

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA
GOIANO - CAMPUS RIO VERDE
DIRETORIA DE PÓS-GRADUAÇÃO, PESQUISA E INOVAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM BIODIVERSIDADE E
CONSERVAÇÃO**

**IDENTIFICAÇÃO DE ABELHAS NATIVAS NO CERRADO
COM O USO DE INTELIGÊNCIA ARTIFICIAL**

Autor: Elzi Leida do Carmo França

Orientador: Dr. Fernando Henrique Antonioli Farache

Coorientador: Dr. Sebastião Carvalho Vasconcelos Filho

Rio Verde – GO

Agosto/2025

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA
GOIANO - CAMPUS RIO VERDE
DIRETORIA DE PÓS-GRADUAÇÃO, PESQUISA E INOVAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM BIODIVERSIDADE E
CONSERVAÇÃO**

**IDENTIFICAÇÃO DE ABELHAS NATIVAS NO
CERRADO COM O USO DE INTELIGÊNCIA ARTIFICIAL**

Autor: Elzi Leida do Carmo França

Orientador: Dr. Fernando Henrique Antonioli Farache

Coorientador: Dr. Sebastião Carvalho Vasconcelos Filho

Dissertação apresentada como parte das exigências da obtenção do título de Mestre em Biodiversidade e Conservação no Programa de Pós-graduação do Instituto Federal de Educação, Ciência e Tecnologia Goiano – Campus Rio Verde – Goiás. Área de concentração Conservação dos Recursos Naturais.

Rio Verde – GO

Agosto/2025

**Ficha de identificação da obra elaborada pelo autor, através do
Programa de Geração Automática do Sistema Integrado de Bibliotecas do IF Goiano - SIBi**

F815i França, Elzi Leida
IDENTIFICAÇÃO DE ABELHAS NATIVAS NO CERRADO
COM O USO DE INTELIGÊNCIA ARTIFICIAL / Elzi Leida
França. Rio Verde 2025.

52f. il.

Orientador: Prof. Dr. Dr. Fernando Henrique Antonioli Farache.

Coorientador: Prof. Dr. Dr. Sebastião Carvalho Vasconcelos
Filho.

Dissertação (Mestre) - Instituto Federal Goiano, curso de
0231084 - Mestrado em Biodiversidade e Conservação (Campus
Rio Verde).

1. Abelhas. 2. Inteligência Artificial. 3. Cerrado. 4. Novas
Tecnologias. 5. Conservação. I. Título.



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

- ☐ Tese (doutorado)
☒ Dissertação (mestrado)
☐ Monografia (especialização)
☐ TCC (graduação)

- ☐ Artigo científico
☐ Capítulo de livro
☐ Livro
☐ Trabalho apresentado em evento

☐ Produto técnico e educacional - Tipo:

Nome completo do autor:
Elzi Leida do Carmo França

Matrícula:
2023202310840005

Título do trabalho:
IDENTIFICAÇÃO DE ABELHAS NATIVAS NO CERRADO COM O USO DE INTELIGÊNCIA ARTIFICIAL

RESTRIÇÕES DE ACESSO AO DOCUMENTO

Documento confidencial: ☒ Não ☐ Sim, justifique:

Informe a data que poderá ser disponibilizado no RIIF Goiano: 27 / 10 / 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 incluídos 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
gov.br ELZI LEIDA DO CARMO FRANÇA
Data: 23/10/2025 10:17:05-0300
Verifique em <https://validar.iti.gov.br>

Rio Verde - Goiás
Local

20 / 05 / 2025
Data

Assinatura do autor e/ou detentor dos direitos autorais

Ciente e de acordo:

Assinatura do(a) orientador(a)

Documento assinado digitalmente
gov.br FERNANDO HENRIQUE ANTONIOLLI FARACHE
Data: 23/10/2025 10:43:33-0300
Verifique em <https://validar.iti.gov.br>



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

Documentos 49/2025 - SREPG/CMPR/CPG-RV/DPGPI-RV/CMPRV/IFGOIANO

IDENTIFICAÇÃO DE ABELHAS NATIVAS DO CERRADO COM O USO DE INTELIGÊNCIA ARTIFICIAL

Autora: Elzi Leida do Carmo França

Orientador: Prof. Dr. Fernando Henrique Antonioli Farache

TITULAÇÃO: Mestre em Biodiversidade e Conservação - Área de Concentração Conservação dos Recursos Naturais

APROVADA em 27 de agosto de 2025.

Prof^a. Dra. Gisele Cristina de Oliveira Menino
Avaliadora Externa
IFGOIANO / Rio Verde

Prof. Dr. Adriano Ferraz da Costa
Avaliador Externo
UEG / Santa Helena de Goiás

Prof. Dr. Fernando Henrique Antonioli Farache
Presidente da Banca
IFGOIANO / Rio Verde

Documento assinado eletronicamente por:

- **Fernando Henrique Antonioli Farache**, PROFESSOR ENS BASICO TECN TECNOLOGICO , em 27/08/2025 16:21:57.
- **Gisele Cristina de Oliveira Menino**, PROFESSOR ENS BASICO TECN TECNOLOGICO , em 27/08/2025 17:40:37.
- **ADRIANO FERRAZ DA COSTA**, ADRIANO FERRAZ DA COSTA - Professor Avaliador de Banca - Ueg (01112580000171) , em 02/09/2025 14:58:58.

Este documento foi emitido pelo SUAP em 15/08/2025. 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: 733095

Código de Autenticação: 28a9639378



AGRADECIMENTOS

O caminho percorrido até a conclusão desta dissertação foi construído com o apoio, incentivo e presença de pessoas fundamentais, as quais expresso minha mais profunda gratidão.

Em primeiro lugar, agradeço à minha mãe, Anézia, minha primeira professora, que, com dedicação e mão firme guiou-me pelos caminhos da leitura. Agradeço por ser o alicerce da minha vida. Sua força, fé e perseverança me conduziram até aqui. Sem o seu apoio e exemplo, nada disso teria sido possível.

Ao professor Fernando Henrique Antonioli Farache, meu orientador, agradeço pela orientação generosa, pela paciência diante das minhas dúvidas e pela condução segura ao longo deste trabalho. Sua dedicação à pesquisa e à formação de cientistas é uma inspiração.

Ao professor Sebastião Carvalho Vasconcelos Filho, meu coorientador, registro minha sincera gratidão pelo apoio constante, pelas sugestões valiosas e pelo incentivo que me ajudaram a expandir horizontes e enfrentar os desafios da pesquisa.

Aos professores do Programa de Pós-Graduação, agradeço pelo conhecimento compartilhado em sala de aula, pelas contribuições acadêmicas e pelas reflexões que ampliaram minha visão crítica e científica. Cada disciplina, orientação e diálogo contribuiu significativamente para minha formação como pesquisadora.

Agradeço ao discente Wésio Coelho, aluno do curso de Ciências da Computação, pela valiosa contribuição na etapa de desenvolvimento e implementação da parte de Inteligência Artificial deste trabalho. Sua dedicação, competência técnica e disposição para colaborar foram fundamentais para a obtenção dos resultados apresentados, enriquecendo significativamente a qualidade da pesquisa.

Ao Instituto Federal de Educação, Ciência e Tecnologia Goiano – Campus Rio Verde, pela concessão do suporte essencial à realização deste trabalho, especialmente pela disponibilização da infraestrutura dos laboratórios, em especial ao Laboratório de Inteligência Artificial Aplicada (LIAA), cuja contribuição técnica e apoio foram fundamentais para o desenvolvimento desta pesquisa. Agradeço também à CAPES, pelo apoio financeiro, o presente trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior–Brasil (CAPES)—Código de Financiamento 001.

Ao meu marido, Josué França de Oliveira, agradeço a compreensão nos momentos de ausência e por caminhar ao meu lado com apoio e encorajamento, mesmo nos dias mais difíceis.

Aos meus filhos, Heyde, que esteve ao meu lado com apoio e orientação durante todo esse percurso, Ana e Júlio, minha razão maior, que me ensinam diariamente sobre resiliência, afeto e propósito. Esta conquista é, em muitos sentidos, também de vocês.

Aos meus colegas do mestrado, agradeço a convivência enriquecedora, pelas trocas de saberes, pelos momentos de companheirismo e por todo o apoio mútuo ao longo dessa caminhada. Cada um contribuiu de forma única para tornar esse percurso mais leve, estimulante e cheio de aprendizado.

A todos que, de alguma forma, contribuíram para a realização deste trabalho, o meu sincero agradecimento.

BIOGRAFIA DO AUTOR

Elzi Leida do Carmo França desde cedo desenvolveu o gosto pela natureza e pela leitura. Ao longo de sua trajetória, conciliou a vida pessoal e profissional com os estudos, acreditando no valor da educação como instrumento de transformação. Graduiu-se em Direito pela UNIRV – Universidade de Rio Verde-Go., em 2005, pós-graduada em Direito Constitucional pela Faculdade de Montes Belos em 2007, e Licenciada em Ciências Biológicas pelo Instituto Federal Goiano – Campus Rio Verde-Go., em 2024, unindo duas áreas distintas, mas complementares, que refletem seu interesse tanto pela Direito quanto pela preservação da vida. Possui experiência profissional na área jurídica, atuando na esfera judicial, mas manteve sempre o olhar voltado para as questões ambientais e sociais.

