

Detecção de Abelhas Nativas em Colmeias em Campo Utilizando Visão Computacional

Rodolfo R. V. Leocádio¹, Alan K. R. Segundo¹, Jefferson R. Souza², Juliana Galaschi-Teixeira³, Paulo de Souza⁴, Gustavo Pessin^{1,5}

¹Programa de Pós-Graduação em Ciência da Computação
Universidade Federal de Ouro Preto (UFOP) – Ouro Preto, MG, Brasil

²Faculdade de Computação
Universidade Federal de Uberlândia (UFU) – Uberlândia, MG, Brasil

³Instituto Tecnológico Vale - Desenvolvimento Sustentável
Belém, PA, Brasil

⁴School of Information and Communication Technology
Griffith University – Gold Coast, Queensland 4222, Australia

⁵Instituto Tecnológico Vale – Mineração
Ouro Preto, MG, Brasil

{rodolfo.leocadio, alankardek}@ufop.edu.br, jrsouza@ufu.br,
{juliana.teixeira, gustavo.pessin}@itv.org,
paulo.desouza@griffith.edu.au

Abstract. *Artificial intelligence approaches can, like computer vision, help improve the understanding behavior of bee species. Accurate detection of bees in the field is challenging. We investigate the use of the detector YOLO in the task of species recognition; with benefits from its speed and generalization. YOLO detected most bees present in the frames, with an effectiveness mAP of 99.5%.*

Resumo. *Abordagens de inteligência artificial, como visão computacional, podem ajudar a entender melhor o comportamento de abelhas e ajudar no seu manejo. Detectar espécies de abelhas em campo é ainda um desafio para os métodos tradicionais. Neste trabalho, propõe-se o uso do detector YOLO justificado por sua capacidade, velocidade e generalização. Foi possível detectar a grande maioria das abelhas presentes nos frames, com mAP de 99,5% de eficácia.*

1. Introdução

Os insetos desempenham um papel fundamental na natureza incluindo polinização, herbivoria, detritivoria, ciclagem de nutrientes e fonte de alimento para outras espécies [Hallmann *et al.* 2017]. As abelhas nativas são polinizadores que se relacionam com variados alimentos vegetais consumidos pela humanidade [Arruda *et al.* 2018 (apud Klein *et al.* 2007)]. Polinizadores, particularmente insetos sociais como abelhas, desempenham um papel importante na agricultura mundial, pois melhoram a qualidade da colheita, e consequentemente, o rendimento financeiro das culturas [Kuan *et al.* 2018]. Além disso, elas contribuem ativamente na recuperação de ecossistemas degradados [Giannini *et al.*

2020], podem ser utilizadas em biovetorização, tecnologia que envolve o uso de insetos como agentes de biocontrole [Macharia *et al.* 2020] e também podem desempenhar um papel crucial em projetos e programas de desenvolvimento sustentável [Giannini *et al.* 2020]. Perdas de biodiversidade entre abelhas nativas têm sido documentadas para as regiões tropicais [Sánchez-bayo e WyckhuysBorges 2019] e [Borges *et al.* 2020]. Os principais fatores responsáveis por esse declínio incluem: infecções disseminadas por parasitas e patógenos; falta de variabilidade genética; estresse devido a movimentação sazonal de colmeias para polinização de frutas e hortaliças; resíduos de pesticidas tóxicos encontrados no pólen e néctar ou aplicado a colmeias para controlar ácaros; baixo valor nutricional de agropaisagens dominadas por monoculturas (como milho, soja e algodão); e condições climáticas mais adversas das últimas décadas [Hallmann *et al.* 2017], [Sánchez-bayo e WyckhuysBorges 2019], [Gomes *et al.* 2020], [Filipiak 2018] e [Marstaller *et al.* 2019].

