, com o objetivo de reconhecer e classificar entre peles normais, com acne e com rugas, de forma eficiente e precisa.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 Aprendizagem de Máquina

O aprendizado de máquina, ou *machine learning*, é uma subárea da inteligência artificial que tem como objetivo aprender a realizar tarefas, fazer previsões ou tomar decisões sem ser explicitamente programado para isso. O treinamento de um modelo de machine learning começa com um grande conjunto de dados, a partir do qual características relevantes são extraídas. Com base nessa extração de características, o modelo é capaz de aprender e aprimorar sua performance sem a necessidade de intervenção humana constante.

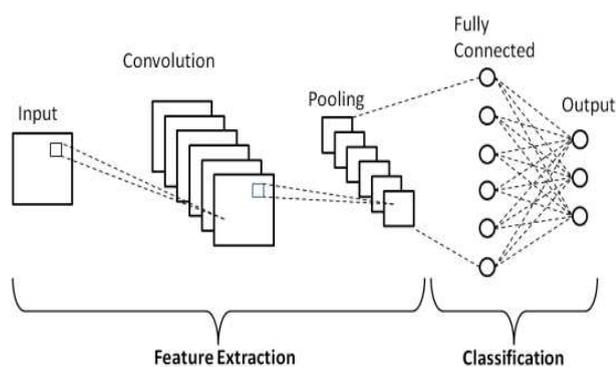
2.2 Redes Neurais Convolucionais

Redes neurais convolucionais (CNNs) são modelos de inteligência artificial que se inspiram no comportamento dos neurônios. Elas consistem em várias camadas de nós, incluindo uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, com conexões entre si. Cada neurônio recebe dados através de suas conexões e o resultado é comparado a um limiar, determinando se o neurônio é ativado ou não.

As redes neurais convolucionais são particularmente adequadas para tarefas de aprendizado supervisionado, como classificação de imagens. Para classificar imagens, elas operam aplicando filtros a

partir de uma matriz inicializada aleatoriamente (camada convolucional), realizando uma filtragem das características, seguida por uma redução de tamanho (camada de *pooling*). Essa redução de tamanho simplifica a informação da camada anterior, diminuindo a quantidade de pesos e evitando o *overfitting* [3]. Somente após essas etapas, a classificação é realizada, através da camada totalmente conectada. Dessa forma, a rede aprende quais filtros são mais eficazes na identificação de padrões relevantes nas imagens.

Figura 1. Arquitetura de uma Rede Neural Convolucional



Fonte: Figura extraída de [5]

2.3 Data Augmentation

Data Augmentation é uma técnica utilizada para aumentar de forma artificial a quantidade de dados usados no treinamento de modelos de inteligência artificial. Essa técnica é frequentemente empregada quando a quantidade de dados disponíveis é limitada ou para melhorar a capacidade de generalização do modelo, especialmente em tarefas de classificação de imagens.

No contexto de imagens, essa técnica pode ser aplicada ao realizar transformações como rotação, *zoom*, translação, ajustes de brilho, entre outras. Com esses ajustes, é possível criar variações no conjunto de dados, tornando-o mais diversificado e possibilitando que o modelo aprenda a reconhecer diferentes cenários.

2.4 Extração de Características

A Extração de Características, ou *Feature Extraction*, é uma técnica utilizada com o objetivo de reduzir a dimensão dos dados, identificando e selecionando as características mais importantes e que melhor representam esses dados.

A redução da dimensionalidade dos dados é importante em cenários em que há muitas características disponíveis. Nessas

situações, algumas dessas características podem ser irrelevantes ou redundantes, o que pode prejudicar o desempenho do modelo de aprendizado. Portanto, a técnica de extração de características pode ser muito útil, tornando o processo de aprendizado mais eficiente e preciso.

2.5 Aprendizado por Transferência

O aprendizado por transferência é uma técnica que visa aproveitar o conhecimento adquirido ao resolver um problema para solucionar outro problema semelhante, tornando o processo de aprendizado mais rápido e eficiente. Essa abordagem é especialmente útil quando há uma quantidade limitada de dados disponíveis ou quando se deseja economizar recursos computacionais.