É esposa de Josué França de Oliveira e mãe de Heyde, Ana e Júlio, que representam sua maior inspiração e motivação para seguir no caminho acadêmico. Atualmente, é Mestre pelo Programa de Pós-Graduação em Biodiversidade e Conservação do Instituto Federal Goiano – Campus Rio Verde, onde desenvolve a pesquisa “**Identificação de abelhas nativas no Cerrado com o uso de Inteligência Artificial**”. Sua pesquisa une tecnologia e conservação, buscando contribuir para a preservação dos polinizadores nativos, essenciais à biodiversidade e à segurança alimentar. Seus principais interesses acadêmicos envolvem biologia da conservação, polinizadores nativos, inteligência artificial aplicada e interdisciplinaridade entre direito, tecnologia e meio ambiente.

SUMÁRIO

1	INTRODUÇÃO	10
1.1	Importância das abelhas no Cerrado	11
1.2	Impedimento Taxonômico	15
1.3	A Inteligência Artificial e sua contribuição para a Taxonomia	17
1.4	Redes Neurais	17
1.5	Deep Learning	18
1.6	Redes Neurais Convolucionais	19
2	OBJETIVOS	20
2.1	Objetivo geral	20
2.2	Objetivos específicos	21
3	MATERIAL E MÉTODOS	21
3.1	Seleção de Grupos Taxonômicos e aquisição de imagens	21
3.2	Protocolo para aquisição de imagens	22
3.3	Treinamento da Rede Neural	26
3.4	Avaliação do Modelo, validação e análises estatísticas	29
4	RESULTADOS	31
4.1	Primeiro Experimento	31
4.1.1	Segunda base de dados	34
4.2	Segundo Experimento	41
5	DISCUSSÃO	44
6	CONCLUSÃO	46
	Referências	47

ÍNDICE DE FIGURAS

Figura 1 – Multicamadas de uma rede neural.	18
Figura 2 – Caixa delimitadora ao redor da abelha.	25
Figura 3 – Estrutura da arquitetura YOLO.	27
Figura 4 – Imagens utilizadas para treinamento da rede neural.	28
Figura 5 – Visão geral do número de <i>labels</i> por classe da primeira base de dados	32
Figura 6 – Imagem da espécie <i>Tetragonisca angustula</i> (Jataí) catalogada na primeira base de dados.	32
Figura 7 – Matriz de confusão da primeira base de dados.	33
Figura 8 – Aplicação de tons de cinza e efeito isolado de rotação.	34
Figura 9 – Imagem da espécie <i>Trigona spinipes</i> (Irapuã) antes de aplicar técnicas de <i>data augmentation</i>	35
Figura 10 – Matriz de confusão da primeira base de dados antes de aplicar <i>data augmentation</i>	36
Figura 11 – Visão geral do número de <i>labels</i> por classe da segunda base de dados.	37
Figura 12 – Gráficos resultantes do treinamento e validação gerados pela YOLO...38	
Figura 13 – Gráficos resultantes do treinamento gerados pela YOLO.	39
Figura 14 – Matriz de confusão do treinamento feito na segunda base de dados....	40
Figura 15 – Matriz de confusão normalizada do segundo experimento.	42
Figura 16 – Desempenho do modelo no segundo experimento: curvas de <i>Recall- Confiança</i> , <i>F1-Confiança</i> , <i>Precisão-Confiança</i> e <i>Precisão-Recall</i>	43

RESUMO

FRANÇA, Elzi. **Identificação de abelhas nativas no Cerrado com o uso de Inteligência Artificial**. Agosto de 2025 Dissertação – Programa de Pós-Graduação em Biodiversidade e Conservação, Instituto Federal Goiano - Campus Rio Verde. Rio Verde, GO. **Orientador:** Dr. Fernando H. Antonioli Farache. Coorientador: Dr. Sebastião C. Vasconcelos Filho

Este trabalho propôs e avaliou o uso de redes neurais convolucionais, por meio da arquitetura YOLO, para a identificação automática de abelhas nativas do Cerrado a partir de imagens, contribuindo para a conservação da biodiversidade e para o avanço de ferramentas de apoio ao monitoramento de polinizadores. Foram utilizadas imagens obtidas de diferentes fontes e devidamente rotuladas, abrangendo diversas espécies nativas. No experimento geral, o modelo alcançou métricas expressivas, com bons índices de precisão e *recall* para a maioria das espécies, evidenciando a eficiência na detecção e classificação. Adicionalmente, foi conduzido um segundo experimento restrito às espécies morfologicamente semelhantes *Trigona hyalinata* (Guaxupé) e *Trigona spinipes* (Irapuã), no qual o modelo obteve acurácia geral de 79,67%, precisão de 79,35% para Guaxupé e 80,00% para Irapuã, confirmando a capacidade de discriminação mesmo em cenários de alta similaridade visual. Os resultados demonstram a viabilidade e a robustez da abordagem, apontando o potencial para aplicação em programas de monitoramento, manejo sustentável e preservação de abelhas nativas no Cerrado.

Palavras-chave: Polinizadores; Conservação da Biodiversidade; Redes neurais convolucionais; *Deep Learning*, *YOLO*.

ABSTRACT

FRANÇA, Elzi. **Identification of native bees in the Cerrado using Artificial Intelligence**. Agosto, 2025. Dissertation – Graduate Program in Biodiversity and Conservation, Goiano Federal Institute – Rio Verde Campus. Rio Verde, GO, August 2025. **Advisor:** Dr. Fernando H. Antonioli Farache. Co-advisor: Dr. Sebastião C. Vasconcelos Filho

This study proposed and evaluated the use of convolutional neural networks, through the YOLO architecture, for automatic identification of native Cerrado bees from images, contributing to biodiversity conservation and to the advancement of tools supporting pollinator monitoring. Images obtained from different sources and properly labeled were used, covering several native species. In the general experiment, the model achieved significant metrics, with strong precision and recall rates for most species, demonstrating its efficiency in detection and classification. Additionally, a second experiment was carried out focusing on the morphologically similar species *Trigona hyalinata* (Guaxupé) and *Trigona spinipes* (Irapuã), in which the model achieved an overall accuracy of 79.67%, a precision of 79.35% for Guaxupé, and 80.00% for Irapuã, confirming its discrimination capability even in scenarios of high visual similarity. The results demonstrate the feasibility and robustness of the approach, highlighting its potential for application in monitoring programs, sustainable management, and conservation of native bees in the Cerrado.

Keywords: Pollinators, Biodiversity conservation, Convolutional neural networks, Deep Learning, YOLO.

1 INTRODUÇÃO

A biodiversidade é essencial para a manutenção da vida no planeta, fornecendo serviços ecossistêmicos indispensáveis, como a polinização, a ciclagem de nutrientes, a regulação climática e a manutenção dos solos férteis. Dentre os organismos que desempenham funções centrais nesses processos, destacam-se os polinizadores, responsáveis por assegurar a reprodução de grande parte das espécies vegetais. Estima-se que mais de 75% das plantas com flores dependam, em algum grau, da polinização realizada por insetos, aves e outros animais, sendo as abelhas os principais agentes nesse serviço ecológico (Freitas e Silva, 2015; Klink; Machado, 2005; Macedo *et al.*, 2014).

As abelhas, tanto as sociais quanto as solitárias, exercem papel estratégico na sustentabilidade dos ecossistemas e na segurança alimentar humana. Elas contribuem diretamente para a produção agrícola, aumentando a qualidade e a quantidade de frutos e sementes, ao mesmo tempo que sustentam a diversidade vegetal em ambientes naturais (Freitas e Silva, 2015). No Cerrado, considerado um dos *hotspots* mundiais de biodiversidade, esses insetos chegam a polinizar mais de 80% das espécies vegetais, configurando-se como espécies-chave na manutenção do equilíbrio ambiental (Ballivián, 2008).

Apesar dessa relevância, as populações de abelhas vêm sofrendo declínio acentuado em função de múltiplos fatores de origem antrópica. O desmatamento, a fragmentação de habitats, o avanço da fronteira agrícola, o uso intensivo de agrotóxicos e as mudanças climáticas globais comprometem a sobrevivência desses polinizadores (Aragaki, 2019; Ballivián, 2008). As consequências são amplas e afetam não apenas a biodiversidade, mas também a produção de alimentos e a saúde dos ecossistemas (Ballivián, 2008). No Brasil, o agronegócio ocupa posição central na economia, esses impactos assumem dimensões críticas, demandando estratégias inovadoras de monitoramento, conservação e manejo das populações de abelhas.