O declínio dos insetos resulta em efeitos adversos em ecossistemas. Assim, preservar sua abundância e diversidade são de grande importância para ecologia [Hallmann *et al.* 2017]. Indivíduos com pouco conhecimento entomológico não são capazes de distinguir categorias de insetos, bem como seus estágios de maturidade e comportamento. Desta forma, é necessário desenvolver abordagens mais rápidas e eficazes para resolver esses problemas [Xia *et al.* 2018]. As questões que devem ser abordadas no processo de reconhecimento e classificação de insetos são: (i) detectar rapidamente o animal de interesse posicionado em um fundo complexo; (ii) distinguir com precisão adequada as espécies de insetos com alta similaridade entre as classes; e (iii) identificar efetivamente padrões de interesse do comportamento das classes. Ferramentas que fazem uso de inteligência artificial podem ter uma relação mutualista com os demais métodos aplicados em ecologia. O monitoramento de colmeias pode ajudar no combate ao declínio das abelhas, relacionadas ao forrageamento, características do pólen, comportamento da colmeia e espécies invasoras.

Para ajudar no monitoramento das colmeias, este trabalho faz uso de um detector de objetos, um modelo de *machine learning*, baseado em visão computacional para detectar abelhas da espécie *Melipona seminigra* (Figura 1). Estudos atuais sobre recursos utilizados pelo gênero *Melipona* se relacionam com a ecologia de plantas nativas da região Amazônica [Pimentel *et al.* 2020].



Figura 1. Abelha nativa da amazônia *Melipona seminigra* (Uruçu-boca-de-renda ou uruçu-preta) [Costa 2019].

Considerando a metodologia desenvolvida, neste trabalho de pesquisa admite-se a hipótese de que detectar e classificar essa espécie de abelha no campo é a tarefa inicial para implementação de um monitoramento de colmeias. A partir disso será possível implementar as demais fases (detecção de espécies invasoras, identificação do sentido dos movimentos das abelhas, contagem de insetos e identificação de pólen) que podem constituir um monitoramento inteligente das colmeias dessas espécies. A seguir são apresentados os trabalhos mais recentes relacionados a inteligência artificial auxiliando no manejo e conservação de insetos, bem como o método utilizado na detecção e classificação da *Melipona seminigra*. Os resultados obtidos são apresentados e discutidos, bem como trabalhos e perspectivas futuras.

2. Trabalhos relacionados

Alguns trabalhos desenvolvidos nos últimos três anos se destacam por tentar automatizar processos aplicados a Ciências Biológicas envolvendo a Classe *Insecta* do Filo *Arthropoda* (Reino *Animalia*). Técnicas de Inteligência Artificial (IA) utilizadas para identificar e contar insetos a partir de imagens podem resultar em uma alternativa para reduzir atividades manuais, e erros de origem humana [Júnior e Rieder 2020]. Nesse sentido, há uma tendência em utilizar abordagens de *deep learning* para o reconhecimento de insetos. Dentre elas, a técnica de detecção de objetos provou ser mais adequada e a abordagem Faster R-CNN tem sido mais utilizada para essa tarefa. Desta forma, tem sido possível identificar e contar insetos em plantas, folhas, fotografias, armadilhas e grãos [Júnior e Rieder 2020].

Outras abordagens como a combinação dos modelos VGG19 e *Region Proposal Network* (RPN) para reconhecimento e classificação de insetos no campo [Xia *et al.* 2018] também têm sido utilizadas. Estudos anteriores ainda incluem algumas outras espécies de insetos, como vespas e mariposas, classificadas com técnicas de *machine learning*.

Liu *et al.* (2019) desenvolveram um sistema chamado PestNet para detecção de pragas em campo. O monitoramento do número de espécies de pragas evita o uso indiscriminado de pesticidas que resultam em safras prejudiciais à saúde. A abordagem é satisfatória para a tarefa, porém seu melhor desempenho atingiu precisão de somente 75,46% *mean Average Precision* (mAP). O equipamento de aquisição é baseado em armadilha de luz multiespectral e uma câmera HD, projetado de forma que espécimes de pragas capturadas pela armadilha em uma bandeja sejam fotografadas periodicamente com posterior limpeza da bandeja. O PestNet consiste de três etapas: extração de características, pesquisa de regiões de interesse (RoI) e previsão das pragas. Para isso, é utilizado um *backbone* com *Convolutional Neural Network* (CNN) para extrair mapas de recursos e *Channel-Spatial Attention* (CSA) para aprimoramento dos recursos. Em seguida, RPN e *Position-Sensitive Score Map* (PSSM) para fornecer regiões de pragas e previsão de pragas, respectivamente. Durante a fase de predição, os RoIs contextuais são apresentados como informações contextuais para melhorar a precisão da detecção. *Non-Maxima Supression* (NMS) é adotado como técnica para eliminar sobreposição de caixas delimitadoras.

