

Classificação dos Principais Gêneros de Orquídeas de Chapada dos Guimarães

Cristiane Oldoni¹, Thiago Ventura¹, Flávia Luis¹

¹Instituto de Computação – Universidade Federal de Mato Grosso (UFMT)
Av. Fernando Corrêa da Costa, nº 2367, Bairro Boa Esperança, 78.060-900, Cuiabá –
MT – Brasil

crisoldoni@yahoo.com.br, thiago@ic.ufmt.br, saneflavia@gmail.com

Abstract. *This work deals with automatic identification of some species of orchids from the region of Chapada dos Guimarães, using image classification techniques with Artificial Intelligence, specifically Deep Learning. For this, a database was created with images collected from the internet. The data augmentation technique was applied to enrich the training set and avoid overfitting. Among the tested models, a convolutional neural network model with architecture 32-64-16-64 reached an accuracy of about 65% for the test data, a promising result for this kind of problem.*

Resumo. *Esse trabalho aborda a identificação automática de algumas espécies de orquídeas da região de Chapada dos Guimarães, utilizando técnicas de classificação de imagens com Inteligência Artificial, especificamente Deep Learning. Para isso, foi criada uma base de dados com imagens coletadas da internet. A técnica de data augmentation foi aplicada para enriquecer o conjunto de treinamento e evitar overfitting. Dentre os modelos testados, uma rede neural convolucional com arquitetura 32-64-16-64 atingiu uma acurácia de cerca de 65% para os dados de teste, um resultado promissor para esse tipo de problema.*

1. Introdução

A preservação do bioma do Cerrado está diretamente ligada a proteção da fauna e flora presente. Entretanto, segundo Nascimento e Rocha (2022), de 1999 a 2018 ocorreram 1.390.251 focos de incêndio no bioma do Cerrado e aproximadamente 15% ocorreram em território de preservação. O município de Chapada dos Guimarães, inserido neste bioma, tem sofrido com as queimadas e a degradação ambiental, assim como um dos componentes ameaçados, as orquídeas.

Inserida em uma das maiores famílias de plantas existentes, as orquídeas que compõem a família Orqhidaceae possui cerca de vinte e cinco mil espécies e corresponde a aproximadamente 8% das plantas que produzem sementes.

Predominantes nas regiões tropicais e ocorrendo em todos os continentes, exceto na Antártida, é uma planta relativamente adaptável. Segundo Gonçalves, et al. (2024), a presença de orquídeas tem relação com a preservação de abelhas-das-orquídeas que somam 392 espécies listadas no Brasil. Além disso, há grande potencial comercial, com algumas espécies consideradas raras com alto valor de venda, gerando interesse tanto por floricultores e consumidores, quanto por biólogos e pesquisadores da área.

Independente do perfil de interesse, ter um sistema apto a realizar a classificação automática de espécies de orquídeas pode auxiliar nos fluxos de trabalho, aumentando a precisão e produtividade. Para tanto, técnicas de Inteligência Artificial (IA) podem ser utilizadas para realizar a classificação de orquídeas, principalmente através de técnicas de Machine Learning e Deep Learning para classificação de imagens, conforme pesquisado, como pesquisado por Sharma e Guleria (2022), que compararam modelos de Rede Neural Artificial (ANN), Redes Neurais Recorrentes (RNN) e Redes Neurais Convolucionais (CNN).

Em relação a classificação de orquídeas, alguns trabalhos já foram publicados. Xiao et al. (2022) propôs um modelo de rede neural para classificar diferentes fases de crescimento da orquídea *Phalaenopsis*, baseado em modelos de CNN MobileNets. Em Fu et al. (2022), foi proposto a classificação de diferentes espécies de *Cymbidium* (um gênero de orquídea). Sarachai et al. (2022) propôs uma arquitetura de modelo híbrido para classificar espécies de orquídeas a partir de imagens. Han et al. (2018) discutem um modelo que combina aprendizado por transferência (transfer learning) dos modelos AlexNet, VGG-16 e ResNet-152 (pretreinados com o ImageNet), data augmentation da web e algoritmo de otimização bayesiana para realizar o ajuste dos hiperparâmetros, aplicado a conjuntos de dados de treinamento limitados, obtendo um bom desempenho, particularmente com o ResNet. Gogul e Kumar (2017) utilizam uma abordagem de Deep Learning usando CNN para reconhecer espécies de flores de imagens capturadas usando a câmera de um celular.