A técnica de aprendizado por transferência pode ser realizada utilizando a técnica de extração de características, na qual a última camada (ou camadas) de um modelo pré-treinado é substituída por uma nova camada, treinada para o novo problema. As camadas iniciais, que foram pré-treinadas com um conjunto maior de dados e são capazes de extrair características úteis, são mantidas inalteradas. Dessa forma, é possível usar um conjunto menor de dados para resolver um novo problema, aproveitando as características extraídas pelas camadas iniciais [6].

Outra abordagem para o aprendizado por transferência é o *fine-tuning* (ajuste fino), que além de substituir a última camada, ajusta os parâmetros das camadas iniciais do modelo pré-treinado para se adaptarem melhor ao novo problema [6].

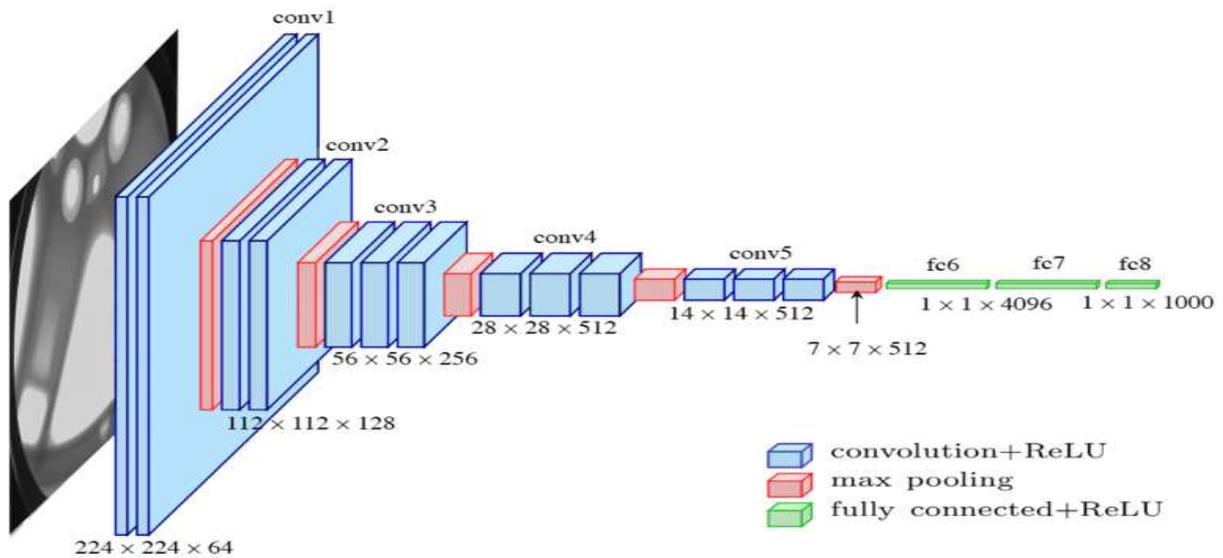
Tanto na extração de características quanto no *fine-tuning*, o objetivo principal é ajustar o modelo pré-treinado para resolver um novo problema com um conjunto menor de dados, refinando os parâmetros da rede. Essa estratégia aproveita o conhecimento prévio da rede para acelerar o processo de aprendizado e melhorar o desempenho em novas tarefas.

2.6 VGG16

O *VGG16* é uma rede neural convolucional profunda composta por 16 camadas, sendo 13 camadas convolucionais e 3 camadas totalmente conectadas. Essa arquitetura foi proposta por K. Simonyan e A. Zisserman em [8] e obteve uma precisão de 92,7% nos dados do conjunto de dados *ImageNet*, onde foi capaz de classificar entre 1000 classes de imagens.

O modelo recebe como entrada imagens *RGB* com resolução de 224 x 224 *pixels*. Ele é composto por várias camadas convolucionais e de *pooling*, seguidas por camadas totalmente conectadas, como pode ser visualizada na Figura 2.