Algoritmos para detecção de objetos baseado no Faster R-CNN foram aplicados para identificar insetos em grãos armazenados misturados com finos (*finer*), materiais estranhos (*foreign materials*), impurezas (*dockages*) e grãos quebrados (*broken grains*); sob diferentes condições de iluminação [Shen *et al.* 2018]. Os procedimentos foram

realizados em laboratório. As etapas de detecção do objeto alvo foram: adquirir as regiões propostas na imagem pela RPN, obter caixas candidatas por NMS, mapear as caixas candidatas como mapas de características, classificar essas regiões e usar o NMS para evitar caixas candidatas sobrepostas.

Outra abordagem com grãos propõe monitorar pragas de arroz em tempo real com objetivo de realizar um manejo dessas pragas [Qing *et al.* 2020]. Cinco espécies no campo são identificadas e contadas, três grandes (8 a 15 mm) com 88,9% mAP e duas pequenas (3 a 5 mm) com 90,4% mAP. A metodologia de captura das pragas é similar a proposta por Liu *et al.* (2019), mas as imagens dos insetos são enviadas para um servidor na nuvem que intermedia a comunicação entre a armadilha e os dispositivos de controle. As imagens são pré-processadas: remoção de fundo, remoção de ruído e segmentação de insetos que se tocam. As regiões contendo uma praga alvo passam por um classificador CNN de insetos grandes (ResNet-152) ou por um classificador CNN de insetos pequenos (ResNet-18).

Concomitantemente, trabalhos envolvendo a Família *Apidae* da Ordem *Hymenoptera* também têm sido desenvolvidos. Para identificar espécies de abelhas com *machine learning* interpretando dados de forrageamento, Arruda *et al.* (2018) monitoraram abelhas com etiquetas RFID coladas em seu tórax. Os dados gerados pelos RFID são pré-processados em vetores de recursos. Três métodos de *machine learning* são empregados, mas somente o modelo *Random Forest* consegue atender ao objetivo, para diferentes configurações de vetores de recursos. Desta forma foi possível classificar duas espécies de abelhas amazônicas por meio de seu padrão de forrageamento. Nessa mesma linha de pesquisa, ocorreram investigações como uma forma de melhorar previsões da atividade das abelhas por meio de *Recurrent Neural Networks* (RNN), com abordagem relacionada ao comportamento das abelhas [Gomes *et al.* 2020]. Também utiliza etiquetas RFID coladas em abelhas em conjunto com dados de temperatura, pressão barométrica e irradiância solar. Para isso, definem uma arquitetura RNN que tem o melhor desempenho na previsão do comportamento das abelhas, mostram que diferentes tamanhos de entrada impactam na precisão da previsão e mostram como algoritmos para seleção de atributos e análise de correlação podem ajudar a melhorar a precisão da previsão.

Existem ainda sistemas com *deep learning* para monitoramento automatizado de colmeias de abelhas [Marstaller *et al.* 2019]. Neste caso, as abelhas são filmadas na entrada da colmeia. O processamento responsável por localizar e rastrear as abelhas são executados na borda. Amostras de abelhas individuais são transferidos para a nuvem, onde o processo de inferência sobre a saúde das abelhas é executado (*DeepBees*). Um módulo chamado de *Genus* distingue entre abelhas e vespas. Dessa forma, informações sobre ataques e invasões são coletados. O módulo *Pollen* detecta pólen nas abelhas, gerando e agregando medidas da nutrição na colmeia e identificando carências de comida. O módulo *Pose* prevê a localização de 32 pontos-chave no inseto, benéfico para identificar anomalias de comportamento e no monitoramento da saúde e higiene da colmeia. O módulo *Classification* pontua probabilidades para um total de quatro classes mutuamente exclusivas: abelhas operárias com pólen, sem pólen, zangões e abelhas mortas. Também é incluído um módulo *Decoder* para aprendizado estrutural. Contudo, ainda existem desafios na precisão da detecção de pólen, no mapeamento direto de atividades, doenças ou infestação de ácaros devido à falta de dados.