Como pode ser visto, há viabilidade em utilizar IA para classificação de orquídeas. Por outro lado, não há um trabalho específico relacionados às espécies da região do Mato Grosso, em específico de Chapada dos Guimarães. Na região de Chapada dos Guimarães há o registro de cerca de 80 espécies de Orchidaceae (distribuídas em 48 gêneros). Esses gêneros exibem distribuição ampla em todo o Brasil, ocupando diferentes tipos de vegetação. Embasado nos artigos supracitados, este estudo tem por objetivo criar um classificador capaz de identificar os principais gêneros de orquídeas existentes na região de Chapada dos Guimarães, que pode ser utilizado para suprir as lacunas existentes em informações e permitir a amplitude de trabalho de pesquisadores e floricultores locais.

2. Metodologia

Inicialmente, foram definidos os gêneros a serem identificados pelo modelo. Segundo Petini-Benelli e Vaz-De-Mello (2016), os gêneros mais representados em Chapada

dos Guimarães em número de espécies são *Catasetum*, *Encyclia*, *Epidendrum*, *Galeandra* e *Vanilla*. Após, foi construída a base de imagens para possibilitar o treinamento de um modelo de deep learning.

As imagens foram obtidas em pesquisas de páginas da internet, priorizando variabilidade de ângulos e luminosidades diferentes para uma maior generalização. Foram coletadas imagens para cada gênero selecionado, sendo entre 125 e 177 imagens para cada gênero, conforme mostrado na Tabela 1. Ao todo, foram selecionadas 795 imagens do conjunto de dados original.

Foi realizado o tratamento das imagens padronizando-as em formato de quadrado, ou seja, com a mesma quantidade de pixels na horizontal e na vertical. Neste processo de recorte, havia imagens extensas em uma das dimensões (horizontal ou vertical), com informações úteis em quase toda sua extensão. Para aproveitamento do conteúdo, foi feita data augmentation no qual tais imagens foram cortadas e divididas em duas. Além dessa ação, foram aplicadas ações de espelhamento e inversão das imagens (flip horizontal) para gerar 10% a mais de imagens, aumentando ainda mais o conjunto de dados. Ao final do processo, o conjunto de dados consistia em 1.758 imagens (conforme Tabela 1).

Tabela 1: Distribuição de imagens para cada gênero selecionado originalmente e após a aplicação de *data augmentation*

Gênero	Exemplo	Quantidade original	Quantidade após <i>data augmentation</i>
<i>Catasetum</i>		177	412
<i>Encyclia</i>		172	380
<i>Epidendrum</i>		161	352
<i>Galeandra</i>		125	284
<i>Vanilla</i>		160	330

O conjunto de dados foi dividido e utilizado para treinamento (80%) e teste (20%) de um modelo de redes neurais convolucionais (CNN). O modelo foi criado em linguagem Python que é uma linguagem de programação orientada a objeto e utilizando o ambiente Google Colab para processamento.

A rede neural foi construída utilizando a biblioteca Keras do Python. Para definição da arquitetura da rede, várias foram testadas e avaliadas, sendo escolhida a que apresentou melhor desempenho. O mesmo foi feito para os parâmetros de

quantidade de neurônios, funções de ativação e número de épocas de treinamento. A arquitetura do modelo ficou com as seguintes camadas ocultas: 3 (três) camadas convolucionais, todas seguidas por um MaxPooling, e uma camada densa. Nas camadas ocultas foi utilizada a função de ativação ReLU. A camada de saída consiste em 5 (cinco) neurônios (quantidade de classes do modelo) e utiliza função de ativação Softmax para fazer a classificação. Inicialmente foram utilizadas as seguintes quantidades de neurônios em cada uma das camadas ocultas (3 convolucionais + 1 densa): 16-32-64-128.