Nesse cenário, a integração entre biologia da conservação e avanços tecnológicos mostra-se promissora. Ferramentas de Inteligência Artificial (IA) têm sido aplicadas para o reconhecimento de padrões em grandes volumes de dados e oferecem potencial para

superar obstáculos históricos, como o impedimento taxonômico. Esse entrave, caracterizado pela escassez de especialistas e pela dificuldade de identificar com precisão, espécies de elevada diversidade morfológica, pode ser parcialmente mitigado pelo uso de algoritmos de visão computacional capazes de auxiliar na classificação automática de organismos

Dessa forma, o estudo das abelhas nativas do Cerrado com o apoio de sistemas de IA não apenas contribui para o avanço do conhecimento científico, mas também fortalece iniciativas de conservação da biodiversidade e de promoção da sustentabilidade. A presente dissertação insere-se nesse contexto, propondo e avaliando metodologias inovadoras para a identificação de espécies nativas, com vistas a apoiar estratégias de monitoramento e preservação de polinizadores em um dos biomas mais ameaçados do planeta.

1.1 Importância das abelhas no Cerrado

As abelhas desempenham papel essencial como polinizadoras para a conservação da biodiversidade. Elas são fundamentais no processo de reprodução de diversas plantas, garantindo a continuidade de inúmeras espécies vegetais e, conseqüentemente, dos ecossistemas que delas dependem. Esses polinizadores desempenham papel essencial na manutenção dos ecossistemas tropicais, sendo responsáveis pela polinização de mais de 50% das espécies vegetais em florestas tropicais e alcançando índices superiores a 80% no Cerrado brasileiro. (Freitas e Silva, 2015). A polinização é uma função ecológica primordial para a reprodução e preservação da diversidade das plantas, além de prover alimento tanto para seres humanos quanto para animais. Considerando as plantas cultivadas e utilizadas de forma direta ou indireta na alimentação humana, as abelhas são responsáveis pela polinização de 73% do total e de 42% das 57 espécies vegetais mais plantadas no mundo (Freitas e Silva, 2015).

O grupo das abelhas é muito diverso. No mundo são mais de 20.000 espécies de sete famílias. No Brasil estão descritas quase 2.000 espécies, mas estima-se que existam mais de 2.500 espécies de abelhas distribuídas em cinco famílias (Souza *et al.*, 2024).

Esses insetos ocupam posição expressiva como bioindicadoras de qualidade ambiental, uma vez que são altamente sensíveis às mudanças e contaminações no ecossistema. Devido à sua extensa área de forrageamento, as abelhas podem acumular substâncias tóxicas presentes no ambiente, como metais pesados e resíduos de agrotóxicos, através do pólen, néctar e água que consomem (Wolff *et al.*, 2008). O uso indiscriminado de agrotóxicos tem sido associado ao declínio acentuado das populações de abelhas, o que compromete não apenas a saúde das colônias, mas também a polinização de culturas agrícolas e a manutenção da biodiversidade. A presença e a saúde das abelhas podem revelar níveis de poluição e outros fatores que impactam o equilíbrio natural (Ballivián, 2008).

A contaminação ambiental por substâncias químicas tóxicas, representa ameaça crescente para as abelhas e seu papel na polinização (Freitas e Silva, 2015). As partículas tóxicas em suspensão podem aderir aos pelos no corpo das abelhas, sendo inaladas e até armazenadas na vesícula melífera, órgão responsável por armazenar o néctar coletado. Durante o processo de transformação do néctar em mel, essas substâncias podem contaminar o produto (Wolff *et al.*, 2008; Oliveira e Nagashima, 2018). Além de afetar a produção de mel, essas toxinas também impactam diretamente a polinização. O pólen coletado pelas abelhas, essencial para a reprodução de muitas plantas, também pode estar contaminado. Essa contaminação do pólen compromete a reprodução vegetal, com possíveis consequências devastadoras para a biodiversidade (Wolff *et al.*, 2008).

Esses insetos desempenham papel estratégico na reconstituição de florestas tropicais e na preservação da natureza (Ballivián, 2008). Apesar de seu pequeno tamanho são essenciais para o ecossistema, pois conseguem alcançar distância de voo que variam entre 600 e 2.400 metros, dependendo da espécie. Essa variação está relacionada principalmente ao tamanho corporal de cada espécie, com abelhas menores percorrendo distâncias mais curtas, enquanto as maiores podem voar vários quilômetros de distância (Ballivián, 2008). Estudos indicam que essas abelhas se concentram nas copas das árvores mais altas e antigas da floresta, sendo fundamentais para a regeneração natural e a recuperação da floresta primária. Ao contrário das abelhas africanizadas, que raramente

são vistas em florestas densas e preferem áreas desmatadas, as abelhas sem ferrão ocupam espaço vital no interior dessas florestas. Por essa razão, os meliponíneos, como são chamados, têm importância fundamental em projetos de preservação ambiental, facilitando a conexão entre fragmentos florestais remanescentes e contribuindo para a manutenção e a recuperação dos ecossistemas (Ballivián, 2008).

A perda da biodiversidade é hoje considerada uma das cinco maiores ameaças à saúde do planeta (Werthmuller, 2023). A conservação das abelhas e a continuidade dos serviços de polinização que elas proporcionam são temas de crescente relevância no contexto atual de declínio populacional de insetos. A importância das abelhas como polinizadoras é amplamente reconhecida. Estudos demonstram que, embora as abelhas melíferas (*Apis mellifera*) sejam frequentemente utilizadas como polinizadoras geridas, os polinizadores selvagens desempenham papel fundamental que não pode ser totalmente substituído por espécies domesticadas. No Brasil, das 141 espécies de plantas cultivadas para alimentação humana e produção animal, a cerca de 60% dependem em certo grau da polinização deste inseto (Rosa *et al.*, 2023; Freitas *et al.*, 2009). Considerando a relevância das abelhas para a preservação da vida e o equilíbrio sustentável do planeta é fundamental a promoção de iniciativas de proteção e gestão responsável para garantir a conservação desses polinizadores (Beringer *et al.*, 2019).

Segundo a Organização das Nações Unidas para a Alimentação e a Agricultura (FAO), 75% dos cultivos destinados à alimentação humana no mundo dependem das abelhas (Grigori, 2019). Porém, o que acontece é que há diversidade de abelhas nativas, tanto sociais quanto solitárias, que estão morrendo silenciosamente, sem ninguém se dar conta, por viverem em matas ou entornos (Aragaki, 2019).

Na Ecologia da Paisagem, pesquisas recentes têm enfatizado a influência da configuração das paisagens na composição e organização das comunidades de plantas e polinizadores, analisando esses efeitos em múltiplas escalas espaciais. De forma tradicional, as áreas de Ecologia e Biologia da Polinização concentram-se em explorar os processos de reprodução das plantas, identificando possíveis agentes polinizadores e

desenvolvendo estratégias de manejo para otimizar a polinização e os retornos econômicos associados. Paralelamente, as investigações em Genética de Populações têm complementado esse campo, aprofundando o entendimento das interações entre plantas e polinizadores e considerando medidas práticas para a conservação e o manejo sustentável, além de cultivo a colaboração interdisciplinar em Ciências Biológicas e áreas afins. O papel desempenhado pelas abelhas é fundamental para preservar a diversidade vegetal e a flora nativa, que, por sua vez, sustentam a fauna dependente desses recursos. Proporcionar mais locais adequados para a nidificação dessas abelhas é uma ação direta em prol da conservação da biodiversidade, garantindo que a flora e a fauna, em interação com outros organismos, continuem a sustentar o equilíbrio ambiental (Silva e Paz, 2012).

O Cerrado, considerado o segundo maior bioma do Brasil, é um ecossistema de grande relevância para a biodiversidade mundial. Ele representa a cerca de 5% de toda a diversidade biológica do planeta, abrangendo ampla variedade de flora e fauna, além de abrigar aproximadamente um terço da biodiversidade brasileira. O Cerrado se destaca por possuir uma das mais ricas diversidades de espécies vegetais vasculares do mundo (Scariot, *et al.*, 2005). Reconhecido internacionalmente como uma formação de savana, o Cerrado está localizado, em sua maior parte, no planalto central do Brasil, abrangendo principalmente os estados de Goiás, Bahia, Minas Gerais, Mato Grosso e Mato Grosso do Sul. Assim, a distribuição das espécies nessas regiões resulta em rica diversidade de mosaicos (Scariot, *et al.*, 2005).

Referido bioma possui enorme diversidade em sua vegetação, tanto em termos de fisionomia quanto de espécies. As diferentes formações do cerrado variam em densidade e altura, formando um gradiente que vai de campos abertos até áreas florestais densas. Estima-se que a flora seja composta por cerca de 1.000 a 2.000 espécies de árvores e arbustos, além de 2.000 a 5.250 espécies de plantas herbáceas e subarbustivas. No entanto, assim como ocorre em outros países tropicais que exploram intensamente os recursos florestais, o Brasil tem enfrentado manipulação contínua e crescente da vegetação original provocando a perda da biodiversidade (Borges e Shepherd, 2005).

A intervenção humana no Cerrado resultou em perda significativa de biodiversidade. O cenário que predomina atualmente é a substituição da vegetação original por espécies exóticas, impulsionada pela expansão da agricultura, criação de pastagens, desmatamento e queimadas (Macedo *et al.*, 2014). Ações como queimadas, exploração seletiva de madeira, pastoreio e introdução de espécies não nativas, levam à fragmentação das florestas, alterando profundamente a dinâmica natural. Uma característica marcante do Cerrado é a presença de alto índice de espécies endêmicas, assim, quando ocorre a intervenção humana, grande parte dessa riqueza biológica está comprometida, incluindo espécies que poderiam ser aproveitadas para fins benéficos, como plantas com potencial para fármacos e fitoterápicos (Macedo *et al.*, 2014). O Cerrado se destaca pela impressionante biodiversidade, possuindo um número de plantas vasculares que supera o de muitas outras regiões ao redor do mundo. O bioma é caracterizado por ampla variedade de habitats e alternância marcante de espécies (Klink; Machado, 2005; Macedo *et al.*, 2014).

