

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**Desenvolvimento de Ferramentas de IA para o Monitoramento da
Dinâmica de Colmeias de Abelhas Canudo (*Scaptotrigona spp*)**

Manoel Freitas Campos Neto

DM 32/2024

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Para-Brasil
2024

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Manoel Freitas Campos Neto

Desenvolvimento de Ferramentas de IA para o Monitoramento da Dinâmica de Colmeias de Abelhas Canudo (*Scaptotrigona spp*)

Dissertação submetida à Banca Examinadora do Programa de Pós-Graduação em Engenharia Elétrica da UFPA para obtenção do Grau de Mestre em Engenharia Elétrica na Área de Computação Aplicada.

Orientador: Prof. Dr. Roberto Célio Limão de Oliveira

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil
2024

**Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)**

C198d Campos Neto, Manoel Freitas.
Desenvolvimento de Ferramentas de IA para o Monitoramento
da Dinâmica de Colmeias de Abelhas Canudo (*Scaptotrigona spp*) /
Manoel Freitas Campos Neto. — 2024.
89 f. : il. color.

Orientador(a): Prof. Dr. Roberto Célio Limão de Oliveira
Coorientador(a): Prof. Dr. Marcos Enê Chaves Oliveira
Dissertação (Mestrado) - Universidade Federal do Pará,
Instituto de Tecnologia, Programa de Pós-Graduação em
Engenharia Elétrica, Belém, 2024.

1. Abelhas nativas. 2. Inteligência artificial. 3. Impressão
3D. 4. Comportamento das abelhas. 5. Metodologia de
aquisição imagens. I. Título.

CDD 621.31098115

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

“DESENVOLVIMENTO DE FERRAMENTAS DE IA PARA O MONITORAMENTO DA DINÂMICA DE COLMEIAS DE ABELHAS CANUDO (*SCAPTOTRIGONA SPP*)”

AUTOR: MANOEL FREITAS CAMPOS NETO

DISSERTAÇÃO DE MESTRADO SUBMETIDA À BANCA EXAMINADORA APROVADA PELO COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, SENDO JULGADA ADEQUADA PARA A OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA ELÉTRICA NA ÁREA DE COMPUTAÇÃO APLICADA.

APROVADA EM: 16/12/2024

BANCA EXAMINADORA:

Prof. Dr. Roberto Célio Limão de Oliveira
(Orientador – PPGEE/ITEC/UFGA)

Prof. Dr. Marcos Enê Chaves Oliveira
(Coorientador – Embrapa)

Prof^a. Dra. Adriana Rosa Garcez Castro
(Avaliador Interno – PPGEE/ITEC/UFGA)

Prof. Dr. Daniel Santiago Pereira
(Avaliador Externo ao Programa – Embrapa)

VISTO:

Prof. Dr. Diego Lisboa Cardoso
(Coordenador – PPGEE/ITEC/UFGA)

Dedico este trabalho a todos que me acompanharam nesta jornada.

AGRADECIMENTOS

Agradeço a Deus pela sabedoria e discernimento para a realização deste trabalho.

Agradeço aos meus pais, Edna Campos e José Elias, à minha namorada, Hérica Costa, e aos meus irmãos, Ellen Dias e José Elias Jr., pelo apoio incondicional que me deram ao longo de toda a minha vida.

Agradeço ao meu orientador, professor Dr. Roberto Célio Limão pela oportunidade de continuar os estudos cursando o mestrado, pelas orientações ao longo de todo o percurso e pela confiança depositada em mim.

Agradeço aos pesquisadores da Embrapa Amazônia Oriental, Dr. Marcos Enê e Dr. Daniel Santiago, pelas orientações, e ao Dr. Cláudio Carvalho pela confiança e por abrir as portas do LASS para mim.

Agradeço aos meus amigos, MSc. André Ramos, Mozart Júnior, João Cardoso e Mário Lucas, pela disponibilidade, pelo apoio ao longo de todo o trabalho, pela paciência e pelos conhecimentos compartilhados.

Agradeço a todos os membros do Laboratório de Análises e Sistemas Sustentáveis (LASS) e do Laboratório de Botânica, especialmente à equipe de campo, Anderson Schwanke, Marta Silva, Jéssica Gouvêa e Vivian Albuquerque, pelo apoio e contribuição.

Agradeço profundamente à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de mestrado. Esse apoio foi essencial para a realização deste trabalho. A CAPES desempenhou um papel crucial no meu crescimento profissional e pessoal, pelo qual sou extremamente grato.

Agradeço a todos os professores que contribuíram para a minha formação acadêmica. Minha sincera gratidão a todos vocês, por me ajudarem a chegar até este momento.

“O sucesso é a capacidade de ir de um fracasso ao outro sem perder o entusiasmo.”

Winston Churchill

RESUMO

As abelhas sociais nativas vêm apresentando elevado potencial agrônomo na polinização de plantas no Brasil, destacando-se as abelhas do gênero *Scaptotrigona*, que melhoram a produtividade do açaizeiro (*Euterpe oleracea*) em até 70% e do cafeeiro (*Coffea arabica*) em até 30% com a ajuda desses polinizadores. Contudo, tem-se observado uma drástica redução das populações de abelhas, atribuída a várias causas, como à destruição dos habitats naturais, ao aumento das práticas agrícolas, ao desmatamento que leva à perda de diversidade de plantas, às mudanças climáticas e ao uso de pesticidas. Essas ameaças não só afetam diretamente as abelhas, mas também comprometem a polinização, que é fundamental para a manutenção dos ecossistemas e para a produção de alimentos em todo o mundo. Diante deste cenário, este trabalho tem como objetivo monitorar o comportamento das abelhas *Scaptotrigona*, também conhecidas como abelhas canudo, utilizando ferramentas de Inteligência Artificial (IA) para obter informações que auxiliem em novas pesquisas para o desenvolvimento tecnológico da criação e na divulgação do conhecimento sobre as abelhas e sua importância. Para isso, foi desenvolvida uma nova metodologia de aquisição de imagens, utilizando impressão 3D, para a criação de um banco de dados inédito com 7.806 imagens de abelhas canudo, contendo 19.954 anotações, que serviram de apoio para a construção de um modelo de rede neural utilizando a rede YOLOv8 para a classificação das classes *scapto*, *scapto_garbage* e *scapto_polen*, com precisão de 96% nessa tarefa. Além disso, o modelo demonstrou grande potencial para estimar a população das colmeias, selecionar as colmeias mais higiênicas e analisar a preferência das abelhas por determinadas floradas, além de auxiliar indiretamente em estudos botânicos para entender melhor o período de abertura das floradas.

Palavras-chave: Abelhas nativas, Inteligência artificial, Impressão 3D, Comportamento das abelhas, Metodologia de aquisição imagens, YOLOv8.

ABSTRACT

Native social bees have shown a high agronomic potential in the pollination of plants in Brazil, with bees of the genus *Scaptotrigona* standing out for improving the productivity of açai palm (*Euterpe oleracea*) by up to 70% and coffee plants (*Coffea arabica*) by up to 30%, with the help of these pollinators. However, a drastic reduction in bee populations has been observed, attributed to several causes, such as the destruction of natural habitats, the increase in agricultural practices, deforestation leading to the loss of plant diversity, climate change, and the use of pesticides. These threats not only directly affect the bees but also compromise pollination, which is essential for maintaining ecosystems and food production worldwide. Considering this scenario, this work aims to monitor the behavior of *Scaptotrigona* bees, also known as "canudo" bees, using Artificial Intelligence (AI) tools to obtain information that will support further research for the technological development of beekeeping and the dissemination of knowledge about bees and their importance. For this, a new image acquisition methodology was developed, using 3D printing, to create an unprecedented database with 7,806 images of canudo bees, containing 19,954 annotations, which supported the construction of a neural network model using the YOLOv8 network to classify the *scapto*, *scapto_garbage* and *scapto_polen* classes, with 96% accuracy in this task. Additionally, the model demonstrated great potential for estimating hive populations, selecting the most hygienic hives, and analyzing the bees' preference for certain blooms, while also indirectly assisting in botanical studies to better understand the flowering period.

Keywords: Native bees, Artificial intelligence, 3D printing, Bee behavior, Image acquisition methodology, YOLOv8.

LISTA DE FIGURAS

Figura 1 – Modelo de Colmeia Vertical	15
Figura 2 – Abelha no Momento da Polinização da Flor do Açaí	16
Figura 3 – Abelha no Momento da Polinização da Flor do Café	16
Figura 4 – Abelha Canudo.....	22
Figura 5 – Algoritmos Tradicionais e Algoritmos de Aprendizagem Profunda	29
Figura 6 – Arquitetura Básica Comumente Encontradas em CNNs	30
Figura 7 – Visão Humana x Visão Computacional	31
Figura 8 – Configuração Inicial do Modelo YOLO	32
Figura 9 – Arquitetura da Rede de Detecção YOLO.....	33
Figura 10 – Visualização da Rede Bibliométrica das Principais Aplicações com YOLO	34
Figura 11 – Linha do Tempo das Versões do YOLO	35
Figura 12 – Arquitetura YOLOv8	35
Figura 13 – Visualização da Arquitetura YOLOv8.....	37
Figura 14 – Visualização de uma Caixa de Âncora no YOLO	38
Figura 15 – Ilustração do Processo de Tomada de Decisão das Redes YOLO	38
Figura 16 – Exemplo de Detecção de Objetos com uma Abelha	39
Figura 17 – <i>Intersection Over Union</i>	39
Figura 18 – Previsões para Diferentes Limites de IoU.....	40
Figura 19 – Localização x Classificação	42
Figura 20 – Fluxograma Metodológico	43
Figura 21 – Imagem do Meliponário.....	44
Figura 22 – Ilustração da Instalação da Plataforma.....	45
Figura 23 – As Principais Partes do Corpo de uma Operária de Meliponíneo.....	45
Figura 24 – Sistema Implementado	46
Figura 25 – Scapto.....	47
Figura 26 – Scapto_garbage	47
Figura 27 – Scapto_poleno.....	47
Figura 28 – Comparação de Desempenho de Redes YOLO	48
Figura 29 – Imagem após Redimensionamento	50
Figura 30 – Ilustração do Método Existente de Contagem	52
Figura 31 – Imagem do Vídeo Original para Contagem Manual	53
Figura 32 – Primeira Versão da Plataforma	56
Figura 33 – Segunda Versão da Plataforma	57
Figura 34 – Versão Final da Plataforma.....	57

Figura 35 – Adaptação das Abelhas com a Plataforma 3D	58
Figura 36 – Transmissão do YouTube	59
Figura 37 – Banco de Dados	60
Figura 38 – Análise do Banco de Dados	61
Figura 39 – Resultados de Validação do Treinamento.....	62
Figura 40 – Matriz de Confusão	62
Figura 41 – Gráficos de Desempenho	63
Figura 42 – Comparação de Entrada Modelo x Humano	64
Figura 43 – Comparação de Saída Modelo x Humano.....	65
Figura 44 – Comparativo entre 3 Colmeias.....	66
Figura 45 – Gráfico de <i>mES</i> por Faixa Populacional	67
Figura 46 – Gráfico de Entrada de Abelhas	69
Figura 47 – Gráfico de Saída de Abelhas	70
Figura 48 – Gráfico de Saída de Lixo	71
Figura 49 – Gráfico de Barra com Saída de Lixo.....	72
Figura 50 – Valor Percentual de CH	73
Figura 51 – Gráfico de Comportamento Forrageiro.....	74
Figura 52 – Gráfico de Barra com Entrada de Pólen.....	75
Figura 53 – Pólen C08.....	75
Figura 54 – Pólen C03.....	75
Figura 55 – Technology Readiness Levels.....	76

LISTA DE TABELAS

Tabela 1 – Alimentos cultivados no Brasil e a dependência da produção por polinizadores...	21
Tabela 2 – Tipos de modelos de Detecção YOLOv8	49
Tabela 3 – Divisão dos Dados	51
Tabela 4 – Informações do Banco de Dados	61
Tabela 5 – Tabela de Estimativa Populacional	68
Tabela 6 – Informações de retirada de lixo de sete colmeias	72
Tabela 7 – Valor Percentual de CH de cada Colmeia.....	88
Tabela 8 – Nível de Maturidade da Pesquisa TRL	89

LISTA DE ABREVIATURAS E SIGLAS

ASF	Abelhas Sem Ferrão
IA	Inteligência Artificial
EBIA	Estratégia Brasileira de Inteligência Artificial
EMBRAPA	Empresa Brasileira de Pesquisa e Agropecuária
INPA	Instituto Nacional de Pesquisas da Amazônia
CNNs	Redes Neurais Convolucionais
PLN	Processamento de Linguagem Natural
GPU	<i>Graphic Processing Unit</i>
YOLO	<i>You Only Look Once</i>
FPS	Frames por Segundo
SPPF	<i>Spatial Pyramid Pooling Faster</i>
U	<i>Upsample</i>
NMS	<i>Non-Maximum Suppression</i>
IoU	<i>Intersection Over Union</i>
mAP	<i>Mean Average Precision</i>
AP	<i>Average Precision</i>
PLA	Ácido Polilático
RGB	<i>Red, Green and Blue</i>
COCO	<i>Common Objects in Context</i>

SUMÁRIO

1	Introdução.....	15
1.1	Contextualização.....	15
1.2	Objetivos Gerais	17
1.3	Objetivos Específicos.	17
1.4	Motivação	18
1.5	Organização do Trabalho	18
2	Fundamentação Teórica	20
2.1	Meliponicultura e Abelhas sem Ferrão	20
2.1.1	<i>Scaptotrigona spp.</i>	22
2.1.2	Comportamento Higiênico de Abelhas.....	23
2.1.3	Comportamento Forrageiro de Abelhas.....	25
2.1.4	Tamanho Populacional e Contagem de Abelhas.	27
2.2	Redes Neurais Convolucionais	28
2.2.1	Visão Computacional.....	30
2.3	YOLO.	31
2.3.1	Aplicações com Redes YOLO.....	33
2.3.2	Arquitetura YOLOV8.....	35
2.3.3	Avanços na Arquitetura.	37
2.4	Medidas de Avaliação.....	39
2.4.1	Interseção sobre União.....	39
2.4.2	<i>Precision, Recall e F1-score</i>	41
2.4.3	<i>Mean Average Precision</i>	41
3	Metodologia.....	43
3.1	Coleta dos Dados	44
3.2	Banco de Dados	46
3.3	Modelagem e Treinamento da Rede Neural	47
3.3.1	YOLOv8s.....	47
3.3.2	Pré Processamento de Imagens.....	50
3.3.3	Configuração do Treinamento.	51

3.4	Metodologia de Validação do Modelo	51
3.5	Metodologia de Estimativa Populacional e Comportamento Higiênico	53
3.5.1	Estimativa Populacional.	53
3.5.2	Estimativa de Comportamento Higiênico.....	54
4	Resultados e discussão	56
4.1	Plataforma 3D	56
4.2	Metodologia de Coleta de Imagens	58
4.3	Banco de Dados Desenvolvido	60
4.4	Resultados do Treinamento	61
4.5	Métodos Existentes de Contagem x Modelo	64
4.6	Resultados Comportamentais	65
4.6.1	Estimador Populacional.....	65
4.6.2	Impacto na Dinâmica por Condições Climáticas.....	69
4.6.3	Comportamento Higiênico.....	71
4.6.4	Comportamento Forrageiro.....	74
4.7	Nível de Maturidade Tecnológica	76
5	Conclusões.....	78
5.1	Trabalhos Futuros	78
5.2	Publicações	79
	Referências	80
	Apêndices.....	88

1. Introdução

1.1 Contextualização

As abelhas sem ferrão (ASF) são encontradas por todo o mundo. No Brasil estão bastante presentes nas regiões de florestas onde se encontra mais de 60% da sua população total, sendo mais de 300 espécies sociais conhecidas. Essas abelhas são os principais responsáveis pela conservação de mais de 90% de toda a fauna e flora brasileira, graças ao serviço de polinização prestado pelas mesmas ao meio ambiente (KULIK, 2019; KERR *et al.*, 1996).

A criação racional destas abelhas constitui atividade zootécnica denominada meliponicultura, que é caracterizada por um manejo e sistema de criação em caixas de madeiras padronizadas, conforme apresentado na Figura 1. Esta atividade tem ganhado visibilidade por serem espécies de fácil manejo se comparado às abelhas com ferrão (*Apis mellifera*), e por produzirem meles de elevada aceitação pelos consumidores.

Figura 1 – Modelo de Colmeia vertical (Embrapa).



Fonte: LEÃO *et al.*, 2016.

A Amazônia apresenta elevada diversidade de abelhas nativas, das quais muitas espécies são encontradas no estado do Pará. Estas abelhas diferem da *Apis mellifera* em várias características, tais como a ausência de ferrão, o armazenamento do mel em potes e meles com sabores e texturas bem característicos.

Das 600 espécies deste gênero encontradas no mundo, 244 ocorrem no Brasil, sendo que 89 ainda aguardam descrição científica. No bioma Amazônia, localizado no Brasil, existem 215 espécies, e no estado do Pará há 114 espécies, número que tende a crescer (PEDRO, 2014; FILHO, 2019).

Na edição de 2022 da Agrishow, a Embrapa apresentou um painel especial sobre o potencial papel das ASF na polinização agrícola (Embrapa, 2022). Dentre estas, o gênero *Scaptotrigona*, também conhecidas como abelhas canudo nativas da Amazônia, tem ganhado destaque pelo seu potencial de polinização do açaizeiro (*Euterpe oleracea*), frequentando eficientemente as flores do açaí, conforme indicado na Figura 2. O açaizeiro desempenha um papel inquestionável na economia da Amazônia, onde a polinização realizada pelas abelhas pode aumentar a produtividade em até 70% (MUTO et al., 2020).

Figura 2 - Abelha no Momento da Polinização da Flor de Açaí (*Euterpe oleracea*).



Fonte: Fotos de Giorgio Venturieri.

Além do açaí, diversas outras culturas agrícolas também se beneficiam do processo de polinização das abelhas. A cultura do cafeeiro (*Coffea arabica*) é um exemplo, podendo aumentar sua produtividade em até 30% com a contribuição desses polinizadores (Figura 3) (WOLOWSKI et al., 2019; PDG Brasil, 2022). Outras culturas que também se beneficiam são a do tomate e a do morango, e gradativamente esse conhecimento sobre a importância dos polinizadores e seu uso agrícola tem sido ampliado (HEARD, 1999; NUNES e FREITAS, 2012).

Figura 3 - Abelha no Momento da Polinização da Flor do Café (*Coffea arabica*).



Fonte: Globo Rural.

Atualmente, há um grande esforço de pesquisa para o desenvolvimento tecnológico da criação e para a divulgação do conhecimento sobre as abelhas e de sua importância como polinizadores. No entanto, fatores como a destruição do habitat natural, aumento das atividades agrícolas, perda da biodiversidade de flora causadas pelo desmatamento, mudanças climáticas e utilização de pesticidas são os principais causadores da atual e preocupante queda no número de abelhas em todo o mundo, conseqüentemente, comprometendo a polinização (POTTS *et al.*, 2010). Fatores estes que colaboram para a redução na produção de vários produtos fabricados pelas abelhas.

A pesquisa com abelhas pode se beneficiar dos avanços recentes na área da tecnologia, como a utilização de modelos de IA, que podem colaborar com pesquisas inéditas sobre as abelhas. Diante desse cenário, instituída pela Portaria MCTI nº 4.617, de 6 de abril de 2021, alterada pela Portaria MCTI nº 4.979, de 13 de julho de 2021, a Estratégia Brasileira de Inteligência Artificial (EBIA) assume o papel de nortear as ações do Estado brasileiro em prol do desenvolvimento de iniciativas que estimulem a pesquisa, a inovação e o desenvolvimento de soluções em Inteligência Artificial, bem como seu uso consciente e ético, visando a um futuro melhor (BRASIL, 2021). Nesse contexto, podemos destacar a importância das ferramentas de Inteligência Artificial (IA) para monitorar colônias de abelhas, adquirindo informações inéditas sobre o comportamento dessas espécies e viabilizando estratégias para a detecção de doenças e contaminações dos enxames, utilizando modelos de redes neurais, com o intuito de melhorar a produção e o manejo dessas espécies na Amazônia.