Figura 2. Arquitetura do VGG16



Fonte: Figura extraída de [7]

A arquitetura do *VGG16* consiste em um total de 13 camadas convolucionais. À medida que a rede se aprofunda, o número de filtros utilizados nas camadas convolucionais aumenta progressivamente, começando com 64 e terminando com 512. Após cada operação de convolução, a função de ativação *ReLU* (1) é aplicada, retornando o valor passado se for positivo e zero caso contrário.

$$f(x) = \max(0, x) \quad (1)$$

Após um conjunto de camadas convolucionais, é aplicada uma camada de *max pooling*, que reduz a dimensão do mapa de características, mantendo as características mais relevantes.

No final da arquitetura, após todas as camadas convolucionais, existem três camadas totalmente conectadas. As duas primeiras camadas têm 4096 canais cada, enquanto a última camada possui 1000 canais, correspondendo a uma saída para cada classe possível [8].

3. TRABALHOS RELACIONADOS

Na pesquisa realizada por YIN et al. em [9], foi utilizado o algoritmo de redes neurais convolucionais *EfficientNet-b4* para a classificação de doenças inflamatórias na pele, como psoríase, eczema e dermatite atópica. Os resultados obtidos demonstraram a eficiência do uso de redes neurais convolucionais na classificação de condições dermatológicas, além da classificação de melanoma, que já havia sido abordada anteriormente.

No estudo de WU et al. em [10], foi realizada uma comparação entre diferentes algoritmos de redes neurais convolucionais para a classificação de doenças na pele com base em imagens clínicas. As cinco estruturas de redes neurais convolucionais avaliadas foram *ResNet-50*, *Inception-v3*, *DenseNet121*, *Xception* e *Inception-ResNet-v2*. Os resultados indicaram que a *Inception-ResNet-v2* apresentou um desempenho superior, alcançando uma precisão de 77%. É relevante destacar que essa precisão superou a de alguns médicos em determinados casos, principalmente devido à similaridade de algumas doenças dermatológicas.

Esses estudos evidenciam a utilidade e eficácia das redes neurais convolucionais na classificação de doenças dermatológicas, oferecendo potencial para auxiliar médicos e especialistas na tomada de decisões clínicas mais precisas e eficientes.

4. METODOLOGIA

4.1 Obtenção dos Dados

Para o treinamento do modelo, foi utilizado o conjunto de dados ACNE04 [11] para as imagens de acne. Esse *dataset* possui 3.765 imagens de pessoas chinesas com acne e é voltado para a classificação da severidade da acne.

Para as imagens de pele normal, foi utilizado o *dataset* Human Faces Dataset [12], que contém mais de 7.000 imagens de faces humanas de pessoas de todas as idades e nacionalidades.

Já para as imagens de rugas, foi utilizado o Skin Wrinkles vs Non-Wrinkles Dataset [13], que possui 381 imagens de pele com rugas.

4.2 Pré-Processamento

Para obter um melhor desempenho no treinamento, foi necessário realizar um pré-processamento das imagens, uma vez que elas pertencem a *datasets* diferentes e não estão padronizadas.

O objetivo principal foi realizar cortes quadrados nas regiões com a presença de acne, rugas ou pele normal, descartando informações que poderiam prejudicar o treinamento, como olhos e boca. Para isso, foi criado um algoritmo que realizou cortes quadrados de 224x224 *pixels* nas imagens, como pode ser visto na figura 3. Em seguida, foi realizada uma análise manual, selecionando apenas as imagens de boa qualidade. Esse processo resultou em um *dataset* com 478 imagens de acne, 371 de rugas e 323 de pele normal.

Figura 3. Imagens antes e depois do corte.



Fonte: Autoria própria

Essa estratégia foi necessária devido à limitação dos datasets e ao fato de o *dataset* de acne conter apenas imagens de pessoas chinesas. Isso resultou em erros de classificação na primeira versão do modelo, que foi treinado utilizando o rosto inteiro. O modelo acabou realizando classificações com base em características distintas entre pessoas asiáticas e ocidentais.

Além disso, foi aplicada a técnica de data augmentation utilizando o *ImageDataGenerator* do Keras, que realiza data augmentation em tempo real durante o treinamento. Foram aplicadas rotações, translações horizontais e verticais, zoom e distorção, conforme mostrado na figura 4.