3. Metodologia

Detectar objetos é uma tarefa de visão computacional que lida com a detecção de instâncias de objetos semânticos de uma determinada classe em imagens e vídeos digitais. Alguns métodos podem ser utilizados para esta tarefa como: (i) *Deformable parts models* usam uma abordagem com janelas deslizantes para detecção de objetos; (ii) R-CNN e suas variantes usam propostas de região, como a Busca Seletiva, para encontrar objetos nas imagens; (iii) *Deep MultiBox* treina uma CNN para prever RoI; (iv) *OverFeat* requer pós-processamento significativo para produzir detecções coerentes; (v) *MultiGrasp* prevê uma única região na imagem contendo um objeto; e (vi) YOLO (*You Only Look Once*) unifica os componentes de detecção de objetos em uma única rede neural [Redmon *et al.* 2015].

Este trabalho utiliza o detector de código aberto YOLO devido a sua velocidade de detecção ser consideravelmente rápida, por analisar globalmente a imagem ao fazer previsões e por aprender representações generalizáveis dos objetos. Isso somente é possível devido a detecção de quadros ser tratado como um problema de regressão, não precisando de um pipeline complexo [Redmon *et al.* 2015].

A versão 4 do YOLO [Bochkovskiy *et al.* 2020] recebe as imagens com formato de (320,320,3) a (608,608,3) [Redmon e Farhadi 2016] em sua entrada. O *Backbone* utiliza a CNN CSPDarknet53 como extrator de características. *Spatial Pyramid Pooling* (SPP) e *Path Aggregation Network* (PAN) compõem o *Neck*. O bloco SPP sobre o CSPDarknet53 aumenta significativamente o campo receptivo e separa as características de contexto mais significativas, sem causar redução significativa da velocidade. Já o PAN é o método de segmentação e agregação de parâmetros do *backbone* para diferentes níveis do detector. A *Head* é composta pela versão 3 do YOLO [Redmon e Farhadi 2018], baseado em âncoras [Redmon e Farhadi 2016], que utiliza classificadores logísticos independentes ao invés do *softmax*. Este conjunto compõem a arquitetura YOLO.

Uma imagem pré-processada contendo o objeto, como o exemplo da Figura 2a, entra na rede neural convolucional representada na Figura 2b, que por sua vez divide a imagem em um grid de 19x19 células (Figura 2c). Cada uma dessas células é responsável por fazer a predição de 5 caixas delimitadoras, detalhadas na Figura 2d, caso haja mais de um objeto naquela célula.

Cada caixa delimitadora (Figura 2d) pode ser descrita com uma pontuação de confiança (pc), que indica a probabilidade de existir um objeto naquela caixa delimitadora; centro (bx, by), largura (bw) e altura (bh) da caixa delimitadora e; classe (c), um valor de probabilidade para cada uma das classes possíveis do objeto. pc e c são combinados em uma pontuação final para gerar as caixas delimitadoras que contém o objeto detectado, como exemplificado na Figura 2e. NMS é aplicada para remover caixas com baixa probabilidade de conter um objeto e também caixas que possuem uma área compartilhada, restando somente uma caixa delimitadora contendo o objeto identificado (Figura 2f).

O pré-processamento das imagens é feito utilizando a biblioteca OpenCV¹ no Python². As imagens são normalizadas com padrão de dados *float* 32, redimensionadas para o tamanho (416x416) preservando sua proporção, convertidas para o padrão RGB e

¹ <https://opencv.org/>

² <https://www.python.org/>

transformadas em um vetor com 4 dimensões com a forma (Lotes, Canais, Largura, Altura), compatível com a entrada do YOLO.

