



BACHAREL EM CIÊNCIA DA COMPUTAÇÃO

**CLASSIFICAÇÃO DE ESPÉCIES DE ABELHAS NATIVAS SEM
FERRÃO UTILIZANDO REDES NEURASIS CONVOLUCIONAIS**

WÉSIO PASCOAL MESSIAS COELHO

Rio Verde, GO

2023



INSTITUTO FEDERAL GOIANO - CAMPUS RIO VERDE
BACHAREL EM CIÊNCIA DA COMPUTAÇÃO

**CLASSIFICAÇÃO DE ESPÉCIES DE ABELHAS NATIVAS SEM
FERRÃO UTILIZANDO REDES NEURAIIS CONVOLUCIONAIS**

WÉSIO PASCOAL MESSIAS COELHO

Trabalho de Conclusão de Curso apresentado ao Instituto Federal Goiano - Campus Rio Verde, como requisito parcial para a obtenção do Grau de Bacharel em Ciência da Computação.

Orientadora: Prof. Dra. Heyde Francielle do Carmo França

Rio Verde, GO

Março, 2023

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO PARA DISPONIBILIZAR PRODUÇÕES TÉCNICO-CIENTÍFICAS NO REPOSITÓRIO INSTITUCIONAL DO IF GOIANO

Com base no disposto na Lei Federal nº 9.610, de 19 de fevereiro de 1998, AUTORIZO o Instituto Federal de Educação, Ciência e Tecnologia Goiano a disponibilizar gratuitamente o documento em formato digital no Repositório Institucional do IF Goiano (RIIF Goiano), sem ressarcimento de direitos autorais, conforme permissão assinada abaixo, para fins de leitura, download e impressão, a título de divulgação da produção técnico-científica no IF Goiano.

IDENTIFICAÇÃO DA PRODUÇÃO TÉCNICO-CIENTÍFICA

- | | |
|--|---|
| <input type="checkbox"/> Tese (doutorado) | <input type="checkbox"/> Artigo científico |
| <input type="checkbox"/> Dissertação (mestrado) | <input type="checkbox"/> Capítulo de livro |
| <input type="checkbox"/> Monografia (especialização) | <input type="checkbox"/> Livro |
| <input checked="" type="checkbox"/> TCC (graduação) | <input type="checkbox"/> Trabalho apresentado em evento |

Produto técnico e educacional - Tipo:

Nome completo do autor:

Wésio Pascoal Messias Coelho

Matrícula:

2020102201940083

Título do trabalho:

Classificação de espécies de abelhas nativas sem ferrão utilizando redes neurais convolucionais

RESTRIÇÕES DE ACESSO AO DOCUMENTO

Documento confidencial: Não Sim, justifique:

Informe a data que poderá ser disponibilizado no RIIF Goiano: 05 /02 /2025

O documento está sujeito a registro de patente? Sim Não

O documento pode vir a ser publicado como livro? Sim Não

DECLARAÇÃO DE DISTRIBUIÇÃO NÃO-EXCLUSIVA

O(a) referido(a) autor(a) declara:

- Que o documento é seu trabalho original, detém os direitos autorais da produção técnico-científica e não infringe os direitos de qualquer outra pessoa ou entidade;
- Que obteve autorização de quaisquer materiais inclusos no documento do qual não detém os direitos de autoria, para conceder ao Instituto Federal de Educação, Ciência e Tecnologia Goiano os direitos requeridos e que este material cujos direitos autorais são de terceiros, estão claramente identificados e reconhecidos no texto ou conteúdo do documento entregue;
- Que cumpriu quaisquer obrigações exigidas por contrato ou acordo, caso o documento entregue seja baseado em trabalho financiado ou apoiado por outra instituição que não o Instituto Federal de Educação, Ciência e Tecnologia Goiano.

Documento assinado digitalmente
 **WESIO PASCOAL MESSIAS COELHO**
Data: 05/02/2025 10:28:11-0300
Verifique em <https://validar.iti.gov.br>

RioVerde

Local

05 /02 /2025

Data

Assina



Documento assinado digitalmente

HEYDE FRANCIELLE DO CARMO FRANCA

Data: 06/02/2025 11:52:31-0300

Verifique em <https://validar.iti.gov.br>

s autorais

Ciente e de acordo:

Assinatura do(a) orientador(a)



SERVIÇO PÚBLICO FEDERAL
MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA GOIANO

Ata nº 1/2025 - GEPTNM-RV/DE-RV/CMPRV/IFGOIANO

ATA DE DEFESA DE TRABALHO DE CURSO

Ao(s) **23** dia(s) do mês de janeiro de 2025, às 14 horas e 00 minutos, reuniu-se a banca examinadora composta pelos docentes: Heyde Francielle do Carmo (orientadora), Fábio Montanha Ramos(membro), Adriano Carvalho Costa(membro), para examinar o Trabalho de Curso intitulado “Classificação de espécies de abelhas I utilizando redes neurais convolucionais” do(a) estudante Wésio Pascoal Messias Coelho, Matrícula nº 2020102201940083 do Curso de Bacharelado em Ciência da Computação do IF Goiano – Campus Rio Verde. A palavra foi concedida ao(a) estudante para a apresentação oral do TC, houve arguição do(a) candidato pelos membros da banca examinadora. Após tal etapa, a banca examinadora decidiu pela APROVAÇÃO do(a) estudante. Ao final da sessão pública de defesa foi lavrada a presente ata que segue assinada pelos membros da Banca Examinadora.

(Assinado Eletronicamente)

Heyde Francielle do Carmo

Orientador(a)

(Assinado Eletronicamente)

Fábio Montanha Ramos

Membro

(Assinado Eletronicamente)

Adriano Carvalho Costa

Membro

Observação:

() O(a) estudante não compareceu à defesa do TC.

Documento assinado eletronicamente por:

- **Heyde Francielle do Carmo Franca**, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 23/01/2025 15:20:30.
- **Adriano Carvalho Costa**, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 23/01/2025 15:26:33.
- **Fabio Montanha Ramos**, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 23/01/2025 15:27:29.

Este documento foi emitido pelo SUAP em 23/01/2025. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifgoiano.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código Verificador: 668927

Código de Autenticação: 1ad0ef4835



INSTITUTO FEDERAL GOIANO

Campus Rio Verde

Rodovia Sul Goiana, Km 01, Zona Rural, 01, Zona Rural, RIO VERDE / GO, CEP 75901-970

(64) 3624-1000

Dedico este trabalho, em primeiro lugar, aos meus pais, por todo o apoio, incentivo e amor incondicional ao longo de toda a minha jornada acadêmica. Vocês sempre acreditaram em mim, mesmo nos momentos mais difíceis, e isso foi fundamental para que eu chegasse até aqui.

Aos meus amigos, que assim como eu, se dedicaram para finalizar este curso. A nossa parceria e apoio mútuo foram essenciais durante essa caminhada. Dedico também àqueles que, por algum motivo, desistiram ao longo do percurso, mas que fizeram parte dessa história e deixaram suas marcas.

E, de maneira especial, dedico este trabalho à minha querida avó, Luiza Araújo Coelho, que sempre sonhou comigo desde o início deste curso e me admirava pela minha capacidade e inteligência. Mesmo com sua partida neste ano, ano de apresentação do meu TCC, sua presença, amor e orgulho continuam vivos em mim. Este trabalho é para você, vó, com todo o meu amor e saudade.

AGRADECIMENTOS

Gostaria de expressar minha sincera gratidão à Prof. Dra. Heyde Francielle do Carmo França pela orientação e suporte inestimáveis ao longo deste trabalho. Sua paciência, conhecimento e dedicação foram essenciais para o desenvolvimento deste projeto.

Agradeço também à Elzi Leida do Carmo França pela parceria e colaboração durante as pesquisas, que foram fundamentais para a evolução deste estudo.

Uma menção especial à Geni Alexandria de Moraes, que contribuiu de forma inestimável fornecendo uma ampla base de imagens de abelhas, o que facilitou a montagem da base de dados. Sua ajuda foi de grande importância para o andamento deste trabalho. Infelizmente, Geni faleceu durante este o desenvolvimento deste trabalho de conclusão, mas seu apoio e dedicação continuam presentes em cada passo desta jornada. Este trabalho também é uma homenagem ao seu esforço e paixão pela ciência.

A todos os meus familiares e amigos, meu mais profundo agradecimento pelo apoio neste processo de pesquisa e aprendizagem.

RESUMO

COELHO, Wésio. **Classificação de espécies de abelhas nativas sem ferrão utilizando redes neurais convolucionais**. Março, 2023. 21 f. Monografia – (Curso de Bacharel em Ciência da Computação), Instituto Federal Goiano - Campus Rio Verde. Rio Verde, GO.