Figura 4. Exemplo da aplicação de data augmentation em uma imagem de acne



Fonte: Autoria própria

4.3 Treinamento

No treinamento, foi utilizada a biblioteca Keras em conjunto com a linguagem *Python*, por meio de *Jupyter Notebooks*.

Inicialmente, as imagens foram divididas em conjuntos de treinamento (80%), validação (10%) e teste (10%).

Para o treinamento, foi adotada a estratégia de aprendizado por transferência, utilizando como ponto de partida o modelo pré-treinado *VGG16*. Essa abordagem permitiu aproveitar os parâmetros já treinados do modelo, economizando tempo e recursos computacionais, especialmente devido ao tamanho pequeno do conjunto de dados de treinamento.

Para realizar o aprendizado por transferência, foi utilizada a técnica proposta por Hoang Ho em [14]. Seguindo essa abordagem, a última camada do *VGG16* foi removida e todas as camadas restantes foram congeladas. Em seguida, foram adicionadas novas camadas ao final do modelo, incluindo uma

camada de *global max pooling*, uma camada totalmente conectada com 512 unidades e com a função *ReLU*, uma camada de *dropout* com taxa de 0.5 e uma camada de ativação *softmax* para as 3 classes de imagens, conforme ilustrado na figura 5.

Figura 5. Descrição das camadas usadas no treinamento

Layer (type)	Output Shape
input_2 (InputLayer)	[(None, 224, 224, 3)]
block1_conv1 (Conv2D)	(None, 224, 224, 64)
block1_conv2 (Conv2D)	(None, 224, 224, 64)
block1_pool (MaxPooling2D)	(None, 112, 112, 64)
block2_conv1 (Conv2D)	(None, 112, 112, 128)
block2_conv2 (Conv2D)	(None, 112, 112, 128)
block2_pool (MaxPooling2D)	(None, 56, 56, 128)
block3_conv1 (Conv2D)	(None, 56, 56, 256)
block3_conv2 (Conv2D)	(None, 56, 56, 256)
block3_conv3 (Conv2D)	(None, 56, 56, 256)
block3_pool (MaxPooling2D)	(None, 28, 28, 256)
block4_conv1 (Conv2D)	(None, 28, 28, 512)
block4_conv2 (Conv2D)	(None, 28, 28, 512)
block4_conv3 (Conv2D)	(None, 28, 28, 512)
block4_pool (MaxPooling2D)	(None, 14, 14, 512)
block5_conv1 (Conv2D)	(None, 14, 14, 512)
block5_conv2 (Conv2D)	(None, 14, 14, 512)
block5_conv3 (Conv2D)	(None, 14, 14, 512)
block5_pool (MaxPooling2D)	(None, 7, 7, 512)
global_max_pooling2d_1 (GlobalMaxPooling2D)	(None, 512)
dense_2 (Dense)	(None, 512)
dropout_1 (Dropout)	(None, 512)
dense_3 (Dense)	(None, 3)

Fonte: Autoria própria

Após essa etapa, foram realizadas 3 épocas de extração de características com as novas camadas adicionadas, com o objetivo de melhorar o desempenho no *fine-tuning*.

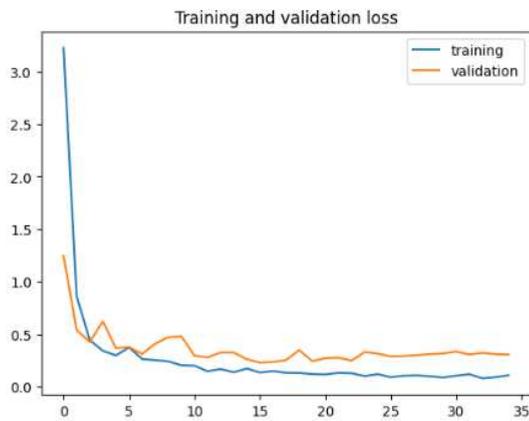
Posteriormente, as camadas foram descongeladas, mantendo apenas as 15 primeiras congeladas, e foi realizado o *fine-tuning* por 35 épocas. O treinamento foi realizado com um *batch size* de 32, utilizando um *learning rate* de 0.0001 e o otimizador Adam.