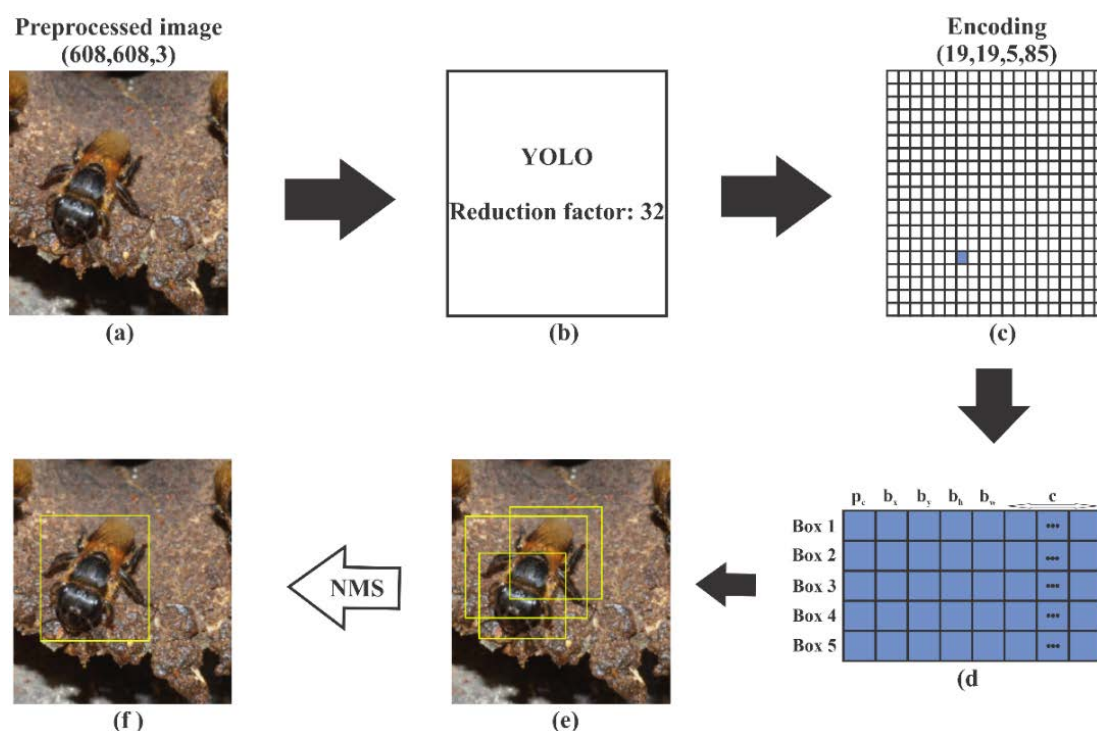


Figura 2. Método de previsão de abelhas em imagens.

Vídeos de colmeias da espécie em questão foram gravados no campo com dispositivos móveis, com tamanho de 1280x720 em condições adequadas de iluminação. Os vídeos apresentam a movimentação na entrada da colmeia, ocasionando em diferentes poses e inúmeras situações em que desejam-se identificar as abelhas. Para cada *frame* contendo uma pose ainda não marcada, utilizou-se o LabelImg³ (software livre) para gerar anotações desses *frames*. As anotações contêm um número correspondente à classe do objeto seguido das coordenadas das caixas delimitadoras contendo abelhas. O *Dataset* para o treinamento foi composto com 459 imagens, sendo 368 imagens para treinamento e 91 imagens para validação.

O treinamento pode ser realizado com o YOLO, caso deseje uma melhor precisão na detecção ou com o YOLO-Tiny (utilizado neste trabalho), caso deseje maior velocidade de detecção. Lotes de 64 imagens são gerados para cada época de treinamento. Foram utilizadas 2000 épocas para treinamento do modelo que identifica somente uma classe “Abelhas”. O treinamento é realizado no Google Colaboratory⁴, um serviço gratuito na nuvem voltado a pesquisas de *machine learning* e Inteligência Artificial. A disponibilização de GPU foi a principal justificativa na utilização do Colaboratory. Pesos pré-treinados no conjunto de dados COCO [Redmon e Farhadi 2016] foram utilizados para inicializar a rede.