1.2 Objetivos Gerais

Utilizar ferramentas computacionais de IA para monitorar a dinâmica populacional em colmeias de abelha canudo (*Scaptotrigona spp*).

1.3 Objetivos Específicos

- Desenvolver metodologia de aquisição de imagens;
- Criar banco de dados de imagens de abelhas canudo (*Scaptotrigona spp*);
- Desenvolver softwares para avaliação da dinâmica populacional em colmeias de abelhas canudo (*Scaptotrigona spp*).

1.4 Motivação

Este trabalho tem como principal motivação oferecer precisão à informação sobre o comportamento higiênico, forrageiro e populacional das abelhas por meio de uma nova metodologia de aquisição de imagens e monitoramento, já que os métodos existentes são bastante onerosos, demandam muito tempo e apresentam baixa precisão. Em contraste, a metodologia proposta utiliza técnicas avançadas de inteligência artificial com redes neurais convolucionais do tipo YOLO, para automatizar a coleta de informações, processamento e análise dos dados, redução de custos e tempo de trabalho, coleta contínua de dados em tempo real, contribuindo para informações mais precisas e auxiliando no aperfeiçoamento de técnicas de manejo das abelhas, otimizando recursos agrícolas e serviços ambientais, como a polinização.

Outro ponto motivacional, é que em virtude do risco potencial que a presença de doenças pode causar, os meliponicultores devem estar sempre atentos à situação sanitária das abelhas, conferindo a saúde de suas colônias. Para isso, devem estar capacitados ao reconhecimento visual das anormalidades que possam indicar a presença de possíveis doenças, o que auxiliará a evitar a disseminação e o impacto de novas doenças no Brasil. Sendo assim, o desenvolvimento de um sistema de monitoramento com câmeras para a aquisição de imagens é muito importante considerando este cenário, onde as informações irão compor um banco de dados inédito, para que os padrões sejam analisados por modelos de redes neurais, caracterizando como um sistema menos invasivo, onde o contato do homem com as abelhas seja mínimo.

1.5 Organização do Trabalho

Além da introdução, este documento está dividido em cinco capítulos, incluindo a conclusão. O Capítulo 2 fornece a base teórica necessária para entender a meliponicultura, redes neurais e suas aplicações em visão computacional. O Capítulo 3 aborda a implementação do sistema, detalhando a metodologia desenvolvida para coleta e treinamento do modelo proposto. No Capítulo 4, são apresentados os resultados da implementação da plataforma 3D, assim como a análise do novo método para aquisição de imagens e monitoramento em tempo real das abelhas. Em seguida, o banco de dados criado para este trabalho é discutido, junto com uma comparação do desempenho do modelo em relação aos métodos existentes de contagem de abelhas. Por fim,

são apresentados os resultados das análises comportamentais das abelhas, seguidos pelas conclusões do Capítulo 5 e sugestões para melhorias futuras do projeto.

2. Fundamentação Teórica

Neste capítulo serão abordados os principais temas que auxiliaram no desenvolvimento da metodologia proposta, servindo como base teórica para entendimento da mesma, também serão descritas as tecnologias e medidas de desempenho utilizadas no trabalho.

2.1 Meliponicultura e Abelhas Sem Ferrão

A meliponicultura é a criação de abelhas silvestres nativas do Brasil (NOGUEIRA, 1997). Este termo foi definido por Paulo Nogueira Neto em 1953. Trata-se de insetos da ordem *Hymenoptera*, e da família *Apidae*. Destaca-se, dentro dessa prática, a tribo *Meliponini*, abrangendo diversas famílias cujos gêneros englobam espécies tradicionalmente criadas por comunidades e povos há várias gerações (RIBEIRO, 2020). Estas abelhas são também conhecidas como abelhas sem ferrão, uma vez que o ferrão entre as Melíponas é atrofiado. Esta é uma das características que distingue o gênero *Melípona* daquele mais comumente criado no Brasil, do gênero *Apis* (da tribo *Apini*).

As ASF são geralmente manejadas para fornecerem produtos como o mel e a própolis, porém a principal atividade dessas abelhas é a polinização, com estimados 66% das culturas de interesse comercial do mundo polinizadas pelas abelhas (KREMEN, 2007), tendo culturas extremamente dependentes dos polinizadores para a produção dos frutos e sementes como abóbora, pepino, manga e a jaca (YAMAMOTO *et al.*, 2012). Existem também espécies cuja polinização aumentam a sua produção, como a castanha-do-pará, o cacau, o morango, o açaí e o café (GHAZOUL, 2005; AIZEN *et al.*, 2008).

A Tabela 1 apresenta alguns alimentos cultivados no Brasil e sua relação com esses polinizadores. Estima-se que as abelhas sem ferrão encontradas no Brasil sejam responsáveis pela polinização de até 90% das árvores nativas (KERR *et al.*, 1996).

Tabela 1 – Alimentos cultivados no Brasil e a dependência da produção por polinizadores animais.

ESSENCIAL	ALTA	MODERADA	BAIXA	NENHUMA
90%	40 - 90%	10 - 40%	1 - 10%	-
Açaí	Manga	Algodão	Amendoim	Arroz
Maracujá	Pepino	Coco	Pimentão	Mandioca
Cacau	Guaraná	Laranja	Palma de Óleo	Banana
Cupuaçu	Goiaba	Café	Mamão	Milho
Urucum	Tomate	Soja	Tangerina	Abacaxi

Fonte: Adaptado de GIANNINI *et al.*, (2015), KLENTE *et. al.*, (2007).

Na Amazônia, a pesquisa voltada à meliponicultura vem sendo conduzida desde a década de 1990, especialmente a partir dos esforços da Embrapa Amazônia Oriental, do INPA e de organizações da sociedade civil, como o Instituto Iraquara e o Instituto Peabiru. Há crescente interesse por essas abelhas, principalmente por desempenharem importante papel na polinização de frutas, legumes e verduras.

A meliponicultura deve ser compreendida como atividade vital em nossa sociedade, não apenas para a produção de mel e outros subprodutos, mas também para a manutenção da vida vegetal nos trópicos por meio da polinização de plantas e manutenção da diversidade genotípica deste importante ecossistema (AIDAR, 1996).

Na atualidade, o cultivo de abelhas vem conquistando e consolidando novos mercados e se transformado em importante fonte de renda e de emprego no Pará, Amazônia e em todo Brasil. As ASF são polinizadoras essenciais que aumentam a produtividade agrícola e promovem uma agropecuária mais sustentável. Socialmente, essa prática gera empregos e valoriza o empreendedorismo local, além de promover a educação ambiental, a conservação da biodiversidade e a manutenção dos ecossistemas.

2.1.1 *Scaptotrigona* spp

O gênero *Scaptotrigona* é composto por 24 espécies, comumente conhecidas como abelhas canudo ou mandaguari (MOURE, 1942). Dentre essas espécies, destaca-se a *Scaptotrigona aff. postica* (LATREILLE, 1807), popularmente chamada de canudo, pois na entrada do ninho é característica do gênero construir um tubo defensivo feito de cerume, conforme observado na Figura 4 o que permite que as abelhas se posicionem simultaneamente tornando-as forte no processo de defesa.

Figura 4: Abelha Canudo.



Fonte: Abelhas.org.

As colônias dessa espécie são bastante populosas, resistentes à manipulação e têm a possibilidade de serem criadas de forma racional e multiplicadas em larga escala (NOGUEIRA-NETO, 1997; ROUBIK, 2006; MICHENER, 2007; LEÃO, 2016). Essa abelha, que possui um tamanho aproximado de 6 mm, é uma espécie de abelha sem ferrão encontrada em pelo menos oito estados brasileiros, com destaque para a região Amazônica. Além do grande potencial de produção de mel, a abelha canudo tem um valor significativo para a polinização de espécies cultivadas nativas (VENTURIERI *et al.*, 2012), devido à sua tolerância ao manejo, por possuírem colônias populosas, possibilitando a multiplicação em larga escala (MENEZES *et al.*, 2012).

A *Scaptotrigona aff. postica* tem despertado interesse em pesquisas que exploram seu nicho ecológico, bem como os produtos derivados de seus serviços ecossistêmicos (SILVA, 2009; SANCHES, 2014). Estudos aprofundados têm sido conduzidos visando compreender melhor a

sua importância no ecossistema local e a potencial aplicação dessas abelhas para benefício humano. Isso contribui para a proposta da ODS 15 - Vida Terrestre, das Nações Unidas¹, que visa proteger, recuperar e promover o uso sustentável dos ecossistemas terrestres, gerir de forma sustentável as florestas, combater a desertificação, deter e reverter a degradação da terra e deter a perda de biodiversidade.

2.1.2 Comportamento Higiênico de Abelhas

O comportamento higiênico das abelhas é um mecanismo de defesa natural, voltado principalmente para doenças de cria e parasitas como a Cria giz e *Varroa destructor* (PARK, 1937). As abelhas operárias expressam esse comportamento detectando e removendo o opérculo que cobrem as células dos favos das colmeias com células com crias mortas ou infectadas, descartando-as da colônia (ROTHENBUHLER, 1964). Este comportamento é hereditário e controlado por múltiplos genes, permitindo a caracterização de colônias higiênicas (ROTHENBUHLER, 1964).

Alguns trabalhos sobre o comportamento higiênico de ASF (FERREIRA, 2019; SOUSA, 2019) vêm sendo desenvolvidos nos últimos anos. Esses estudos analisam esse mecanismo de defesa em colmeias de *Scaptotrigona spp.*, relacionadas a doenças, com potencial de contribuição em programas de melhoramento genético dessas espécies.

Os estudos sobre comportamento higiênico tiveram como base a análise feita com a abelha do gênero *Apis mellifera*, no qual, durante muitos anos, acreditava-se que as abelhas melíferas não removiam crias mortas por doenças, embora fosse observado que estas não se acumulavam no ninho (ROTHENBUHLER, 1964). Os primeiros estudos sobre comportamento higiênico em *Apis mellifera* datam da década de 1930, quando colônias foram infectadas experimentalmente com esporos da cria pútrida americana. Neste estudo observou-se que, em algumas colônias, larvas e pupas mortas se acumulavam, enquanto em outras as operárias removiam as crias mortas dos favos, comportamento denominado comportamento higiênico (PARK, 1937).

Após a descoberta do comportamento higiênico nessa espécie, diversos estudos foram realizados para compreender os mecanismos de defesa contra doenças de cria em *Apis mellifera* (ARATHI *et al.*, 2000; GRAMACHO e SPIVAK, 2003). Estes estudos tiveram como objetivo o melhoramento genético das colônias, com o auxílio do manejo, seleção genética e redução da

¹ <https://brasil.un.org/pt-br/sdgs> acessado em 18/11/2024

suscetibilidade a infecções a doenças (ROTHENBUHLER, 1964). Outras pesquisas também têm buscado quantificar e identificar os genes envolvidos nessa característica de defesa natural (BOUTIN *et al.*, 2015; LAPIDGE *et al.*, 2002). Este comportamento é um dos métodos para seleção de colônias saudáveis, que tendem a apresentar maior longevidade, maior número de indivíduos no ninho e, conseqüentemente, maior produção de mel (ROTHENBUHLER, 1960). Para que uma colônia seja considerada higiênica, realiza-se um teste baseando-se na remoção de crias mortas ou doentes em um intervalo de 24 a 48 horas. Colônias que removem 95% a 100% das crias mortas são consideradas higiênicas (SPIVAK e DOWNEY, 1998; GRAMACHO e GONÇALVES, 1994).

Este comportamento também foi observado em algumas espécies de abelhas sem ferrão (AL TOUFAILIA *et al.*, 2016; DE JESUS *et al.*, 2017; MEDINA *et al.*, 2009; NUNES-SILVA *et al.*, 2009). Entender a diversidade de expressão do comportamento higiênico entre as espécies de abelhas sem ferrão é importante, já que para a espécie *Apis mellifera* métodos para testar o comportamento higiênico das colmeias estão estabelecidos, e são utilizados rotineiramente para pesquisa e em programas de melhoramento genético (GRAMACHO, 1999).

Em ASF essas pesquisas ainda são escassas, possivelmente devido à grande variedade de espécies e suas particularidades. No trabalho de TOUFAILIA *et al.* (2016), descreve-se um experimento em que foram testados métodos de congelamento em três espécies de abelhas sem ferrão: *Melipona scutellaris*, *Scaptotrigona depilis* e *Tetragonisca angustula*. Observou-se que, no comportamento de limpeza e remoção das pupas mortas, a abelha *M. scutellaris* removeu 99% da ninhada morta, a *S. depilis*, 80%, e a *T. angustula*, 62%, resultando em um valor médio de 80% para o comportamento higiênico comparando as três colmeias.

De acordo com NUNES-SILVA *et al.* (2009), estudos anteriores realizados com ASF demonstraram que a abelha *Plebeia remota*, ao utilizar o método de perfuração, apresentou uma remoção de 69,6% das crias mortas após 24 horas, aumentando para cerca de 96,4% após 48 horas. Neste estudo, também ficou evidente o comportamento higiênico dessa e de outras espécies de ASF.

Outros trabalhos envolvendo o comportamento higiênico em ASF foi o de MEDINA (2009), no qual foram investigadas duas espécies de ASF, *Melipona beecheii* e *Scaptotrigona pectoralis*, utilizando o método de congelamento. Os resultados apresentaram uma diferença significativa entre as espécies, onde operárias de *Melipona beecheii* levaram um período de 2 a

9 dias para remover 100% das pupas mortas, enquanto *Scaptotrigona pectoralis* realizou a remoção em menos de 3 dias. Através destes estudos, conclui-se que o comportamento higiênico é uma característica marcante também nas abelhas sem ferrão.

2.1.3 Comportamento Forrageiro de Abelhas

No Brasil, o grupo das ASF se destaca com metade das espécies descritas para as regiões tropicais e subtropicais do mundo (PEDRO, 2014; ASCHER e PICKERING, 2021). As abelhas sem ferrão são insetos altamente eussociais, ou seja, possuem um alto grau de organização social, formando colônias compostas por uma rainha-mãe responsável pela postura de ovos, machos e centenas a milhares de operárias que desempenham diversas funções (MICHENER, 1974). A divisão de trabalho ocorre de acordo com a idade, um fenômeno conhecido como polietismo etário (MICHENER, 1974). Assim, as operárias, ao longo de sua vida, dedicam-se a diferentes tarefas como cuidar da cria, limpar o ninho, manipular o alimento estocado nos potes e, nos últimos dias de vida, iniciar as atividades de forrageamento.

Atividades de forrageamento referem-se à busca e coleta por recursos tróficos e não-tróficos no ambiente (SAKAGAMI, 1982) por animais, especialmente insetos sociais como as abelhas. Isso inclui a procura de alimentos como néctar e pólen para a colmeia, usando pistas visuais e olfativas para se orientar. Elas também comunicam a localização das fontes de alimento para outras abelhas através de danças e sinais químicos. Esse comportamento é essencial para a nutrição da colônia e a polinização de plantas, crucial para a reprodução vegetal e a produção de alimentos.

A importância da atividade de forrageamento está diretamente relacionada à saúde da colônia, pois esta depende de uma nutrição adequada tanto em quantidade quanto em qualidade. As larvas dependem do pólen como fonte proteica para seu desenvolvimento, e quando há escassez desse recurso no ambiente, a quantidade de cria é reduzida, resultando em menos adultos e comprometendo a sobrevivência da colônia (BRODSCHNEIDER e CRAILSHEIM, 2010). Portanto, a decisão de coletar recursos alimentares é crucial e complexa, pois depende da integração de informações sobre as necessidades nutricionais da colônia e a disponibilidade desses recursos no ambiente (BIESMEIJER *et al.*, 1998).

Apesar das diferenças morfológicas e biológicas entre as espécies de abelhas sem ferrão, estas forrageiam em faixas de temperatura e umidade relativa semelhantes, embora o pico de atividade possa variar temporalmente, permitindo a partilha de recursos florais e aumentando as chances de coexistência de diferentes espécies em uma mesma área (KLEINERT *et al.*, 2009).

É importante destacar que a quantidade de pólen coletado nas flores também é influenciada pelas condições climáticas. Após dias com temperaturas muito baixas ou chuvas intensas, as forrageiras retornam aos ninhos com cargas polínicas maiores do que em períodos com temperaturas elevadas e pouca ou nenhuma chuva (RAMALHO *et al.*, 1998). Além das condições climáticas, a quantidade de pólen nas cargas pode ser influenciada pelo tamanho da forrageira, capacidade máxima de voo, saúde da colônia e disponibilidade de recursos no ambiente (RAMALHO *et al.*, 1994; ARAUJO *et al.*, 2004).

A preferência das abelhas por determinadas plantas é uma característica essencial do comportamento forrageiro, impactando significativamente no processo de polinização. As ASF, assim como outras espécies, exibem preferências por plantas específicas ao forragear, baseadas em fatores como a disponibilidade de néctar e pólen, a morfologia das flores e a época de floração. Estudos apresentaram que essa seleção pode ser otimizada para aumentar a eficiência da polinização em culturas agrícolas (HEARD, 1999).

Conhecer essas preferências alimentares pode melhorar a produção de culturas específicas. Por exemplo, abelhas que preferem forragear em plantas de café e maracujá podem aumentar significativamente os rendimentos dessas culturas (GIANNINI *et al.*, 2015). Essa informação também é valiosa para a multiplicação de enxames. Enxames que têm afinidade por pólen de determinadas plantas podem ser direcionados para áreas onde essas plantas são abundantes, aumentando a produção e a saúde das colônias (SOMERVILLE, 2000).

Portanto, a compreensão do comportamento forrageiro das abelhas e suas preferências por plantas específicas é fundamental. Isso não só beneficia a produção agrícola, mas também ajuda na saúde e multiplicação dos enxames, proporcionando um manejo mais eficiente e sustentável das colônias.

2.1.4 Tamanho Populacional e Contagem de Abelhas

Atualmente, diversos estudos têm sido publicados sobre a relação entre o tamanho populacional e características coloniais de abelhas sem ferrão amazônicas. Um exemplo é o trabalho de LEÃO (2019), que teve como objetivo determinar o tamanho da colônia de cinco espécies de abelhas sem ferrão amazônicas e entender como outras características coloniais se relacionam com o tamanho da população. Os resultados desse estudo mostraram que, entre os parâmetros biológicos avaliados, a atividade externa é o que melhor explica o tamanho da população, podendo ser utilizada para estimar a população das colônias dessas abelhas. O método utilizado para a avaliação da taxa de atividade externa envolveu a contagem do número de operárias que entram no ninho durante um período de cinco minutos, na fase de pico de atividade diária, entre às 9:00 e 11:00 da manhã, durante cinco dias consecutivos, onde posteriormente, foram calculadas as médias para representar o fluxo de entrada de operárias.

Nas ASF, diversos parâmetros também estão relacionados ao tamanho das colônias, como número de abelhas adultas, quantidade de cria, estoque de alimento, atividade externa da colônia, tempo de vida dos indivíduos e taxa de postura. Com essas informações, é possível estimar o tamanho das colônias avaliando alguns desses parâmetros biológicos que se correlacionam com o número de indivíduos de acordo com os trabalhos de (DEGRANDI-HOFFMAN *et al.*, 1989; MALHAM *et al.*, 2013; DUARTE *et al.*, 2016; ROLDÃO-SBORDONI *et al.*, 2018).

O processo de contagem de abelhas envolve diversos métodos de avaliação manuais que demandam significativo esforço e dedicação dos pesquisadores. No trabalho de MECCA (2013), foi realizada uma contagem manual de quatro colônias de abelhas de *Scaptotrigona depilis* durante o período de julho de 2001 a junho de 2002, com observações duas vezes por mês, com intervalos de aproximadamente quinze dias. Cada observação foi feita em intervalos de 1 hora e 15 minutos, das 17:00 às 18:15 horas. Para cada colônia, o padrão de atividade de voo e a quantidade de pólen coletado foram avaliados pela contagem do número de operárias que entravam e saíam das colônias durante 3 minutos. Posteriormente, foi registrado o número de operárias que entraram na colônia com pólen durante 2 minutos.

O trabalho de LEÃO (2019) indicou que o número de abelhas adultas foi utilizado como indicador do tamanho da colônia baseado no estudo de (DORNHAUS; POWELL; BENGSTON, 2012). A metodologia de contagem de abelhas consistiu em um grande esforço,

onde as caixas que abrigavam as colônias estudadas foram fechadas à noite com telas de metal para facilitar a entrada de ar.