RESUMO DO TRABALHO

As abelhas são fundamentais para a polinização na agricultura e, conseqüentemente, para a produção de alimentos. No entanto, a identificação manual dessas espécies pode ser imprecisa e causar estresse aos insetos, tornando essencial o desenvolvimento de métodos automatizados para essa tarefa. Este estudo tem como objetivo utilizar Redes Neurais Convolucionais (CNNs) para reconhecer e classificar espécies de abelhas de forma rápida e precisa, eliminando a necessidade de identificação manual. Para isso, foi construída uma base de dados balanceada na plataforma Roboflow, dividida em cinco classes, cada uma representando uma espécie de abelha. O modelo de CNN foi treinado utilizando esse conjunto de dados, permitindo que a aplicação identificasse as espécies a partir de imagens enviadas pelos usuários. Após o treinamento, a CNN apresentou uma precisão de 79% com uma base de dados relativamente pequena, demonstrando um desempenho promissor e superando métodos convencionais imprecisos e desgastantes. Os resultados obtidos indicam que a CNN pode substituir os métodos manuais de identificação e classificação de abelhas, oferecendo um processo mais eficiente e confiável. Esse avanço pode contribuir para a preservação dos polinizadores e para a sustentabilidade na produção agrícola.

Palavras-chave: Inteligência Artificial, Rede Neural Convolucional, abelhas, Classificação de Imagens.

ABSTRACT

COELHO, Wésio. Classification of native stingless bee species using convolutional neural networks. Março, 2023. 21 f. Trabalho de Conclusão de Curso – Bacharel em Ciência da Computação, Instituto Federal Goiano - Campus Rio Verde. Rio Verde, GO, Março, 2023.

Bees are essential for pollination in agriculture and, consequently, for food production. However, manual identification of these species can be inaccurate and cause stress to the insects, making it essential to develop automated methods for this task. This study aims to use Convolutional Neural Networks (CNNs) to recognize and classify bee species quickly and accurately, eliminating the need for manual identification. To this end, a balanced database was built on the Roboflow platform, divided into five classes, each representing a bee species. The CNN model was trained using this dataset, allowing the application to identify the species from images submitted by users. After training, the CNN presented an accuracy of 79% with a relatively small dataset, demonstrating promising performance and outperforming conventional methods that are inaccurate and time-consuming. The results obtained indicate that the CNN can replace manual methods of bee identification and classification, offering a more efficient and reliable process. This advance can contribute to the preservation of pollinators and sustainability in agricultural production.

Keywords: Artificial Intelligence, Convolutional Neural Network, bees, Image Classification.

SUMÁRIO

1 – INTRODUÇÃO	1
2 – REVISÃO DE LITERATURA	3
2.1 Inteligência Artificial	3
2.2 Redes Neurais	3
2.3 Deep Learning	4
2.4 Redes Neurais Convolucionais	4
2.5 Uso da IA na agricultura	5
3 – TRABALHOS RELACIONADOS	6
4 – MATERIAL E MÉTODOS	8
5 – RESULTADOS E DISCUSSÕES	12
Referências	20

1 INTRODUÇÃO

As abelhas desempenham um papel vital na polinização, essencial para a produção de alimentos e o equilíbrio ecológico. Elas são responsáveis por melhorar a qualidade e quantidade de frutos e sementes, sendo fundamentais para qualquer tipo de cultivo agrícola (BERINGER; MACIEL; TRAMONTINA, 2019).

Nos últimos anos, tem-se observado um preocupante declínio populacional das abelhas. A ausência desses polinizadores impacta negativamente a produção de alimentos e pode levar a uma série de consequências ecológicas e econômicas, incluindo a extinção de plantas e animais e mudanças nas funções dos ecossistemas. Dado a importância das abelhas para a manutenção da vida e sustentabilidade do planeta, é importante desenvolver ações de conservação e manejo sustentável para preservar esses polinizadores (BERINGER; MACIEL; TRAMONTINA, 2019).

A classificação das espécies de abelhas é crucial para a compreensão do papel da biodiversidade nos serviços ecossistêmicos, particularmente na polinização das culturas. Ajuda a identificar a dominância funcional e a renovação de espécies, garantindo níveis adequados de polinização em diversas escalas espaciais, o que é essencial para a produtividade agrícola (WINFREE et al., 2018).

Identificar espécies de abelhas manualmente é um processo complexo e sujeito a erros devido a vários fatores. A variabilidade morfológica dentro da mesma espécie pode levar a equívocos, já que diferenças em idade, sexo ou condições ambientais influenciam na aparência. Além disso, a semelhança entre espécies relacionadas torna difícil distinguir entre elas sem um alto nível de especialização, o que resulta em erros para observadores menos experientes. A falta de chaves de classificação abrangentes e a necessidade de taxonomistas treinados dificultam ainda mais o processo. Esse trabalho manual é demorado e intensivo, agravado pela escassez de especialistas qualificados, refletindo o "impedimento taxonômico", que afeta a identificação de espécies de forma eficiente (SANTANA et al., 2014).

Nesse cenário, em que as limitações da identificação manual de abelhas existem, a aplicação de tecnologias avançadas como inteligência artificial (IA) e redes neurais convolucionais - *convolutional neural networks* (CNNs) se mostra promissora. A utilização de redes neurais convolucionais surge como uma solução eficiente e precisa para a classificação das espécies de abelhas e insetos em geral. Essa abordagem baseada em inteligência artificial permite que qualquer pessoa identifique a espécie apenas de uma imagem, de forma rápida e precisa. Portanto, "as redes neurais convolucionais se distinguem de outras redes neurais por seu desempenho superior com entradas de imagem, fala ou sinal de áudio" atendendo às limitações da identificação manual (IBM, 2023).

Portanto, ao aplicar redes neurais convolucionais para a identificação e classificação de espécies de abelhas, espera-se contribuir para a redução do estresse desses importantes polinizadores, além de facilitar e agilizar a identificação para pesquisadores e apicultores com um classificador rápido, preciso e assertivo.

Para alcançar o objetivo de treinar uma CNN capaz de identificar e classificar espécies de abelhas nativas e sem ferrão, o restante deste trabalho foi organizado em mais quatro capítulos. O próximo capítulo é a Revisão de Literatura, onde são detalhados os

principais conceitos utilizados. Em seguida, no capítulo de Trabalhos Relacionados, são discutidas pesquisas semelhantes, com destaque para seus resultados, vantagens e limitações. O quarto capítulo descreve as metodologias e técnicas aplicadas para extração de imagens das bases de dados públicas, na criação da base de dados, incluindo a catalogação e a classificação das imagens por espécie, treinamento e avaliação da rede neural escolhida. Finalmente, os resultados são apresentados e discutidos no último capítulo, com análise baseada em métricas de avaliação, como precisão, recall e F1score.

2 REVISÃO DE LITERATURA

2.1 Inteligência Artificial

A Inteligência Artificial (IA) é um campo recente na área da computação, com seus primeiros indícios surgindo logo após a Segunda Guerra Mundial, e o próprio termo sendo cunhado em 1956. Atualmente, a IA abrange uma vasta gama de campos, desde atividades gerais até atividades muito específicas, sendo relevante para qualquer atividade de cunho intelectual, o que a torna um campo universal (RUSSELL; NORVIG, 2013).

Para este trabalho, a IA é utilizada para executar funções que exigem inteligência e técnica quando realizadas por seres humanos (KURZWEIL, 1990). Em essência, a IA é a capacidade de uma máquina, por meio de métodos computacionais e algoritmos, de realizar atividades cognitivas semelhantes as de um ser humano. Dessa forma, um computador pode executar tarefas que anteriormente eram exclusivas do homem (SILVA; MAIRINK, 2019).

2.2 Redes Neurais

Segundo o engenheiro elétrico e professor da *McMaster University*, HAYKIN uma rede neural é um processador maciço e paralelamente distribuído construído de unidades de processamento simples, que têm como princípio a capacidade de armazenar conhecimento experimental e torná-lo disponível para uso. A rede neural se assemelha ao cérebro em dois aspectos: O seu conhecimento é adquirido através de um processo de aprendizagem, e suas forças de conexão entre neurônios, os pesos sinápticos, armazenam o conhecimento aprendido.

As redes neurais podem possuir múltiplas camadas para o processamento de dados, como demonstrado na figura 1.