As métricas utilizadas para avaliar o modelo são: *Loss* – Quanto menor, melhor a acurácia do modelo; *Average Precision (AP)* – Acurácia do detector para cada classe; *mean Average Precision (mAP)* – Média do AP; *Precision* – Informa o quanto o modelo

³ <https://github.com/tzutalin/labelImg>

⁴ <https://colab.research.google.com>

está certo quando realizou previsões; *Recall* – Informa o quanto o modelo classificou corretamente; e *Interseccion over Union* (IoU) – Avalia o desempenho do detector, ou seja, se ele encontrou a classe e a localização do objeto (caixas delimitadoras).

O IoU foi predefinido para um limite de 0,5 ao classificar a previsão. Se $\text{IoU} \geq 0,5$, classifica-se a detecção do objeto como *True Positive* (TP). Um TP ocorre quando o detector prevê as classes corretamente. Já $\text{IoU} < 0,5$ indica uma detecção errada, logo, classifica-se como *False Positive* (FP). Um FP é classificado como erro do detector e ocorre quando o classificador erra a previsão. Um *True Negative* (TN) ocorre quando o detector prevê que não há objeto de interesse na região em questão e realmente não há. E *False Negative* (FN), também classificado como erro do detector, ocorre quando o classificador prevê que não há objeto de interesse na região em questão, porém, há.

4. Resultados e discussão

O resumo do processo de treinamento do detector pode ser visualizado na Figura 3. Trata-se de um gráfico de *Loss* em função das épocas do treinamento. A partir do gráfico, foi obtido um valor para *Loss* de 0,1966 e mAP de 99,5%. Vale ressaltar que, neste caso, AP é igual a mAP, pois foi treinado o modelo com só uma classe. Para um *dataset* pequeno que contém poucas classes, o valor final de *Loss* pode cair até a segunda casa decimal após a virgula. As abelhas observadas no campo exibem inúmeras poses que devem ser consideradas durante o treinamento, portanto, a *Loss* obtida está entre os valores aceitáveis para a aplicação. A acurácia do detector para a classe *Melipona seminigra* (Figura 1) apresentou resultados que surpreenderam os autores, porém deve ser monitorado minuciosamente com a adição de novas classes.

O valor de IoU é 81,81%, ou seja, o detector foi capaz de localizar as abelhas. As caixas delimitadoras traçadas enquadram as *Melipona seminigra* de forma que possam ser identificadas. O modelo está correto em 98% (*Precision*) das vezes que realizou as detecções e em 99% (*Recall*) das vezes que classificou. Isso indica que ocorrem alguns erros durante as detecções e que ocorrem erros mínimos na classificação das detecções. O detalhe das observações é apresentado na Tabela 1.

Tabela 1. Matriz de confusão do treinamento do modelo.

YOLO	<i>Com abelha</i>	<i>Sem abelha</i>
<i>Com abelha</i>	431 (TP)	9 (FP)
<i>Sem abelha</i>	4 (FN)	473 (TN)

A matriz de confusão indica que o sistema acerta a grande maioria das abelhas presentes nos *frames*. Os resultados exibiram métricas relativamente altas, sugerindo que os erros ocorridos são pouco significativos. Também foi possível notar que a principal fonte de erro são as localizações incorretas detectadas, seguindo o mesmo padrão descrito em Redmon *et al.* (2015).

O maior desafio nesse tipo de implementação é conseguir condições e dados provenientes das espécies que se deseja detectar e classificar em campo para compor o *dataset* de treinamento. Intempéries comuns em ambientes naturais dificultam a utilização e manutenção do hardware. Para diversificar os dados para o treinamento são necessárias prolongadas horas de gravação na colmeia, e posterior mineração desses dados com o objetivo de reconhecer ataques e inúmeras poses diferentes com e sem pólen.




Figura 3. Loss e mAp do treinamento do detector de abelhas em campo.

