



Classificação de predadores de abelhas melíferas utilizando redes neurais convolucionais e transferência de conhecimento

Leticia Torres Pereira², Antony Michael A. Chagas¹, Daniel Santos da Silva¹,
Valdenio Mendes Mascena¹, Wellington Franco²,
Renato William R. de Souza¹

¹Centro de Inovação e Difusão de Tecnologias para o Semiárido (CIDTS)
Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)
Caixa Postal 63.870-000 – Boa Viagem – CE – Brasil

²Campus de Crateús
Universidade Federal do Ceará (UFC) – Crateús, CE – Brasil

{santos.daniel, renato.william}@ifce.edu.br, leticiatorres@alu.ufc.br

Abstract. *The preservation of biodiversity is a crucial issue in a world increasingly threatened by environmental changes and the loss of natural habitats. In this context, beekeeping and bee conservation have proven to be essential for the pollination of various agricultural crops and for the maintenance of ecosystems. Bees are important pollinating insects for agriculture and the environment. However, they are also vulnerable to predators such as ants, wasps and flies. Identifying bee predators is important to protect hives and ensure successful pollination. In this article, we present a computational model based on artificial intelligence (AI) to differentiate bees from predators, where it is trained from a database of images of bees and predators. The model uses different feature extractors based on convolutional neural networks (CNNs) to extract features from the images, such features are then classified by different pattern classifiers, such as support vector machine (SVM), K-Nearest Neighbors (k-NN) and multilayer neural network (MLP). The analysis of the experimental results showed that the proposed model obtained a satisfactory accuracy in relation to the Acucária metric, obtaining a value of 86.94%.*

Resumo. *A preservação da biodiversidade é um tema crucial em um mundo cada vez mais ameaçado pelas mudanças ambientais e pela perda de habitats naturais. A apicultura e a conservação das abelhas têm se mostrado fundamentais para a polinização de diversas culturas agrícolas e para a manutenção dos ecossistemas. As abelhas são insetos polinizadores importantes para a agricultura e o meio ambiente. No entanto, elas também são vulneráveis a predadores, como formigas, vespas e moscas. A identificação de predadores de abelhas*

é importante para proteger as colmeias e garantir o sucesso da polinização. Neste artigo, apresentamos um modelo computacional baseado em inteligência artificial (IA) para diferenciar abelhas de predadores, onde é treinado a partir de uma base de dados de imagens de abelhas e predadores. A análise dos resultados experimentais mostrou que o modelo proposto obteve uma acurácia satisfatória em relação à métrica Acurácia, obtendo um valor de 86.94%. O modelo utiliza diferentes extratores de características baseados em redes neurais convolucionais (CNNs) para extrair características das imagens, tais características são então classificadas por diferentes classificadores de padrões, como máquina de vetor de suporte (SVM), K-vizinhos mais próximos (k-NN) e rede neural multicamada (MLP).

1. Introdução

Abelhas são o maior grupo de polinizadores da agricultura. Este processo realizado, não somente por esta espécie, mas também por outros insetos e animais de outras espécies, é essencial para a produtividade de lavouras e contribui para a preservação do meio ambiente [Junior et al. 2021]. De acordo com [Lopes et al. 2021], as abelhas *Apis mellifera L.* tem sofrido com, entre outros fatores, alterações climáticas e diminuição e fragmentação do seu habitat, o que tem comprometido o bem-estar e a longevidade das colmeias. Além disso, a presença de predadores, parasitas e patógenos de outros continentes tem levado a grandes perdas de colmeias ao redor do mundo. A identificação de predadores de abelhas é importante para proteger as colmeias e garantir o sucesso da polinização [Munhoz 2000].