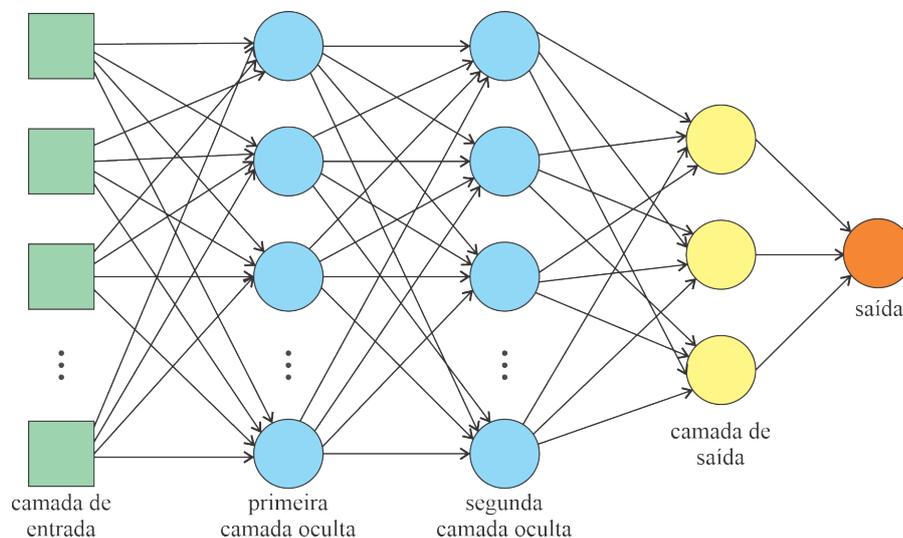


Figura 1 – Multicamadas de uma rede neural. Fonte: adaptado de (FLECK et al., 2016)

1. Camada de Entrada: Recebe as informações iniciais e as distribui para as camadas ocultas.
2. Camadas Ocultas: Localizadas entre a entrada e a saída, são responsáveis por processar e transformar as informações. Cada neurônio em uma camada está conectado apenas aos neurônios da camada seguinte, sem realimentação.
3. Camada de Saída: Produz a solução do problema, com o número de neurônios correspondendo ao número de saídas desejadas.

A rede neural multicamada tem suas camadas alinhadas de neurônios, sendo elas totalmente conectadas, permitindo que a camada de entrada distribua os dados para uma ou várias camadas ocultas e o resultado deste processamento é obtido na camada de saída (FLECK et al., 2016).

2.3 Deep Learning

O Aprendizado Profundo de máquina (*Deep Learning*) motivou a pesquisa em redes neurais já nos anos 2000, ao inserir elementos que tornaram o treinamento de redes profundas mais simples. O surgimento das GPUs e a disponibilidade de grandes conjuntos de dados foram os principais responsáveis pelo avanço do *Deep Learning* (DL), também não pode ser dispensado os de software flexíveis e de código aberto que foram desenvolvidos na época, como o Theano, Torch, Caffe, TensorFlow e PyTorch. Todas essas novidades facilitaram para o treinamento das redes neurais (BENGIO; LECUN; HINTON, 2021).

Pesquisas destacam que o *Deep Learning* é bastante eficiente e utilizado em vários campos, inclusive na medicina, permitindo a extração automatizada de características relevantes presentes em imagens de pacientes, aumentando a precisão na classificação de lesões, acelerando o processo de análise do caso e aumentando a confiabilidade dos diagnósticos. A capacidade do DL de processar imagens e realizar previsões com ótima precisão faz do *Deep Learning* uma ferramenta poderosa em qualquer aplicação, incluindo a identificação de abelhas, que é um dos objetivos deste trabalho (CASTIGLIONI et al., 2021).

2.4 Redes Neurais Convolucionais

Uma Rede Neural Convolucional (ou *Convolutional Neural Network* - CNN) é uma adaptação das redes de Perceptrons de Múltiplas Camadas, que foi baseado no método biológico de processamento de dados visuais. A CNN é capaz de fazer filtragem de dados visuais, conservando a relação entre os *pixels* vizinhos de uma imagem que está sendo usada durante o longo processo de treinamento da rede (VARGAS; PAES; VASCONCELOS, 2016).

Uma CNN é formada por múltiplas camadas com métodos funcionais diferentes. Uma camada de convolução é formada por vários neurônios, cada um é responsável por aplicar um filtro em uma parte específica da imagem. Os neurônios atribuem um peso a cada conjunto de *pixel* que ele se conecta. Por fim, os neurônios produzem uma saída para a próxima camada (VARGAS; PAES; VASCONCELOS, 2016).

2.5 Uso da IA na agricultura

O uso de Inteligência Artificial (IA) vem se mostrando bastante promissor na produção agrícola. Temos como exemplo máquinas autônomas, como tratores e colheitadeiras, que são capazes de oferecer operações mais precisas ao serem equipadas com IA, podendo ainda ter funcionalidade de 24 horas, reduzir desperdício, aumentar a produtividade e diminuir os custos na agricultura (FERREIRA et al., 2024).

O uso de Inteligência Artificial (IA) vem se mostrando bastante promissor na produção agrícola. Máquinas autônomas equipadas com IA, como tratores e colheitadeiras, são capazes de realizar operações com precisão, funcionar 24 horas por dia, reduzir o desperdício, aumentar a produtividade e diminuir os custos na agricultura.

A IA pode auxiliar a agricultura a aumentar sua produtividade, automatizando processos, ajudando na aplicação correta e distribuição quantitativa de insumos. Com isso, inteligência artificial contribui para uma agricultura mais conectada e automatizada, com drones para monitoramento, sistemas de irrigação inteligentes e análise de dados para tomada de decisões (SARAIVA et al., 2024).

Assim, o uso de inteligência artificial é uma ferramenta indispensável na agricultura e pode contribuir de forma eficaz na automatização de processos complexos que exigem muitos cálculos e análises de grandes bases de dados.

3 TRABALHOS RELACIONADOS

Várias pesquisas recentes usam redes neurais convolucionais (CNNs) na classificação de espécies por meio de imagens. Já para a classificação especificamente de abelhas nativas sem ferrão, não há muitos estudos e treinamento de CNNs voltados para estas espécies, o que torna mais difícil encontrar estudos diretamente ligados aos propósitos deste trabalho. Em contrapartida, existem pesquisas que servem como base para a elaboração deste Trabalho de Conclusão de Curso, particularmente no que se refere às técnicas de inteligência artificial e redes neurais empregadas na identificação de espécies.

O artigo de Folliot et al. (2022), intitulado *Using acoustics and artificial intelligence to monitor pollination by insects and tree use by woodpeckers*, utiliza uma abordagem diferente, embora focada no monitoramento por meio do uso de sons, utiliza uma rede neural para monitorar e classificar insetos polinizadores. Nesse estudo, foi usada uma base de dados com 1401 sons de referência para treinar uma CNN. Mesmo que os métodos deste estudo sejam diferentes, o objetivo foi alcançado, deixando claro que uma CNN treinada adequadamente independente do tipo de entrada é capaz de classificar insetos (FOLLIOT et al., 2022).

Em outro estudo recente e realizado no Instituto Federal Sul-rio-grandense (IFSul), em Passo Fundo, mostrou que o uso de redes neurais foi eficaz na classificação de insetos a partir de imagens. A base de dados utilizada no experimento foi composta por 209 imagens com 17.908 insetos rotulados. Um dos principais desafios enfrentados foi a sobreposição de insetos e detritos presentes nas imagens, que como consequência contribuiu para uma baixa precisão. O modelo foi treinado com 100 épocas, o que resultou em parâmetros aceitáveis na identificação de pragas. O estudo alcançou seus objetivos com sucesso, auxiliando na identificação de flutuações populacionais de pragas, como pulgões e parasitoides. Em relação às alternativas para aumentar a precisão do modelo, os resultados indicaram que novas imagens contendo parasitoides em diferentes ângulos e com diferentes posições de cauda devem ser adicionadas ao conjunto de imagens para treinamento (JÚNIOR et al., 2022).

Outra pesquisa relevante é o estudo de Morais et al. (2022), desenvolvido na Universidade Tecnológica Federal do Paraná, que aborda o uso de redes neurais para a identificação de insetos. Este trabalho reconhece a complexidade e a alta propensão a erros na diferenciação de espécies a olho nu, um desafio que também se aplica ao classificar abelhas. Este estudo também utiliza de técnicas computacionais para automatizar a identificação de espécies, eliminando os possíveis erros de uma classificação manual. No entanto, enquanto ele faz uso de um software de terceiros para essa tarefa, o presente trabalho propõe a implementação de uma arquitetura YOLO, especificamente a versão 8, visando alcançar uma maior precisão na classificação das espécies de abelhas. Assim, este trabalho avança no sentido de utilizar uma abordagem mais moderna e precisa em relação à proposta por Morais et al. (2022).

No estudo de Hansen et al. (2019), que também utilizou uma CNN para classificar espécies de insetos, foram observadas limitações que impactaram diretamente a precisão dos resultados, com uma taxa de acurácia de 51,9% na classificação em nível de espécie.