A precisão alcançada com o conjunto de treinamento foi de 94,24%, enquanto a precisão obtida com o conjunto de validação foi de 92,66%.

Após o treinamento, foi gerado o gráfico de perda (*loss*), conforme ilustrado na figura 6. Observa-se uma tendência de estabilidade nas curvas de perda tanto para o conjunto de

treinamento quanto para o conjunto de validação. Essa estabilidade indica que o modelo está aprendendo de forma consistente e não está sofrendo com problemas de *overfitting* (sobreajuste) ou *underfitting* (subajuste).

Figura 6. Gráfico de loss do treinamento



Fonte: Autoria própria

5. RESULTADOS

Para avaliar os resultados, o modelo foi utilizado em um conjunto de 120 imagens de teste que não foram utilizadas durante o treinamento. Isso foi feito para garantir que o modelo é capaz de realizar boas previsões em imagens com as quais ele nunca teve contato.

Foi utilizado a função *classification_report* da biblioteca *sklearn* para gerar um relatório com as métricas de classificação. As métricas calculadas foram a precisão (porcentagem de previsões positivas corretas em relação ao total de previsões positivas), a revocação (porcentagem de previsões positivas em relação ao total de verdadeiros positivos) e o *F1-score* (média harmônica entre a precisão e o recall). Os resultados podem ser observados na tabela 1.

Tabela 1. Métricas do *classification_report*

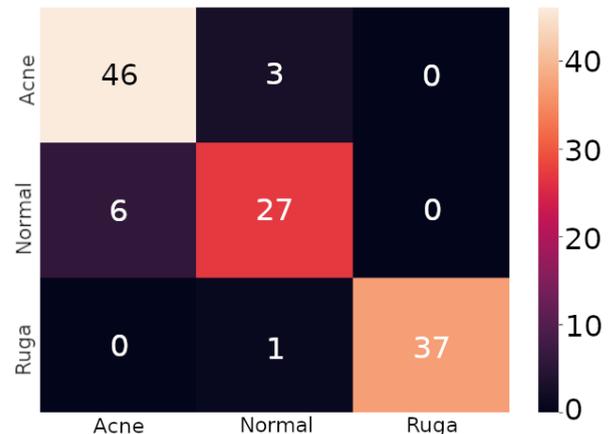
	Precisão	Revocação	F1-Score
Acne	0.88	0.94	0.91
Normal	0.87	0.82	0.84
Ruga	1.00	0.97	0.99
Média Macro	0.92	0.91	0.91
Média Ponderada	0.92	0.92	0.92

Fonte: Autoria própria

Ao analisar as métricas acima, é possível observar que o modelo apresentou um bom desempenho, com uma precisão de aproximadamente 92%. Ao analisar as classes individualmente, pode-se perceber um desempenho excelente na classificação de rugas, com uma precisão de 100%, revocação de 97% e *F1-score* de 99%. No entanto, ao

examinar a matriz de confusão apresentada na Figura 7, nota-se uma confusão entre as classes de acne e pele normal. Isso pode ser atribuído ao fato de que a acne pode variar em termos de gravidade, sendo mais fácil para o modelo classificar casos de acne mais severa, enquanto casos mais leves podem ser erroneamente classificados como pele normal.

Figura 7. Matriz de confusão



Fonte: Autoria própria

6. CONSIDERAÇÕES FINAIS

Os resultados obtidos, de modo geral, foram satisfatórios, alcançando uma precisão de 92% na classificação das diferentes condições de pele, como peles normais, com acne e com rugas. É importante destacar que esses resultados foram obtidos mesmo com um conjunto de dados pequeno, o que destaca a eficácia do aprendizado por transferência ao utilizar o modelo *VGG16*.

6.1 Limitações

A principal limitação encontrada durante o desenvolvimento do modelo foi a escassez de dados adequados para o treinamento. Além da escassez de dados, os dados disponíveis vieram de diferentes bases de dados, o que exigiu um extenso trabalho de limpeza para padronizar as imagens e torná-las adequadas para o treinamento.