Além disso, ainda segundo LEÃO (2019), a contagem de abelhas adultas foi feita em laboratório com aspiração manual, utilizando sugadores acoplados à boca e conferindo os indivíduos com o auxílio de um contador manual. Para espécies muito populosas, como a *Scaptotrigona aff. postica* e *Friseomelitta longipes*, foi utilizado dióxido de carbono para anestésiar os indivíduos em algumas ocasiões.

A realização do processo de contagem para estimar a população de abelhas, comportamento higiênico e comportamento forrageiro é uma tarefa complexa que exige esforço significativo dos pesquisadores e apesar das informações importantes para a promoção das ASF no Brasil, estas metodologias podem impactar negativamente o comportamento natural das abelhas devido às interferências que esses métodos exigem. Além disso, métodos manuais são trabalhosos e sujeitos a erros, destacando a necessidade de novas tecnologias que ofereçam informações precisas sem interferir o cotidiano das colônias. A utilização de técnicas de inteligência artificial pode revolucionar esses estudos, proporcionando ferramentas automatizadas para monitoramento e análise, facilitando a coleta de dados e melhorando a precisão das estimativas populacionais, análises sobre a atividade de forrageamento e sanidade das colmeias.

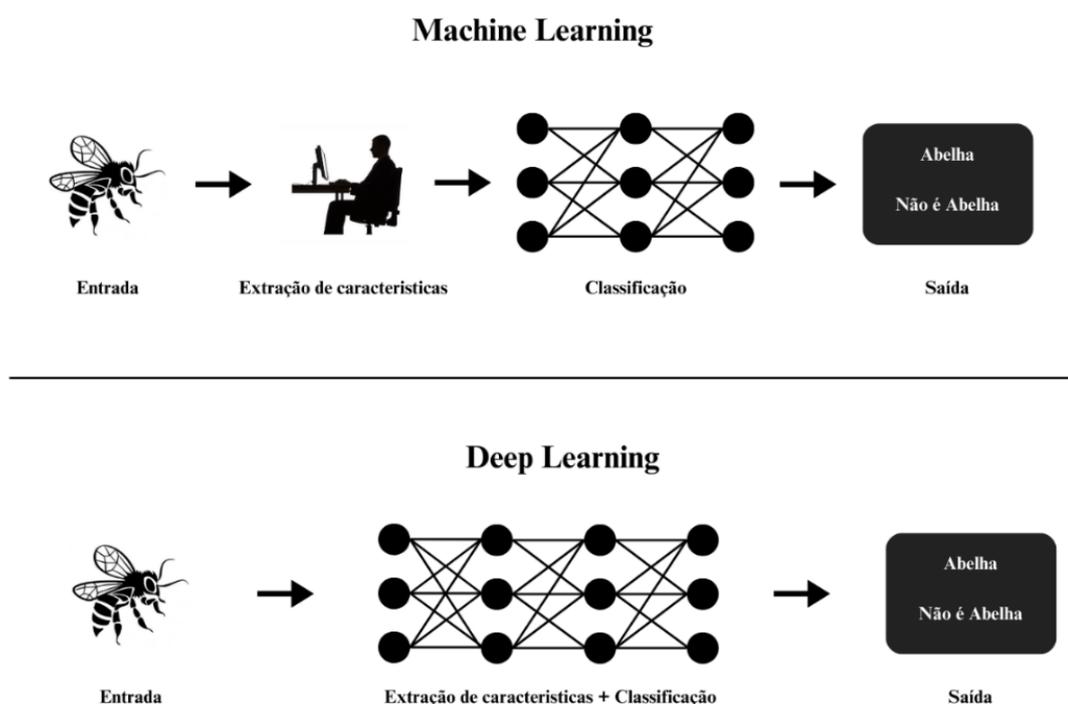
2.2 Redes Neurais Convolucionais

As Redes Neurais Convolucionais (CNNs) são ferramentas essenciais na aprendizagem profunda (*Deep learning*), tendo alcançado avanços significativos em áreas como visão computacional e processamento de linguagem natural, atraindo grande atenção da indústria e da comunidade acadêmica (ZEWEN *et al.*, 2021). A popularidade dos algoritmos de aprendizagem profunda cresceu com o avanço das GPUs, que reduzem o tempo de treinamento e aumentam a precisão das previsões, permitindo que esses algoritmos superem as técnicas tradicionais de aprendizagem de máquina em problemas complexos (SCHMIDHUBER, 2015; CHEVTCHENKO, 2018).

Além disso, as CNNs destacam-se por sua capacidade de instanciar múltiplas camadas que transformam objetos de entrada em diferentes níveis de representação, extraindo automaticamente características de alto nível necessárias para a classificação (BENGIO, 2011).

Suas principais vantagens são a facilidade de treinamento e a capacidade de generalização, o que elimina a necessidade de uma etapa específica de extração de características para cada problema (SCHMIDHUBER, 2015; CHEVTCHENKO, 2018). Por exemplo, uma CNN usada para detectar veículos pode ser reutilizada para detectar animais sem adaptação adicional. A Figura 5 apresenta as etapas de algoritmos convencionais em comparação com as etapas de algoritmos baseados em aprendizagem profunda, como as CNNs.

Figura 5: Etapas dos algoritmos tradicionais e dos algoritmos baseados em aprendizagem profunda.

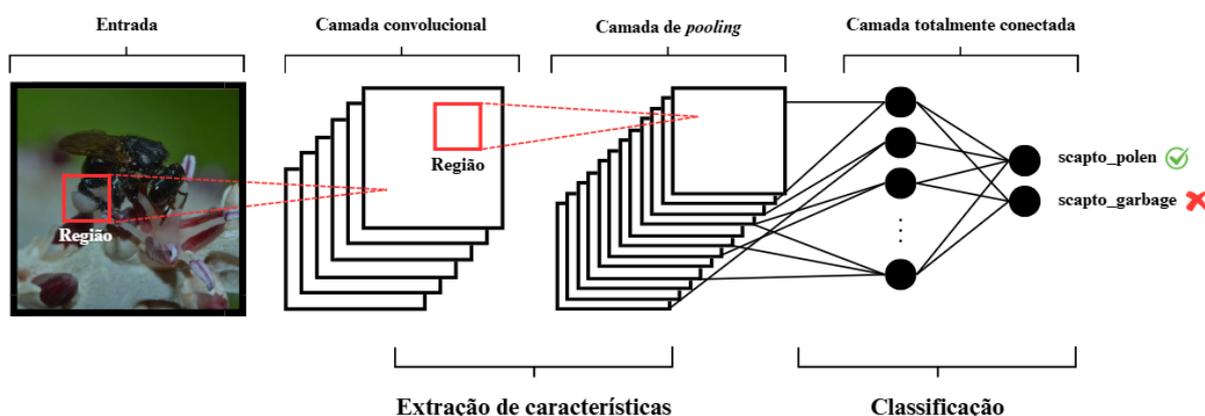


Fonte: Do autor com base em GEORGE SEIF (2018).

A CNN utiliza três elementos básicos para a extração das características, como podemos observar na imagem da Figura 6, que apresenta um tipo de arquitetura comumente encontradas em CNNs. Primeiro, a camada de convolução, que realiza a extração inicial dos recursos capturados na imagem. Nessa etapa, o filtro de convolução, de tamanho reduzido, passa por todos os dados de entrada para realizar a operação de convolução. Em seguida, a camada de *Pooling* entra em ação, diminuindo o tamanho dos dados capturados pela camada de convolução. Isso permite que o próximo passo convolucional receba uma forma diferente de representação de dados. O objetivo da camada de *Pooling* é reduzir o poder computacional necessário para processar os dados e extrair as principais características das imagens, garantindo que as classes possam ser reconhecidas independentemente de seu tamanho e

distribuição na imagem (HONG *et al.*, 2019). Por fim, a rede totalmente conectada, localizada no final da rede neural, aplica os recursos extraídos pelas camadas anteriores para a classificação. Nesta etapa, os dados são achatados e transformados em um vetor unidimensional de números, que são conectados por uma ou mais camadas totalmente conectadas, encerrando com uma camada softmax que contém a probabilidade das classes.

Figura 6: Arquitetura básica comumente encontradas em CNNs.



Fonte: Do autor com base em O'SHEA e NASH (2015) e com imagem de Giorgio Venturieri (2024).

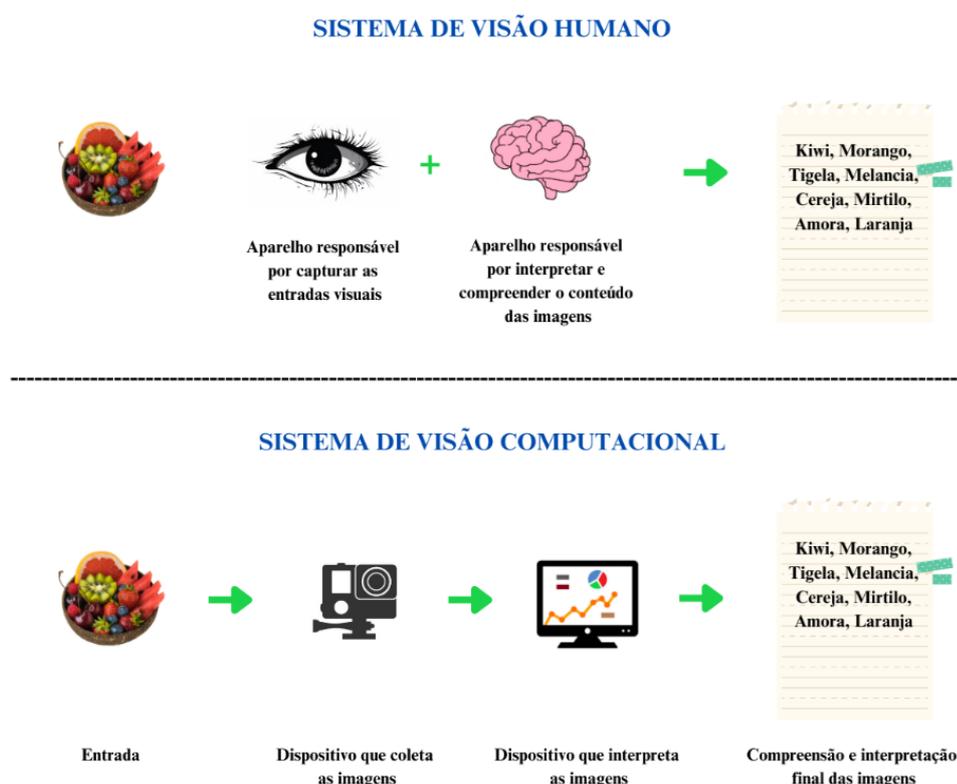
2.2.1 Visão Computacional

A técnica de visão computacional é um ramo da Inteligência Artificial que visa permitir que computadores capturem e compreendam padrões do mundo visual. Para atingir seus objetivos, as técnicas de visão computacional utilizam várias abordagens, incluindo CNNs, Aprendizado Supervisionado, Aprendizado Não Supervisionado, Aprendizado Semi-Supervisionado, Transferência de Aprendizado, Processamento de Linguagem Natural (PLN), Processamento Paralelo com GPU, Algoritmos de Pré-processamento de Imagem, Técnicas de Segmentação de Imagem e Técnicas de Pós-processamento (GHAZAL *et al.*, 2024).

A visão computacional é uma técnica de inspeção que se baseia na análise e processamento de imagens, oferecendo uma abordagem automatizada, não destrutiva, econômica, rápida e sem contato para determinar padrões de qualidade e controle em diversos setores (BROSNAN *et al.*, 2002; BROSNAN *et al.*, 2004; SUN, 2007; SYKES *et al.*, 2024). Sua aplicação vai além de substituir a inspeção manual, aprimorando também as habilidades manuais na indústria (SALDAÑA *et al.*, 2013), além de melhorar a precisão e a repetibilidade dos processos

(CHOPDE *et al.*, 2013). A imagem da Figura 7 ilustra a comparação entre as interpretações do sistema de visão humano e do sistema de visão computacional.

Figura 7: Visão Humana x Visão Computacional.



Fonte: Autor (2024).

2.3 YOLO (*You Only Look Once*)

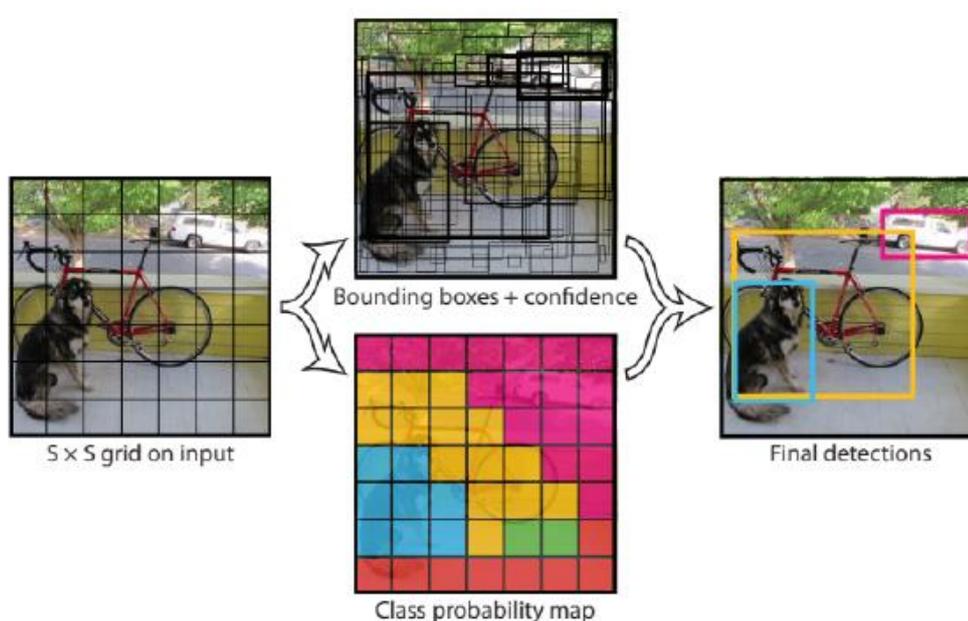
A técnica de detecção de objetos em tempo real emergiu como um componente crítico em inúmeras aplicações, abrangendo vários campos, como veículos autônomos, robótica, vigilância por vídeo e realidade aumentada. Entre os diferentes algoritmos de detecção de objetos, o framework YOLO se destacou pelo seu notável equilíbrio entre velocidade e precisão, permitindo a identificação rápida e confiável de objetos em imagens (SÁ *et al.*, 2023).

O YOLO utiliza uma única rede neural, recebendo uma imagem de entrada e treinando-a integralmente para prever caixas delimitadoras (*bounding boxes*) junto com as possíveis classes associadas a cada uma delas. Devido ao uso de uma única rede, o YOLO consegue alcançar

uma velocidade superior no processamento, tornando-se ideal para a detecção de objetos em tempo real (HUANG; PEDOEEM; CHEN, 2018).

O YOLO modela a detecção como um problema de regressão, ele divide a imagem em uma grade de $S \times S$, onde cada célula da grade pode conter várias caixas delimitadoras (REDMON *et al.*, 2016). Para cada caixa, é calculada a probabilidade de existência de um objeto. Se essa probabilidade ultrapassa um determinado limiar, a caixa é considerada uma candidata para a localização do objeto na imagem de entrada, conforme ilustrado na Figura 8.

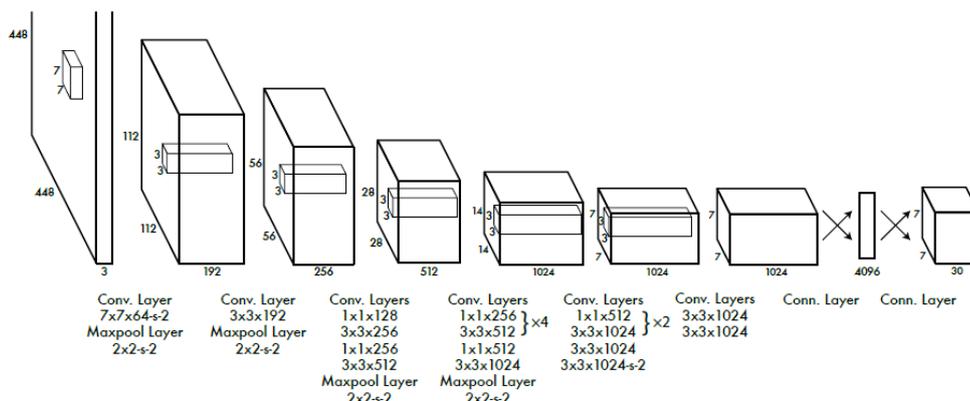
Figura 8: Configuração Inicial do Modelo YOLO.



Fonte: YOLO. (REDMON *et al.*, 2016).

Na Figura 9, é apresentada a configuração inicial do modelo YOLO. Este modelo consiste em uma rede neural com 24 camadas convolucionais, seguidas por 2 camadas totalmente conectadas. Para otimizar o espaço das camadas anteriores, são utilizadas camadas de convolução 1×1 intercaladas. As camadas convolucionais da rede YOLO foram previamente treinadas usando a arquitetura de classificação de imagens do ImageNet, onde as imagens de entrada foram processadas com metade da sua resolução original (REDMON *et al.*, 2016). As camadas convolucionais iniciais são responsáveis pela extração de características das imagens, enquanto as camadas totalmente conectadas fazem a previsão das probabilidades e das coordenadas das caixas delimitadoras na imagem de saída.

Figura 9: Arquitetura da rede de detecção YOLO.



Fonte: (REDMON *et al.*, 2016).

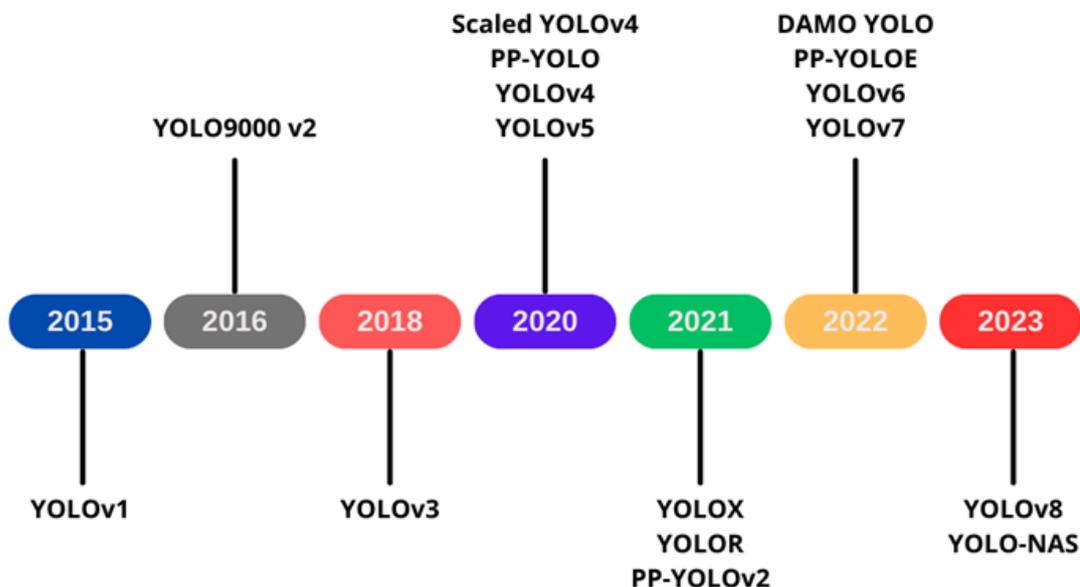
2.3.1 Aplicações com Redes YOLO

O algoritmo YOLO revolucionou a detecção de objetos em tempo real, sendo amplamente aplicado em diversas áreas, como veículos autônomos, vigilância por vídeo, análise esportiva, interação homem-computador, agricultura e sistemas de biometria e segurança.

Nas aplicações de veículos autônomos, o YOLO é essencial para a navegação segura, permitindo a rápida identificação e rastreamento de veículos, pedestres, bicicletas e outros obstáculos, contribuindo significativamente para evitar colisões (LAN *et al.*, 2018; HSU e LIN 2021). Em vigilância por vídeo, o YOLO é usado para o reconhecimento de ações, ajudando a monitorar comportamentos suspeitos ou atividades específicas, o que melhora a segurança em ambientes monitorados (SHINDE; KOTHARI e GUPTA, 2018; ASHRAF *et al.*, 2022).

