

Native Bee Scan: App Inteligente para Identificação de Abelhas Nativas Utilizando Técnicas de IA

Manoel F. C. Neto^{1(*)}, André J. A. Ramos¹, João P. S. Cardoso¹, William V. Direito¹, Vivian C. N. Albuquerque³, Marcos E. C. Oliveira⁴, Daniel S. Pereira⁴, Roberto C. L. Oliveira¹

¹Instituto de Tecnologia – Universidade Federal do Pará (UFPA)

³ Instituto de Ciências Agrárias – Universidade Federal Rural da Amazônia (UFRA)

⁴Embrapa Amazônia Oriental - (CEPATU)

(*)manoel.campos@itec.ufpa.br, {jpscamos, limao}@ufpa.br, {andre.ramos7, willvaz84, vivian.albuquerque.1996}@gmail.com, {marcos-ene.oliveira, daniel.pereira}@embrapa.br

Resumo. *Apresentamos o Native Bee Scan, aplicativo que utiliza técnicas de machine learning (ML) e visão computacional para identificar espécies de abelhas nativas sem ferrão, com foco em duas espécies, a Uruçu-amarela (*Melipona flavolineata* Friese) e Uruçu-cinzenta (*Melipona fasciculata* Smith), que desempenham um papel importante para o meio ambiente e para a criação de novos produtos baseados na biodiversidade Amazônica. Para isso, foi criado um banco de dados chamado Nbees_Dataset, com mais de 8000 imagens utilizando técnicas de Data Augmentation, para auxiliar o desenvolvimento de um modelo de deep learning (DL). Foram realizados testes de inferência e acurácia do modelo em dispositivos Android, com precisão de 96,47%.*

1. Introdução

São estimadas 25 mil espécies de abelhas no planeta e, no Brasil, existem milhares de espécies, com destaque para o gênero *Melipona*, as abelhas sem ferrão. Diferentemente das abelhas do gênero *Apis*, introduzidas no Brasil em 1838, animal exótico e perigoso (sua picada pode matar), as *Meliponas*, com elevada diversidade na Amazônia, não apresentam risco, além de estarem evolutivamente adaptadas ao ambiente.

Das 600 espécies do gênero *melipona* no mundo, 244 encontram-se no Brasil e na Amazônia já foram catalogadas 114 espécies, número que pode crescer, [Filho, 2019].

O aumento da destruição do habitat natural, aumento das atividades agrícolas, perda da biodiversidade de flora causadas pelo desmatamento, mudanças climáticas e utilização de pesticidas são os principais causadores da atual e preocupante queda no número de abelhas em todo o mundo, conseqüentemente, comprometendo a polinização, [Potts e outro, 2010]. Fatores estes que colaboram para a redução na produção de vários produtos das abelhas, onde podemos citar culturas extremamente dependentes dos polinizadores para a produção dos frutos e sementes, como a abóbora, pepino, manga e a jaca [Yamamoto e outros, 2012], e também há espécies cuja a polinização aumentam a produção, como a castanha-do-pará, cacau, açaí e morango [Ghazoul e Jaboury, 2005], [Aizen e outros, 2008].

Este trabalho teve como objetivo desenvolver um aplicativo embarcado em dispositivos móveis, conforme [Arani e outros, 2022], chamado **Native Bee Scan**, para reconhecimento de Uruçu-amarela e Uruçu-cinzenta, duas abelhas do gênero melípona de elevada importância econômica na Amazônia e, em especial, no estado do Pará. A ferramenta tem potencial de aplicação na área de educação e conscientização ambiental, entre outros. O desenvolvimento do aplicativo fez uso de redes neurais convolucionais para efetuar a classificação de imagens e reconhecer padrões típicos para cada espécie de abelha, visto ser esta abordagem facilitada por tais técnicas quando o foco está no embarque da ferramenta desenvolvida [Zhu e outros, 2019].

2. Materiais e Métodos

2.1 Redes Neurais Convolucionais

A escolha das redes neurais convolucionais para este trabalho se deu devido ao seu bom desempenho nos resultados de acurácia, e outras métricas de avaliação, como *Precision*, *Recall*, e *F1-Score* comparados a outros métodos. Para o desenvolvimento do modelo foram destinadas 90% das imagens para o treinamento e 10% para teste. A validação foi feita através das 85 imagens coletadas via aplicativo.