Entre os fatores que comprometeram o desempenho do modelo estão a dificuldade de diferenciar visualmente as espécies devido ao tamanho corporal dos insetos e a qualidade limitada das imagens utilizadas no treinamento. Este estudo deixa claro a importância da qualidade e diversidade dos dados para melhorar os resultados de classificação, fator que foi previsto no presente trabalho através da criação de uma base de dados de alta qualidade, composta por imagens variadas de diferentes espécies de abelhas (HANSEN et al., 2019).

Outro estudo relevante é o de Spiesman et al. (2021), intitulado *Assessing the potential for deep learning and computer vision to identify bumble bee species from images*. O trabalho utilizou três tipos de redes neurais convolucionais (CNNs) para classificar 36 espécies de abelhas-bumble (mamangavas) com uma base de dados composta por 89.000 imagens. O modelo Wide-ResNet teve a maior precisão de teste, com 91,7%, o InceptionV3 teve uma precisão de 91,6% e o ResNet100 teve 91,3%. Como é possível notar, este estudo alcançou uma alta precisão na classificação de abelhas, demonstrando o potencial das CNNs no reconhecimento de espécies (SPIESMAN et al., 2021).

O estudo de Marstaller, Tausch e Stock (2019), *DeepBees: Building and Scaling Convolutional Neural Networks for Fast and Large-Scale Visual Monitoring of Bee Hives*, é um estudo bastante relevante. Nele foi desenvolvido o sistema *DeepBees*, que utiliza CNNs para o monitoramento visual, classificação e detecção de pólen nas abelhas. Embora o objetivo principal fosse o monitoramento da saúde das colmeias, o modelo treinado obteve uma acurácia de 82,41% na classificação. Sua base de dados foi construída com imagens de abelhas e outros insetos, ou seja, isso deixa evidente que as CNNs são capazes de identificar as abelhas entre outros insetos. Além disso, o sistema conseguiu classificar se a abelha estava carregando pólen, sem pólen, se era um zangão ou uma abelha morta (MARSTALLER; TAUSCH; STOCK, 2019).

O estudo mais recente é o *BeeNet: An End-To-End Deep Network for Bee Surveillance* de Yoo et al. (2023). Nele foi projetado um modelo de aprendizado profundo de ponta a ponta especificamente para o monitoramento de abelhas. Ele utilizou a arquitetura ResNet50d que é uma variante da arquitetura ResNet (Rede Residual) para classificar 11 espécies de abelhas, detectar também a presença de parasitas e pólen. O modelo treinado alcançou uma acurácia de 92,45% usando uma base de dados composta por mais de 20.000 imagens retiradas do site www.inaturalist.org. O modelo BeeNet demonstrou grande eficácia na extração de características visuais complexas, o que gerou resultados excelentes na classificação de abelhas (YOO et al., 2023).

Comparando os métodos e resultados dos trabalhos citados, observa-se que os estudos com melhores resultados utilizaram bases de imagens significativamente maiores, com volumes pelo menos 16 vezes superiores. Em contrapartida, este trabalho utilizou uma base de dados menor, limitada pela disponibilidade de imagens das espécies de abelhas nativas e sem ferrão, mas ainda assim alcançou uma precisão próxima à dos estudos com maior disponibilidade de dados. O trabalho desenvolvido no IFSul, que aplicou métodos semelhantes, obteve menor precisão devido a imagens sobrepostas e de baixa qualidade, problema evitado neste estudo. Esse cuidado na construção da base de dados foi fundamental para que nossa precisão fosse satisfatória em comparação a esse estudo específico.

4 MATERIAL E MÉTODOS

O início da parte prática deste estudo consistiu na criação de uma base de dados a partir de imagens obtidas do site *www.inaturalist.org*, uma plataforma colaborativa onde pessoas compartilhavam imagens de diversas espécies de animais e insetos. Esses compartilhamentos no site eram conhecidos como observações.

Para conseguir muitas imagens da mesma espécie de abelha de uma única vez, foi criado um algoritmo com a linguagem Python (versão 3). Para o funcionamento adequado deste algoritmo foi preciso procurar a espécie pretendida no site do *iNaturalist* e localizar seu código identificador dentro dos parâmetros especificados na URL (Localizador Uniforme de Recursos) do site ao navegar pela página da espécie.

Após inserir o número identificador da espécie como parâmetro na linha 6 do código, conforme ilustrado na Listagem 4.1, foi estabelecido a quantidade de páginas que o código deveria percorrer para recolher um número adequado de imagens. Em cada página, o código recorria à API (Interface de Programação de Aplicações) do *iNaturalist* para solicitar as URLs (Localizador Uniforme de Recursos) correspondentes de cada imagem. E assim, foi possível coletar todas as imagens das espécies de abelhas nativas e sem ferrão que seriam posteriormente catalogadas no Roboflow (acessível através do site *roboflow.com*).

```

1  import json
2  from urllib.request import urlopen
3  import os
4
5  #URL da API do iNaturalist para obter as imagens
6  url = 'https://www.inaturalist.org/observations.json?parameters'
7
8  #requisitar dados da API
9  response = urlopen(url)
10 data = json.loads(response.read())
11
12 #Local para salvar as imagens
13 output_dir = '/path/to/save/images'
14 os.makedirs(output_dir, exist_ok=True)
15
16 #Percorrer e salvar as imagens por perfil de cada observador
17 for observation in data:
18     for photo in observation.get('photos', []):
19         photo_url = photo.get('large_url')
20         if photo_url:
21             #Baixar a imagem e salvar no local escolhido
22             with urlopen(photo_url) as img_response:
23                 filename = os.path.join(output_dir, os.path.basename
(photo_url))
24
25                 with open(filename, 'wb') as img_file:
26                     img_file.write(img_response.read())

```

Listing 4.1 – Código em Python usado para baixar imagens em massa do *iNaturalist*.

Com as *URLs* das imagens coletadas do *JSON*, o algoritmo descarregou e salvou todas elas em um diretório especificado. Este processo foi repetido para cada observação e suas respectivas imagens, resultando em uma coleção abrangente para cada espécie de

interesse.

Por fim, as imagens coletadas foram importadas no Roboflow, uma plataforma dedicada à preparação de dados para o treinamento de modelos de aprendizado de máquina. Nessa etapa, as imagens foram rotuladas e catalogadas de acordo com as espécies. O processo envolveu a abertura de cada imagem individualmente, onde se desenhou manualmente uma caixa delimitadora ao redor das abelhas presentes na imagem. As coordenadas dessas caixas foram convertidas em *labels* ou anotações, que representaram as localizações e dimensões dos objetos de interesse.

As *labels* geradas durante a catalogagem no Roboflow foram processadas e utilizadas no treinamento da rede neural usando a arquitetura YOLO (*You Only Look Once*). A YOLO usou essas caixas delimitadoras para identificar objetos, como as abelhas, em novas imagens, prevendo suas coordenadas, além de atribuir uma pontuação que indicava a certeza da detecção e a probabilidade da classe à qual o objeto pertencia. Esse processo foi essencial para garantir que o modelo aprendesse a reconhecer corretamente as abelhas nas imagens.

Para realizar a classificação das espécies, utilizou-se a arquitetura YOLO na versão 8 (YOLOv8). Essa versão, mais avançada, possuía uma estrutura eficiente para a tarefa, conforme ilustrado na figura 2.

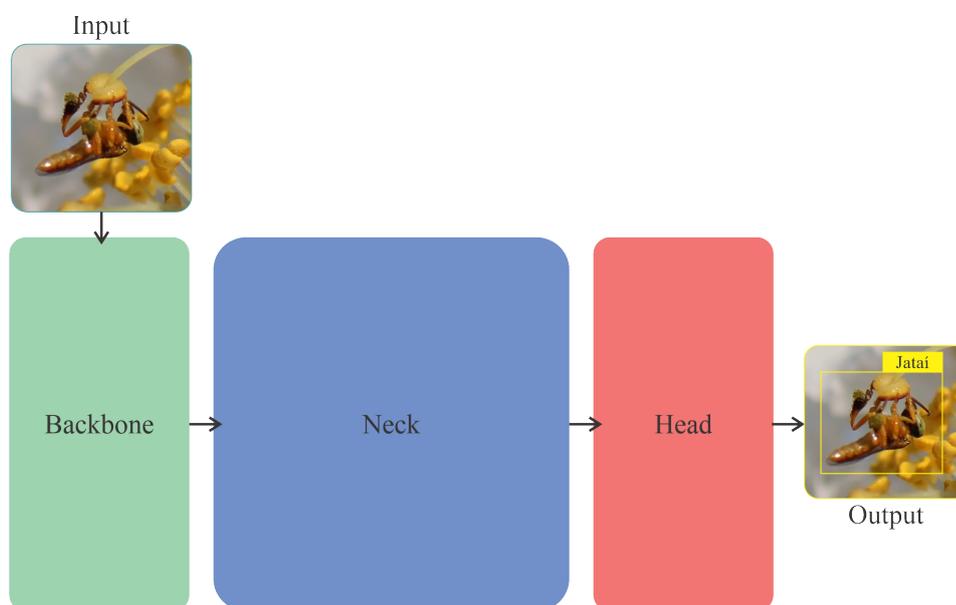


Figura 2 – Estrutura da arquitetura Yolo. Fonte: Adaptado de (TORRES, 2024).