Na análise esportiva, ele monitoriza o desempenho de jogadores, identifica padrões de jogo e fornece insights detalhados sobre o esporte, oferecendo dados valiosos para treinadores e uma experiência mais envolvente para o público (ZHENG e ZHANG *et al.*, 2022). Na interação homem-computador, o YOLO reconhece gestos e ações humanas, permitindo uma interação mais intuitiva e natural com dispositivos e sistemas, especialmente em ambientes de realidade virtual e aumentada (MA; CELIK; LI, 2021).

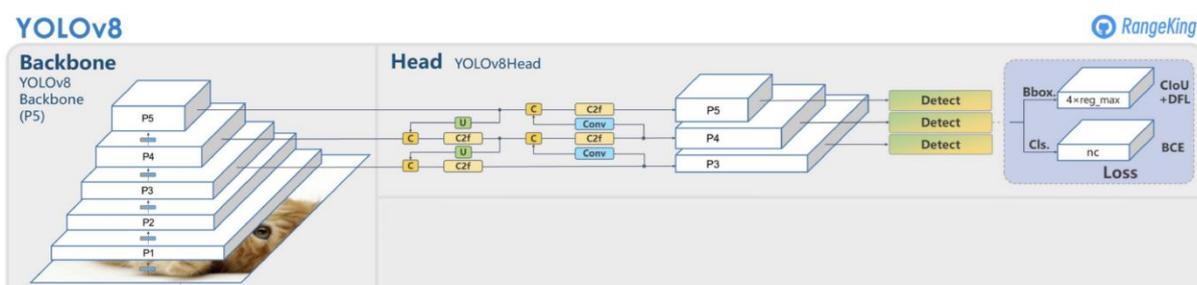
Figura 11: Linha do tempo das versões do YOLO.



2.3.2 Arquitetura YOLOv8

A arquitetura do YOLOv8 apresentado na Figura 12 é composta por duas partes principais, o *backbone* e o *head*, ambos utilizando uma rede neural totalmente convolucional.

Figura 12: Arquitetura YOLOv8.



Fonte: GitHub do usuário RangeKing.

A Figura 13 apresenta o fluxograma de dados do YOLOv8, destacando uma nova rede *backbone*, que é uma versão adaptada da arquitetura CSPDarknet53 (BOCHKOVSKIY; WANG; LIAO, 2020). Esta arquitetura é composta por 53 camadas convolucionais e implementa conexões parciais em estágio cruzado para otimizar a transmissão de informações entre os diferentes níveis da rede.

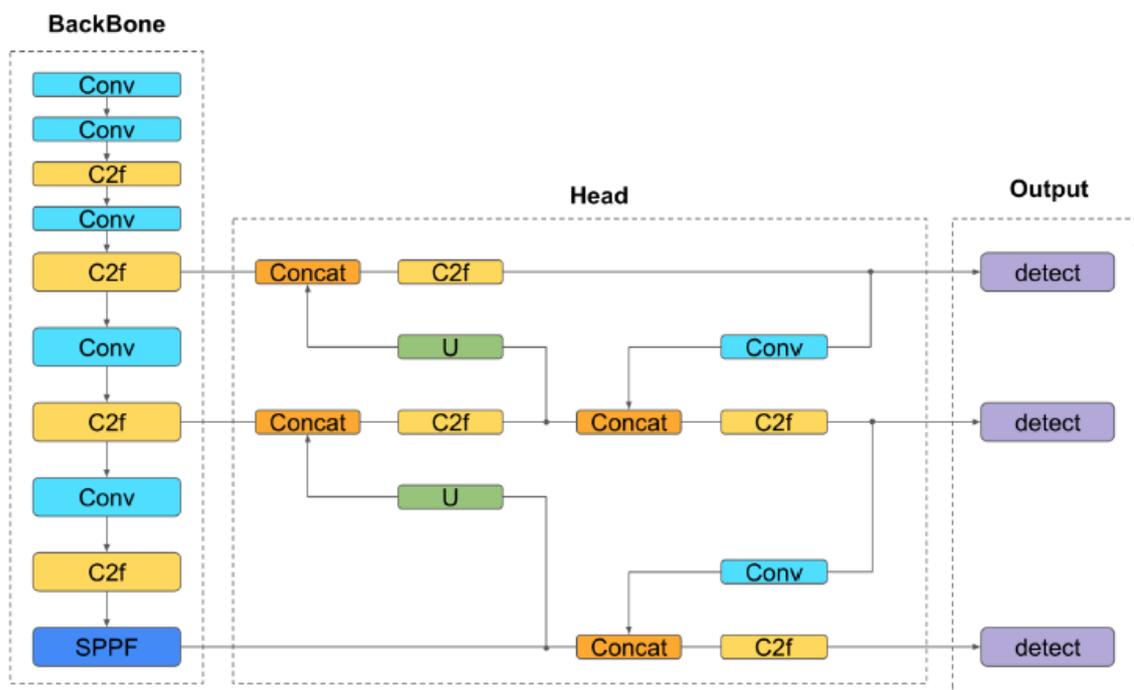
O *backbone* do YOLOv8 inclui uma série de camadas convolucionais dispostas de forma sequencial, responsáveis por extrair características importantes da imagem de entrada. Além disso, o novo módulo C2f combina características de alto nível com informações contextuais para aumentar a precisão da detecção. O módulo SPPF (Spatial Pyramid Pooling Faster) e outras camadas convolucionais subsequentes processam características em várias escalas (HE *et al.*, 2015; RANGEKING; JOCHER, 2023).

O *head* do YOLOv8 utiliza os mapas de características gerados pelo *backbone* para produzir a saída final do modelo, que inclui caixas delimitadoras e classes de objetos. Este *head* é projetado para ser modular, permitindo que cada ramo se concentre em tarefas específicas, como pontuações de objetividade, classificação e regressão, o que melhora a precisão global do modelo.

As camadas U, ou camadas de *upsample*, aumentam a resolução dos mapas de características (RANGEKING; JOCHER, 2023). O *head* emprega uma série de camadas convolucionais para analisar esses mapas, seguido por uma camada linear que prevê as caixas delimitadoras e as probabilidades das classes. O design do *head* é otimizado para proporcionar velocidade e precisão, com atenção especial ao número de canais e tamanhos de kernel de cada camada para maximizar o desempenho (SOHAN *et al.*, 2024).

Por fim, o módulo de detecção utiliza uma combinação de camadas convolucionais e lineares para transformar as características de alta dimensão em caixas delimitadoras e classes de objetos de saída. Toda a estrutura é concebida para ser rápida e eficaz, mantendo uma alta precisão na detecção de objetos.

Figura 13: Visualização da arquitetura YOLOv8, as setas representam o fluxo de dados entre as camadas.



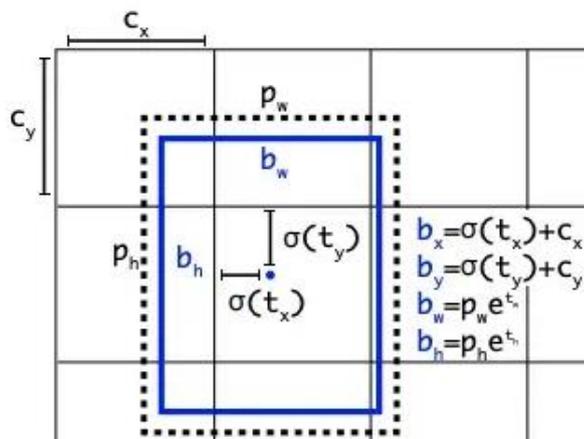
Fonte: SOHAN *et al.*, 2024.

2.3.3 Avanços na Arquitetura

Assim como os modelos YOLOv6 e YOLOv7, o YOLOv8 não depende de âncoras. Isso significa que ele prevê diretamente o centro de um objeto, sem precisar calcular desvios a partir de caixas âncoras conhecidas. Nos modelos anteriores, como o YOLOv5 e versões anteriores, o uso de caixas âncoras era complexo. Embora representassem a distribuição da caixa de referência do alvo, não refletiam o conjunto de dados personalizado (LIU; HASAN; LIAO, 2023). As âncoras, retângulos de tamanhos pré-definidos, foram introduzidas a partir do YOLOv2 para que as caixas delimitadoras previstas tivessem maior relação com as caixas esperadas como resultado.

Essas âncoras possuíam tamanhos de altura e largura próximos aos dos objetos identificados, sendo criadas durante o treinamento da rede neural com base nas classes de objetos (Figura 14). A partir das coordenadas das caixas dos objetos detectadas, as âncoras eram selecionadas, redimensionadas para a proporção dos objetos identificados e utilizadas como saída da rede neural YOLO.

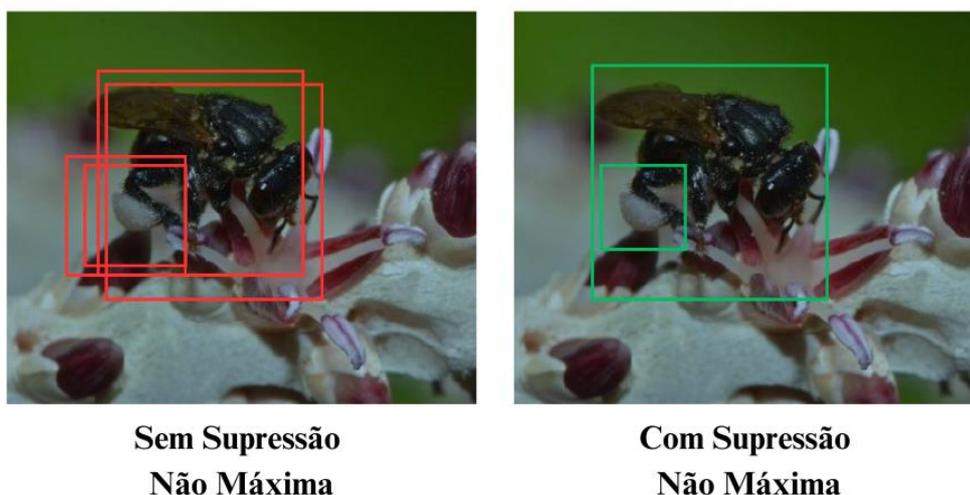
Figura 14: Visualização de uma caixa de âncora no YOLO.



Fonte: blog.roboflow.com.

A detecção sem âncoras reduz o número de previsões de caixas, acelerando a supressão de não-máximos (NMS), uma fase de pós-processamento filtra as detecções candidatas após a inferência (LIU; HASAN; LIAO, 2023). Durante a detecção de objetos, várias caixas delimitadoras são identificadas, mas muitas não contêm objetos ou compartilham a mesma região de um objeto (Figura 15). Portanto, é necessário remover as caixas com baixas probabilidades ou que compartilham área.

Figura 15: Ilustração do processo de tomada de decisão das redes YOLO.



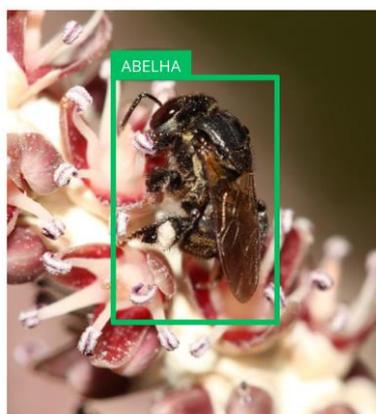
Fonte: Autor com imagens de Giorgio Venturieri (2024).

2.4 Medidas para avaliação de modelos de detecção

2.4.1 *Intersection Over Union* (Interseção sobre União)

Os sistemas de detecção de objetos fazem previsões em termos de uma caixa delimitadora e um rótulo de classe como apresentando na figura 16.

Figura 16: Exemplo de detecção de objetos com uma abelha.



Fonte: Autor com imagem de Giorgio Venturieri (2024).

A medida *Intersection over Union* (IoU) é amplamente utilizada para avaliar o desempenho em benchmarks de detecção de objetos (REZATOFIGHI *et al.*, 2019). Ela quantifica a sobreposição entre a caixa delimitadora prevista e a esperada, dividindo a área de interseção pela área de união de ambas. Um valor de IoU mais próximo de um indica uma detecção mais precisa em relação à rotulação. A Figura 17 ilustra graficamente esse cálculo.

Figura 17: Intersection over Union.

$$IoU = \frac{\text{area of overlap}}{\text{area of union}} = \frac{\text{Predicted box} \cap \text{Ground Truth}}{\text{Predicted box} \cup \text{Ground Truth}}$$

Para tarefas de detecção de objetos, calculamos a Precisão e o Recall usando o valor de IoU para um determinado limite (*Threshold*) de IoU.

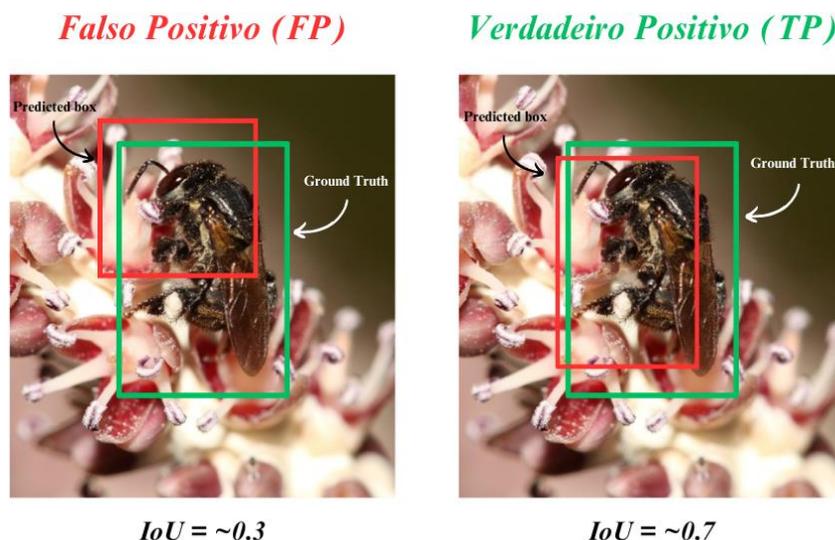
Para compreender o cálculo da precisão e do *recall*, é importante entender os seguintes conceitos:

- **Verdadeiro Positivo (TP)**: representa uma detecção correta, onde o IoU obtido é maior que o limite definido.
- **Falso Positivo (FP)**: representa uma detecção incorreta, seja identificando um objeto inexistente ou uma detecção errada de um objeto existente, com IoU abaixo do limite.
- **Falso Negativo (FN)**: representa a ausência de detecção de um objeto que está presente.

Esse conceito é importante para determinar a precisão das previsões. Um limiar de IoU é estabelecido para avaliar se uma detecção é correta ou não. Se o valor de IoU obtido ultrapassar esse limiar, a detecção é considerada correta, caso contrário, é considerada incorreta. Por exemplo, nas imagens da Figura 18, temos o limiar de IoU = 0,5 se o valor de IoU para uma previsão for 0,3, a previsão é classificada como Falso Positivo (FP). Por outro lado, se o IoU for 0,7, a previsão é classificada como Verdadeiro Positivo (TP)

Figura 18: Previsões para diferentes limites de IoU.

if IoU threshold = 0.5



Fonte: Autor com imagens de Giorgio Venturieri (2024).

2.4.2 Precision, Recall e F1-Score.

A precisão (*precision*) é a proporção de detecções corretas entre todas as previsões feitas pelo modelo (AKTOUF; SHIVANNA; DHIMISH, 2024). Esta medida calcula a capacidade do modelo de identificar corretamente os objetos existentes. O cálculo da precisão é realizado da seguinte maneira:

$$P = \frac{TP}{TP + FP} \quad (2.1)$$

O *recall* é a proporção de detecções corretas entre todas as ocorrências reais. Ele mede a capacidade do modelo de capturar o máximo de detecções esperadas. A fórmula para calcular essa medida é a seguinte:

$$R = \frac{TP}{TP + FN} \quad (2.2)$$

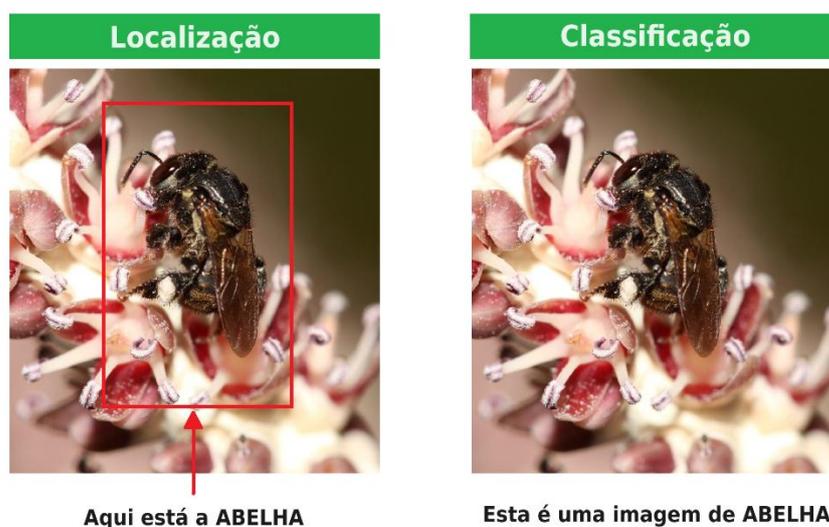
Outra medida importante é o *F1-score*, que é a média harmônica entre o recall e a precisão. Seu propósito é combinar essas duas medidas em um único valor, facilitando a avaliação geral do desempenho do modelo. A fórmula para calcular o F1-score é a seguinte:

$$F1 - score = 2 * \frac{P * R}{P + R} \quad (2.3)$$

2.4.3 Mean Average Precision (mAP).

O *Mean Average Precision* (mAP), em visão computacional, é uma medida de avaliação utilizada para detecção de objetos, abrangendo tanto a localização quanto a classificação (AKTOUF; SHIVANNA; DHIMISH, 2024). A localização determina as coordenadas da instância, como caixas delimitadoras, e a classificação identifica o que é a instância, por exemplo, um cachorro, um gato ou uma abelha, conforme ilustrado na Figura 19.

Figura 19: Localização x Classificação.



Fonte: Autor com imagens de Giorgio Venturieri (2024).

O mAP é uma medida que combina precisão e recall para medir o desempenho de um modelo. Ele é calculado como a média dos valores de precisão *Average Precision* (AP) em diferentes pontos de recall, integrando a área sob a curva de precisão-recall.

$$mAP = \frac{1}{N} \sum_{i=0}^N AP_i \quad (2.4)$$

Onde:

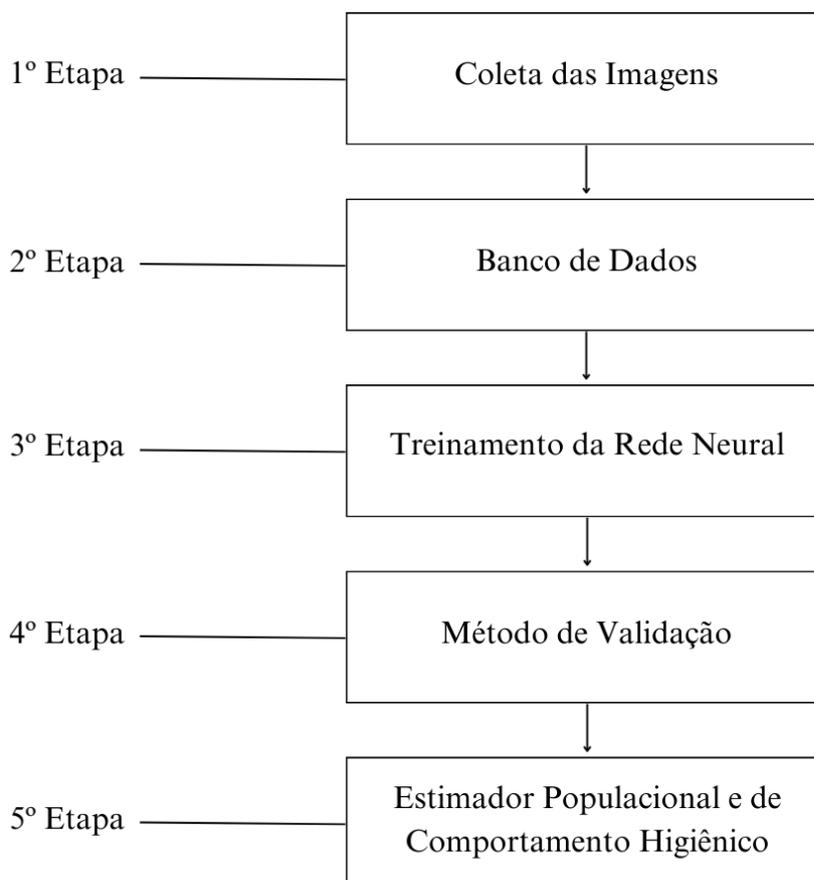
- N é o número de classes.
- AP_i é a média dos valores de precisão em diferentes pontos de recall para a classe i .