2.2 NBees_Dataset

Foram utilizadas 1800 imagens RGB (Vermelho-Verde-Azul) das melíponas urucu-amarela e urucu-cinzenta (Autorização SISGEN **A64B467**). As imagens foram coletadas do Meliponário Iratama, localizado no Laboratório de Botânica da Embrapa Amazônia Oriental, em Belém-PA. Por uma questão de diversidade, seguindo as recomendações em [Lu e outros, 2020], as imagens foram capturadas de diferentes ângulos de visão, sob condições de luz natural do local e de diferentes caixas de abelhas.

As imagens foram anotadas de acordo com a sua espécie e depois foi utilizada uma técnica de *Data Augmentation*, que teve como objetivo aumentar artificialmente o conjunto de treino criando cópias modificadas do conjunto de dados. Isso incluiu fazer pequenas alterações no conjunto de dados, como girar imagens em diversos ângulos.

2.3 Desenvolvimento do modelo de DL para aplicativo

O passo a passo para a criação do modelo em ambiente virtual e posterior implementação do modelo de DL no Android ocorreu da seguinte ordem: 1) **Criação:** Em um notebook no Google Colab, o modelo foi criado utilizando o keras; 2) **Conversão:** Após um bom desempenho, o modelo foi convertido (Através do TF Lite converter) para o formato de extensão .tflite do tipo flatBuffer otimizado criado pelo Google; 3) **Implantação:** A API do tensorflow lite para Android exige que o arquivo .tflite contenha metadados que informe os rótulos das classes do modelo para que, então, possam ser manipulados através de códigos em linguagem Kotlin. Posteriormente o arquivo é adicionado ao projeto do aplicativo no Android Studio.

2.4 Native Bee Scan

O aplicativo desenvolvido neste trabalho foi construído na plataforma Android Studio IDE na qual a depuração e os testes iniciais foram realizados em um aparelho Xiaomi Note 8 com 8 cores, arquitetura 2x 2.0 GHz Cortex-A75 + 6x 1.8 GHz Cortex-A55.

3. Resultados

Após o processo de *data augmentation*, as 1800 imagens originais levaram à formação de um banco de dados para treinamento da rede neural com 8000 imagens.

Na Figura 1 apresenta-se a matriz de confusão para os 85 dados de validação feitas via aplicativo, onde as métricas de avaliação utilizadas foram *recall* e *precision*. Para a classe de uruçú cinzenta o recall foi de 93,33% a precisão foi de 96,55%, para a uruçú amarela o recall foi de 98,03% e a precisão foi de 95,15%. Para a classe indefinida, tanto o recall quanto a precisão foram de 100%, e a acurácia para as imagens testadas foi de 96,47%.

Output Class	Uruçu Cinzenta	28 32,94%	1 1,17%	0 0,00%	96,55% 3,45%	P R E C I S I O N
	Uruçu Amarela	2 2,35%	50 58,82%	0 0,00%	96,15% 3,84%	
	Indefinido	0 0,00%	0 0,00%	4 4,70%	100,00% 0,00%	
		93,33% 6,67%	98,03% 1,97%	100,00% 0,00%	96,47% 3,53%	
	Uruçu Cinzenta	Uruçu Amarela	Indefinido	RECALL		

Figura 1. Matriz de confusão para os dados de validação

Na Figura 2 apresentam-se imagens de interfaces do aplicativo desenvolvido. A tela principal contém 3 opções de menu: 1) **Scan**: Opção onde a câmera do dispositivo roda o classificador em *background* e em tempo real. Na parte inferior é mostrado o valor de inferência com uma classificação prévia da espécie de abelha encontrada e seu valor de confiança. Uma opção de informação irá redirecionar o usuário para uma interface com detalhes específicos sobre a espécie; 2) **Help**: Nesta opção o usuário terá um breve guia de como utilizar o aplicativo e; 3) **About**: Contém informações sobre o desenvolvimento do aplicativo.