A YOLOv8 é uma versão aprimorada de seus predecessores para detecção de objetos, e sua estrutura é composta por três partes principais:

- **Backbone:** Responsável por extrair o máximo de características da entrada, que neste caso é uma imagem. Essa parte é rica em recursos e processa as informações mais importantes do input.
- **Neck:** Combina as informações extraídas em várias escalas, melhorando a capacidade de detecção de objetos de diferentes tamanhos. É essencial para garantir a eficiência

do modelo em diversos cenários.

- Head: Gera as previsões com base nos dados extraídos pelo backbone e nas combinações feitas pelo neck. Nessa etapa, o modelo utiliza caixas de ancoragem para prever o objeto, fornecendo as coordenadas e uma pontuação que representa tanto a objetividade quanto a probabilidade de classe associada.

O YOLOv8 demonstrou melhorias consideráveis em termos de precisão e velocidade em comparação com versões passadas. Com recursos melhores para a detecção de objetos em tempo real, o YOLOv8 tornou-se uma escolha bastante popular em várias aplicações, incluindo robótica, vigilância e realidade aumentada (TORRES, 2024).

Para a avaliação da rede neural devidamente treinada, foram utilizadas as principais métricas de avaliação, precisão, *recall*, *F1-score* e a curva ROC.

Para entender como são feitos os cálculos foi necessário entender como funcionava uma matriz de confusão. Ela é uma tabela que indica os acertos e os erros do modelo treinado, comparando com o resultado esperado.

As métricas de avaliação do desempenho de um treinamento são várias. E todas essas medidas são construídas a partir de uma matriz de confusão que registra exemplos reconhecidos corretamente e incorretamente para cada classe. Normalmente, essas matrizes têm estruturas compostas por quatro categorias de resultados: os verdadeiros positivos (VP), os falsos negativos (FN), os falsos positivos (FP) e os verdadeiros negativos (VN). A tabela 1 mostra como são organizado esta estrutura (SOKOLOVA; JAPKOWICZ; SZPAKOWICZ, 2006).

		Detectada	
		Sim	Não
Real	Sim	Verdadeiro Positivo (VP)	Falso Negativo (FN)
	Não	Falso Positivo (FP)	Verdadeiro Negativo (VN)

Tabela 1 – Matriz de Confusão. Tabela adaptada de (MARIANO, 2024).

Ao treinar o modelo de aprendizagem é necessário validar seu desempenho. Uma rede neural para classificação de dados é construída para prever resultados com base em ocorrências passadas. Para isso, ele utiliza uma base de dados e suas propriedades como entrada. Além disso, é essencial conhecer os resultados esperados desse conjunto de dados rotulados antes do treinamento. Após o processo de treinamento, um novo conjunto de dados, que não foi utilizado durante o treinamento, é aplicado para validar e testar a assertividade do modelo. As métricas de validação utilizadas para avaliar o modelo treinado dependem exclusivamente do tipo de problema em estudo (MARIANO, 2024).

Assim, a precisão é uma métrica que valida a quantidade de verdadeiros positivos em razão da soma Verdadeiro positivo e falso positivo:

$$\text{precisão} = \frac{VP}{VP + FP}$$

já a sensibilidade ou *recall*. Ela avalia a capacidade do modelo de detectar com sucesso resultados classificados como positivos. E pode ser obtida pela equação:

$$\text{recall} = \frac{VP}{VP + FN}$$

E a F-measure, F-score ou score F1 é uma média harmônica calculada com base na precisão e no recall. Ela pode ser obtida com base na equação:

$$F1 = 2 \cdot \frac{\text{precisão} \cdot \text{recall}}{\text{precisão} + \text{recall}}$$

E para concluir, foram realizadas análises estatísticas para avaliar a viabilidade do uso das redes neurais para a classificação e monitoramento de abelhas em uma agricultura vertical. Os resultados obtidos serão discutidos e comparados com outros trabalhos relacionados para identificar possíveis limitações e avanços alcançados neste estudo.

5 RESULTADOS E DISCUSSÕES

Neste capítulo iremos apresentar os resultados obtidos no treinamento da rede neural para classificação de espécies de abelhas, destacando as principais dificuldades e detalhando todo o processo de treinamento, validação e teste, bem como as métricas de avaliações obtidas pelo modelo.

No primeiro treinamento da CNN, foi utilizada uma base de dados composta por cinco classes, cada uma representando uma espécie de abelha. A meta inicial era obter, em média, 200 imagens por espécie. Essas imagens foram coletadas de diferentes fontes, incluindo o site *www.inaturalist.org*, além das contribuições das estudantes de mestrado Geni Alexandria de Moraes e Elzi Leida, e também de imagens próprias.

Apesar do objetivo de construir uma base de dados equilibrada, com o mesmo número de imagens por classe, o resultado final foi uma base desbalanceada. Algumas espécies possuíam poucas imagens disponíveis, enquanto outras superaram a meta inicial de 200 unidades, gerando um total de mais de 1000 *labels* para algumas classes, como ilustrado na Figura 3.

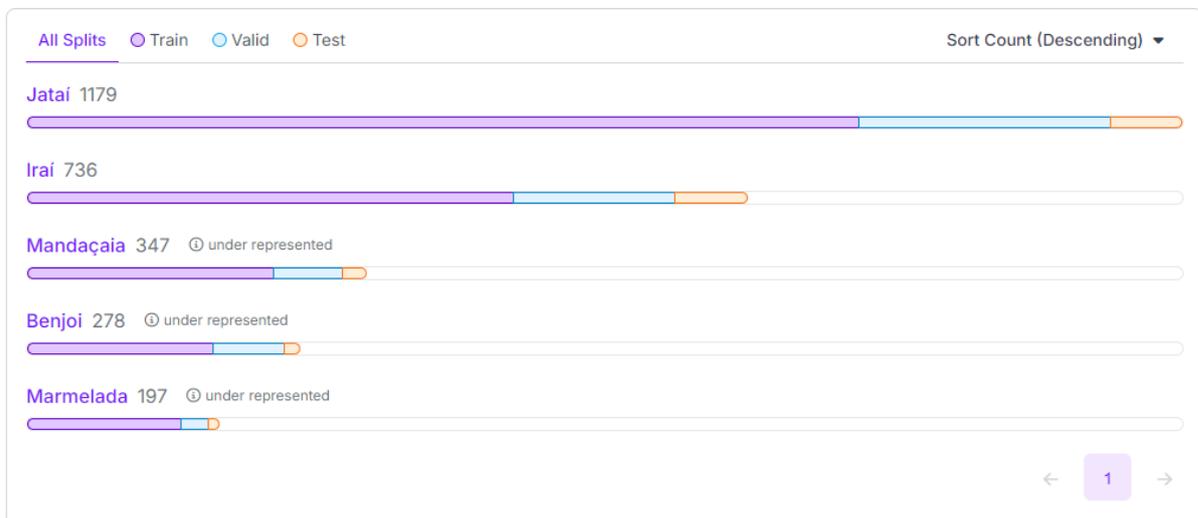


Figura 3 – Visão geral do número de *labels* por classe da primeira base de dados. Fonte: Autoria própria, gerado no Roboflow.

A causa do aumento desproporcional no número de labels deve-se ao fato de que muitas das imagens catalogadas nessa primeira base de dados eram de colmeias, onde era possível identificar e rotular várias abelhas em uma única imagem, como é possível observar na imagem 4.

O desequilíbrio entre as classes da primeira base de dados impactou negativamente o desempenho do modelo que foi treinado utilizando a Yolov8, com 200 épocas e em uma máquina equipada apenas com um processador Intel Core i5-10500H (10^a geração) com duração aproximada de 18 horas. O treinamento gerou uma precisão insatisfatória na



Figura 4 – Imagem da espécie Jataí catalogada na primeira base de dados. Fonte: Própria e retirada do Roboflow.

identificação das espécies, o que pode ser observado na matriz de confusão da figura 5.

A matriz (figura 5) indica uma alta taxa de erros, especialmente na classe *background*- que representa o fundo da imagem, e foi confundida com espécies em várias ocasiões. Isso reflete uma baixa capacidade do modelo em distinguir corretamente as espécies de abelhas do fundo em que elas se encontram. Tornando desnecessário aumentar o número de épocas e de um novo treinamento.