O monitoramento e a avaliação da biodiversidade figuram entre os mais relevantes e urgentes desafios da biologia contemporânea, sobretudo diante do acelerado desaparecimento de ambientes naturais e das profundas alterações que a perda de espécies tem causado no funcionamento dos ecossistemas (Meier *et al.* 2021), a rápida perda da biodiversidade em escala global, aliada às mudanças climáticas, evidencia a necessidade urgente de descrever, classificar e compreender os organismos vivos (Engel *et al.*, 2021). Essa disparidade — marcada pelo aumento da demanda por conhecimento taxonômico e pela redução da capacidade científica para atendê-la — é comumente denominada de “impedimento taxonômico” (Carvalho *et. al.*, 2007).

1.2 Impedimento Taxonômico

O impedimento taxonômico, caracterizado pela escassez de especialistas e pela dificuldade no acesso a informações taxonômicas, compromete a identificação precisa de espécies e torna especialmente desafiadora a identificação de grupos megadiversos como os artrópodes (Carvalho *et al.*, 2007; Meier *et al.*, 2021; Wheeler *et al.*, 2004). No

caso das abelhas, esse desafio é agravado pela alta diversidade, semelhanças morfológicas entre espécies, dimorfismo sexual, presença de espécies crípticas — organismos morfolologicamente semelhantes, mas geneticamente distintos — representa um desafio significativo para a taxonomia e intensifica o impedimento taxonômico. A identificação dessas espécies exige métodos avançados, como análises moleculares, bioacústicas ou comportamentais, que demandam recursos financeiros, infraestrutura e especialistas, frequentemente escassos no Brasil. Essa limitação resulta na subestimação da biodiversidade, na formulação de planos de manejo imprecisos e na possível perda silenciosa de espécies não reconhecidas formalmente, tornando indispensável o uso de ferramentas moleculares e tecnológicas para acelerar e aprimorar o processo de identificação (OLIVEIRA *et al.*, 2012)

Diante das limitações associadas a este impedimento, o uso de tecnologias avançadas, como inteligência artificial (IA) e redes neurais convolucionais, *convolutional neural networks* (CNNs), desponta como uma alternativa promissora. As CNNs destacam-se como ferramenta eficaz e precisa para a identificação de espécies de abelhas e outros insetos. Essa estratégia tecnológica permite que qualquer indivíduo identifique a espécie a partir de uma imagem, de maneira ágil e confiável. Assim, as redes neurais convolucionais diferenciam-se de outros tipos de redes neurais pelo desempenho superior na análise de dados como imagens, fala ou sinais de áudio (IBM, 2023), oferecendo uma solução para as limitações dos métodos manuais.

Assim, ao implementar redes neurais convolucionais para a identificação e categorização de espécies de abelhas presentes no cerrado, busca-se auxiliar na preservação desses importantes polinizadores. Além disso, essa tecnologia visa simplificar e acelerar o processo de identificação para pesquisadores, meliponicultores, agricultores etc., oferecendo um sistema de identificação ágil, eficiente e confiável. Reconhecer e documentar as abelhas nativas do Cerrado é um passo essencial para a preservação de seus serviços ecossistêmicos, contribuindo não apenas para a conservação da biodiversidade, mas também para o fortalecimento do conhecimento científico e o desenvolvimento sustentável da região.

1.3 A Inteligência Artificial e sua contribuição para a Taxonomia

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 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 e 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 às de um ser humano. Dessa forma, um computador pode executar tarefas que anteriormente eram exclusivas do homem (Silva e Mairink, 2019).

1.4 Redes Neurais

Uma rede neural é um processador maciço e paralelamente 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 assemelha-se ao cérebro em dois aspectos: O seu conhecimento é adquirido através de um processo de aprendizagem, e as forças de conexão entre neurônios, os pesos sinápticos, armazenam o conhecimento aprendido (Haykin, 2001).

As redes neurais podem possuir múltiplas camadas para o processamento de dados como demonstrado na figura 1, sendo: (I) Camada de Entrada: Recebe as informações iniciais e as distribui para as (II) camadas ocultas; (III) 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; (IV) Camada de Saída: Produz a solução do problema, com o número de neurônios correspondendo ao número de (V) saídas desejadas.




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

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).

1.5 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. Impulsionado pelo surgimento das GPUs (*Graphics Processing*

Unit) ou Unidade de Processamento Gráfico, pela ampla disponibilidade de grandes conjuntos de dados e pelo desenvolvimento de bibliotecas de software flexíveis e de código aberto, como *Theano*, *Torch*, *Caffe*, *TensorFlow* e *PyTorch* (Bengio *et al.*, 2021).

A aplicação do *Deep Learning* demonstrou-se eficaz em diversas áreas, como a medicina, que é empregado na classificação de imagens com alta precisão e confiabilidade diagnóstica (Castiglioni *et al.*, 2021), esses avanços tornaram o treinamento de redes neurais profundas mais acessível e eficiente, viabilizando a automatização da extração de características em imagens. No presente trabalho, tais recursos foram empregados para identificar espécies de abelhas nativas do Cerrado, permitindo que o modelo aprenda padrões visuais complexos e realize a classificação de forma precisa, mesmo diante de variações sutis ou características morfológicamente semelhantes. Essa abordagem contribui não apenas para o avanço tecnológico na identificação de polinizadores, mas também para a conservação da biodiversidade e para a formulação de estratégias de manejo mais eficazes em um bioma de elevada relevância ecológica, cuja manutenção depende diretamente da ação de polinizadores (Giannini *et al.*, 2012; Imperatriz-Fonseca *et al.*, 2012; Silveira *et al.*, 2002). Estudos recentes já demonstram o potencial do *Deep Learning* na identificação automática de abelhas e outros polinizadores a partir de imagens, alcançando altos índices de acurácia e possibilitando monitoramento em larga escala (Oliveira *et al.*, 2012).

1.6 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 *et al.*, 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 *et al.*, 2016).

Para a classificação das espécies de abelhas, utilizou-se uma Rede Neural Convolucional (*Convolutional Neural Network* – CNN), uma arquitetura derivada das redes *Perceptron* de Múltiplas Camadas, inspirada no modelo biológico de processamento visual (Vargas *et al.*, 2016). As CNNs são projetadas para processar dados visuais, preservando as relações espaciais entre *pixels* adjacentes, favorecendo a extração de padrões em imagens durante o treinamento da rede. Essas redes são compostas por múltiplas camadas funcionais, sendo a camada de convolução responsável pela aplicação de filtros que extraem características específicas de regiões da imagem. Cada filtro atribui pesos aos *pixels* com os quais se conecta e gera uma saída que é propagada para as camadas subsequentes, permitindo o aprendizado progressivo de representações visuais relevantes (Vargas *et al.*, 2016).

Reconhecendo que o desempenho dos modelos de CNN pode ser prejudicado por fatores como a similaridade morfológica entre espécies de insetos e a baixa qualidade das imagens (HANSEN *et al.*, 2019), este trabalho priorizou a construção de uma base de dados composta por imagens representativas de diferentes espécies de abelhas nativas. Essa medida visou mitigar limitações comuns na classificação automática e maximizar a acurácia do modelo.

2 OBJETIVOS

2.1 Objetivo geral

Este trabalho tem por objetivo o treinamento e avaliação da eficiência de uma rede neural convolucional para detecção e classificação de espécies de abelhas nativas do cerrado de forma a auxiliar em análises ambientais, ecológicas e de conservação da biodiversidade que demandem identificação rápida e precisa por meio de fotografias ou vídeos.

2.2 Objetivos específicos

- i. Coletar e organizar imagens de abelhas nativas do Cerrado a partir de bases de dados como *iNaturalist*, *Biodiversity4All* e registros fotográficos próprios;
- ii. Anotar e processar as imagens coletadas utilizando a ferramenta *Roboflow*, estabelecendo um conjunto de dados consistente para o treinamento da rede neural;
- iii. Treinar e validar modelos de aprendizado profundo, com ênfase na arquitetura YOLO, para identificar visualmente a espécie-alvo;
- iv. Avaliar o desempenho do modelo utilizando diferentes métricas como precisão, *recall*, *F1-score* e comparando com resultados obtidos em estudos similares;
- v. Discutir as contribuições do sistema para a conservação da biodiversidade, destacando o potencial de uso da inteligência artificial como ferramenta de apoio à taxonomia e monitoramento de polinizadores nativos.