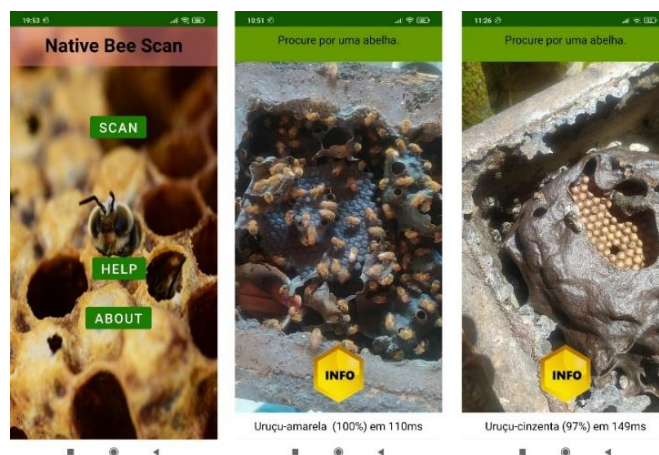


Figura 2. Interface do aplicativo Native Bee Scan

Os resultados obtidos nas etapas de validação do modelo de rede neural permitiram verificar a adequação do banco de dados *Nbees_Dataset*, e os testes de campo com o aplicativo desenvolvido mostraram um desempenho adequado com uma boa resposta de inferência na classificação das abelhas, especialmente considerando-se a complexidade de coletar imagens de animais vivos, de características defensivas e bastante sensíveis.

O aplicativo **Native Bee Scan** ainda está em fase de desenvolvimento, e ocupa 131MB de armazenamento dos dispositivos móveis. Analisando o desempenho do aplicativo através do recurso *Profiler* do Android Studio, onde foi possível visualizar que, no processo de inferência no streaming da câmera, o app utiliza em média 34% da CPU e consome em média 183MB de memória RAM. Seu futuro aperfeiçoamento poderá ampliar sua área de aplicação até mesmo para o manejo das abelhas por produtores.

4. Conclusões

Neste trabalho utilizou-se um banco de imagens de uruçu-amarela e uruçu-cinzenta para o desenvolvimento de um aplicativo de identificação de abelhas por meio de rede neural convolucional. Os resultados permitiram classificar as espécies com nível de acerto superior a 95%. Futuramente, pretende-se expandir a quantidade de classes utilizando mais espécies de abelhas nativas, enriquecendo o banco de dados, e também aprimorando os outros métodos adotados para o desenvolvimento do aplicativo.

5. Referências

- J. M Filho. A Revolução das Abelhas sem Ferrão. Revista Página 22, no 2019.
- Potts, Simon G. et al. Global pollinator declines: trends, impacts and drivers. *Trends in ecology & evolution*, v. 25, n. 6, p. 345-353, 2010.
- Yamamoto, M. et al. The role of bee diversity in pollination and fruit set of yellow passion fruit (*Passiflora edulis* forma *flavicarpa*, Passifloraceae) crop in Central Brazil. *Apidologie*. V(43): 515, 2012.
- Ghazoul, Jaboury. Buzziness as usual? Questioning the global pollination crisis. *Trends in ecology & evolution*, v. 20, n. 7, p. 367-373, 2005.
- Aizen, Marcelo A. et al. Long-term global trends in crop yield and production reveal no current pollination shortage but increasing pollinator dependency. *Current biology*, v. 18, n. 20, p. 1572-1575, 2008.
- Arani, Samen Anjum et al. Melanlysis: A mobile deep learning approach for early detection of skin cancer. In: 2022 IEEE 28th International Conference on Parallel and Distributed Systems (ICPADS). IEEE, 2023. p. 89-97.
- Zhu, Lili; Spachos, Petros. Butterfly classification with machine learning methodologies for an android application. In: 2019 IEEE Global Conference on Signal and Information Processing (GlobalSIP). IEEE, 2019. p. 1-5.
- Khalid, Fatimah et al. Smartflora Mobile Flower Recognition Application Using Machine Learning Tools. In: 2022 IEEE 18th International Colloquium on Signal Processing & Applications (CSPA). IEEE, 2022. p. 204-209.
- Lu, Yuzhen; Young, Sierra. A survey of public datasets for computer vision tasks in precision agriculture. *Computers and Electronics in Agriculture*, v. 178, p. 105760, 2020.