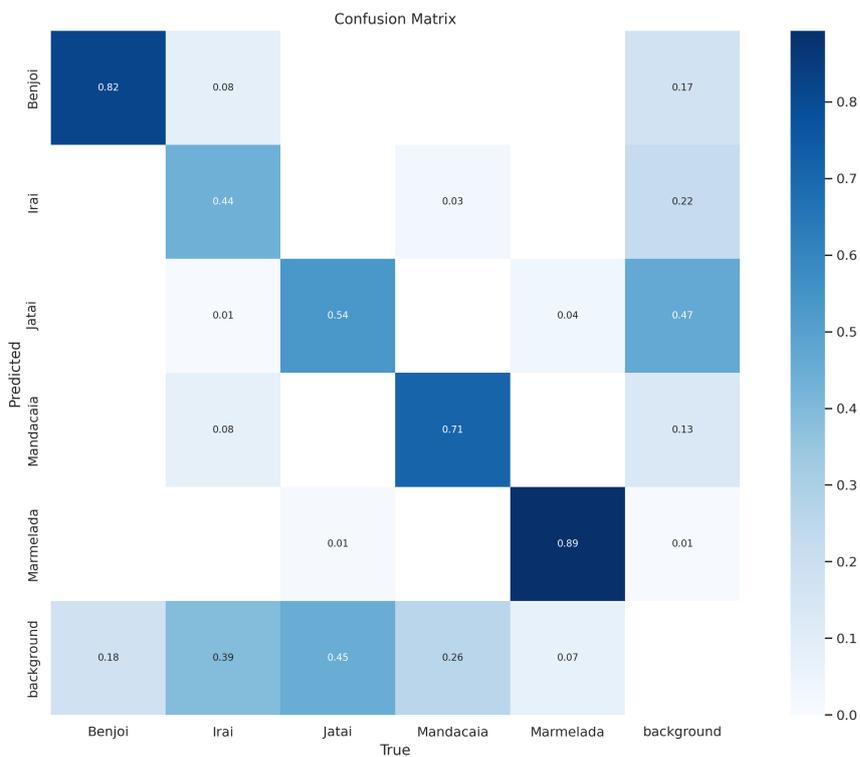


Figura 5 – Matriz de confusão da primeira base de dados. Fonte: Própria.

Esse resultado não foi satisfatório porque um modelo treinado com uma base de dados desbalanceada tende a favorecer algumas classes mais que outras. Neste modelo, houve o desfavorecimento da classe de abelhas da espécie Iraí, devido à sua coloração escura, onde era confundida com fundos de imagens. A classe Jataí tinha uma quantidade muito superior de *labels*, tornando a base de dados ainda mais desbalanceada e fazendo com que o modelo favorecesse essa classe majoritária durante a predição. Como consequência, o modelo apresentou uma baixa precisão nestas classes, e essa base de dados foi descartada. Então tornou-se necessário criar uma nova, contendo apenas espécies que tinham uma quantidade de imagens disponíveis e suficientes para catalogar, em média, 200 abelhas por classe.



Figura 6 – Visão geral do número de *labels* por classe da segunda base de dados. Fonte: Própria e retirada do Roboflow.

Essa nova base de dados foi criada com foco no balanceamento das *labels*, assegurando uma quantidade uniforme de *boxes* catalogadas por classe, como é possível observar na figura 6. Além disso, foi aplicada a técnica de *data augmentation* diretamente no Roboflow antes do treinamento, com o objetivo de aprimorar os resultados do modelo e garantir uma melhor detecção das espécies de abelhas. As técnicas de *augmentation* utilizadas incluíram:

- Rotação de 90°: sentido horário e anti-horário;
- Cisalhamento: $\pm 15^\circ$ horizontal e $\pm 15^\circ$ vertical;
- Aplicação de tons de cinza em 20% das imagens.

Antes de aplicar o *data augmentation*, esta base de dados foi treinada por 800 épocas, e a matriz de confusão resultante mostrou que a classe Irapuã apresentou um baixo valor de verdadeiros positivos, como mostrado na Figura 7. As 800 épocas foram adotadas porque, ao analisar as imagens geradas pelo treinamento, observamos gráficos semelhantes ao da Figura 9. Nele, percebe-se que não era possível treinar o modelo com apenas 200 épocas devido à grande oscilação nos valores de precisão e *recall*, o que indicava que o modelo ainda não estava com um treinamento adequado. Para lidar com essa instabilidade e melhorar a capacidade de identificação e classificação do modelo, adotamos a estratégia de aumentar o treinamento em mais 600 épocas, utilizando a segunda base de dados

balanceada. Dessa forma, buscamos estabilizar o aprendizado e otimizar o desempenho do classificador. Para melhorar ainda mais a performance, foram aplicadas as três técnicas listadas acima.

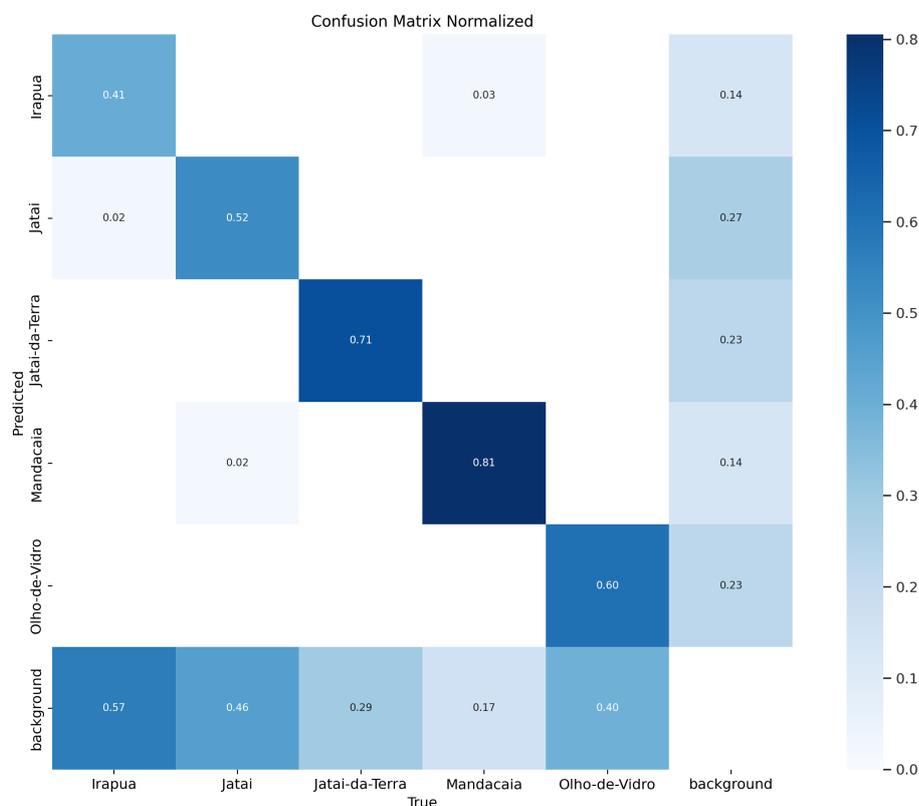


Figura 7 – Matriz de confusão da segunda base de dados antes de aplicar *data augmentation*.
Fonte: Própria.

A segunda base à princípio tinha uma média aproximada de 200 *labels* catalogados por espécie como mostrado na figura 6. Isso garantiu uma distribuição uniforme entre as classes, evitando a sub-representação de algumas delas. No total, foram catalogadas 635 imagens, distribuídas entre cinco classes: Irapuã, Jataí, Jataí-da-Terra, Mandacaia e Olho-de-Vidro. E posteriormente depois de aplicar as técnicas de *augmentation* a base expandiu para 1.527 imagens e aproximadamente 480 anotações por classe.

Após a importação da nova base de dados balanceada, o treinamento do modelo foi iniciado utilizando a arquitetura YOLOv8, usando como parâmetro 1.000 épocas. O processo foi conduzido no Laboratório de Inteligência Artificial Aplicada (LIAA) do Instituto Federal Goiano, Campus Rio Verde. O LIAA possui máquinas equipadas com processador AMD Ryzen™ 9 7900X3D × 24, 32 GB DDR5 5200MHz (2x16GB), 1TB de armazenamento SSD NVMe e placa de vídeo NVIDIA GeForce RTX 4080 SUPER 16GB GDDR6, e com ela foi possível reduzir o tempo de treinamento, gastando aproximadamente 8 horas. Os resultados da validação, ficaram disponíveis ao final do treinamento em um arquivo CSV (Comma-Separated Values) e confirmaram um desempenho satisfatório. O modelo alcançou uma precisão de cerca de 79% após a milésima época, com um *recall* de 62%. E utilizando a fórmula apresentada na Seção 4, foi calculado o *f-score*, resultando em um valor aproximado de 69%. Esses resultados indicam que o modelo foi capaz de

identificar com eficácia as diferentes espécies de abelhas disponíveis no conjunto de dados, demonstrando um bom equilíbrio entre a capacidade de prever corretamente as classes e a cobertura das amostras.