3 MATERIAL E MÉTODOS

3.1 Seleção de Grupos Taxonômicos e aquisição de imagens

Para este trabalho foram selecionadas espécies de abelhas nativas do Cerrado, com o objetivo de amostrar a diversidade de grupos amplamente conhecidos, bem como incluir espécies morfológicamente similares e de difícil distinção. Foram selecionados os seguintes táxons descritos na tabela 1. Foram escolhidas espécies comuns no cerrado e de importância para a polinização e produção de mel. Além de incluir espécies bem diferentes como *Melipona quadrifasciata* e *Trigona spinipes* foram incluídas espécies bem similares e que ocorrem em simpatria como a *Trigona spinipes* e *Trigona hyalinata* (Anacleto e Marchini, 2005).

Tabela 1: Espécies analisadas neste estudo.

Nome científico	Nome popular
<i>Nannotrigona testaceicornis</i> (Lepeletier, 1836)	Iraí
<i>Melipona quadrifasciata</i> , Lepeletier, 1836	Mandaçaia
<i>Scaptotrigona polysticta</i> , Moura, 1950	Benjoi
<i>Trigona spinipes</i> (Fabricius, 1793)	Irapuã
<i>Tetragonisca angustula</i> (Latreille, 1811)	Jataí
<i>Paratrigona subnuda</i> , Moure, 1947	Jataí-da-terra
<i>Trigona pallens</i> (Fabricius, 1798)	Olho de vidro
<i>Trigona hyalinata</i> (Lepeletier, 1836)	Guaxupé

Fonte: Elaborada pela autora (2025).

3.2 Protocolo para aquisição de imagens

Foi criada uma base de dados a partir de imagens obtidas da plataforma *iNaturalist* (iNaturalist.org) e *Biodiversity4All* (biodiversity4all.org), comunidades globais de ciência-cidadã que reúnem observações georreferenciadas de biodiversidade feitas por usuários voluntários, incluindo pesquisadores, fotógrafos, naturalistas e entusiastas da natureza. O site funciona como um repositório colaborativo em que os participantes compartilham registros fotográficos de seres vivos — como animais, plantas, fungos e, no caso desta pesquisa, abelhas — junto com informações relevantes como localização, data e sugestões de identificação taxonômica.

Para acessar esse conteúdo de forma automatizada, foi desenvolvido um algoritmo em linguagem *Python* (versão 3), utilizando requisições à API pública do *iNaturalist*. Esse código permitiu extrair imagens específicas de espécies de abelhas previamente selecionadas com base em seu identificador único na base de dados da plataforma. A API retornava metadados em formato JSON, a partir dos quais eram extraídas as URLs das imagens em alta resolução, que então foram baixadas e armazenadas localmente em diretórios organizados por espécie.

Esse processo possibilitou a coleta eficiente de grandes volumes de imagens (tabela 2), respeitando os critérios de licença de uso e atribuição com observações à Nível de Pesquisa – possuem mídia, localização, uma data e consenso da comunidade sobre a identificação precisa (geralmente a nível de espécie). Além de garantir a diversidade morfológica entre os registros (variações de ângulo, iluminação, ambiente etc.), essa abordagem reduziu significativamente o tempo necessário para a montagem da base de dados, permitindo ao mesmo tempo a curadoria manual para exclusão de imagens de baixa qualidade, duplicadas ou que não correspondessem à espécie-alvo.

Com o algoritmo criado foi possível conseguir muitas imagens da mesma espécie de abelha de uma única vez. Para o funcionamento adequado deste algoritmo foi preciso procurar a espécie pretendida no site do *iNaturalist* e *Biodiversity4All*, localizar seu código identificador nos 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 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.

Lista 1 – Código em *Python* usado para baixar imagens em massa do *iNaturalist*.

```
import json
from urllib.request import urlopen
import os

# URL da API do iNaturalist para obter as imagens
url = 'https://www.inaturalist.org/observations.json?parameters='

# requisitar dados da API
response = urlopen(url)
data = json.loads(response.read())

# Local para salvar as imagens
output_dir = '/path/to/save/images'
os.makedirs(output_dir, exist_ok=True)

# Percorrer e salvar as imagens
for observation in data:
    for photo in observation.get('photos', []):
        photo_url = photo.get('large_url')
        if photo_url:
            # Baixar a imagem e salvar no local escolhido with urlopen(photo_url) as img_response:
            filename = os.path.join(output_dir, os.path.basename(photo_url))
            with open(filename, 'wb') as img_file:
                img_file.write(img_response.read())
            # Baixar a imagem e salvar no local escolhido with urlopen(photo_url) as img_response:
            filename = os.path.join(output_dir, os.path.basename(photo_url))
            with open(filename, 'wb') as img_file:
                img_file.write(img_response.read())
```

Fonte: elaborado pela autora (2025).

Tabela 2: Número de fotos coletadas cada espécie.

Nome científico	Nome popular	Quantidade de imagens
<i>Nannotrigona testaceicornis</i>	Iraí	736
<i>Melipona quadrifasciata</i>	Mandaçaia	347
<i>Scaptotrigona polysticta</i>	Benjoi	278
<i>Trigona spinipes</i>	Irapuã	2.904
<i>Tetragonisca angustula</i>	Jataí	2.506
<i>Paratrigona subnuda</i>	Jataí-da-terra	1.110
<i>Trigona pallens</i>	Olho de vidro	235
<i>Trigona hyalinata</i>	Guaxupé	1.037

Fonte: elaborado pela autora (2025).

O processo de catalogação das imagens envolveu a abertura de cada imagem individualmente, em que se desenhou manualmente uma caixa delimitadora ao redor das abelhas presentes na imagem (Figura 2). As coordenadas dessas caixas foram convertidas em etiquetas (*labels*) ou anotações, que representaram as localizações e dimensões dos objetos de interesse.



Figura 2: Caixa delimitadora ao redor da abelha
Fonte: elaborado pela autora (2025).

As *labels* geradas durante a catalogação no *Roboflow* foram rotuladas e utilizadas no treinamento da rede neural usando a arquitetura YOLO (*You Only Look Once*). A YOLO usou essas caixas delimitadoras para identificar as abelhas em novas imagens, prevendo as 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.

3.3 Treinamento da Rede Neural

Para a classificação das espécies, foram testadas diferentes versões da arquitetura YOLO (YOLOv8, YOLOv9, YOLOv10, YOLOv11 e YOLOv12). A análise comparativa de desempenho indicou que a versão YOLOv8 apresentou os melhores resultados nos testes preliminares com diferentes *datasets*, sendo, portanto, selecionada para as etapas subsequentes do estudo, concentrando-se nela todo o desenvolvimento e os ajustes posteriores do modelo.

A YOLOv8 (Figura 3) é uma versão aprimorada de seus predecessores para detecção de objetos, e sua estrutura é composta por três partes principais:

- i. *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*.
- ii. *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.
- iii. *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.




Figura 3: Estrutura da arquitetura Yolo.
Fonte: Adaptado de (TORRES, 2024).

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).

A base de dados utilizada para o treinamento do modelo foi composta por imagens, nas quais o número de abelhas por fotografia variava. Algumas imagens apresentavam apenas um indivíduo, enquanto outras continham múltiplos exemplares de uma mesma espécie (Figura 4). Essa heterogeneidade impossibilitou o balanceamento do conjunto apenas com base na quantidade de imagens por espécie, sendo necessário considerar o número de objetos (abelhas) para essa finalidade.




Figura 4: Imagens utilizadas para treinamento da rede neural.
Fonte: elaborado pela autora (2025).

Essa heterogeneidade impossibilitou o balanceamento do conjunto apenas com base na quantidade de imagens por espécie, sendo necessário considerar o número de objetos (abelhas) para essa finalidade.

O critério de balanceamento adotado foi estabelecer aproximadamente 200 abelhas de cada espécie no conjunto de dados. Esse valor foi definido em função da espécie *Melipona quadrifasciata* (Mandaçaia), que possuía o menor número de registros disponíveis, de modo a evitar discrepâncias acentuadas na distribuição das classes.

Após o balanceamento, foi realizado novo treinamento. O conjunto de dados final foi dividido em 245 imagens para treinamento, 88 para validação e 42 para teste. As métricas de desempenho foram calculadas exclusivamente com base nas imagens de teste, enquanto as demais foram utilizadas para o ajuste dos parâmetros do modelo.

Durante a etapa de anotação, buscou-se minimizar a inclusão excessiva de áreas de fundo nas caixas delimitadoras (*bounding boxes*), uma vez que a rede neural interpreta todo o conteúdo da caixa como parte do objeto de interesse.

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 $\times$ 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*).

3.4 Avaliação do Modelo, validação e análises estatísticas

Para a avaliação da rede neural devidamente treinada, foram utilizadas as principais métricas de avaliação, precisão, *recall* e *F1-score*. As métricas de avaliação do desempenho de um treinamento são várias. E todas essas medidas são construídas a partir de uma matriz de confusão - tabela que indica os acertos e os erros do modelo treinado, comparando com o resultado esperado - 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 3 mostra como são organizado esta estrutura (Sokolova *et al.*, 2006).

Tabela 3: Matriz de Confusão. Tabela adaptada de (Mariano, 2024).

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

Fonte: elaborado pela autora (2025).

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:

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

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

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

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.

