

DETECÇÃO DE PATÓGENOS EM ABELHAS BASEADA EM TÉCNICAS DE VISÃO COMPUTACIONAL

ALMEIDA M. E. M.¹, CAMARGO, S. S.¹

¹ Universidade Federal do Pampa (Unipampa) – Bagé – RS – Brasil – mariaema2.aliuno@unipampa.edu.br

RESUMO

Este trabalho propõe o uso de técnicas de visão computacional para detecção do ácaro *Varroa destructor* em abelhas *Apis mellifera*. Foi utilizado um modelo baseado em *Transfer Learning* com MobileNetV2, treinado em uma base de imagens rotuladas e avaliado em um conjunto independente. O modelo apresentou alto desempenho na validação (acurácia de 94%), porém baixa capacidade de generalização em imagens externas, evidenciando forte dependência da qualidade e diversidade dos dados de treinamento. Os resultados indicam que, embora promissora, a abordagem depende fortemente da qualidade e diversidade dos dados de treinamento.

Palavras-chave: Inteligência Artificial, Deep Learning, *Apis Mellifera*, *Varroa Destructor*.

1 INTRODUÇÃO

As abelhas possuem papel fundamental no ecossistema, sendo a polinização uma de suas funções mais relevantes. Estima-se que aproximadamente 75% das culturas agrícolas dependam, em parte, desse processo (Giovanetti et al., 2021). Elas também contribuem para a preservação da biodiversidade, assegurando o êxito reprodutivo das plantas. Serviços ecossistêmicos associados favorecem ainda a conservação de áreas naturais. Dessa forma, o desaparecimento das abelhas no ambiente pode gerar consequências significativas, como a redução ou perda da biodiversidade. (Ordunha et al., 2023). Assim, a espécie *Apis mellifera* destaca-se por sua ampla distribuição geográfica (Feketéné Ferenczi, 2023; Oliveira et al, 2024). No bioma pampa, a *Apis mellifera* exerce papel relevante na polinização de espécies nativas quanto de culturas agrícolas introduzidas, contribuindo para a manutenção da diversidade vegetal e para a sustentabilidade de sistemas produtivos regionais.

Uma das maiores ameaças à *Apis mellifera* é o ácaro *Varroa destructor*. Recentemente, houve um crescimento notável no número de estudos sobre este ácaro e sua interação com a abelha, que revelaram a complexidade dessa interação. As proteínas

secretadas na saliva do *Varroa destructor* podem afetar negativamente o sistema imunológico da abelha, seu metabolismo e seu funcionamento neural. Assim, podendo comprometer a saúde da colônia (Morfin et al., 2023).

No contexto atual, os apicultores utilizam de técnicas como métodos apícolas biotécnicas, acaricidas sintéticos e acaricidas orgânicos ou suaves. No entanto, novos obstáculos surgem conforme a abordagem escolhida (Souza et al., 2023). Dessa forma, métodos tradicionais de detecção do ácaro são manuais, demorados e sujeitos a erro humano, o que abre espaço para abordagens automatizadas baseadas em inteligência artificial e visão computacional.

Diante deste cenário, o objetivo deste trabalho é aplicar técnicas de visão computacional e inteligência artificial para detectar patógenos, com foco no ácaro *Varroa destructor*, em abelhas.

2 METODOLOGIA

Foram utilizadas duas bases de imagens: *Bee Images Separated*, destinada ao treinamento e validação, e *New Data for Predictions*, empregada como conjunto de teste independente (Morphew, 2021). Ao todo, o estudo utilizou aproximadamente 2.650 imagens, sendo 2.000 de abelhas saudáveis e 650 infectadas pelo ácaro *Varroa destructor*, caracterizando um desbalanceamento entre as classes. A Figura 1 apresenta imagens das duas classes.

As imagens, originalmente com dimensões variadas, foram padronizadas durante o pré-processamento. Os valores de intensidade dos *pixels*, inicialmente no intervalo [0,255], foram normalizados para [-1,1], adequando os dados aos requisitos do modelo. Para lidar com o desbalanceamento, foram aplicados pesos de classe, atribuindo maior penalização aos erros na classe minoritária.

O modelo foi desenvolvido em Python, utilizando as bibliotecas TensorFlow/Keras, com execução no ambiente Google Colab. Foi adotada a técnica de *Transfer Learning* com a arquitetura MobileNetV2, na qual as camadas convolucionais pré-treinadas foram mantidas congeladas, enquanto as camadas superiores foram ajustadas para a tarefa de classificação binária (“saudável” e “infectada”).

O conjunto Bee Images Separated foi dividido em 70% para treinamento e 30% para validação. Já o conjunto *New Data for Predictions* foi utilizado exclusivamente para

teste, garantindo a independência entre os dados e permitindo uma avaliação mais realista da capacidade de generalização do modelo.