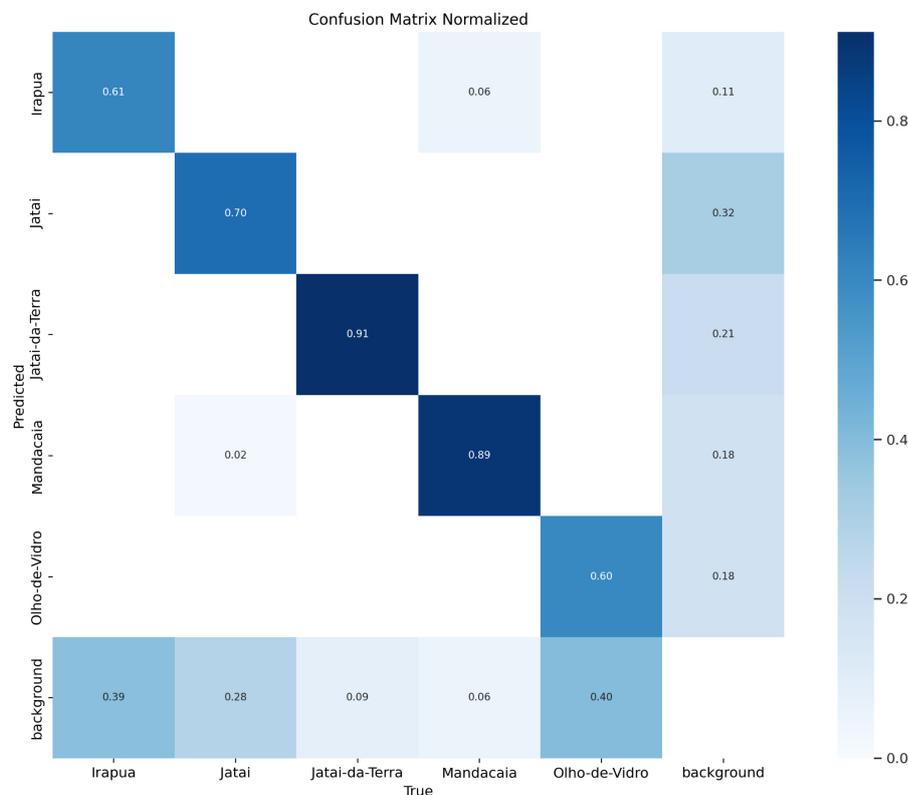


Figura 8 – Matriz de confusão da segunda base de dados após aplicar *data augmentation*.
 Fonte: Própria

Ao analisar a matriz de confusão apresentada na Figura 8, é possível observar que algumas espécies, como a Mandacaia, apresentou um alto número de verdadeiros positivos (VP). Esse número é consequência do tamanho relativamente grande da espécie, o que facilitou sua detecção pelo modelo. Por outro lado, a Irapuã, espécie menor que a Mandacaia e de coloração totalmente escura, apresentaram valores menores de verdadeiros positivos, sendo bastante confundido com fundos de imagens. Esses resultados indicam que as características visuais, como cor e tamanho, são fatores determinantes na performance durante a classificação correta das abelhas.

Outra espécie que vale ressaltar é a Olho-de-Vidro, que tem coloração marrom e, mesmo assim, apresentou baixa precisão. Isso foi motivado pelo fato de sua classe conter imagens de baixa qualidade e também pela sua coloração, que pode ser facilmente confundida com o fundo de imagens com tons marrons, uma cor comum e encontrada em fotos que mostram solos e terras.

Os gráficos apresentados na figura 9, ilustram o comportamento das perdas (*losses*) durante o treinamento e a validação. Observa-se em geral uma redução gradual dos *losses*, tanto no treinamento quanto na validação, o que reflete um aprendizado eficiente do modelo ao longo das épocas. Esse comportamento é esperado em bases de dados balanceadas,

já que a representação equitativa entre as classes contribui para que o modelo aprenda a distinguir as espécies de maneira mais uniforme, sem favorecimento de uma classe em detrimento de outra.

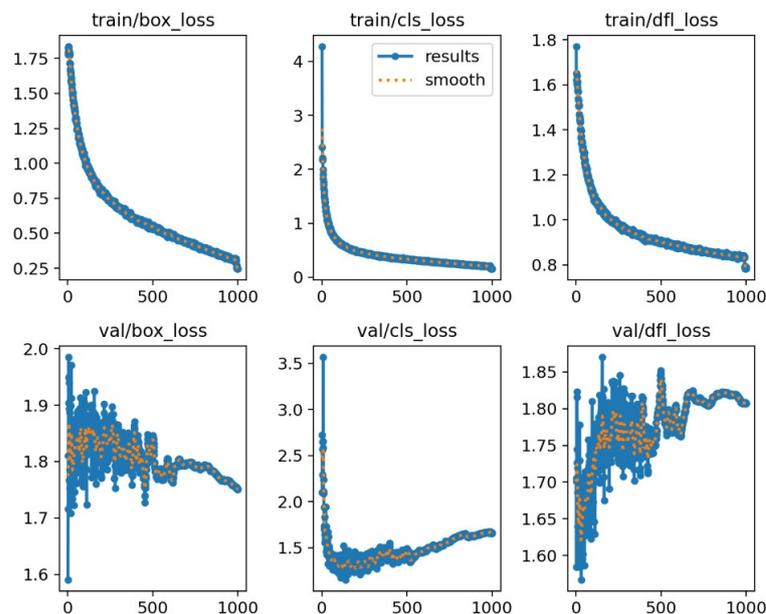


Figura 9 – Gráficos resultantes do treinamento e gerado pela YOLO. Fonte: adaptado dos resultados do treinamento com a Yolo

Quanto à precisão e ao *recall* (na figura 10), notamos que ambos não se estabilizam, mas diminuem sua grande variação apenas após 700 épocas. Por conta disso, foi necessário estender o treinamento até 1.000 épocas, para garantir que o modelo atingisse uma capacidade satisfatória de classificação e identificação das classes. Ao combinar esses resultados, a da matriz de confusão e os dados extraídos do arquivo CSV, podemos concluir que o modelo treinado usando a YOLOv8 foi capaz de identificar com precisão de 79% as espécies de abelhas a partir das imagens, demonstrando um desempenho sólido e aceitável.

Embora os resultados obtidos neste trabalho, com uma precisão de 79%, um *recall* de 62% e um *F-score* de 69%, demonstrem que o modelo teve um desempenho considerável na identificação das espécies de abelhas, eles se mostram ainda mais promissores ao serem comparados com os trabalhos relacionados. Em estudos como os de Spiesman et al. (2021) e Yoo et al. (2023), que alcançaram precisões superiores, observou-se a utilização de bases de dados extremamente amplas, com até 89.000 imagens. Esses resultados superiores foram, em grande parte, favorecidos pela grande disponibilidade de imagens no seu banco de dados, o que aumenta a precisão de modelo como este.

Por outro lado, este trabalho obteve resultados significativos mesmo com uma base de dados menor, o que reforça que este modelo tem potencial para alcançar resultados ainda melhores depois de uma boa expansão da base de imagens com a contribuição de biólogos e pesquisadores do Instituto Federal Goiano - Campus Rio Verde. A limitação da base de dados neste trabalho foi causada pela dificuldade em encontrar grandes quantidades de imagens de abelhas nativas e sem ferrão, o que restringe a disponibilidade de dados para treinamento. Em comparação com outros estudos que também utilizam bases

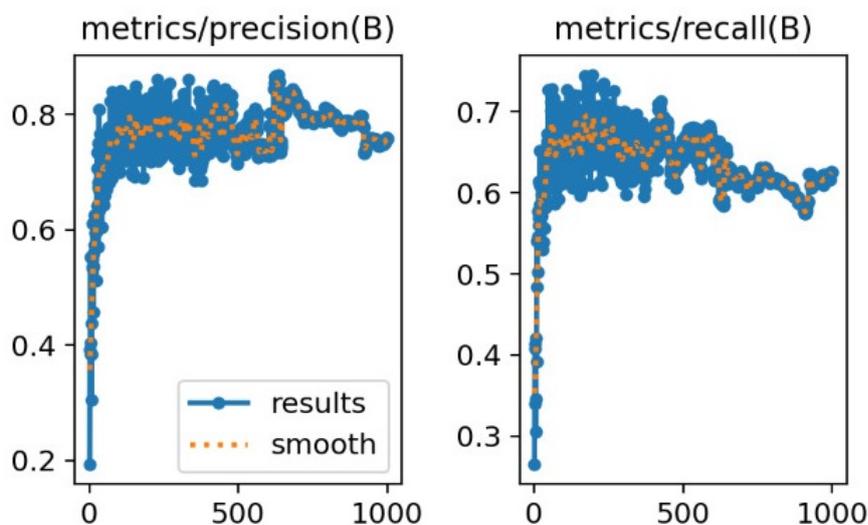


Figura 10 – Gráficos resultantes do treinamento e gerado pela YOLO. Fonte: adaptado dos resultados do treinamento com a Yolo.