Ademais, no início do projeto, havia a intenção de classificar outras condições da pele, como desidratação, oleosidade, flacidez e comedões. No entanto, não foi encontrada nenhuma base de dados apropriada para treinar o modelo nessas categorias, o que fez com que essas classes fossem deixadas para trabalhos futuros.

6.2 Trabalhos Futuros

Para trabalhos futuros, seria interessante incluir novas classes no modelo, como as mencionadas anteriormente. Isso exigiria a busca de bases de dados apropriadas para o treinamento ou até mesmo a criação dessas bases de dados.

Além disso, seria bom realizar otimizações no modelo, especialmente em relação às classes de pele normal e com acne, que apresentaram maior confusão entre si. Uma hipótese para melhorar a precisão nessas situações seria adicionar mais imagens de acne de baixa severidade no conjunto de

treinamento, já que casos de acne mais leves podem ser confundidos erroneamente com uma pele normal, o que pode levar a imprecisões no modelo.

7. AGRADECIMENTOS

Gostaria de agradecer ao meu professor orientador, Eanes, pelo conhecimento transmitido e pela orientação durante o projeto. Também gostaria de agradecer ao aluno e colega de projeto, Victor Vinicius Freire de Araújo, pela ajuda na busca por conjuntos de dados e no pré-processamento das imagens.

8. REFERÊNCIAS

- [1] STAMU-O'BRIEN, C. et al. Psychodermatology of acne: Psychological aspects and effects of acne vulgaris. *Journal of Cosmetic Dermatology*, v. 20, n. 4, 23 out. 2020.
- [2] BRINKER, T. J. et al. Skin Cancer Classification Using Convolutional Neural Networks: Systematic Review. *Journal of Medical Internet Research*, v. 20, n. 10, p. e11936, 17 out. 2018.
- [3] LITJENS, G. et al. A Survey on Deep Learning in Medical Image Analysis. *Medical Image Analysis*, v. 42, p. 60–88, dez. 2017.
- [4] ESTEVA, A. et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, v. 542, n. 7639, p. 115–118, 25 jan. 2017.
- [5] PHUNG; RHEE. A High-Accuracy Model Average Ensemble of Convolutional Neural Networks for Classification of Cloud Image Patches on Small Datasets. *Applied Sciences*, v. 9, n. 21, p. 4500, 23 out. 2019.
- [6] Tensorflow, 2022, Disponível em: https://www.tensorflow.org/tutorials/images/transfer_learning
- [7] GOIS, M, Kaggle, 2023, Disponível em: <https://www.kaggle.com/code/marcosgois07/fine-tuning-with-vgg16-to-detection-of-pneumonia>
- [8] SIMONYAN, K. et al. Very deep convolutional networks for large-scale image recognition. 3rd International Conference on Learning Representations (ICLR 2015), 1–14, 10 abr. 2015.
- [9] WU, H. et al. A deep learning, image based approach for automated diagnosis for inflammatory skin diseases. *Annals of Translational Medicine*, v. 8, n. 9, p. 581–581, maio 2020.
- [10] WU, Z. et al. Studies on Different CNN Algorithms for Face Skin Disease Classification Based on Clinical Images. *IEEE Access*, v. 7, p. 66505–66511, 2019.
- [11] WU, X. et al. Joint Acne Image Grading and Counting via Label Distribution Learning. Disponível em: <https://ieeexplore.ieee.org/document/9010021>. 2 out. 2021.
- [12] GUPTA, A. Human Faces Dataset, Kaggle, 2020, Disponível em: <https://www.kaggle.com/datasets/ashwingupta3012/human-faces>
- [13] ROKAHA, R. Skin Wrinkles vs Non-Wrinkles Dataset, Kaggle, 2021. Disponível em: <https://www.kaggle.com/datasets/rishantrokaha/skin-wrinkles-vs-nonwrinkles>
- [14] HO, H. Skin Lesions Classification With Deep Convolutional Neural Network, Project Report CIS 5526, 14 nov. 2019

Sobre os autores:

Pedro Henrique de Moraes Nóbrega. Graduando em Ciência da Computação.

Eanes Torres Pereira. Professor orientador.