4 RESULTADOS

4.1 Primeiro Experimento

No primeiro treinamento da CNN, foi utilizada uma base de dados composta por oito classes, cada uma representando uma espécie de abelha. Essas imagens foram coletadas de diferentes fontes, incluindo o site *inaturalist.org* e *biodiversity4all.org* além das contribuições da estudante de mestrado Geni Alexandria de Moraes e o estudante da Graduação Wésio Pascoal Messias Coelho, e de imagens próprias adquiridas na região de Rio Verde-Go.

A qualidade das imagens utilizadas para treinar a rede neural é fator determinante no desempenho do modelo. Por isso, adotou-se uma abordagem criteriosa na curadoria do conjunto de dados. Além da obtenção automatizada via API do *iNaturalist*, as imagens foram submetidas a uma triagem manual, com exclusão de registros com baixa resolução, desfoque acentuado ou obstrução parcial do corpo da abelha. Essa triagem visou assegurar que as informações visuais mais relevantes — como cor, padrões do exoesqueleto, formato das asas e estrutura corporal — estivessem bem definidas para que o modelo pudesse aprender essas características de forma eficiente.

Durante a fase de anotação, foram priorizadas imagens que permitissem delimitação precisa das abelhas no campo visual. As caixas delimitadoras foram ajustadas manualmente para capturar a área mínima necessária que englobasse a abelha inteira, minimizando ruído de fundo. A consistência dessas anotações foi verificada em amostras aleatórias por múltiplas vezes, a fim de garantir a integridade dos dados rotulados e reduzir vieses de anotação que poderiam afetar negativamente a capacidade de generalização do modelo.

Apesar do objetivo de construir uma base de dados equilibrada, com o mesmo número de imagens por classe, o resultado foi uma base desbalanceada. Algumas espécies possuíam poucas imagens disponíveis, enquanto outras superaram a meta inicial, gerando o total de mais de 1000 *labels* para algumas classes, como ilustrado na Figura 5.




Figura 5: 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* ocorreu porque muitas imagens catalogadas nessa primeira base de dados eram de colmeias, permitindo identificar e rotular várias abelhas em uma única imagem, como é possível observar na figura 6.



Figura 6: Imagem da espécie *Tetragonisca angustula* (Jataí) catalogada na primeira base de dados.

Fonte: Própria gerada no *Roboflow* (2025).

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 (10ª geração) com duração aproximada de 18 horas. O treinamento gerou precisão

insatisfatória na identificação das espécies, podendo ser observado na matriz de confusão da figura 7.

A matriz indica alta taxa de erros, especialmente na classe *background* - que representa o fundo da imagem, e foi confundida com espécies em várias ocasiões. Isso reflete a baixa capacidade do modelo em distinguir corretamente as espécies de abelhas do fundo em que elas se encontram.




Figura 7 – Matriz de Confusão de primeira base de dados.

Fonte: elaborado pela autora (2025).

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, por causa da coloração escura, sendo 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 baixa precisão nestas classes, e essa base de dados foi descartada.

4.1.1 Segunda base de dados

Devido ao desbalanceamento da primeira base de dados, tornou-se necessário criar uma nova, contendo apenas espécies que tinham quantidade de imagens disponíveis e suficientes para catalogar, em média, 200 abelhas por classe.

Essa nova base de dados foi criada com foco no balanceamento das *labels*, assegurando uma quantidade uniforme de boxes catalogadas por classe. 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 melhor detecção das espécies de abelhas. As técnicas de *augmentation* utilizadas incluíram:

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




Figura 8: Aplicação de tons de cinza e efeito isolado de rotação

Fonte: Própria gerada no *Roboflow* (2025).

Complementarmente, foi realizada uma análise de sensibilidade para compreender o impacto de diferentes combinações de técnicas de *data augmentation* nas métricas de desempenho. Testou-se, por exemplo, o efeito isolado da rotação, da aplicação de tons de cinza (figura 8) e do cisalhamento, bem como suas combinações, o que contribuiu para identificar o melhor conjunto de transformações a ser aplicado nas imagens da base de dados balanceada. Esses testes revelaram que a combinação de todas as técnicas mencionadas resultou em maior robustez do modelo em relação à variação de posição e iluminação das abelhas nas 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 (figura 9) apresentou um baixo valor de verdadeiros positivos, como mostrado na Figura 10. Para melhorar seu desempenho, foram aplicadas as três técnicas listadas acima.




Figura 9: Imagem da espécie *Trigona spinipes* (Irapuã) antes de aplicar técnicas de *data augmentation*.
Fonte: Própria gerada no Roboflow (2025).




Figura 10 – Matriz de confusão da primeira base de dados antes de aplicar técnicas de *data augmentation*.

Fonte: elaborado pela autora (2025).

A segunda base, a princípio, tinha a média aproximada de 200 *labels* catalogados por espécie como mostrado na figura 11. Isso garantiu a 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. Depois de aplicar as técnicas de *augmentation* a base expandiu para 1.527 imagens e aproximadamente 480 anotações por classe.




Figura 11: Visão geral do número de *labels* por classe da segunda base de dados.

Fonte: Própria e retirada do Roboflow (2025).

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. e confirmaram desempenho satisfatório. O modelo alcançou precisão a 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 bom equilíbrio entre a capacidade de prever corretamente as classes e a cobertura das amostras.

A análise da matriz de confusão indicou que o modelo apresentou bom desempenho na identificação das espécies, com poucos erros de classificação entre classes distintas. Para a espécie *Trigona spinipes* (Irapuã), registraram-se 29 acertos e apenas um erro, este resultante de confusão com *Tetragonisca angustula* (Jataí-da-terra). Esta última apresentou elevado número de acertos, enquanto *Oxytrigona tataira* (Olho-de-vidro) foi, ocasionalmente, confundida com *Tetragonisca angustula* (Jataí), e pode ser considerado plausível pela semelhança morfológica entre ambas. A Irapuã foi confundida apenas com a Jataí-da-terra.

Um fator recorrente foi a confusão com o *background* das imagens. Tal ocorrência foi atribuída à semelhança cromática entre as abelhas e o substrato, sobretudo

em imagens de colmeias, nas quais a cor do material se assemelha à coloração do corpo dos insetos. Esse fator dificulta a detecção mesmo para observadores humanos. Embora todas as espécies tenham apresentado algum grau de confusão com o fundo, o nível de confiança dessas classificações equivocadas foi geralmente baixo.

O uso de fotografias provenientes de armadilhas, com fundo branco padronizado, mostrou-se vantajoso, pois possibilitou a exclusão do fundo e o isolamento do indivíduo. Entretanto, esse tipo de registro foi limitado às espécies Irapuã e Jataí.

A análise evidenciou que o modelo apresentou bom desempenho em imagens com contraste favorável entre o inseto e o ambiente, especialmente em ambientes naturais, como flores e folhas, que proporcionam melhor separação visual. Por outro lado, em registros de colmeias de Jataí e Jataí-da-terra, nas quais as abelhas estavam aglomeradas ou parcialmente visíveis, a taxa de confiança foi reduzida. Nessas situações, o reconhecimento foi dificultado pelo formato e pela disposição das abelhas, frequentemente visíveis apenas de forma parcial.

Os gráficos apresentados na Figura 12 ilustram o comportamento das perdas (*losses*) durante o treinamento e a validação. Observa-se em geral a redução gradual dos *losses*, tanto no treinamento quanto na validação, refletindo um aprendizado eficiente do modelo ao longo das épocas.




Figura 12: Gráficos resultantes do treinamento/validação e gerado pela YOLO

Fonte: elaborado pela autora (2025).

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.

Quanto à precisão e ao *recall* (figura 13), observa-se que ambos não se estabilizam, mas apresentam grande variação, 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, pode-se 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 desempenho sólido e aceitável.




Figura 13: Gráficos resultantes do treinamento e gerado pela YOLO.

Fonte: elaborado pela autora (2025).

Ao analisar a matriz de confusão apresentada na Figura 14, é possível observar que algumas espécies, como a Mandaçaia, apresentaram alto número de verdadeiros positivos (VP). Esse número é consequência do tamanho relativamente grande da espécie, o que facilitou a detecção pelo modelo. Por outro lado, a Irapuã, espécie menor que a Mandaçaia 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.




Figura 14: Matriz de confusão do treinamento feito na segunda base de dados.

Fonte: elaborado pela autora (2025).

Outra espécie que vale ressaltar é a Olho-de-Vidro, que tem coloração marrom e, mesmo assim, apresentou baixa precisão. Esse resultado ocorreu porque a classe possui imagens de baixa qualidade e sua cor pode ser facilmente confundida com o fundo de imagens com tons marrons, uma cor comum e encontrada em fotos que mostram solos e terras. Com base nos resultados obtidos, verifica-se que o modelo de rede neural treinado demonstrou elevada eficiência na detecção de abelhas e na diferenciação das espécies, desde que treinado com um conjunto de imagens representativo, de alta qualidade e com bom contraste entre a coloração do fundo e a do inseto. Observou-se que imagens de colmeias não são indicadas para essa tarefa, em razão do baixo contraste entre o material da colmeia e o corpo das abelhas, o que dificulta o reconhecimento.