O próximo passo é desenvolver um trabalho de monitoramento completo de colmeias de *Melipona seminigra*, semelhante ao que foi feito por Marstaller *et al.* (2019). O monitoramento deve englobar detecção de espécies invasoras nativas da Amazônia como outras espécies de abelhas, formigas, aranhas, vespas, dentre outros como forídeos. Deve-se identificar o sentido dos movimentos das abelhas, entrada e saída da colmeia, e realizar a contagem das mesmas, com o objetivo de facilitar trabalhos semelhantes a Arruda *et al.* (2018), de Souza *et al.* (2018) e Gomes *et al.* (2020). Por fim, pretende-se também identificar o pólen, para agregar monitoramento da nutrição e carências de alimentos na colmeia.

Agradecimentos

Os autores agradecem a Luciano Costa (ITV-DS), Helder Arruda (Unisinos) e Vera Lúcia Imperatriz-Fonseca (USP) por diversas e frutíferas discussões e também pelo apoio na obtenção dos dados ambientais. Os autores agradecem a Renato Hidaka (UFPA) pelo apoio com os métodos computacionais. Esta pesquisa recebeu apoio financeiro da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) - Código de financiamento 001.

Referências

- Arruda, H., Imperatriz-fonseca, V., De Souza, P. e Pessin, G. (2018) “Identifying Bee Species by Means of the Foraging Pattern Using Machine Learning”, in *2018 International Joint Conference on Neural Networks (IJCNN)*, p. 1-6.
- Bochkovskiy, A., Wang, C. e Liao, H. M. (2020) “YOLOv4: Optimal Speed and Accuracy of Object Detection”, Cornell Univ., no. April. arXiv:2004.10934v1
- Borges, R. C., Padovani, K., Imperatriz-Fonseca, V. L. e Giannini, T. C. (2020) “A dataset of multi-functional ecological traits of Brazilian bees”, *Sci. Data*, vol. 7, p. 1-9. doi: <https://doi.org/10.1038/s41597-020-0461-3>
- Costa, L. (2019) *Guia Fotográfico de Identificação de Abelhas Sem Ferrão, para resgate em áreas de supressão florestal*. Belém: Brasil.
- de Souza, P., Marendy, P., Barbosa, K., Budi, S., Hirsch, P., Nikolic, N., Gunthorpe, T. Pessin, G., Davie, A. (2018) “Low-Cost Electronic Tagging System for Bee Monitoring”, *Sensors* vol.18 2124. doi: 10.3390/s18072124
- Filipiak, M. (2018) “A Better Understanding of Bee Nutritional Ecology Is Needed to Optimize Conservation Strategies for Wild Bees - The Application of Ecological Stoichiometry”, *Insects*, vol. 9, no. July, p. 1-13. doi: 10.3390/insects9030085
- Giannini, T. C., Costa, W. F., Borges, R. C., Miranda L., Costa, C. P. W., Saraiva, A. M. e Fonseca, V. L. I. (2020) “Climate change in the Eastern Amazon: crop-pollinator and occurrence-restricted bees are potentially more affected”, *Reg. Environ. Chang.*, vol. 20, p. 1-12. doi: <https://doi.org/10.1007/s10113-020-01611-y>
- Gomes, P. A. B., Suhara, Y., Nunes-Silva, P., Costa, L., Arruda, H., Venturieri, G., Imperatriz-Fonseca, V. L., Pentland, A., Souza, P. e Pessin, G. (2020) “An Amazon stingless bee foraging activity predicted using recurrent artificial neural networks and attribute selection”, *Nature research*, vol. 10, pp. 1-12. doi: <https://doi.org/10.1038/s41598-019-56352-8>
- Hallmann, C. A., Sorg, M., Jongejans, E., Siepel, H., Hofland, N., Schwan, H., Stenmans, W., Müller, A., Sumser, H., Hörren, T., Goulson, D. e de Kroon, H. (2017) “More than 75 percent decline over 27 years in total flying insect biomass in protected areas”, *PLoS One*, vol. 12, no. October, p. 18-22. doi: <https://doi.org/10.1371/journal.pone.0185809>
- Júnior, T. D. C. and Rieder, R. (2020) “Automatic identification of insects from digital images: A survey”, *Comput. Electron. Agric.*, vol. 178, no. April, p. 105784. doi: <https://doi.org/10.1016/j.compag.2020.105784>
- Kuan, A. C., Grandi-Hoffman, G., Curry, R. J., Garber, K. V., Kanarek, A. R., Snyder, M. N., Wolfe, K. L. e Purucker, S. T. (2018) “Sensitivity analyses for simulating pesticide impacts on honey bee colonies”, *Ecol. Modell.*, vol. 376, no. February, p. 15-27. doi: <https://doi.org/10.1016/j.ecolmodel.2018.02.010>
- Liu, L., Wang, R., Xie, C., Yang, P., Wang, F., Surdiman, S. e Liu, W. (2019) “PestNet: An End-to-End Deep Learning Approach for Large-Scale Multi-Class Pest Detection and Classification”, *IEEE Access*, vol. 7, p. 45301-45312. doi: 10.1109/ACCESS.2019.2909522