Atualmente, os apicultores identificam predadores de abelhas por inspeção visual das colmeias. No entanto essa abordagem é demorada e ineficiente, e pode levar à perda de abelhas [Maciel et al. 2018]. Por meio de algoritmos de inteligência artificial (IA), como por exemplos: classificadores de aprendizado de máquina (AM), técnicas de visão computacional e processamento de imagens, tornou-se possível a automatização do processo de identificação e contagens de insetos. Tais técnicas surgem como uma alternativa a realização manual desse processo e possibilitou um aumento na acurácia do mesmo [Júnior and Rieder 2020].

O modelo computacional proposto neste artigo é baseado em inteligência artificial e é treinado em uma base de dados de imagens de abelhas e predadores. O modelo utiliza diferentes extratores de características baseados em redes neurais convolucionais (CNNs) para extrair características das imagens. As características são então classificadas por diferentes classificadores de padrões, como suporte vetorial máquina (SVM), vizinho mais próximo (k-NN) e rede neural multicamada (MLP). O modelo é avaliado em uma base de dados de teste e obteve uma acurácia de 86.94%. Os resultados indicam que o modelo é capaz de diferenciar abelhas de predadores com alta precisão.

Assim, este trabalho tem por finalidade o desenvolvimento de técnicas computacionais para se identificar padrões que possibilitem a diferenciação entre abelhas e outras espécies de insetos, visando a detecção do instante de ataque das colmeias por predadores. As principais contribuições deste trabalho são:

- Comparação de modelos de *Deep Learning* com *Transferring Learning* para a área de Dados e Computação Inteligente;

- Novo Modelo de Aprendizado de Máquina baseado em CNN com *transferring learning*;
- Automatizar tarefas que atualmente são realizadas manualmente por apicultores, como a inspeção visual das colmeias.

O restante deste artigo está organizado da seguinte forma. A Seção 2 descreve os conjuntos de dados e configurações dos experimentos realizados neste trabalho. Também apresentaremos os resultados experimentais e as discussões 3, respectivamente. Finalmente, a Seção 4 apresenta as conclusões e trabalhos futuros.

2. Metodologia

Após obter as imagens, o próximo passo é submetê-las às *Convolutional Neural Networks* (CNNs). Abaixo as técnicas de extração de características baseadas em CNN utilizadas neste trabalho:

- VGG16 e VGG19 ambas propostas por [Simonyan and Zisserman 2014];
- Resnet50 e Resnet50v2 [He et al. 2016];
- MobileNetV3Small[Howard et al. 2019];
- Inception_resnetv2[Szegedy et al. 2017];
- InceptionV3[Szegedy et al. 2016];
- EfficientNetV2B3 e EfficientNetV2B0[Tan and Le 2021];
- ConvNeXtXSmall [Liu et al. 2022].

Essas características extraídas são, então, fornecidas aos algoritmos de aprendizado de máquina SVM (*Support Vector Machine*)[Cortes and Vapnik 1995], MLP (*Multi-Layer Perceptron*) [Taud and Mas 2018] e k-NN (*K-Nearest Neighbors*)[Kramer and Kramer 2013] para classificar os grupos distintos: abelhas e insetos não-abelha.

2.1. Base de dados

A base de dados [Bhuiyan et al. 2022] é composta por 6.332 imagens, das quais 1776 correspondem à classe “abelha”, 360 à classe “não abelhas”. Essa base tem dois objetivos principais: o primeiro é realizar a classificação entre abelhas e não abelhas, enquanto o segundo é focado na classificação entre abelhas e insetos não-abelhas, uma tarefa mais complexa que foi escolhida para análise. Devido à discrepância significativa entre a quantidade de imagens de abelhas e insetos não-abelha, procedeu-se ao balanceamento da base, ajustando a quantidade de imagens de abelhas, escolhendo-as de forma aleatória, para igualar a quantidade de imagens de insetos não abelhas. Na Tabela 1, apresentamos a distribuição balanceada dos dados.