Neste capítulo, foram expostos os principais temas que auxiliam no desenvolvimento da metodologia proposta. Abordaram-se os conceitos de meliponicultura, enfatizando a criação e o manejo de abelhas sem ferrão, além dos estudos comportamentais sobre essas abelhas. Além disso, foram tratados os conceitos de redes neurais convolucionais, os modelos de detecção de objetos YOLO e as medidas de desempenho.

3. Metodologia

Neste capítulo, será apresentada a metodologia utilizada para o desenvolvimento da pesquisa, conforme exibido no fluxograma da Figura 20. Primeiramente, será descrita a técnica desenvolvida para a coleta de imagens de abelhas canudo, incluindo os equipamentos utilizados e o cenário em que ocorreram as gravações. Em seguida será discutido o desenvolvimento do banco de dados, assim como a definição das classes que compõem o modelo de rede neural. Após isso, será abordado o treinamento do modelo utilizando a rede YOLOv8, detalhando como ocorreu esta etapa de treinamento. Na penúltima etapa será apresentada a metodologia de validação do modelo comparando com métodos existentes. Por fim, será apresentada a metodologia para estimar a população e o comportamento higiênico das abelhas.

Figura 20: Fluxograma metodológico.



3.1 Coleta dos Dados (Aquisição, Transmissão e Armazenamento)

Para formação do banco de imagens a ser implementado no trabalho, utilizou-se a estrutura do Meliponário (MELI-TIC I) do Laboratório de Análises de Sistemas Sustentáveis da Embrapa Amazônia Oriental (1°26'15.9"S 48°26'54.3"W), apresentado na Figura 21. Neste meliponário foram utilizadas caixas padrões para a abelha *Scaptotrigona* spp do tipo INPA/Embrapa (Figura 21), para as quais foi desenvolvida uma plataforma de coleta de imagens, visando tornar o processo menos invasivo e, dessa forma, gerar pouco impacto na dinâmica das abelhas.

Figura 21: Imagem do Meliponário.



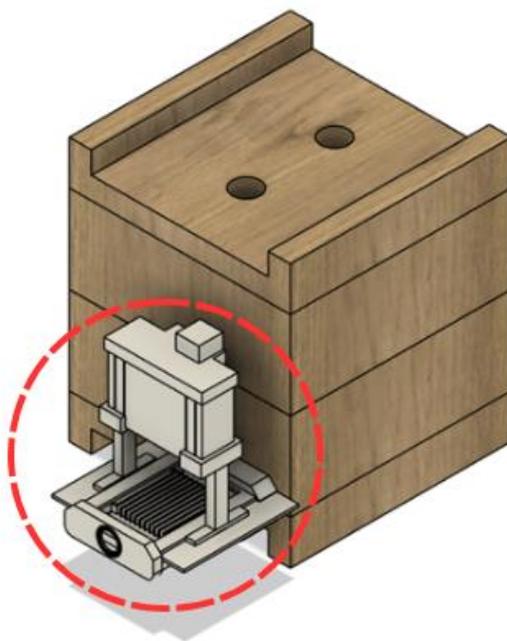
A plataforma desenvolvida foi feita utilizando impressão 3D para o aperfeiçoamento de uma nova técnica de aquisição de imagens, onde um protótipo de plataforma foi projetado utilizando softwares de engenharia como o Fusion 360² da empresa Autodesk, e o Ultimaker Cura³.

A plataforma é feita de biopolímero ácido poliláctico (PLA) e instalado nas entradas das colmeias, conforme ilustrado na Figura 22. O PLA é um polímero derivado de recursos renováveis, diferindo dos plásticos derivados de combustíveis fósseis que não se degradam facilmente no meio ambiente. Por ser muito fácil de trabalhar na impressão 3D, o PLA foi uma excelente alternativa para o desenvolvimento dos protótipos deste trabalho.

² www.autodesk.com/fusion360 acessado em: 18/12/2024

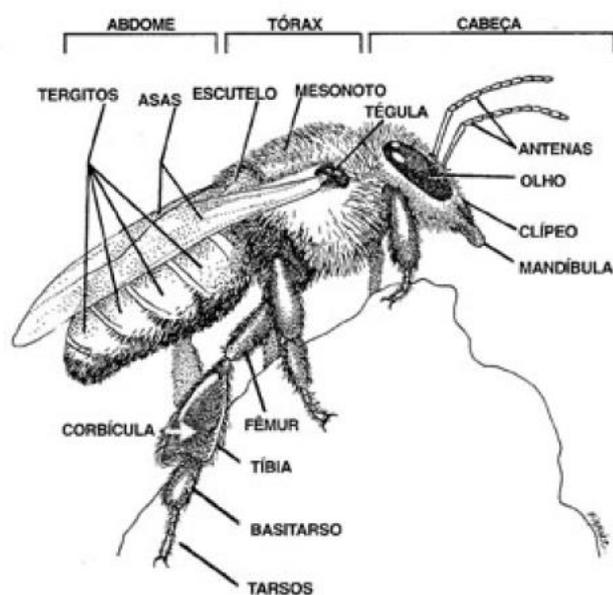
³ www.ultimaker.com acessado em: 18/12/2024

Figura 22: Ilustração da instalação da plataforma na entrada da colmeia.



Um dos critérios importantes e inovadores para o desenvolvimento da plataforma foi levar em conta a anatomia da abelha canudo. Na imagem da Figura 23 apresentam-se as principais partes do corpo de uma operária de Meliponíneo que levamos em consideração para o aperfeiçoamento do sistema.

Figura 23: As principais partes do corpo de uma operária de Meliponíneo (*Melipona compressipes*).



Fonte: Desenho de France Martin Pedreira baseado em foto de Paulo Nogueira Neto.

Para a transmissão e armazenamento das imagens, um computador de baixa configuração e com acesso à internet foi colocado próximo às colmeias (Figura 24), possibilitando no gerenciamento de todas as webcams remotamente via software do OBS Studio⁴. As transmissões ao vivo foram realizadas em um canal privado do YouTube⁵, onde todas as gravações foram armazenadas e utilizadas para a construção do banco de dados.

Figura 24: Implementação do Sistema.



Cada gravação teve duração de 12 horas, iniciando às 06:00h da manhã e seguindo até às 18:00h da noite, período em que o sol normalmente nasce e se põe em Belém. Além disso, outro fator para este horário se dá pelo motivo da abelha canudo possuir hábitos diurnos.

3.2 Banco de Dados

Optou-se pela formação de um banco de dados composto por imagens RGB (vermelho-verde-azul) de abelhas canudo. Para garantir a diversidade das imagens, foram utilizadas diversas colmeias com características distintas, como quantidade populacional (visualização presencial), número de discos de cria e presença ou ausência de rainha. Além disso, as imagens foram coletadas em diferentes condições climáticas, como em dias ensolarados, chuvosos e parcial ou completamente nublados. Os vídeos com as gravações das transmissões das abelhas foram

⁴ Disponível em www.obsproject.com acessado em: 20/11/2024

⁵ Disponível em www.youtube.com acessado em: 20/11/2024

convertidos em imagens utilizando o software Roboflow (DWYER; NELSON; HANSEN, (2024), com frequência de 1 frame por segundo.

Após este processo, também utilizando o software Roboflow, as imagens foram analisadas e anotadas por especialistas para garantir a qualidade das anotações. As imagens contendo características específicas das abelhas foram definidas, resultando em anotações distribuídas entre três classes de interesse, escolhidas para auxiliar no trabalho de detecção de objetos. As classes definidas pela equipe foram:

- **scapto**: imagens individuais de abelhas (Figura 25)
- **scapto_garbage**: imagens de abelhas carregando lixo (Figura 26)
- **scapto_polen**: imagens de abelhas carregando pólen nas corbículas (Figura 27)

Figura 25: scapto.



Figura 26: scapto_garbage.



Figura 27: scapto_polen.



3.3 Modelagem e Treinamento da Rede Neural

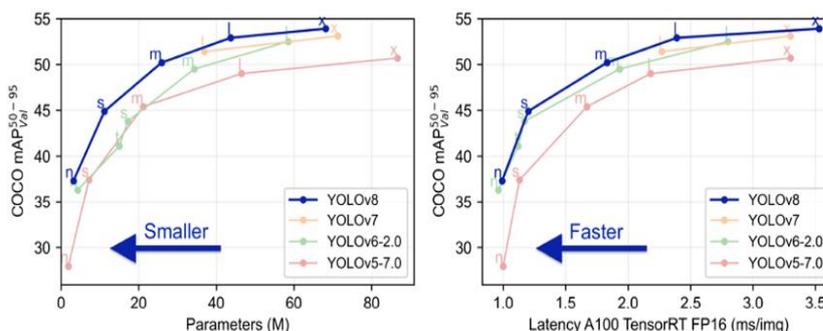
3.3.1 YOLOv8s

Para o desenvolvimento do modelo de detecção de objetos, optou-se pela escolha da rede YOLOv8 desenvolvido pela empresa Ultralytics⁶ e lançado em janeiro de 2023, a escolha desta rede se deve principalmente à sua velocidade e precisão superiores em relação a outras versões e modelos. Os gráficos da Figura 28 apresentam a comparação de desempenho dos modelos de detecção de objetos YOLO utilizando o conjunto de dados COCO (*Common Objects in Context*). O gráfico à esquerda ilustra a relação entre a complexidade do modelo (medida pelo número de parâmetros) e a precisão da detecção (COCO mAP50-95). O gráfico à direita mostra o trade-off entre a velocidade de inferência (latência utilizando a GPU da NVIDIA A100 TensorRT FP16) e a precisão para os mesmos modelos. Cada versão do modelo é representada

⁶ Disponível em www.ultralytics.com acessado em: 20/11/2024

por uma cor distinta, com marcadores indicando variantes de tamanho, de nano a extra. Essa relação é crucial para aplicações onde o processamento em tempo real é essencial, e a escolha do modelo é influenciada pela necessidade de equilibrar velocidade e precisão.

Figura 28: Comparação de desempenho de redes YOLO



Fonte: Ultralytics (2023)

Abaixo segue a lista de variantes dos modelos pré-treinados para detecção de objetos fornecidos pelo Ultralytics YOLOv8 com as informações básicas de cada modelo:

- **YOLOv8n (*nano*)**: Este é o menor e mais rápido modelo da família YOLOv8. Com um número reduzido de parâmetros, o YOLOv8n é otimizado para dispositivos com recursos limitados e aplicações em tempo real onde a velocidade é crucial, mesmo que isso possa sacrificar um pouco da precisão.
- **YOLOv8s (*small*)**: Este modelo é uma versão ligeiramente maior que o YOLOv8n. Ele oferece um equilíbrio entre velocidade e precisão, sendo adequado para aplicações que requerem uma boa performance em dispositivos com recursos moderados.
- **YOLOv8m (*medium*)**: O YOLOv8m é um modelo intermediário que fornece uma melhor precisão em comparação com os modelos menores, mantendo uma boa velocidade de inferência. Ele é ideal para aplicações que exigem uma combinação equilibrada de precisão e velocidade.
- **YOLOv8l (*large*)**: Este é o maior modelo entre os quatro mencionados, com um número significativamente maior de parâmetros. O YOLOv8l oferece a melhor precisão entre os modelos, mas com um custo de inferência mais lento. Ele é adequado para aplicações onde a precisão é mais importante do que a velocidade.

- **YOLOv8x (*extra large*)**: Este é o maior modelo da família YOLOv8. Com o maior número de parâmetros, o YOLOv8x oferece a melhor precisão entre todos os modelos, mas com a latência mais alta. Ele é ideal para aplicações que podem comprometer a velocidade em favor da máxima precisão na detecção.

A Tabela 2 abaixo mostra o desempenho das variantes dos modelos de detecção de objetos do YOLOv8. Esses modelos foram pré-treinados no conjunto de dados COCO, que inclui 80 classes predefinidas.

Tabela 2: Tipos de modelos de Detecção YOLOv8

Modelo	Tamanho (pixels)	mAPval 50-95	Velocidade CPU ONNX (ms)	Velocidade A100 TensorRT (ms)	Parâmetros (M)	FLOPs (B)
YOLOv8n	640	37.3	80.4	0.99	3.2	8.7
YOLOv8s	640	44.9	128.4	1.20	11.2	28.6
YOLOv8m	640	50.2	234.7	1.83	25.9	78.9
YOLOv8l	640	52.9	375.2	2.39	43.7	165.2
YOLOv8x	640	53.9	479.1	3.53	68.2	257.8

Fonte: Ultralytics (2023).

O YOLOv8 incorpora várias melhorias em sua arquitetura, incluindo uma melhor eficiência na inferência e otimizações no treinamento, que permitem processar imagens mais rapidamente sem comprometer a qualidade da detecção. Além disso, o YOLOv8 utiliza o framework Supervision⁷, que melhora a eficiência do treinamento e reduz o tempo de inferência, facilitando a integração com outras ferramentas e plataformas. Isso proporciona um fluxo de trabalho mais ágil e eficiente. Por meio desse algoritmo, também é possível implementar contadores para auxiliar no processo de contagem de objetos. A integração com ByteTrack⁸, uma tecnologia de rastreamento de objetos, proporciona uma rastreabilidade precisa e consistente dos objetos detectados, o que é particularmente útil em cenários dinâmicos onde os objetos se movem rapidamente, como é o caso das abelhas.

⁷ Disponível em <https://supervision.roboflow.com> acessado em: 18/11/2024

⁸ Disponível em <https://roboflow.com/model/bytetrack> acessado em: 18/11/2024

Baseado nas informações da Tabela 2, a variante escolhida para este trabalho foi a YOLOv8s, pois ela se adequa perfeitamente às capacidades do equipamento fornecido para o treinamento, proporcionando uma combinação ideal entre velocidade e precisão e mantendo um equilíbrio adequado entre desempenho e custo computacional, sem comprometer a integridade ou a velocidade do sistema.

3.3.2 Pré processamento de imagens

Todas as imagens que compõe o banco de dados foram capturadas com resolução Full HD de 1920x1080 pixels. Para otimizar a etapa de treinamento do modelo, as imagens foram redimensionadas para 800x800 pixels. Essa redução na resolução foi determinante para a diminuição do custo computacional, e foi adequada devido ao tamanho das abelhas, que possuem tamanhos que variam de 4 mm a 6 mm. Assim, as informações essenciais não foram comprometidas, pois ainda foi garantindo uma boa qualidade de imagem para a detecção das classes, como pode ser observado na Figura 29.

Figura 29: Imagem após redimensionamento: verde (scapto), vermelho (scapto_garbage) amarelo (scapto_polen)



As imagens das 3 classes de abelhas foram divididas aleatoriamente em 70%, 20% e 10% para os conjuntos de treino, validação e teste, respectivamente (ver Tabela 3). Todas as classes de interesse foram balanceadas em sua representação numérica, e para preservar a originalidade dos dados, a equipe decidiu não realizar o processo de *Data Augmentation*.

Tabela 3: Divisão dos Dados

Divisão do Conjunto de Dados	Conjunto de Treinamento	Conjunto de Validação	Conjunto de Teste
Imagens	70%	20%	10%
Pré-processamento	Redimensionamento: 800x800		
Augmentation	Nenhum aumento foi aplicado		

Fonte: Autor (2024).

3.3.3 Configuração do Treinamento

Para o treinamento do modelo YOLOv8s, utilizou-se uma configuração de hardware específica. O sistema operacional empregado foi o Linux Ubuntu, contando com uma placa gráfica NVIDIA GeForce RTX 3060 equipada com 12GB de memória GDDR6. A unidade central de processamento (CPU) foi um AMD Ryzen 7 5700X com frequência de 3.4GHz, possuindo 8 núcleos e 16 threads. A máquina também continha 16GB de memória RAM DDR4 operando a 3000MHz. O ambiente de desenvolvimento foi configurado com Python 3.11 e CUDA 11.5, o que permitiu uma eficiente utilização dos recursos de hardware para o trabalho.

Os hiperparâmetros de treinamento foram configurados para otimizar a performance do modelo e atender as necessidades computacionais disponíveis, na qual foram realizados testes prévios seguido uma abordagem de tentativa e erro para defini-los. Especificamente, configurou-se o número de épocas (epochs) para 100, o tamanho do lote (batch size) para 16, o tamanho das imagens (image size) para 800x800 pixels e a taxa de aprendizado inicial (learning rate, lr0) para 0.01. O treinamento foi realizado utilizando o Jupyter Notebook através do Anaconda Navigator, proporcionando uma interface interativa que facilitou a execução e o monitoramento das diversas etapas do processo.

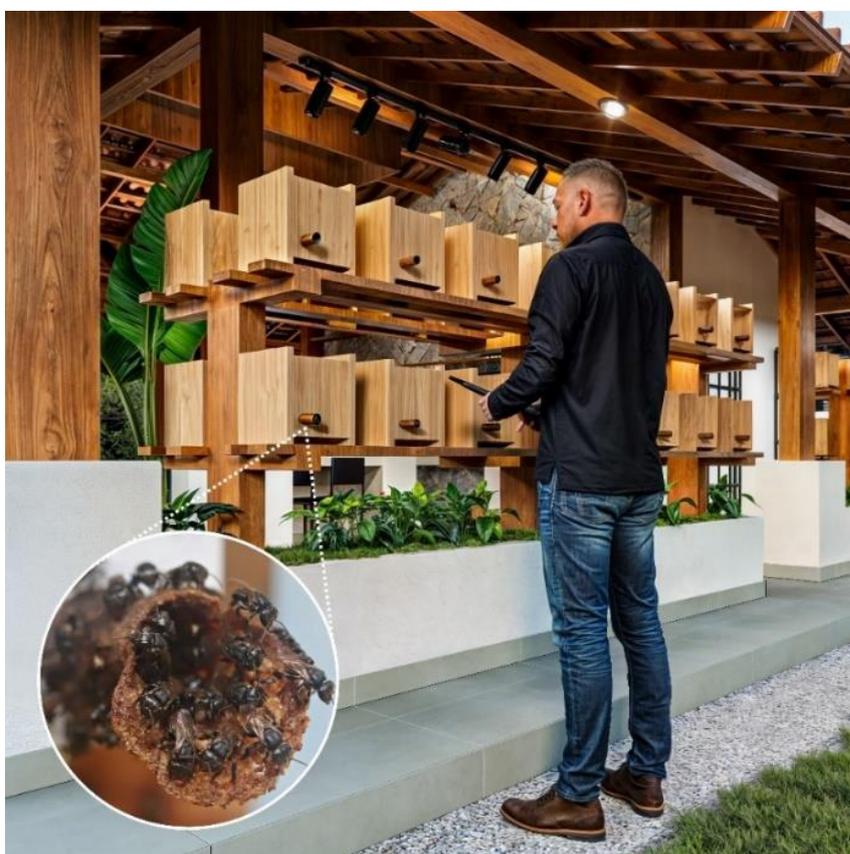
3.4 Metodologia de validação do Modelo

A metodologia utilizada para validar o modelo de rede neural baseou-se na mesma abordagem de contagem manual de abelhas descrita na seção 2.2.5 deste trabalho. No entanto, como ilustrado na Figura 30, observou-se que as abelhas do gênero *Scaptotrigona* apresentam características que complicam esse processo. Especificamente, as abelhas soldado tendem a permanecer em frente ao canudo, dificultando a contagem local. Além disso, o canudo, feito de

cerume, possui uma coloração escura, o que torna o processo ainda mais desafiador, pois a pessoa encarregada pela contagem teria apenas uma pequena fração de segundo para contabilizar a entrada ou saída das abelhas.