Além do modelo criado especificamente para este trabalho, e para auxiliar na comparação dos resultados, foi aplicado a técnica de transfer learning, utilizando o modelo pré-treinado ResNet50. Neste modelo, a camada classificadora foi descartada e ajustada (treinada) com o conjunto de dados aumentado gerado neste trabalho. Por fim, o tamanho da entrada foi variado (de 50x50 a 200x200 pixels) para verificar qual seria a melhor opção para este tipo de dado.

3. Resultados

Seguindo a metodologia proposta, o modelo inicial foi preparado para receber entradas de 100x100 pixels e utilizar apenas as imagens originais. Posteriormente, foi tanto diminuído o tamanho da entrada como aumentado, testando com 50x50 pixels e com 200x200 pixels, respectivamente. O desempenho dos modelos está apresentado na Figura 1. O tempo de treinamento para cada modelo foi de 128,25s. para o modelo de entrada 100x100 pixels, enquanto a menor entrada foi de 56,74s e o de maior entrada de 445,87s.

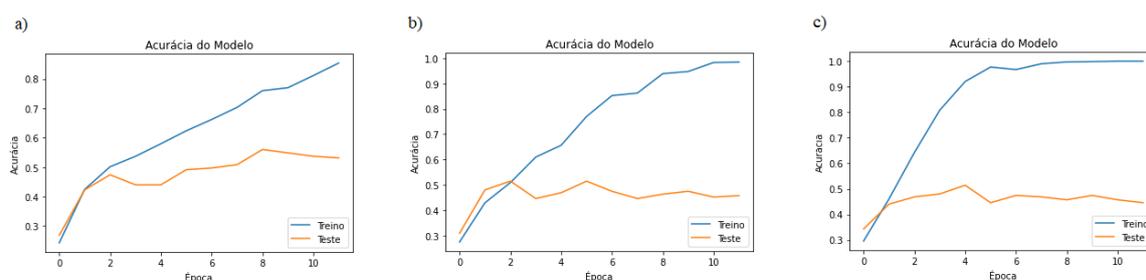


Figura 1. Desempenho do modelo variando o tamanho da entrada: a) 50x50 pixels; b) 100x100 pixels; c) 200x200 pixels.

Como esperado, foi observado que o tamanho da entrada interfere no tempo de processamento, de modo que um maior tamanho implica em maior tempo de aprendizado. Outro ponto importante é que o desempenho no conjunto de teste foi superior com entradas menores (50x50 pixels) em relação aos de entradas maiores. Independente do modelo, detectou-se a presença de overfitting, ou seja, ele aprende especificamente sobre os dados de treino, apresentando acurácia de cerca de 90%, porém não generaliza bem com dados de teste. Isso é ocasionado pelo reduzido número de imagens e complexidade do modelo, gerando uma queda da acurácia quando testado com novas imagens.

Os testes seguintes foram realizados para alcançar melhores índices de acurácia e evitar o overfitting. Para tanto, foram alteradas a quantidade de neurônios das camadas ocultas para 8-15-32-128, 32-64-16-64, 64-128-32-64 e 128-64-32-64. As mudanças de redução de neurônios possibilitaram o aumento de épocas sem que o comportamento de overfitting aparecesse. Nesse caso, os modelos foram treinados com até 30 épocas. Além disso, foi avaliado o uso do conjunto com data augmentation.

Dentre todas as combinações, a que apresentou os melhores resultados foi treinando o modelo com imagens da base aumentada, no tamanho 50x50, com arquitetura da rede 32-64-16-64. Este modelo atingiu cerca de 63% de acurácia com o conjunto de teste (Figura 2). Por fim, para fins de comparação, foi aplicado transfer learning com o modelo ResNet50, utilizando a base de imagens aumentada e formato de entrada no tamanho 50x50 pixels para treinamento da camada de classificação com até 100 épocas. Entretanto, o modelo utilizando Transfer Learning não apresentou acurácia superior a já alcançada pelo modelo próprio, atingindo no máximo 52% de acurácia nos testes realizados.