Tabela 1. Descrição da distribuição das classes da base de dados utilizada

Informações	Quantidade	Percentual
Abelhas	360	50
Insetos não-abelhas	360	50

O balanceamento da base é essencial para evitar viés nos resultados da classificação, garantindo que o modelo não seja tendencioso devido à distribuição desigual das classes. Com isso, a análise entre abelhas e insetos não-abelhas pode ser realizada de forma mais confiável.

2.2. Métricas de validação

Como forma de validação dos métodos, utilizou-se como base a matriz de confusão, avaliando os Verdadeiro Positivo (VP), Falso Positivo (FP), Verdadeiro Negativo (VN) e Falso Negativo (FN). Tendo em vista a matriz de confusão, quatro métricas foram utilizadas para avaliar os resultados, sendo elas: Acurácia Global (AccGlobal), F1-score (F1score), acurácia da classe de abelhas (AccAbelha), acurácia da classe insetos não-abelha (AccInseto). Na Figura 1, apresentamos como vamos classificar abelhas e insetos não-abelhas.

		Classe Predita	
		Abelha	Inseto não-abelha
Classe Real	Abelha	Verdadeiro Positivo (VP)	Falso Negativo (FN)
	Inseto não-abelha	Falso Positivo (FP)	Verdadeiro Negativo (VN)

Figura 1. Exemplo de Matriz de Confusão para classificação de abelhas e insetos não-abelha.

- **Verdadeiro Positivo (VP):** O VP ocorre quando no conjunto real de dados, a classe abelha foi prevista corretamente como classe que possui abelhas.
- **Falso Positivo (FP):** O FP ocorre quando no Conjunto real de dados, a classe que se busca prever foi prevista incorretamente. Isto é, quando era para ser insetos não-abelha e foi diagnosticado como abelha.
- **Verdadeiro Negativo (VN):** O VN ocorre quando no conjunto real de dados, a classe de insetos não abelha foi prevista corretamente como classe insetos.
- **Falso Negativo (FN):** O FN ocorre quando no Conjunto real de dados, a classe que se busca prever foi prevista incorretamente. Ou seja, quando era para ser abelha e foi diagnosticado como inseto não abelha.
- **Acurácia:** Trata-se da probabilidade geral de acerto, ou seja, é a taxa de acerto global considerando as classes analisadas. Dessa forma, a acurácia leva em consideração os acertos das duas classes, abelhas e insetos não-abelha, sob todos os erros e acertos.

$$AccGlobal = \frac{VP + VN}{VP + FP + VN + FN}$$

- **F1-score:** Trata-se da média harmônica entre as previsões corretas da classe abelhas e previsão correta de classe insetos não-abelha, assim, irá analisar sob a ótima da taxa de acerto das classes.

$$F1 - score = 2 \times \frac{Previsões_{abelhas} \times Previsão_{não - abelha}}{Previsões_{abelhas} + Previsão_{não - abelha}}$$

- **Acurácia da classe abelha (AccAbelha):** Trata-se da probabilidade de um imagem que possui abelha, realmente tenha uma abelha.

$$AccAbelha = \frac{VP}{VP + FN}$$

- **Acurácia da classe Inseto não-abelha (AccInseto):** Trata-se da probabilidade de uma imagem que possui inseto não-abelha, realmente tenha um inseto não-abelha.

$$AccInseto = \frac{VN}{VN + FP}$$

2.3. Configuração experimental

As CNNs foram implementadas como extratores de características, utilizando a técnica de transfer learning. Para classificação, utilizou-se os algoritmos *Multilayer Perceptron* (MLP), *Support Vector Machine* (SVM) e *k-Nearest Neighbors* (k-NN). Os conjuntos de dados extraídos pelas CNN foram divididos em dados de treinamento e teste utilizando *K-fold Cross Validation* com 15 folds. Os hiperparâmetros foram otimizados por meio do grid search. Em relação ao k-NN, o número de vizinhos $\in [3, 10]$ e tamanho da folha $\in [10, 50]$. Os parâmetros do SVM, o $\gamma \in [2^{-15}, 2^{-1}]$ e $C \in [2^{-5}, 2^5]$. Quanto a MLP, os parâmetros foram a quantidade de camadas ocultas $\in [1:5]$, quantidade de neurônios por camada oculta $\in [50:500]$, $\alpha \in [000001, 1]$ e taxa de aprendizado $\in [000001, 0.9999]$.