Outro fator complicador é a necessidade de se posicionar próximo às entradas das colmeias a uma distância relativamente pequena, dado que as abelhas têm tamanhos variando de 4 a 6 mm. Essa aproximação acaba gerando uma grande carga de estresse para essas colmeias, pois as abelhas entendem a pessoa como um predador, e isso acaba interferindo no fluxo normal dessas colmeias, uma vez que as abelhas possuem características defensivas (A.B.E.L.H.A, 2020), com isso, comprometendo a dinâmica do trabalho.

Figura 30: Ilustração do método existente de contagem



Para contornar esse problema, foram realizadas adaptações no método de contagem, preservando a essência do método manual. A partir das transmissões de vídeo, três voluntários foram selecionados para assistir ao mesmo vídeo e contar quantas abelhas saíam pela parte superior da tela nos primeiros cinco minutos de cada hora, das 6h da manhã até as 18h. Em seguida, repetiram o processo para contar as abelhas que entravam. A Figura 31 apresenta a visão que os voluntários obtiveram durante o processo de contagem.

Figura 31: Imagem do vídeo original para contagem manual



3.5 Metodologia para Estimativa Populacional e Comportamento Higiênico de Abelhas

3.5.1 Estimativa populacional

A população de abelhas em uma colmeia pode ser estimada observando o movimento de entrada e saída de abelhas. A fórmula para esse cálculo neste trabalho é baseada em uma suposição básica, na qual a população da colmeia é proporcional à taxa de abelhas entrando e saindo. Para isso, utilizamos o valor médio entre as abelhas que entram e saem fornecido pelo modelo de rede neural.

Pressuposição 1: Definimos a população (Pop) como o número estimado de abelhas presentes na colmeia em um determinado momento. A estimativa usa o valor médio (m) entre o número de abelhas entrando (E) e o número de abelhas saindo (S) da colmeia.

Matematicamente, o valor médio é expresso por:

$$m_{ES} = \frac{E + S}{2} \quad (3.1)$$

onde:

- E é o número de abelhas entrando na colmeia.
- S é o número de abelhas saindo da colmeia.
- mES é o valor médio entre E e S .

A fórmula para estimar a população é dada por:

$$Pop = \alpha \cdot mES \quad (3.2)$$

Onde, para fins de comparação de população entre colmeias, utilizou-se α igual a 1 neste trabalho.

3.5.2 Estimativa de Comportamento Higiênico

Pressuposição 2: O Comportamento Higiênico ($CH\%$) é proporcional a saída de lixo relativa à população de abelhas estimada pelo modelo ($garbage$), conforme equação 3.3.

$$CH\% = \left(\frac{\beta \cdot garbage}{\alpha \cdot mES} \right) \times 100 \quad (3.3)$$

onde:

- β é um fator de proporcionalidade característico do comportamento higiênico que se determinou o valor igual a 1.
- $garbage$ é o número de eventos observados de abelhas removendo lixo da colmeia pelo modelo.

Essa fórmula final revela que os valores percentuais de comportamento higiênico das colmeias dependem tanto da proporção de lixo removido quanto da relação entre os valores médios de entrada e saída de abelhas. Esses cálculos indicam o quanto, em termos percentuais, o comportamento higiênico está presente em cada colmeia, considerando a população. Assim, é possível determinar qual colmeia é mais eficiente na remoção de lixo, independentemente de sua população ser grande, média ou pequena. Vale ressaltar que não existe um valor de

referência para que uma colmeia de *Scaptotrigona* seja considerada higiênica com base no tamanho populacional. No entanto, ao fazer uma correlação entre colmeias, é possível identificar as mais eficientes na retirada de lixo por mais que essa diferença seja mínima.

Neste capítulo, foi apresentado o passo a passo da metodologia utilizada para o desenvolvimento do trabalho. Começando pela metodologia de aquisição, transmissão e armazenamento dos dados, seguida pela construção do conjunto de dados, modelagem e o treinamento da rede neural, finalizando com a metodologia de validação em relação aos métodos existentes e métodos para estimar a população e o comportamento higiênico entre colmeias.

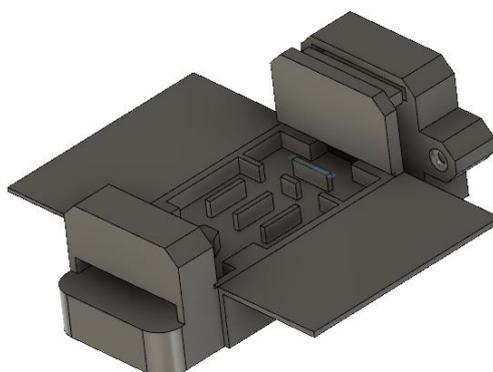
4. Resultados e discussão

Neste capítulo, serão apresentadas análises sobre a utilização da plataforma 3D e a metodologia desenvolvida para a coleta de imagens, além do processo de construção do banco de dados inédito criado para o trabalho. Serão discutidos os resultados obtidos na etapa de treinamento do modelo de rede neural e realizadas comparações com métodos existentes para validar o desempenho do modelo. Além disso, serão exploradas as análises comportamentais das abelhas, com foco na dinâmica de entrada e saída, nos padrões de atividade relacionados ao comportamento higiênico e ao forrageamento. Por fim, serão apresentadas comparações dos resultados referentes à estimativa populacional das colmeias.

4.1 Plataforma 3D

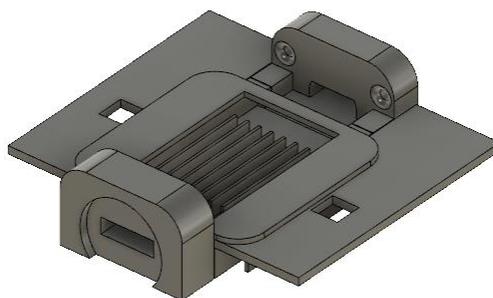
A plataforma 3D desenvolvida para a aquisição de imagens de abelhas passou por diversos ajustes até alcançar sua versão final, como ilustrado nas Figuras 32, 33 e 34. Na primeira versão apresentada na imagem da Figura 32, foi adotado um layout com uma espécie de labirinto para tentar reduzir a velocidade das abelhas, permitindo com que o modelo de rede neural contabilizasse as entradas e saídas de forma mais eficiente. No entanto, esse design resultou em um comportamento indesejado, fazendo com que as abelhas se "perdessem" ou acabassem colidindo umas com as outras, causando acúmulo na parte central da plataforma.

Figura 32: Primeira versão da plataforma.



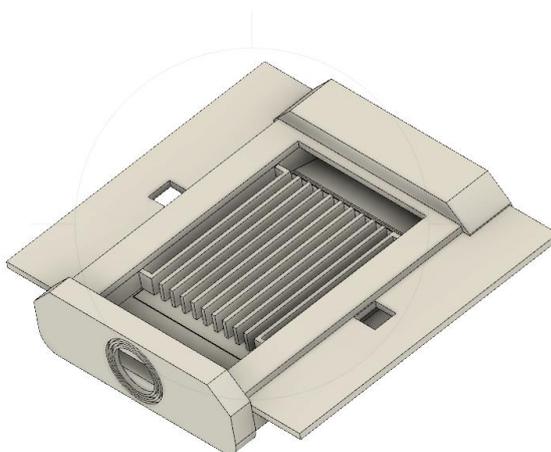
Na segunda versão, Figura 33, adotou-se um layout de trilhas paralelas para melhorar a fluidez do movimento das abelhas. Parâmetros como comprimento, largura e principalmente a altura e quantidade das trilhas ainda precisaram de ajustes devido ao congestionamento observado.

Figura 33: Segunda versão da plataforma.



Na versão final representada pela Figura 34, foram implementados os ajustes baseados nas observações das versões anteriores, incluindo o aumento do número de trilhas. No entanto, a maior quantidade de trilhas levou as abelhas a bloquear algumas passagens com resina, comportamento que se acredita ser um mecanismo de defesa contra predadores e abelhas invasoras, onde as abelhas restringem o tamanho da entrada para uma proteção mais eficiente. Ajustes milimétricos no comprimento e na altura das trilhas garantiram uma melhor fluidez e adaptação das abelhas conforme sua anatomia, facilitando também a contagem pelo modelo.

Figura 34: Versão Final da plataforma.



É importante destacar que em todas as colmeias utilizadas neste estudo, as abelhas formaram o canudo na entrada da plataforma, independentemente do tamanho da colmeia, da quantidade populacional, presença de rainha ou se a colônia estava acometida por qualquer tipo de doença. A resposta das abelhas à implementação da plataforma pode ser observada na imagem da Figura 35, que apresenta a formação do canudo na parte frontal da estrutura, indicando a aceitação da espécie a esse tipo de configuração.

Figura 35: Adaptação das abelhas com a plataforma 3D



4.2 Metodologia de Coleta de Imagens

O novo método de coleta de imagens de abelhas nativas sem ferrão consiste no uso de uma plataforma 3D instalada na entrada da colmeia, que permitiu o acoplamento de câmeras Full HD a 30 fps na parte superior da estrutura. As câmeras, por sua vez, foram conectadas a um computador com acesso à internet, possibilitando ajustes de foco e enquadramento de forma remota, sem a necessidade de deslocamento até o meliponário.

Para a transmissão dos dados, uma chave de segurança foi criada para redirecionar as informações com as imagens das abelhas através do software OBS Studio para o YouTube, permitindo assim a visualização em um canal privado em tempo real. Para o armazenamento foram utilizados tanto o próprio sistema de nuvem do YouTube quanto o computador instalado no meliponário que gerenciou todo o sistema.

A utilização de câmeras permitiu a visualização por uma nova perspectiva das trilhas, aliada a taxa de 30 frames por segundo, que demonstrou ser adequada para o trabalho devido a boa representatividade de informação, garantindo maior fluidez, considerando a rápida movimentação das abelhas.

Esta abordagem menos invasiva permitiu a criação de um banco de dados inédito e robusto das abelhas *Scaptotrigona*, o que foi fundamental para o desenvolvimento de algoritmos de IA, além de possibilitar o acompanhamento remoto e em tempo real por meio de um canal privado no YouTube (Figura 36). Essa estratégia permitiu à equipe aprimorar os métodos desenvolvidos neste trabalho e contribuiu para o desenvolvimento de novas abordagens de manejo da espécie, como a análise do período de abertura de floradas, detecção de doenças, detecção de ataques de predadores, entre outros, possibilitando na tomada de decisão em tempo real.

Figura 36: Transmissão do YouTube

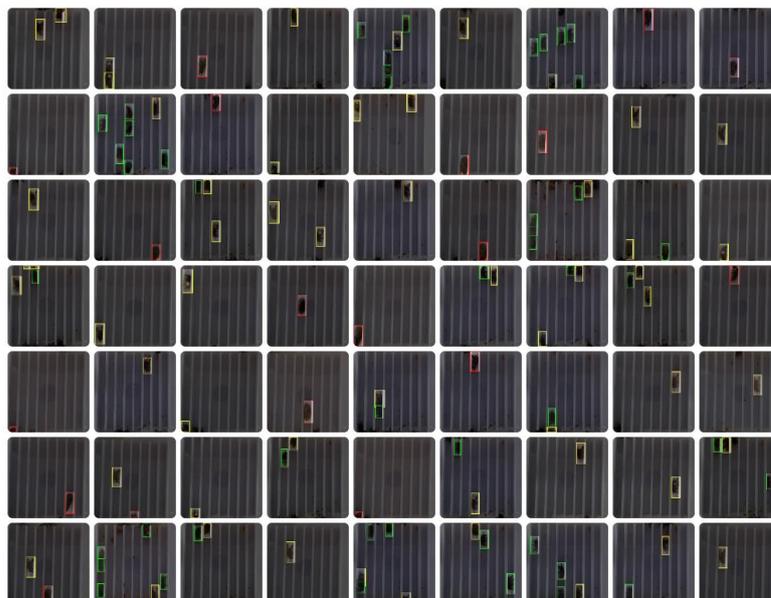


4.3 Banco de Dados Desenvolvido

O banco de dados de imagens de abelhas sem ferrão foi desenvolvido seguindo alguns pré-requisitos para auxiliar no desenvolvimento do modelo de detecção de objetos intitulado “scapto_bee_detection_model”. Esses requisitos incluíram o tratamento dos vídeos armazenados no sistema de nuvem do YouTube, utilizando o software Roboflow para converter os vídeos em imagens. A partir dessas imagens, ainda utilizando o Roboflow, foram realizadas anotações referentes às três classes de interesse escolhidas para este trabalho, resultando em um total de 7.806 imagens e 19.954 anotações. Essas anotações foram distribuídas de forma balanceada entre as três classes de interesse, com uma média de 2,5 anotações por imagem, proporcionando uma distribuição equilibrada e robusta para a análise comportamental.

O balanceamento das classes foi essencial para evitar viés no modelo, melhorar a precisão das previsões e reduzir erros, como falsos negativos e falsos positivos. Com classes balanceadas, o modelo conseguiu generalizar melhor, garantindo uma performance mais consistente e precisa em medidas de avaliação, como precisão, recall e F1-score. A Figura 37 apresenta algumas imagens das abelhas e as classes anotadas no Roboflow.

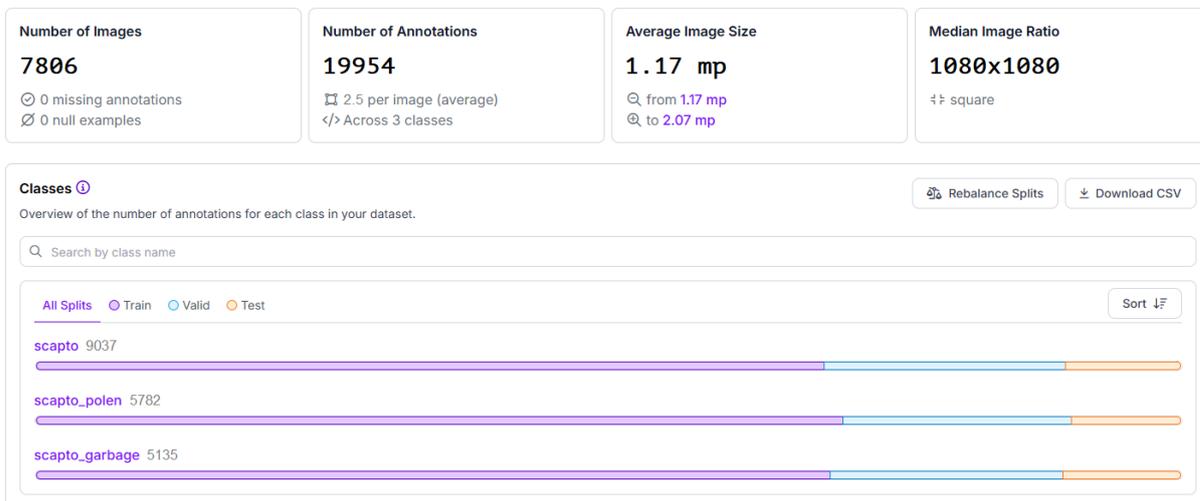
Figura 37: Exemplos de imagens do Banco de dados.



A imagem da Figura 38 apresenta a interface do Roboflow, que permite a análise detalhada do banco de dados desenvolvido. Nessa interface, é possível verificar a quantidade total de imagens que compõem o banco, identificar eventuais imagens que não foram anotadas, além

de conferir o volume e as características das anotações. A ferramenta também fornece informações sobre o tamanho e a proporção das imagens e permite uma análise individual das classes, facilitando a avaliação do balanceamento dos dados.

Figura 38: Análise do banco de dados



Fonte: Autor retirado Roboflow (2024).

Tabela 4: Informações do Banco de Dados

Informação por classe	Nº de imagens	Nº de anotações
scapto	3538	9037
scapto_polen	2264	5782
scapto_garbage	2004	5135
TOTAL	7806	19954

4.4 Resultados do Treinamento

A imagem da Figura 39 apresenta algumas informações referentes ao treinamento do modelo, bem como os resultados para o conjunto de validação. O treinamento durou cerca de 2,944 horas, aproximadamente 3 horas. Os resultados mostram que o modelo alcançou um mAP50 de 96% para as três classes de interesse combinadas. Especificamente, a classe "scapto" obteve um

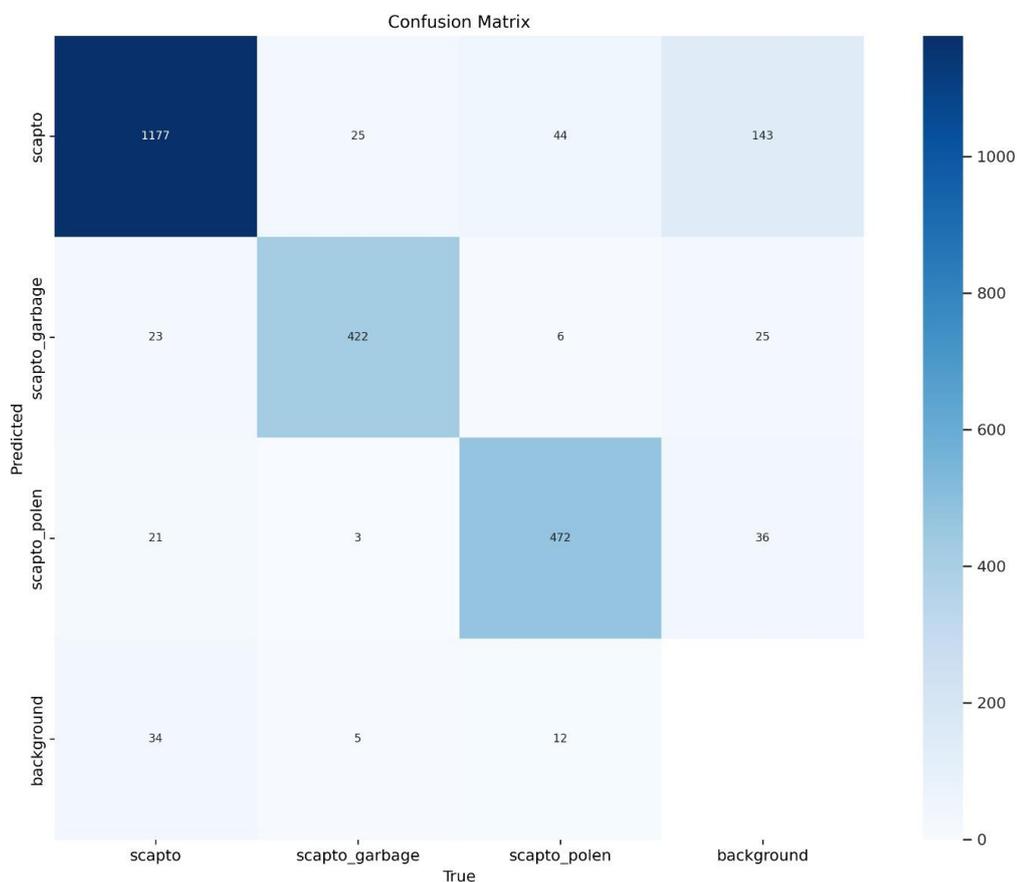
mAP50 de 95%, enquanto as classes "scapto_garbage" e "scapto_polen" atingiram um mAP50 de 96% cada.