- Macharia, J. M., Gikungu, M. W., Karanja, R. e Okoth, S. (2020) “Managed bees as pollinators and vectors of bio control agent against grey mold disease in strawberry plantations”, *African J. Agric. Res.*, vol. 16, no. 12, p. 1674-1680. doi: 10.5897/AJAR2020.15203
- Marstaller, J., Tausch, F. e Stock, S. C. (2019) “DeepBees - Building and Scaling Convolutional Neuronal Nets For Fast and Large-Scale Visual Monitoring of Bee Hives”, in *ICCV Workshop*, October. doi: 10.1109/ICCVW.2019.00036
- Pimentel, A. D. A., Absy, M. L., Rech, A. R. e de Abreu, V. H. R. (2020) “Pollen sources used by Frieseomelitta Ihering 1912 (Hymenoptera: Apidae: Meliponini) bees along the course of the Rio Negro, Amazonas, Brazil”, *Acta Bot. Brasilica*, vol. 34, no. June, p. 371-383. doi: 10.1590/0102-33062019abb0391
- Qing, Y., Jin, F., Jian, T., Wei-gen, X., Xu-hua, Z., Bao-jun, Y., Jun, L., Yi-ze, X., Bo1, Y., Shu-zhen, W., Nai-yang, K. e Li-jun, W. (2020) “Development of an automatic monitoring system for rice light-trap pests based on machine vision”, *J. Integr. Agric.*, vol. 19, no. February, p. 2500-2513. doi: 10.1016/S2095-3119(20)63168-9
- Redmon, J. e Farhadi, A. (2016) “YOLO9000: Better, Faster, Stronger”, Cornell Univ., no. December. arXiv:1612.08242v1
- Redmon, J. e Farhadi, A. (2018) “YOLOv3: An Incremental Improvement”, Cornell Univ., no. April. arXiv:1804.02767v1
- Redmon, J., Divvala, S., Girshick, R. and Farhadi, A. (2015) “You Only Look Once: Unified, Real-Time Object Detection”, Cornell Univ., no. May. arXiv:1506.02640v5
- Sánchez-bayo, F. e Wyckhuys, K. A. G. (2019) “Worldwide decline of the entomofauna: A review of its drivers”, *Biol. Conserv.*, vol. 232, no. September, p. 8-27. doi: <https://doi.org/10.1016/j.biocon.2019.01.020>
- Shen, Y., Zhou, H., Li, J., Jian, F. e Jayas, D. S. (2018) “Detection of stored-grain insects using deep learning”, *Comput. Electron. Agric.*, vol. 145, no. October, p. 319-325. doi: <https://doi.org/10.1016/j.compag.2017.11.039>
- Xia, D., Chen, P., Wang, B., Zhang, J. e Xie, C. (2018) “Insect Detection and Classification Based on an Improved Convolutional Neural Network”, *Sensors*, vol. 18, no. November, p. 1-12. doi: 10.3390/s18124169