3. Resultados

A avaliação do modelo foi realizada por meio da métrica de acurácia, considerando a proporção de acertos na classificação das abelhas e predadores. Os resultados obtidos são comparados entre os diferentes classificadores utilizados, permitindo identificar qual algoritmo obteve a melhor performance na tarefa de diferenciação entre as espécies.

Tabela 2. Média de tempo de extração (segundos)

Extratores/CNN	Tempo [segundos]
VGG19	382.6744
VGG16	322.7996
Resnet50v2	79.7237
Resnet50	143.8612
InceptionV3	84.3739
Inception-resnetv2	146.0863
EfficientNetV2B3	119.8141
ConvNeXtXSmall	2726.5958

A Tabela 3 apresenta o desempenho individual de cada extrator com cada classificador, onde é possível verificar que os extratores Vgg19, Vgg16, Resnet50v2, InceptionV3 e EfficientNetV2B3 apresentaram o melhor desempenho com o SVM e dentre eles o EfficientNetV2B3 obteve a melhor acurácia com 86.94% com um desvio padrão de 4.29%. Enquanto o Resnet50 e o ConvNeXtXSmall com MLP, tendo o Resnet50 o melhor resultado com 87.08% de acurácia e um desvio padrão de 4.88%.

Por fim, o Inception-resnetv2 foi o único a obter o melhor desempenho com o k-NN, obtendo uma acurácia de 58.33% e desvio padrão de 8.33%. Dentre todos, o que apresentou melhor desempenho, com uma acurácia de aproximadamente 87.08%, foi o extrator Resnet50 com MLP, mesmo que estatisticamente semelhante ao Resnet50 com

Tabela 3. Resultados Métricas de Validação

Extratores	Métricas	SVM	MLP	k-NN
VGG19	ACC	83.88 ± 6.65	83.19 ± 4.33	67.36 ± 6.06
	F1 Score	83.63 ± 7.13	83.03 ± 4.95	53.46 ± 10.69
	AccAbelha	84.72 ± 6.74	83.33 ± 5.69	96.38 ± 3.98
	AccInseto	83.05 ± 8.80	83.05 ± 7.97	38.33 ± 9.76
VGG16	ACC	84.44 ± 4.92	82.22 ± 4.98	68.75 ± 5.43
	F1 Score	84.44 ± 4.94	81.70 ± 5.89	55.74 ± 10.92
	AccAbelha	84.16 ± 6.30	83.33 ± 6.45	96.94 ± 2.83
	AccInseto	84.72 ± 6.57	81.11 ± 10.95	40.55 ± 10.25
Resnet50v2	ACC	59.44 ± 7.64	58.88 ± 6.69	58.19 ± 5.56
	F1 Score	59.92 ± 7.39	61.05 ± 6.83	62.84 ± 5.81
	AccAbelha	58.05 ± 11.02	51.94 ± 21.23	44.99 ± 8.89
	AccInseto	60.83 ± 8.97	65.83 ± 15.07	71.38 ± 10.07
Resnet50	ACC	86.94 ± 5.07	87.08 ± 4.88	83.61 ± 4.68
	F1 Score	87.06 ± 5.04	87.17 ± 5.60	83.52 ± 4.89
	AccAbelha	86.11 ± 6.91	85.00 ± 5.22	83.88 ± 6.94
	AccInseto	87.77 ± 5.98	89.16 ± 8.84	83.33 ± 6.97
InceptionV3	ACC	57.91 ± 6.64	51.66 ± 3.89	55.00 ± 6.21
	F1 Score	58.21 ± 6.89	65.42 ± 3.99	59.66 ± 5.98
	AccAbelha	56.66 ± 11.96	10.27 ± 21.07	43.05 ± 9.08
	AccInseto	59.16 ± 10.11	93.05 ± 15.18	66.94 ± 9.06
Inception-resnetv2	ACC	54.44 ± 7.48	50.00 ± 0.00	58.33 ± 8.33
	F1 Score	52.77 ± 13.25	66.66 ± 1.11	54.04 ± 10.07
	AccAbelha	56.66 ± 7.72	0.00 ± 0.00	66.94 ± 10.70
	AccInseto	52.22 ± 13.25	100.0 ± 0.00	49.72 ± 11.53
EfficientNetV2B3	ACC	86.38 ± 4.29	85.55 ± 4.89	80.13 ± 6.22
	F1 Score	86.12 ± 4.61	85.51 ± 4.86	80.02 ± 6.81
	AccAbelha	87.77 ± 5.15	85.83 ± 6.59	79.72 ± 6.78
	AccInseto	85.00 ± 6.59	85.27 ± 5.86	80.55 ± 9.82
ConvNeXtXSmall	ACC	84.30 ± 4.22	85.00 ± 4.57	75.00 ± 4.93
	F1 Score	84.00 ± 4.47	84.81 ± 4.62	78.05 ± 4.53
	AccAbelha	85.83 ± 6.77	86.11 ± 6.91	60.83 ± 6.04
	AccInseto	82.77 ± 6.94	83.88 ± 6.43	89.16 ± 6.77