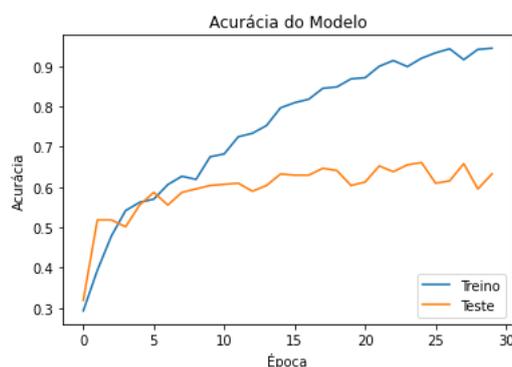


Figura 2. Desempenho do melhor modelo alcançando cerca de 63% de acurácia.

4. Considerações Finais

Este estudo teve como objetivo a criação de modelos de Deep Learning para a classificação de espécies de orquídeas da região da Chapada dos Guimarães. Para tanto, foi necessária a criação da própria base de imagens. Esta nova base está disponível para auxiliar outros pesquisadores da área por meio do link <https://www.dropbox.com/s/lsf90xd05an6v0z/orquideas.tar?dl=0>.

Após a construção da base de imagens e a aplicação de data augmentation, diversos modelos foram criados para encontrar a melhor combinação para a classificação de espécies de orquídeas. Foram testadas combinações variando o tamanho das imagens, número de neurônios, épocas e parâmetros dos modelos. Além destes novos modelos, foi avaliada também a utilização de modelo com Transfer Learning, mas que não obteve desempenho superior ao modelo criado especificamente para este trabalho.

Como trabalhos futuros, planeja-se o incremento da base de dados com a adição de novas espécies e novas imagens para cada espécie já existente. Além disso, novos testes com Transfer Learning serão executados buscando acurácias ainda maiores.

Referências

- FU, Qiaojuan, ZHANG, Xiaoying, ZHAO, Fukang, RUAN, Ruoxin, QIAN, Lihua e LI, Chunnan. Deep Feature Extraction for Cymbidium Species Classification Using Global-Local CNN. *Horticulturae*, v. 8, n. 6, p. 470, 2022.
- GOGUL, I. e KUMAR, V. Sathiesh. Flower Species Recognition System using Convolution Neural Networks and Transfer Learning. 4th International Conference on Signal Processing, Communications and Networking (ICSCN-2017), p. 1-6, 2017.
- GONÇALVES, P.S.; FREITAS, E.V.D.; SILVA, S.C.O.; BEZERRA, I.C.; ARAUJO, W.S Efeito da fragmentação da vegetação sobre a diversidade de abelhas: comparando padrões de resposta em Euglossini e Meliponini V. 09, N. 03169-178, 2024.
- HAN, Dongmei, LIU, Qigang e FAN, Weiguo. A new image classification method using CNN transfer learning and web data augmentation. *Expert Systems with Applications*, v. 95, p. 43-56, 2018.
- PETINI-BENELLI, Adarilda e VAZ-DE-MELLO, Fernando Zagury. Biogeografia das Orquídeas da Chapada dos Guimarães. *Anais do XI Encontro de Botânicos do Centro-Oeste*, p. 359-361, 2016.
- ROCHA, Maíra Iaê Savioli; NASCIMENTO, Diego Tarley Ferreira. Ocorrência de focos de queimadas em áreas legalmente protegidas do bioma Cerrado (1999/2018), v. 16, p. 122-145, 2022. Disponível em: <<https://revistas.ufg.br/atelie/article/view/70801/39025>>. Acesso em: 24 set. 2024
- SARACHAI, Watcharin, BOOTKRAJANG, Jakramate, CHAIJARUWANICH, Jeerayut e SOMHOM, Samerkae. Orchid classification using homogeneous ensemble of small deep convolutional neural network. *Machine Vision and Applications*, v. 33, n. 17, 2022.
- SHARMA, Shagun e GULERIA, Kalpna. Deep Learning Models for Image Classification: Comparison and Applications. 2nd International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE), p. 1733-1738, 2022.
- XIAO, Kehui, ZHOU, Lei, YANG, Hong e YANG, Lei. Phalaenopsis growth phase classification using convolutional neural network. *Smart Agricultural Technology*, v. 2, 2022.