4.2 Segundo experimento

Considerando o bom desempenho alcançado com diferentes espécies, foi conduzido um novo experimento restrito a duas espécies morfologicamente semelhantes — *Trigona hyalinata* (Guaxupé) e *Trigona spinipes* (Irapuã) — com o objetivo de avaliar a capacidade do modelo em distingui-las. Foram utilizadas 1.037 imagens da *Trigona hyalinata* (Guaxupé) e 1.212 imagens da *Trigona spinipes* (Irapuã)

A base de dados utilizada nesse experimento foi dividida em 71% para treinamento (626 imagens), 15% para validação (132 imagens) e 15% para teste (129 imagens) de cada espécie. Conforme apresentado na Figura 15, o modelo alcançou 80,22% de acurácia para a espécie Guaxupé, com apenas 0,5% de detecções equivocadas como Irapuã. Para a espécie Irapuã, a acurácia foi de 79,13%, havendo apenas 0,04% de confusão com a Guaxupé. Esses resultados corroboram as análises anteriores, demonstrando que o modelo treinado não apresentou dificuldades significativas na diferenciação entre espécies, exceto em imagens com baixa nitidez ou em fundos cuja coloração se assemelhava ao corpo das abelhas.

A matriz de confusão normalizada (figura 15) demonstra que o modelo apresenta bom desempenho na identificação da espécie Guaxupé (86% de acertos) e da espécie Irapuã (74% de acertos), embora ocorram erros de classificação entre elas e com a classe “background”. Observa-se, contudo, que a classe “background” apresenta desempenho

inferior, com maior proporção de predições incorretas, indicando que o modelo ainda encontra dificuldade em diferenciar elementos de fundo das abelhas-alvo, o que pode impactar a precisão geral.




Figura 15 – Matriz de confusão normalizada do segundo experimento.

Fonte: elaborado pela autora (2025).

Observa-se na figura 16 que a Guaxupé mantém valores de *recall* ligeiramente superiores em praticamente toda a faixa de confiança, indicando maior sensibilidade do modelo para essa espécie. À medida que o limiar de confiança aumenta, o *recall* de ambas as classes diminui, evidenciando o impacto da filtragem mais rigorosa nas detecções, até convergirem para valores próximos a zero em níveis de confiança muito altos.




Figura 16: Desempenho do modelo no segundo experimento: curvas de Recall-Confiança, F1-Confiança, Precisão-Confiança e Precisão-Recall.

Fonte: elaborado pela autora (2025).

A avaliação de desempenho do modelo, considerando as métricas de *Precision*, *Recall*, *F1-score* e a curva *Precision-Recall*, evidencia comportamento consistente na distinção entre as espécies Guaxupé e Irapuã ao longo de diferentes limiares de confiança. A curva *Recall-Confidence* demonstra que a Guaxupé mantém sensibilidade ligeiramente superior, sobretudo em níveis intermediários de confiança, enquanto a Irapuã apresenta maior estabilidade no F1-score, conforme observado na curva *F1-Confidence*. Na análise da *Precision-Confidence*, a Irapuã atinge valores mais elevados de precisão em praticamente toda a faixa de confiança, indicando menor incidência de falsos positivos para essa classe. Por fim, a curva *Precision-Recall* revela desempenho geral equilibrado, com médias de 0,849 para Guaxupé, 0,870 para Irapuã e 0,860 de

mAP@0.5 para ambas as classes, demonstrando a robustez do modelo e a capacidade de manter alto desempenho mesmo diante de variações no limiar de decisão. O modelo apresenta 86% de precisão média, isso significa que as detecções são consideradas corretas quando a sobreposição entre a caixa delimitadora prevista e a anotada atinge pelo menos 50% da área, evidenciando bom equilíbrio entre precisão e *recall* para ambas as classes analisadas.

5 DISCUSSÃO

Embora os resultados obtidos nesta pesquisa, no primeiro experimento com uma precisão a 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% e, no segundo experimento com precisão de 100% com 71% de confiança, um *recall* de 96% e um *F-score* de 90%, demonstrem que o modelo teve 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.

Apesar disso, a presente investigação obteve resultados significativos mesmo com uma base de dados menor. A limitação da base de dados adotada nesta análise foi causada pela dificuldade em encontrar grandes quantidades de imagens de abelhas nativas, restringindo a disponibilidade de dados para treinamento. Em comparação com outros estudos que também utilizam bases menores, como o de Hansen *et al.* (2019), cujo modelo atingiu a precisão de apenas 51,9%, os resultados deste estudo mostram-se superiores. Esses avanços demonstram que, embora o modelo proposto se baseie em um conjunto de dados mais restrito, ele foi capaz de gerar boa classificação e identificação, destacando a eficácia da arquitetura YOLO.

Dessa forma, a rede neural treinada, não apenas confirma o potencial para a classificação de espécies de abelhas, alcançando resultados superiores aos trabalhos relacionados mesmo quando exposto ao problema complexo com a distinção entre as abelhas Guaxupé e Irapua que são muito semelhantes entre si, mas também sugere que a ampliação da base de dados pode melhorar os resultados. A limitação da base de dados aqui utilizada foi resultado da baixa disponibilidade de imagens de abelhas nativas do Cerrado, fator que reduziu a quantidade de dados para o treinamento.

Por sua vez, os resultados alcançados, ao serem comparados com os de trabalhos que também empregaram bases menores, como o estudo de Hansen *et al.*, (2019), que obteve a precisão de 51,9%, reforçam a aplicabilidade do modelo em classificações complexas de espécies com dados mais limitados. Essa estratégia, utilizando a arquitetura YOLOv8 e uma rotulação criteriosa das imagens, mostrou-se eficiente.

Em síntese, os resultados apresentados confirmam a aplicabilidade da abordagem proposta e fortalecem o papel das redes neurais convolucionais como ferramentas inovadoras para a conservação da biodiversidade, especialmente na classificação automatizada de abelhas nativas.

6 CONCLUSÃO

Foram coletadas, organizadas e rotuladas mais de 6.000 imagens de abelhas nativas do Cerrado, utilizadas para treinar a rede neural destinada à identificação das espécies. O modelo treinado foi avaliado utilizando as métricas Matriz de Confusão, Precisão, *Recall*, *F1-Score*, obtendo resultados robustos mesmo diante das limitações de disponibilidade e qualidade das imagens.

O presente estudo evidenciou o potencial da Inteligência Artificial para a identificação automatizada de espécies de abelhas nativas do Cerrado. A aplicação da arquitetura YOLO demonstrou-se eficaz na classificação das imagens, alcançando, no primeiro experimento (com todas as espécies), precisão de aproximadamente 79%, *recall* de 62% e F1-score de 69%, resultados sólidos considerando a base de dados utilizada e as dificuldades inerentes à obtenção de registros de alta qualidade e representatividade.

As dificuldades enfrentadas, como a desproporcional disponibilidade de imagens por espécie e a qualidade visual dos registros, foram superadas com estratégias de *data augmentation* e com a criação de uma base de dados balanceada. Isso possibilitou ao modelo aprender padrões visuais relevantes mesmo em contextos de espécies morfologicamente semelhantes.

No segundo experimento, restrito às espécies *Trigona hyalinata* (Guaxupé) e *Trigona spinipes* (Irapuã), foram obtidas acurácias de 80,22% para Guaxupé e 79,13% para Irapuã, com 71% de confiança, um *recall* de 96% e um F-score de 90%, evidenciando equilíbrio entre precisão e *recall* e confirmando a robustez do modelo em cenários de maior complexidade taxonômica. Esses resultados demonstram que a abordagem é capaz de distinguir espécies semelhantes com elevado grau de acerto, reforçando a aplicabilidade em situações de identificação de espécies crípticas.

A capacidade de identificação automatizada contribui diretamente para a conservação da biodiversidade, facilitando o trabalho de pesquisadores, agricultores e demais interessados na proteção das abelhas nativas. Ademais, este estudo inaugura caminhos promissores para aplicações de IA em contextos ambientais, revelando nova perspectiva sobre o monitoramento de polinizadores em ecossistemas ameaçados, como é o caso do Cerrado brasileiro.

REFERÊNCIAS

ANACLETO, D.A. e MARCHINI, L.C. **Análise faunística de abelhas (Hymenoptera, Apoidea) Coletadas no Cerrado do Estado de São Paulo**. Departamento de Entomologia, Fitopatologia e Zoologia Agrícola, Escola Superior de Agricultura “Luiz de Queiroz” (Esalq), Universidade de São Paulo (USP) São Paulo, 2005. Disponível em https://www.researchgate.net/publication/247915472_Analise_faunistica_de_abelhas_Hymenoptera_Apoidea_coletadas_no_cerrado_do_estado_de_Sao_Paulo. Acesso em agosto de 2025.

ARAGAKI, C. **Morte de meio bilhão de abelhas é consequência de agrotóxicos**. 2019. Entrevista. Disponível em: <https://jornal.usp.br/atualidades/morte-de-meio-bilhao-de-abelhas-e-consequencia-de-agrotoxicos/>. Acesso em: 19 ago. 2025.

ASTUTI, P. K. *et al.* **Buzzing with intelligence: Current issues in apiculture and the role of artificial intelligence (AI) to tackle it**. *Insects*, v. 15, n. 6, p. 418, 2024.

BALLIVIÁN, J. M. P. P. *et al.* **Abelhas nativas sem ferrão**. São Leopoldo: Oikos, 2008. 128 p.