Figura 39: Resultados de validação do Treinamento

```
Validating runs/detect/train2/weights/best.pt...
Ultralytics YOLOv8.0.227 Python-3.11.5 torch-2.1.2 CUDA:0 (NVIDIA GeForce RTX 3060, 12036MiB)
Model summary (fused): 168 layers, 11126745 parameters, 0 gradients, 28.4 GFLOPs
   Class      Images  Instances  Box(P)      R      mAP50  m
   -----  -
   all         1561     4380      0.931      0.9    0.96   0.725
   scapto      1561     2461      0.91       0.909  0.954  0.616
   scapto_garbage 1561     859      0.938      0.904  0.961  0.772
   scapto_polen 1561     1060     0.944      0.886  0.964  0.786
Speed: 0.2ms preprocess, 5.0ms inference, 0.0ms loss, 0.6ms postprocess per image
Results saved to runs/detect/train2
💡 Learn more at https://docs.ultralytics.com/modes/train
```

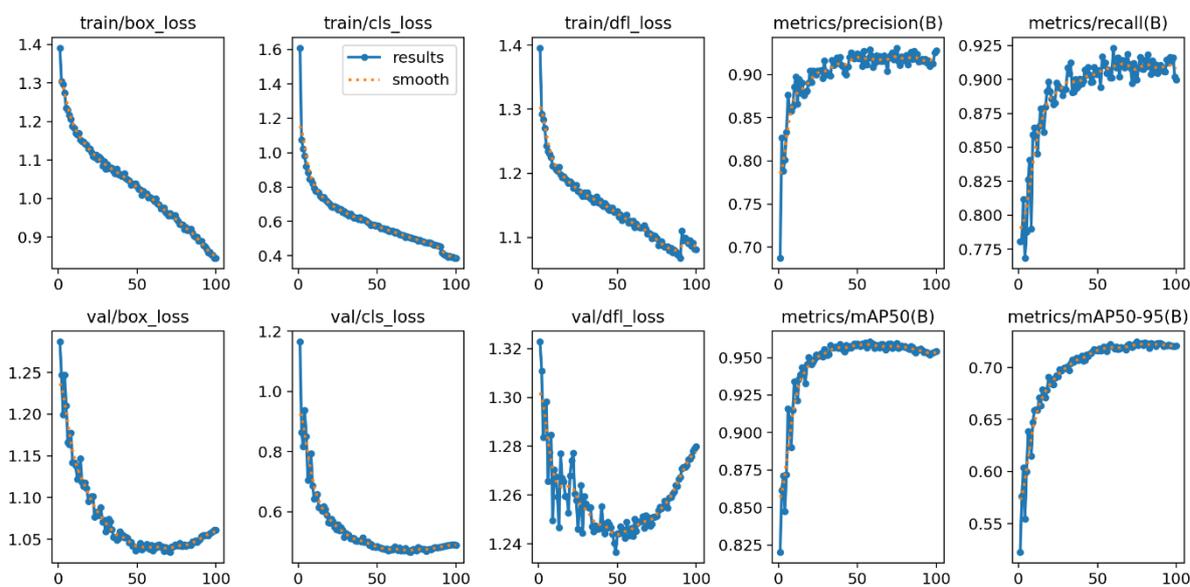
A matriz de confusão da imagem da Figura 40, representa o desempenho da rede no conjunto de teste para as três classes principais. É possível observar os acertos e erros do modelo, evidenciando tanto os verdadeiros positivos quanto as confusões entre as classes. Esses resultados permitem avaliar a eficácia do modelo e identificar áreas de melhoria na detecção.

Figura 40: Matriz de confusão normalizada



Os resultados da Figura 41 exibem uma análise mais detalhada dos gráficos de desempenho do modelo ao longo de 100 épocas. Apresenta-se de cima para baixo e da esquerda para a direita, as seguintes medidas: erro da caixa delimitadora durante o treinamento, erro de classificação durante o treinamento, erro focal distributivo durante o treinamento, medida de precisão, medida de recall, erro da caixa delimitadora durante a validação, erro de classificação durante a validação, erro focal distributivo durante a validação, medida mAP50 e medida mAP50-95.

Figura 41: Gráficos de desempenho



Analisando os gráficos, o modelo YOLOv8s apresentou uma boa performance no treinamento e na validação, com as curvas de erro convergindo para mínimos e as medidas de precisão convergindo para máximos. As perdas de *box_loss*, *cls_loss* e *dfl_loss* diminuíram consistentemente, indicando melhorias na localização e classificação dos objetos. As medidas de precisão e recall aumentaram, demonstrando eficácia na identificação dos objetos e minimização de falsos negativos. As medidas mAP50 e mAP50-95 também aumentaram significativamente, mostrando uma boa precisão média do modelo. A similaridade das curvas de perda e precisão entre treinamento e validação indica que o modelo está generalizando bem e é robusto para novas amostras, embora haja espaço para ajustes finos dos hiperparâmetros para melhorar ainda mais o desempenho.

4.5 Resultados da validação com métodos existentes de contagem x modelo

Os gráficos da Figura 42 e Figura 43 apresentam, respectivamente, as informações de entrada e saída de abelhas, conforme a metodologia descrita na seção 3.5 deste trabalho. Pode-se observar que, tanto para as entradas quanto para as saídas, o modelo, representado pela barra vermelha, sempre manteve uma contagem superior em comparação com a contagem feita por três voluntários nos primeiros 5 minutos de cada hora. Além disso, é possível notar variações nas contagens realizadas pelos três voluntários, o que indica que esses métodos manuais de contagem exigem um alto nível de concentração e, conseqüentemente, apresentam elevada variabilidade nos resultados. Às 18:05 o modelo não conseguiu contabilizar as abelhas entrando devido à falta de luminosidade do ambiente neste horário (início da noite), o mesmo se repetiu para as saídas na Figura 43.

Figura 42: Comparação de Entrada Modelo x Humano

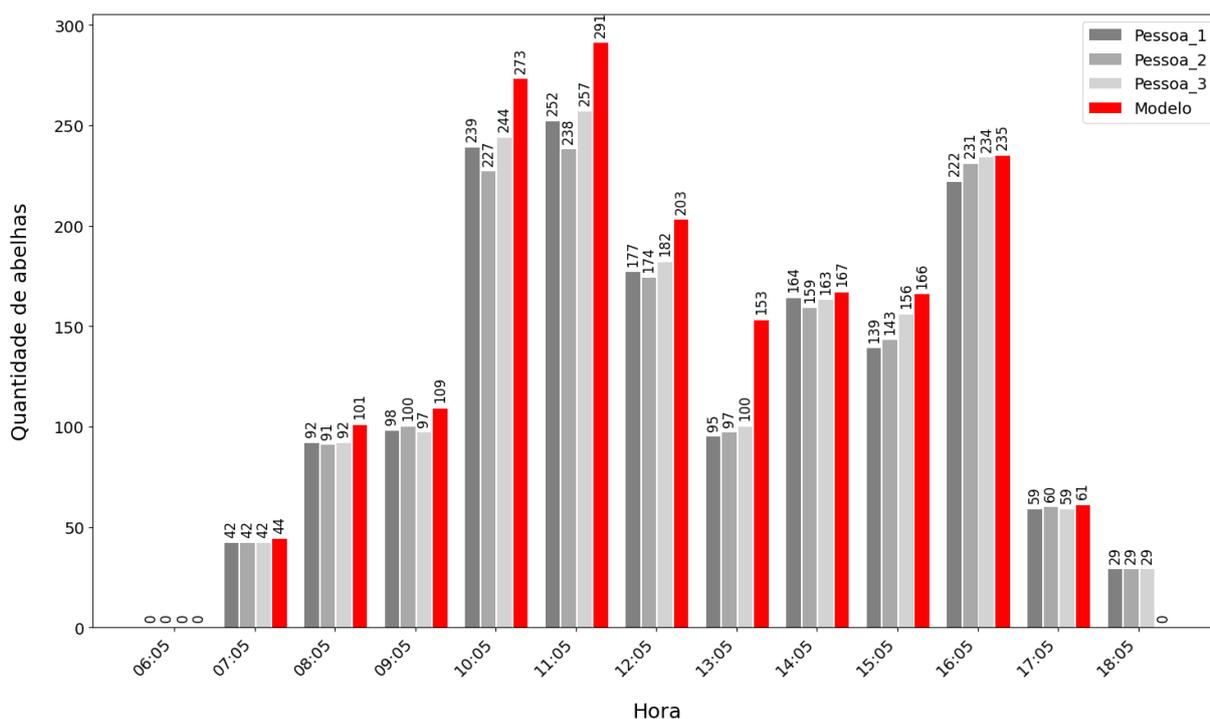
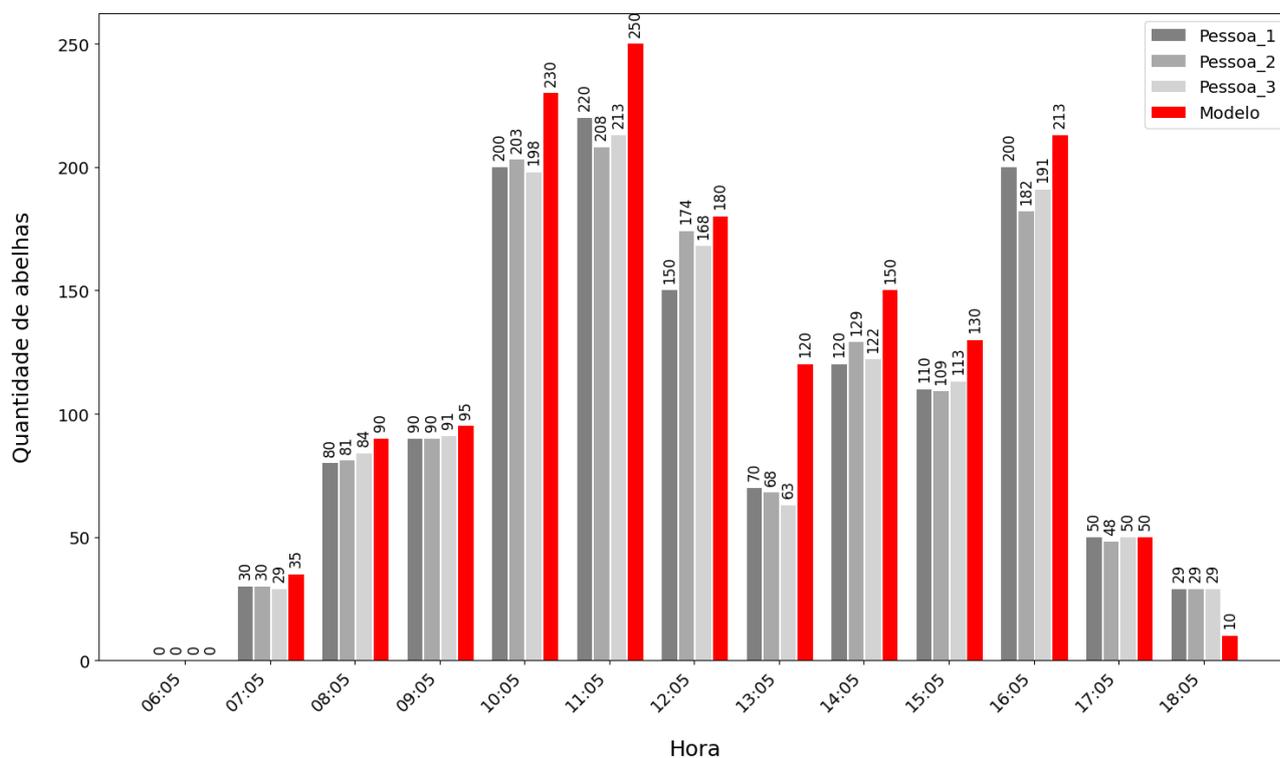


Figura 43: Comparação de Saída Modelo x Humano



4.6 Resultados comportamentais

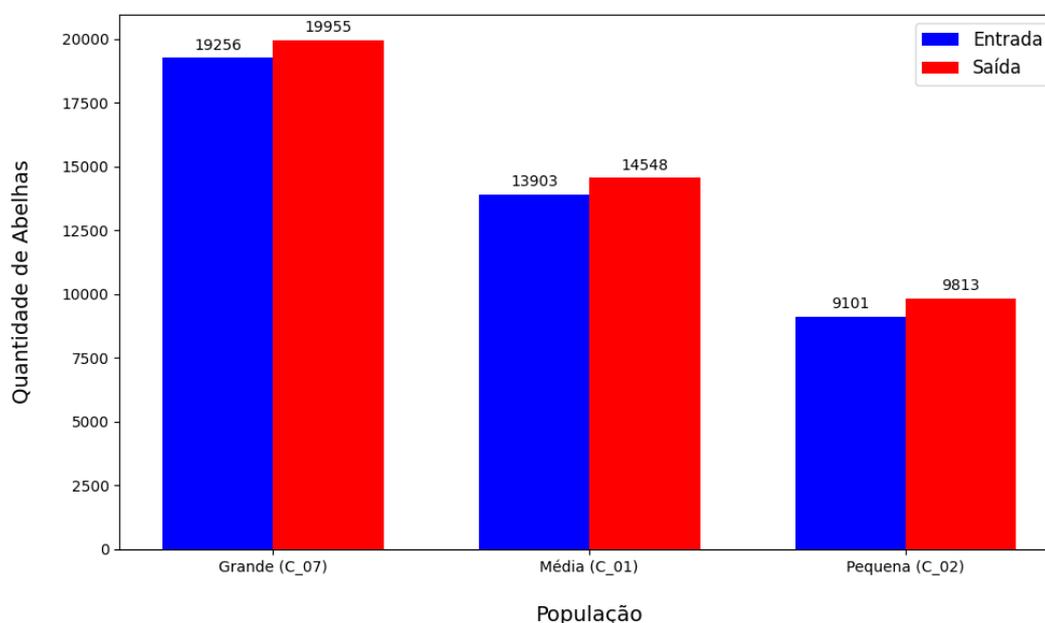
4.6.1 Estimador Populacional

O modelo de rede neural desenvolvido neste trabalho se revela uma ferramenta adequada para análises relacionadas ao tamanho populacional das abelhas, com o objetivo de estimar a população baseados no valor médio de entrada e saída das abelhas. No início das medições, especialistas classificaram todas as caixas de abelhas para este estudo, considerando o tamanho do ninho, o estoque de alimento, quantidade de discos de cria e outras características que foi determinado como o " α " na fórmula (3.1) deste trabalho. Dessa forma, foi pré-determinada a categoria das colmeias, classificando-as como colmeias com a população pequena, média e população grande.

O gráfico da Figura 44 apresenta os valores quantitativos de entrada e saída de abelhas em um único dia, mostrando uma correlação proporcional com a categoria das colmeias definidas pelos pesquisadores. Para a colmeia de população grande (C_07), o número de entrada foi de 19.256 abelhas, enquanto o de saída foi de 19.955. Na colmeia com população mediana (C_01)

registraram-se 13.903 entradas e 14.548 saídas. Já na colmeia com população pequena (C_02), os valores foram de 9.101 abelhas entrando e 9.813 saindo.

Figura 44: Comparativo entre 3 colmeias de *Scaptotrigona* com características populacionais distintas

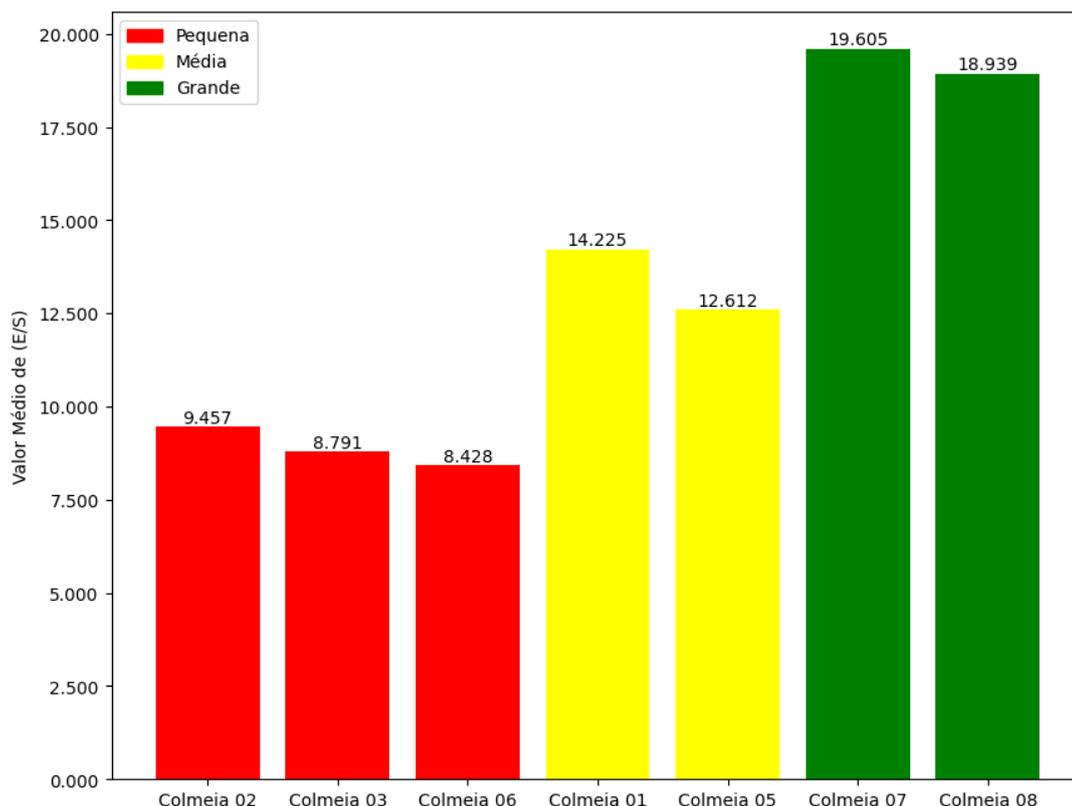


Outra análise observada é que o número de saída das abelhas é sempre maior do que o número de entrada, e essa tendência se mantém independentemente do parâmetro comportamental avaliado. Este comportamento pode ser explicado por vários motivos, como discutido na seção 2.2.3 deste trabalho, onde abordou-se que as operárias, em seus últimos dias de vida, iniciam atividades de forrageamento. Esse comportamento consiste em sair da colmeia em busca de recursos, o que as torna vulneráveis a ataques de predadores, condições climáticas adversas resultando em não retorno à colmeia ocasionando em morte ou morte natural devido ao forrageamento ser a última função no ciclo de vida das abelhas, onde normalmente elas morrem longe da colmeia para evitar qualquer contaminação que possa prejudicar o desenvolvimento da colônia.

Além disso, o número maior de saída em comparação com a entrada também pode ser associado ao comportamento das abelhas que retornam para as colmeias com néctar, resina ou pólen. Essas abelhas geralmente voltam mais rapidamente devido ao seu compromisso com a colônia, que exige a entrega rápida e eficiente dos recursos. Como resultado, a velocidade de retorno tende a ser maior do que a velocidade de saída, tornando a contagem de saída do modelo ligeiramente maior em relação à entrada, já que quanto maior a velocidade do objeto, mais difícil se torna o processo de detecção.

Diante deste cenário, pode-se utilizar faixas com os valores médios de entrada e saída das abelhas fornecido pelo modelo como parâmetro populacional apresentados na Figura 45. Por exemplo, colmeias com uma faixa de 5 mil a 10 mil *mES* podem ser classificadas como tendo população pequena, aquelas com 10 mil a 15 mil, como população média, e, finalmente, colmeias com 15 mil a 20 mil, como população grande.

Figura 45: Gráfico de *mES* por Faixa Populacional Sugerida pelo modelo.



Matematicamente, utilizando as fórmulas (3.1) e (3.2) para estimar a população apresentadas na seção 3.3.5.1 deste trabalho, a análise das três colmeias selecionadas pelos especialistas e com as informações obtidas com modelo de rede neural foi calculada da seguinte maneira:

- **Para a colmeia C_07:**

$$mES = \frac{19.256 + 19.955}{2} \rightarrow Pop = \alpha \cdot mES$$

$$mES = 1 \cdot 19.605 \rightarrow Pop = 19.605 \rightarrow \text{(População Grande)}$$

- **Para a colmeia C_01:**

$$mES = \frac{13.903 + 14.548}{2} \rightarrow Pop = \alpha \cdot mES$$

$$mES = 1 \cdot 14.225 \rightarrow Pop = 14.225 \rightarrow \text{(População Média)}$$

- **Para a colmeia C_02:**

$$mES = \frac{9.101 + 9.813}{2} \rightarrow Pop = \alpha \cdot mES$$

$$mES = 1 \cdot 9.457 \rightarrow Pop = 9.457 \rightarrow \text{(População Pequena)}$$

A Tabela 4 abaixo, apresenta os valores médios de entrada e saída de cada colmeia analisada.

Tabela 5: Tabela de Estimativa Populacional Baseado no *mES*.

Numeração da Colmeia	Entrada de Abelhas	Saída de Abelhas	Valor médio de <i>mES</i>	Estimativa de População
C_01	13.903	14.548	14.225	Média
C_02	9.101	9.813	9.457	Pequena
C_03	8.503	9.080	8.791	Pequena
C_05	12.378	12.847	12.612	Média
C_06	7.983	8.874	8.428	Pequena
C_07	19.256	19.955	19.605	Grande
C_08	18.655	19.223	18.939	Grande

Com esses resultados, existe a possibilidade de aprimorar modelos de redes neurais que reforcem a hipótese de que a quantidade populacional está relacionada às atividades externas das abelhas. No entanto, é importante ressaltar que esses números podem variar devido a condições climáticas e outros fatores. No caso da Tabela 4, a análise foi realizada em um dia predominantemente ensolarado e com pouca incidência de vento, onde, recomenda-se realizar a análise simultaneamente entre colmeias, a fim de capturar a dinâmica natural das abelhas de maneira mais precisa.