SVM. Apesar de possuir uma acurácia maior, o Resnet50 com SVM possui uma AccAbelha maior, sendo mais relevante para essa aplicação. Já em consideração a métrica AccAbelha, a combinação que obteve maior acerto de identificação de abelhas, foi o VGG16 com o k-NN, alcançando um percentual de 96.94%. Dessa forma, pode-se analisar na Figura 2 a relação entre o Resnet50 com SVM e o VGG16 com k-NN, considerando a melhor combinação que obteve melhores resultados para acurácia geral e para taxa de acerto da classe abelhas.

Observa-se que, considerando a acurácia global, o Resnet50 consegue resultados melhores, pois há um equilíbrio entre o acerto das classes, já para identificação de abelhas, tendo em vista a métrica AccAbelha, o VGG16, consegue alcançar maiores percentuais

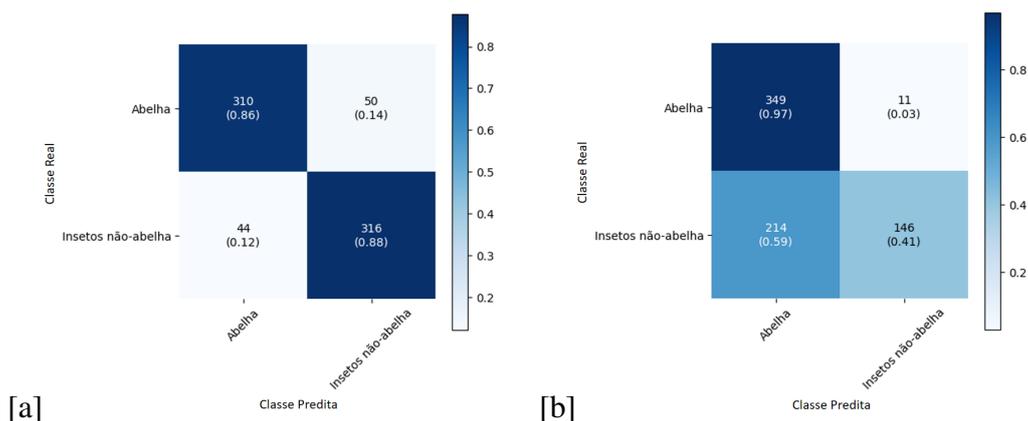


Figura 2. Matriz de confusão para os melhores resultados

de acerto. Além de um maior equilíbrio entre o acerto das classes, Na Tabela 2 é possível analisar que o Resnet50 possui um menor tempo de extração em relação ao VGG16, o que o torna mais eficiente.