Resultados dos treinamentos					
Base de dados	Data Argumentation	Épocas	Precisão	Recall	F-Score
1 ^a	não consta	200	56%	61%	58%
2 ^a	não consta	800	50%	59%	54%
2 ^a	Rotação, cisalhamento e 20% de tons de cinza	1000	79%	62%	69%

Tabela 2 – Resultados de todos os treinamentos executados durante o trabalho

menores, como o de Hansen et al. (2019), cujo modelo atingiu uma precisão de apenas 51,9%, nossos resultados mostram-se superiores. Esses avanços demonstram que, embora o presente modelo utilize uma base de dados mais limitada, ele foi capaz de gerar uma boa classificação e identificação, destacando a eficácia da arquitetura YOLOv8 e uma boa catalogação das imagens.

Assim, este trabalho não apenas confirma o potencial para a classificação de espécies de abelhas, alcançando uma precisão de 79%, um *recall* de 62% e um *F-score* de 69%, mas também evidencia o impacto positivo do *data augmentation*. Mesmo com uma base de dados relativamente pequena, a aplicação dessas técnicas junto com um aumento de 200 épocas, resultou em um aumento de quase 30% na precisão do modelo, como mostrado na Tabela 2. Esses resultados sugerem que a ampliação da base de dados e o uso de *data augmentation* podem melhorar ainda mais o desempenho do modelo. Comparado a estudos anteriores, como os de Spiesman et al. (2021) e Yoo et al. (2023), que utilizam bancos de dados com até 89.000 imagens e obtiveram precisões mais elevadas, nosso modelo, treinado com uma base de dados significativamente menor, demonstrou-se capaz de gerar resultados competitivos. A principal limitação foi a baixa disponibilidade de imagens de abelhas nativas sem ferrão, reduzindo a quantidade de dados para o treinamento. Para superar essa restrição, futuras pesquisas podem investir na expansão da base de dados com novas coletas de imagens e na aplicação de técnicas de aprendizado semi-supervisionado ou transferência de aprendizado para melhorar a generalização do modelo.

Por outro lado, nossos resultados, ao serem comparados com os de trabalhos que também empregaram bases menores, como o estudo de Hansen et al. (2019), que obteve uma precisão de 51,9%, reforçam a aplicabilidade do modelo em classificações complexas de espécies com dados mais limitados. Essa abordagem, utilizando a arquitetura YOLOv8 e uma catalogação detalhada das imagens, mostrou-se eficiente e pode ser expandida com futuras colaborações de biólogos e pesquisadores do Instituto Federal Goiano – Campus Rio Verde, possibilitando o aumento da base de dados.

Dessa forma, os resultados obtidos neste trabalho indicam um potencial para que, em etapas futuras, com a ampliação do banco de imagens e aprofundamento da pesquisa, o modelo alcance uma maior precisão, contribuindo significativamente para o campo de estudo das redes neurais aplicadas à classificação de espécies de abelhas.

Referências

- BENGIO, Y.; LECUN, Y.; HINTON, G. Deep learning for ai. **Communications of the ACM**, ACM New York, NY, USA, v. 64, n. 7, p. 58–65, 2021. Citado na página 4.
- BERINGER, J.; MACIEL, F. L.; TRAMONTINA, F. F. O declínio populacional das abelhas: causas, potenciais soluções e perspectivas futuras. **Revista Eletrônica Científica Da UERGS**, v. 5, n. 1, p. 18–27, 2019. Disponível em: <<https://doi.org/10.21674/2448-0479.51.18-27>>. Citado na página 1.
- CASTIGLIONI, I. et al. Ai applications to medical images: From machine learning to deep learning. **Physica medica**, Elsevier, v. 83, p. 9–24, 2021. Citado na página 4.
- FERREIRA, J. A. et al. O uso da inteligência artificial na agricultura. **Revista Multidisciplinar do Nordeste Mineiro**, v. 9, n. 1, 2024. Citado na página 5.
- FLECK, L. et al. Redes neurais artificiais: Princípios básicos. **Revista Eletrônica Científica Inovação e Tecnologia**, v. 1, n. 13, p. 47–57, 2016. Citado 2 vezes nas páginas 3 e 4.
- FOLLIOT, A. et al. Using acoustics and artificial intelligence to monitor pollination by insects and tree use by woodpeckers. **Science of the Total Environment**, Elsevier, v. 838, p. 155883, 2022. Citado na página 6.
- HANSEN, O. L. P. et al. Species-level image classification with convolutional neural network enables insect identification from habitus images. **Ecology and Evolution**, Wiley, v. 10, n. 2, p. 737–747, 2019. Citado 4 vezes nas páginas 6, 7, 18 e 19.
- HAYKIN, S. **Redes neurais: princípios e prática**. [S.l.]: Bookman Editora, 2001. Citado na página 3.
- IBM. **O que são redes neurais convolucionais**. 2023. Acesso em: 05 ago. 2024. Disponível em: <<https://www.ibm.com/br-pt/topics/convolutional-neural-networks>>. Citado na página 1.
- JÚNIOR, T. D. C. et al. Insectcv: A system for insect detection in the lab from trap images. **Ecological Informatics**, Elsevier, v. 67, p. 101516, 2022. Citado na página 6.
- KURZWEIL, R. **The Age of Intelligent Machines**. Cambridge, MA: MIT Press, 1990. Citado na página 3.
- MARIANO, D. **Métricas de Avaliação em Machine Learning**. 2024. Acesso em: 1 set. 2024. Disponível em: <<https://diegomariano.com/metricas-de-avaliacao-em-machine-learning/>>. Citado na página 10.
- MARSTALLER, J.; TAUSCH, F.; STOCK, S. Deepbees: Building and scaling convolutional neural networks for fast and large-scale visual monitoring of bee hives. In: **Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops**. [S.l.: s.n.], 2019. p. 253–262. Citado na página 7.
- MORAIS, R. d. et al. **Uso de rede neural convolucional no reconhecimento de artrópodes da classe insecta**. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, 2022. Citado na página 6.

- RUSSELL, S. J.; NORVIG, P. **Inteligência Artificial**: Tradução de Regina Célia Simille. 3. ed. Rio de Janeiro: Elsevier, 2013. ISBN 978-85-352-3701-6. Citado na página 3.
- SANTANA, F. S. et al. A reference process for automating bee species identification based on wing images and digital image processing. **Ecological Informatics**, Elsevier, v. 24, p. 248–260, 2014. Citado na página 1.
- SARAIVA, A. M. et al. A inteligência artificial na pesquisa agrícola. **Revista USP**, v. 141, p. 91–106, abril/junho 2024. Citado na página 5.
- SILVA, J. A. S. da; MAIRINK, C. H. P. Inteligência artificial. **LIBERTAS: Revista de Ciências Sociais Aplicadas**, v. 9, n. 2, p. 64–85, 2019. Citado na página 3.
- SOKOLOVA, M.; JAPKOWICZ, N.; SZPAKOWICZ, S. Beyond accuracy, f-score and roc: a family of discriminant measures for performance evaluation. In: SPRINGER. **Australasian joint conference on artificial intelligence**. [S.l.], 2006. p. 1015–1021. Citado na página 10.
- SPIESMAN, B. J. et al. Assessing the potential for deep learning and computer vision to identify bumble bee species from images. **Scientific reports**, Nature Publishing Group, v. 11, n. 1, p. 1–10, 2021. Citado 3 vezes nas páginas 7, 17 e 18.
- TORRES, J. **YOLOv8 Architecture Explained**. 2024. Publicado em: 19 mar. 2024. Acesso em: 1 set. 2024. Disponível em: <<https://yolov8.org/yolov8-architecture-explained/>>. Citado 2 vezes nas páginas 9 e 10.
- VARGAS, A. C. G.; PAES, A.; VASCONCELOS, C. N. Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. In: SN. **Proceedings of the xxix conference on graphics, patterns and images**. [S.l.], 2016. v. 1, n. 4. Citado na página 4.
- WINFREE, R. et al. Species turnover promotes the importance of bee diversity for crop pollination at regional scales. **Science**, v. 359, n. 6377, p. 791–793, 2018. Disponível em: <<https://www.science.org/doi/abs/10.1126/science.aao2117>>. Citado na página 1.
- YOO, J. et al. Beenet: An end-to-end deep network for bee surveillance. **Procedia Computer Science**, Elsevier, v. 222, p. 415–424, 2023. Citado 3 vezes nas páginas 7, 17 e 18.