A otimização dos hiperparâmetros considerou o uso da MobileNetV2 como backbone, visando equilíbrio entre eficiência computacional e capacidade de extração de características. A taxa de aprendizado foi fixada em 0,001 no otimizador Adam, e o uso de Dropout foi empregado para reduzir o risco de overfitting. O treinamento foi realizado por 10 épocas.


Figura 1. Imagens do *dataset* de teste: abelha saudável x infectada



3 RESULTADOS E DISCUSSÃO

Embora a acurácia inicial elevada sugira que o uso de *transfer learning* contribuiu para um bom ponto de partida, essa métrica isolada pode ser influenciada pelo desbalanceamento das classes (Figura 2). Conforme a Tabela 1, a análise dos erros indica um número muito baixo de falsos negativos, sugerindo alta sensibilidade para a classe positiva. No entanto, a presença de um número elevado de falsos positivos evidencia baixa precisão, indicando que o modelo tende a classificar excessivamente amostras como positivas. Tais resultados representaram uma acurácia de 94%, dados os 724 acertos em 770 amostras.

Figura 2. Gráfico de acurácia do treinamento



Fonte: próprio autor.

Tabela 1. Matriz de confusão

		Classe Predita	
		Saudável	Infestada
Classe Real	Saudável	631	45
	Infestada	1	93

Fonte: próprio autor.

Esse comportamento pode estar relacionado ao desbalanceamento dos dados e à possível falta de calibração do limiar de decisão. Dessa forma, métricas adicionais, como precisão, *recall* e *F1-score*, são necessárias para uma avaliação mais completa do desempenho do modelo.

4 CONCLUSÃO

Apesar da excelente performance na validação (94% de acurácia), o modelo ainda tem maior dificuldade na predição de amostras da classe infestada e apresentou dificuldades em generalizar para imagens de fontes externas. Isso ocorre porque o modelo especializou-se nas características específicas de iluminação e captura do dataset de treino, falhando ao encontrar padrões visuais totalmente novos.

REFERÊNCIAS

CRUZ, C. P.; LUNA, P.; VILLALOBOS, F.; GUEVARA, R.; HINOJOZA-DÍAZ, I.; DÁTTILO, W. The central importance of the honeybee (*Apis mellifera* L.) within plant-bee interaction networks decreases along a Neotropical elevational gradient. **Ecological Complexity**, v. 60, 101105, 2024. DOI: <https://doi.org/10.1016/j.ecocom.2024.101105>

FEKETÉNÉ FERENCZI, A.; SZŰCS, I.; BAUERNÉ GÁTHY, A. Evaluation of the pollination ecosystem service of the honey bee (*Apis mellifera*) based on a beekeeping model in Hungary. **Sustainability**, v. 15, p. 9906, 2023. DOI: <https://doi.org/10.3390/su15139906>

GIOVANETTI, M.; ALBERTAZZI, S.; FLAMINIO, S.; RANALLI, R.; BORTOLOTTI, L.; QUARANTA, M. Pollination in agroecosystems: a review of the conceptual framework with a view to sound monitoring. **Land**, v. 10, p. 540, 2021. DOI: <https://doi.org/10.3390/land10050540>

MORFIN, N. et al. Varroa destructor (Acari: Varroidae) and its synergistic interactions with other stressors on honey bee health. **Journal of Economic Entomology**, v. 116, n. 4, p. 1045–1056, 2023. DOI: <https://doi.org/10.1093/jisesa/ieae054>

MORPHEW, S. Bee Images Separated. Kaggle, 2021. Disponível em: <https://www.kaggle.com/datasets/shaylynnmorphew/bee-images-separated>. Acesso em: 27 mar. 2026.

MORPHEW, S. New data for predictions. Kaggle, 2021. Disponível em: <https://www.kaggle.com/datasets/shaylynnmorphew/new-data-for-predictions>. Acesso em: 27 mar. 2026.

NOËL, A.; LE CONTE, Y.; MONDET, F. Varroa destructor: how does it harm *Apis mellifera* honey bees and what can be done about it? **Emerging Topics in Life Sciences**, v. 4, n. 1, p. 45–57, 2020. DOI: <https://doi.org/10.1042/ETLS20190125>

OLIVEIRA, W.; COLARES, L. F.; PORTO, R. G.; VIANA, B. F.; TABARELLI, M.; LOPES, A. V. Food plants in Brazil: origin, economic value of pollination and pollinator shortage risk. **Science of the Total Environment**, v. 912, 169147, 2024. DOI: <https://doi.org/10.1016/j.scitotenv.2023.169147>

ORDUNHA, J. M. Utilização da inteligência artificial para detecção de Varroa destructor em colônias de *Apis mellifera*. 2023. Trabalho de Conclusão de Curso (Graduação em Engenharia de Bioprocessos e Biotecnologia) – Universidade Estadual Paulista (UNESP), Araraquara, 2023.

SOUZA, A. C. P. O Varroa destructor e suas implicações nas abelhas *Apis mellifera*. **Revista COOPEX**, v. 14, n. 1, p. 163–191, 2023. DOI: <https://doi.org/10.61223/coopex.v14i1.116>