4. Conclusão e Trabalhos Futuros

Este apresenta um modelo para identificação de predadores em colmeias baseado em imagens. O nosso modelo utiliza diferentes extratores de características baseados em redes neurais convolucionais (CNNs) para extrair características das imagens. Foram utilizados os seguintes classificadores: suporte vetorial máquina (SVM), vizinho mais próximo (k-NN) e rede neural multicamada (MLP) para classificar as principais características extraídas. Foram realizados diversos testes e obtivemos como resultado 86.94% de métrica de acurácia. Como trabalhos futuros, queremos usar esse modelo em um sistema embarcado juntamente com um sistema web para detectar um predador em uma colmeia e gerar um alerta para o apicultor tomar alguma providência.

5. Agradecimentos

A Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico (Funcap) e ao Centro de Inovação e Difusão de Tecnologias para o Semiárido (CIDTS) pelo financiamento desta pesquisa.

Referências

- Bhuiyan, T., Carney, R. M., and Chellappan, S. (2022). Artificial intelligence versus natural selection: Using computer vision techniques to classify bees and bee mimics. *Isience*, 25(9).
- Cortes, C. and Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20:273–297.
- He, K., Zhang, X., Ren, S., and Sun, J. (2016). Identity mappings in deep residual networks. In *Computer Vision–ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part IV 14*, pages 630–645. Springer.

- Howard, A., Sandler, M., Chu, G., Chen, L.-C., Chen, B., Tan, M., Wang, W., Zhu, Y., Pang, R., Vasudevan, V., et al. (2019). Searching for mobilenetv3. In *Proceedings of the IEEE/CVF international conference on computer vision*, pages 1314–1324.
- Júnior, D. M. R., dos Santos, J. B. S. V., Sant’Anna, D. O., et al. (2021). Polinização, abelhas-robô e a neutralidade da tecnologia. *Liinc em Revista*, 17(1):e5608–e5608.
- Júnior, T. D. C. and Rieder, R. (2020). Automatic identification of insects from digital images: A survey. *Computers and Electronics in Agriculture*, 178:105784.
- Kramer, O. and Kramer, O. (2013). K-nearest neighbors. *Dimensionality reduction with unsupervised nearest neighbors*, pages 13–23.
- Liu, Z., Mao, H., Wu, C.-Y., Feichtenhofer, C., Darrell, T., and Xie, S. (2022). A convnet for the 2020s. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, pages 11976–11986.
- Lopes, A., Henriques, D., and Pinto, M. A. (2021). Vírus: os inimigos invisíveis da abelha (*apis mellifera* l.). *O Apicultor*, (114):9–15.
- Maciel, F. A. O., Braga, A. R., da Silva, T. L. C., Freitas, B. M., and Gomes, D. G. (2018). Reconhecimento de padrões sazonais em colônias de abelhas *apis mellifera* via clusterização. *Revista Brasileira de Computação Aplicada*, 10(3):74–88.
- Munhoz, A. T. (2000). Tópicos sobre manejo em abelhas. In *Seminário Sul Brasileiro de Apicultores*, pages 77–85, Pinhal. Evangraf.
- Simonyan, K. and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Szegedy, C., Ioffe, S., Vanhoucke, V., and Alemi, A. (2017). Inception-v4, inception-resnet and the impact of residual connections on learning. In *Proceedings of the AAAI conference on artificial intelligence*, volume 31.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 2818–2826.
- Tan, M. and Le, Q. (2021). Efficientnetv2: Smaller models and faster training. In *International conference on machine learning*, pages 10096–10106. PMLR.
- Taud, H. and Mas, J. (2018). Multilayer perceptron (mlp). *Geomatic approaches for modeling land change scenarios*, pages 451–455.