BENGIO, Y.; LECUN, Y.; HINTON, G. Deep learning for AI. **Communications of the ACM**, New York, v. 64, n. 7, p. 58–65, 2021.

BERINGER, J. *et al.* **O declínio populacional das abelhas: causas, potenciais soluções e perspectivas futuras**. *Revista Eletrônica Científica da UERGS*, v. 5, n. 1, p. 18–27, 2019.

BORGES, H. B.; SHEPHERD, G. J. **Flora e estrutura do estrato lenhoso numa comunidade de cerrado em Santo Antônio do Leverger - MT, Brasil**. *Revista Brasileira de Botânica*, v. 28, n. 1, p. 61–74, 2005.

CASTIGLIONI, I. *et al.* **AI applications to medical images: From machine learning to deep learning**. *Physica Medica*, Elsevier, v. 83, p. 9–24, 2021.

DE CARVALHO, M. R. *et al.* **Taxonomic impediment or impediment to taxonomy? A commentary on systematics and the cybertaxonomic-automation paradigm**. *Evolutionary Biology*, 2007.

ENGEL, M. S. *et al.* **The taxonomic impediment: a shortage of taxonomists, not the lack of technical approaches.** 2021. Disponível em: <https://www.researchgate.net/publication/354810805>. Acesso em: 19 ago. 2025.

FLECK, L. *et al.* **Redes neurais artificiais: princípios básicos.** Revista Eletrônica Científica Inovação e Tecnologia, v. 1, n. 13, p. 47–57, 2016.

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.

FREITAS, B. M.; SILVA, C. I. **O papel dos polinizadores na produção agrícola no Brasil.** São Paulo: Associação Brasileira de Estudos das Abelhas, 2015. Disponível em: <https://abelha.org.br/publicacoes/ebooks/Agricultura-e-Polinizacao.pdf>. Acesso em: 19 ago. 2025.

FREITAS, B. M. *et al.* **Diversity, threats and conservation of native bees in the Neotropics.** Apidologie, v. 40, p. 332–346, 2009.

GIANNINI, *et al.* **Current challenges of species distribution predictive modelling.** Rodriguésia, 2012. Disponível em <https://doi.org/10.1590/S2175-78602012000300017>, Acesso em agosto de 2025.

GRIGORI, P. **Apicultores brasileiros encontram meio bilhão de abelhas mortas em três meses.** Agência Pública/Repórter Brasil, 2019. Disponível em: <https://reporterbrasil.org.br/2019/06/apicultores-encontram-meio-bilhao-de-abelhas-mortas-em-tres-meses/>. Acesso em: 19 ago. 2025.

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.

HAYKIN, S. **Redes neurais: princípios e prática.** Porto Alegre: Bookman Editora, 2001.

IBM. **O que são redes neurais convolucionais.** 2023. Disponível em: <https://www.ibm.com/br-pt/topics/convolutional-neural-networks>. Acesso em: 19 ago. 2025.

IMPERATRIZ-FONSECA, *et al.* **Polinizadores no Brasil: Contribuição e Perspectivas para a Biodiversidade, Uso Sustentável, Conservação e Serviços**

Ambientais, São Paulo:Ed. Da Universidade de São Paulo, 2012. Disponível em https://www.researchgate.net/publication/319041094_Polinizadores_no_Brasil_-_contribuicao_e_perspectivas_para_a_biodiversidade_uso_sustentavel_conservacao_e_servicos_ambientais. Acesso em agosto de 2025.

IRAÊ. **Anatomia das abelhas – Estrutura corporal completa**. 2019. Disponível em: <https://mel.com.br/anatomia-das-abelhas/>. Acesso em: 19 ago. 2025.

JÚNIOR, T. D. C. *et al.* **Insectev: A system for insect detection in the lab from trap images**. Ecological Informatics, Elsevier, v. 67, p. 101516, 2022.

KLINK, C. A.; MACHADO, R. B. **A conservação do cerrado brasileiro**. Megadiversidade, v. 1, n. 1, p. 147–155, 2005.

KURZWEIL, R. **The Age of Intelligent Machines**. Cambridge, MA: MIT Press, 1990.

LIANG, A. **Developing an AI-based integrated system for bee health evaluation**. Preprint, 2024. Disponível em: <https://typeset.io/papers/developing-an-ai-based-integrated-system-for-bee-health-4ircbds0b0>. Acesso em: 19 ago. 2025.

MACEDO, H. R. *et al.* **Composição florística em formações de cerrado com ação antrópica**. 2014.

MARIANO, D. **Métricas de avaliação em machine learning**. 2024. Disponível em: <https://diegomariano.com/metricas-de-avaliacao-em-machine-learning/>. Acesso em: 19 ago. 2025.

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.

MEIER, R. *et al.* **“Dark taxonomy”: A new protocol for overcoming the taxonomic impediments for dark taxa and broadening the taxon base for biodiversity assessment**. Cladistics, 2021.

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.

OLIVEIRA, K. M. G.; NAGASHIMA, L. A. **Análise dos elementos metálicos no mel como uma ferramenta para o monitoramento ambiental**. Ambiência, Guarapuava, v. 14, n. 1, p. 203–211, 2018.

OLIVEIRA, F. F. de *et al.* **O impedimento taxonômico no Brasil e o desenvolvimento de ferramentas auxiliares para identificação de espécies**. In: Polinizadores no Brasil: contribuição e perspectivas para a biodiversidade, uso sustentável, conservação e serviços ambientais. São Paulo: Edusp, 2012.

ROSA, A. A. *et al.* **Analysis of bee pollen as an environmental bioindicator in the Federal District, Brazil**. 2023. Disponível em: <https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1160485/1/Joao-Paulo-analise-do-polen-apicola.pdf>. Acesso em: 19 ago. 2025.

RUSSELL, S. J.; NORVIG, P. **Inteligência artificial**. 3. ed. Rio de Janeiro: Elsevier, 2013.

SAKOVA, M. *et al.* **Bee hive acoustic monitoring and processing using convolutional neural network and machine learning**. Proceedings Article, 2024. Disponível em: <https://typeset.io/papers/bee-hive-acoustic-monitoring-and-processing-using-1a9p5oqvly>. Acesso em: 19 ago. 2025.

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.

SCARIOT, A.; SOUSA-SILVA, J. C.; FELFILI, J. M. (Ed.). **Cerrado: ecologia, biodiversidade e conservação**. Brasília: Ministério do Meio Ambiente, 2005. Disponível em: https://files.cercomp.ufg.br/weby/up/284/o/Cerrado_Parte1.pdf. Acesso em: 19 ago. 2025.

SILVA, J. A. S.; MAIRINK, C. H. P. **Inteligência artificial**. Libertas: Revista de Ciências Sociais Aplicadas, v. 9, n. 2, p. 64–85, 2019.

SILVA, P. W.; PAZ, J. R. L. **Abelhas sem ferrão: muito mais do que uma importância econômica**. Natureza Online, 2012. Disponível em: <https://www.naturezaonline.com.br/revista/article/view/316/294>. Acesso em: 19 ago. 2025.

SILVEIRA, *et al.* **Abelhas brasileiras: sistemática e identificação**. Belo Horizonte, ISBN 2002. Disponível em

https://www.researchgate.net/publication/280112185_Abelhas_Brasileiras_Sistematica_e_Identificacao. Acesso em agosto de 2025.

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.

SOUZA, L. F. *et al.* **Polinização, polinizadores e abelhas**. São Paulo: Abelha, 2024. Livro eletrônico.

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.

TORRES, J. **YOLOv8 Architecture Explained**. 2024. Disponível em: <https://yolov8.org/yolov8-architecture-explained/>. Acesso em: 19 ago. 2025.

UNICNETRO. **Nova espécie de abelha**. 2024. Disponível em: <https://www.ruraltecv.com.br/wp-content/uploads/2024/07/UNICNETRO-NOVA-ESPECIE-ABELHA-5.2.jpg>. Acesso em: 19 ago. 2025.

VARGAS, A. C. G.; PAES, A.; VASCONCELOS, C. N. **Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres**. In: Proceedings of the XXIX Conference on Graphics, Patterns and Images. [S.l.], 2016. v. 1, n. 4.

WERTHMULLER, S. **Riscos globais de 2023: pico de tensões entre a urgente crise do custo de vida e a ação climática sustentável**. World Economic Forum, 2023. Disponível em: https://www3.weforum.org/docs/WEF_GRR23_Press_Release_PT_BR.pdf. Acesso em: 19 ago. 2025.

WHEELER, Q. D.; RAVEN, P. H.; WILSON, E. O. **Taxonomy: Impediment or expedient?** Science, v. 303, n. 5656, p. 285, 2004.

WOLFF, L. F.; REIS, V. D. A.; SANTOS, R. S. S. **Abelhas melíferas: bioindicadores e qualidade ambiental e de sustentabilidade da agricultura familiar de base ecológica**. Pelotas: Embrapa Clima Temperado, 2008. Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/792720/1/documento244.pdf>. Acesso em: 19 ago. 2025.

YOO, J. *et al.* **Beenet: An end-to-end deep network for bee surveillance.** Procedia Computer Science, Elsevier, v. 222, p. 415–424, 2023.