4.6.2 Impacto na dinâmica das abelhas influenciada por condições climáticas.

Os gráficos cumulativos das Figuras 46 e 47 apresentam, respectivamente, as informações de entrada e saída de duas colmeias de abelha canudo com características distintas. A colmeia C_05, representada pela cor azul, é considerada uma colmeia com população média, enquanto a colmeia C_03, indicada pela cor vermelha, é considerada uma colmeia pequena.

A linha tracejada representa um dia com manhã ensolarada e tarde chuvosa, enquanto a linha contínua indica um dia completamente ensolarado. Para a colmeia C_05, durante o dia completamente ensolarado, o número de entradas e saídas aumenta constantemente ao longo do dia. Já no dia com manhã ensolarada e tarde chuvosa, o aumento nas entradas e saídas é mais modesto, pois nota-se uma desaceleração significativa após o início da chuva, que começa por volta das 13h. Para a colmeia C_03, no dia completamente ensolarado, também possui um aumento constante nas entradas e saídas de abelhas até as 18h. E no dia com manhã ensolarada e tarde chuvosa, a quantidade de entradas e saídas também diminuiu significativamente após o início da chuva.

Figura 46: Gráfico de Entrada de abelhas

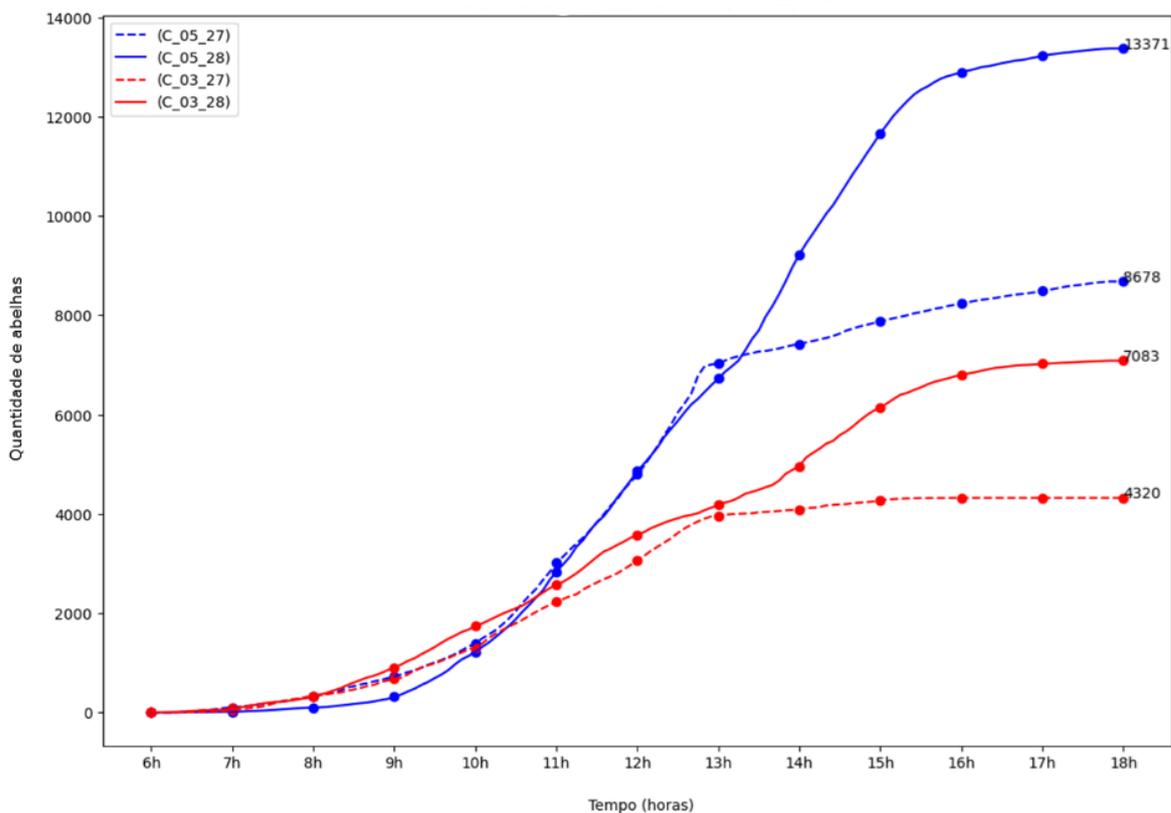
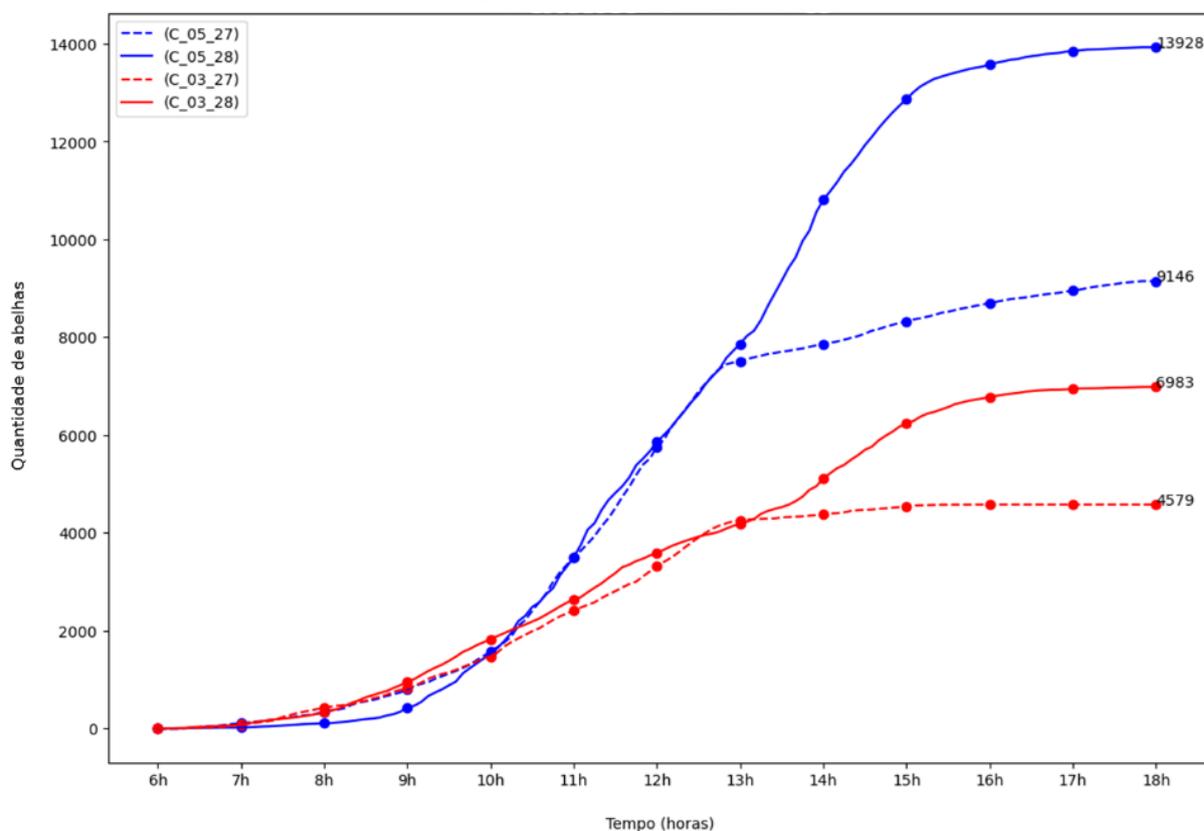


Figura 47: Gráfico de Saída de abelhas



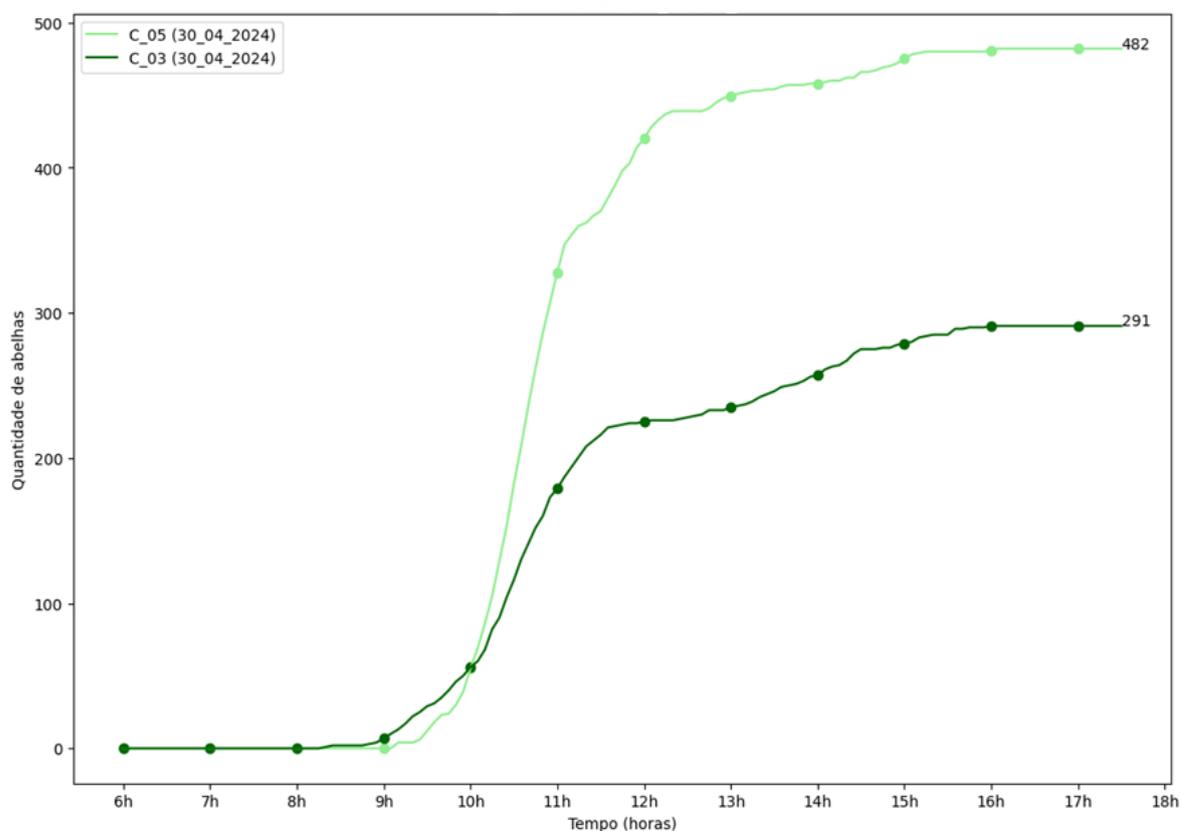
Outra análise importante é que, ao final do dia, a contagem de saída de abelhas nas duas colmeias apresentou uma redução significativa. No entanto, os valores percentuais de redução foram muito próximos entre si, com uma diminuição de aproximadamente 34% em ambas as colmeias. Essas constatações reforçam a hipótese de que dias ensolarados favorecem uma maior atividade de entrada e saída das abelhas.

Uma nova oportunidade para aplicar modelos de redes neurais seria investigar os impactos no desenvolvimento da colônia em relação a índices elevados de temperatura ou umidade com o auxílio de sensores dentro e fora das colmeias, especialmente considerando como essas condições podem afetar a eficiência da termorregulação. Na termorregulação as abelhas mantêm a temperatura interna da colmeia em níveis ideais, que podem variar dependendo do local, utilizando comportamentos como o batimento das asas e a agrupação em certas áreas. Quando as temperaturas externas estão elevadas, as abelhas podem aumentar sua atividade de ventilação, criando um fluxo de ar que ajuda a resfriar a colmeia. Essa habilidade de regular a temperatura não apenas assegura o conforto das abelhas, mas também é vital para o desenvolvimento das larvas e a produção de mel e consequentemente, a saúde da colônia.

4.6.3 Comportamento Higiênico

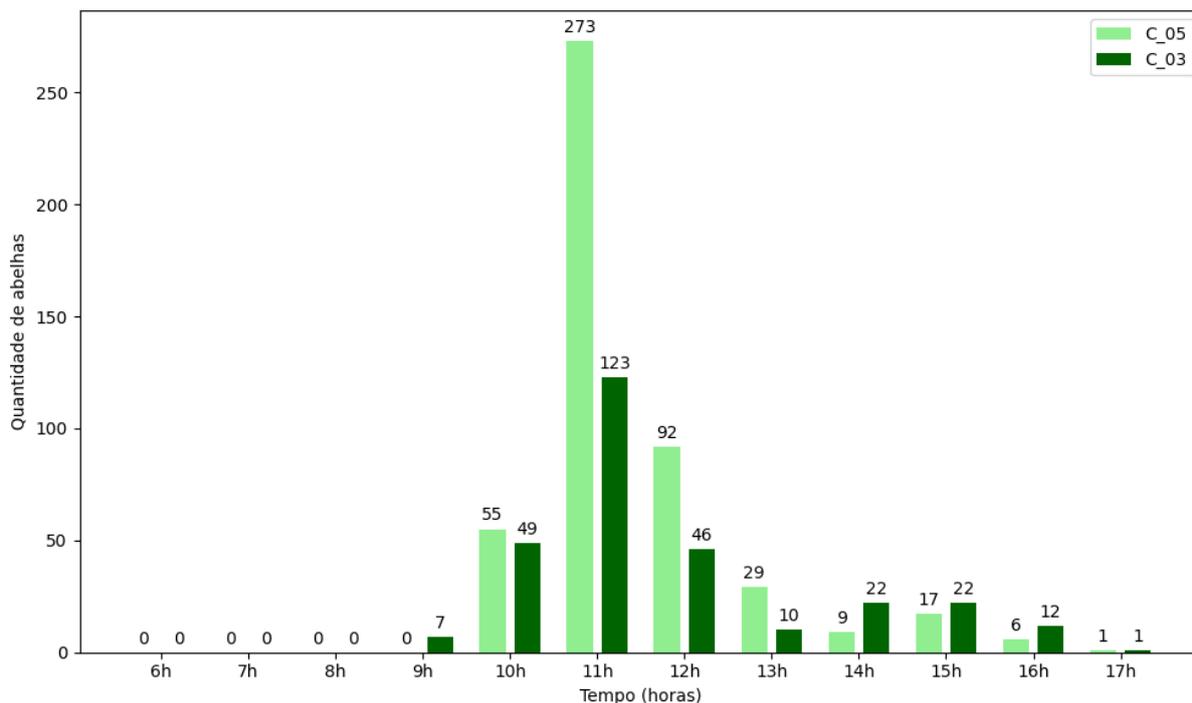
O gráfico cumulativo da Figura 48 apresenta as informações sobre a retirada de lixo em um único dia das colmeias C_05 e C_03. Pode-se observar que as abelhas realizam o processo de limpeza das colmeias, descartando fezes, restos de abelhas mortas ou crias mortas por doenças ao longo do dia.

Figura 48: Gráfico de Saída de Lixo



O gráfico de barras na Figura 49 complementa esta análise ao apresentar uma visualização numérica da quantidade de lixo removido a cada hora do dia pelas duas colmeias gráfico fica claro que o horário de maior incidência de retirada de lixo ocorre entre as 9h e 12h para todas as colmeias analisadas podendo, assim, inferir-se que este é um comportamento da espécie.

Figura 49: Gráfico de barra com Saída de Lixo



A Tabela 5 detalha os horários em que as abelhas *Scaptotrigona* realizaram a retirada de lixo com maior frequência. As análises foram conduzidas em dias distintos, independentemente das características individuais de cada colmeia. A partir dos dados de sete colmeias, podemos formular a hipótese de que o período de maior atividade na retirada de lixo ocorre entre 9h e 12h.

Tabela 6: Informações de retirada de lixo de sete colmeias

Numeração da Colmeia	Tamanho Populacional Estimado	Presença de Rainha	Sintoma de Doença	Período do dia com maior saída de lixo
C_01	Média	Sim	Não	9h – 10h
C_02	Pequena	Sim	Não	10 – 11h
C_03	Pequena	Sim	Sim	10 – 11h
C_05	Média	Sim	Sim	11 – 12h
C_06	Pequena	Sim	Sim	11 – 12h
C_07	Grande	Sim	Não	9h – 10h
C_08	Grande	Sim	Não	11 – 12h

Utilizando a fórmula (3.3) para estimar o valor percentual de comportamento higiênico das colmeias C_03 e C_05, foi realizado o seguinte cálculo:

Para a colmeia C_03 temos:

$$CH_{03}\% = \left(\frac{CH_{03}}{Pop_{03}} \right) \times 100 = ? \rightarrow CH_{03}\% = \left(\frac{\beta \cdot garbage_{03}}{\alpha \cdot mES_{03}} \right) \times 100$$

$$CH^{03}\% = \left(\frac{1 \cdot 291}{1 \cdot 8.141} \right) \times 100 \rightarrow CH^{03}\% = \left(\frac{291}{8.141} \right) \times 100 \approx 0.0357 \times 100 \approx \mathbf{3.57\%}$$

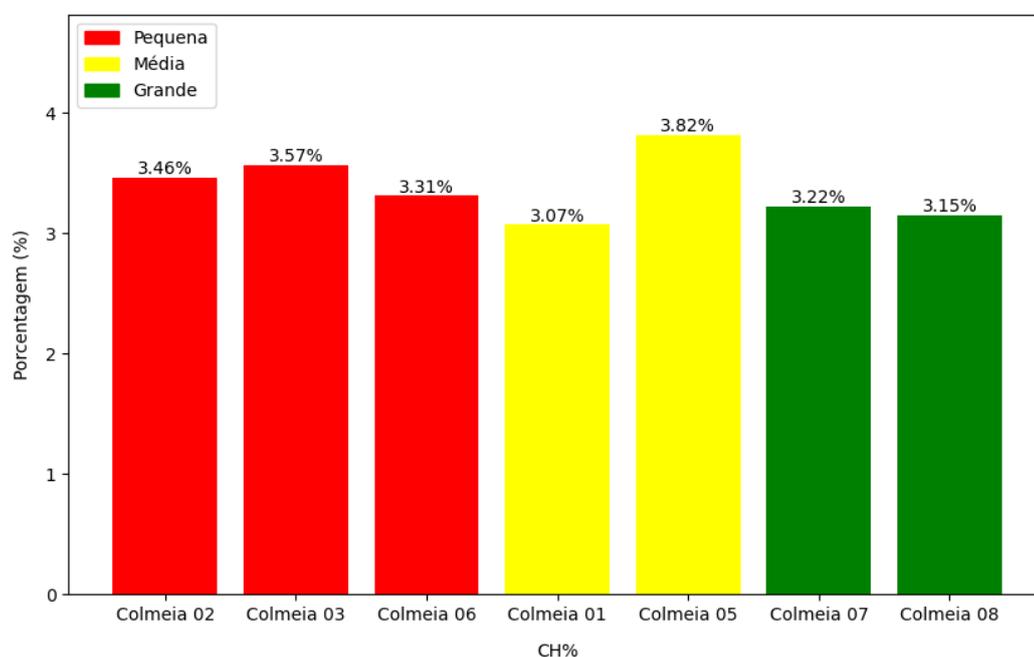
E para a colmeia C_05 temos:

$$CH_{05}\% = \left(\frac{CH_{05}}{Pop_{05}} \right) \times 100 = ? \rightarrow CH_{05}\% = \left(\frac{\beta \cdot garbage_{05}}{\alpha \cdot mES_{05}} \right) \times 100$$

$$CH_{05}\% = \left(\frac{1 \cdot 482}{1 \cdot 12.612} \right) \times 100 \rightarrow CH_{05}\% = \left(\frac{482}{12.612} \right) \times 100 \approx 0.0382 \times 100 \approx \mathbf{3.82\%}$$

O gráfico de barras da Figura 50 apresenta o valor percentual de todas as sete colmeias, na qual cada barra é caracterizada por cores diferentes, de acordo com as faixas populacionais sugeridas pelo modelo.

Figura 50: Valor Percentual de CH

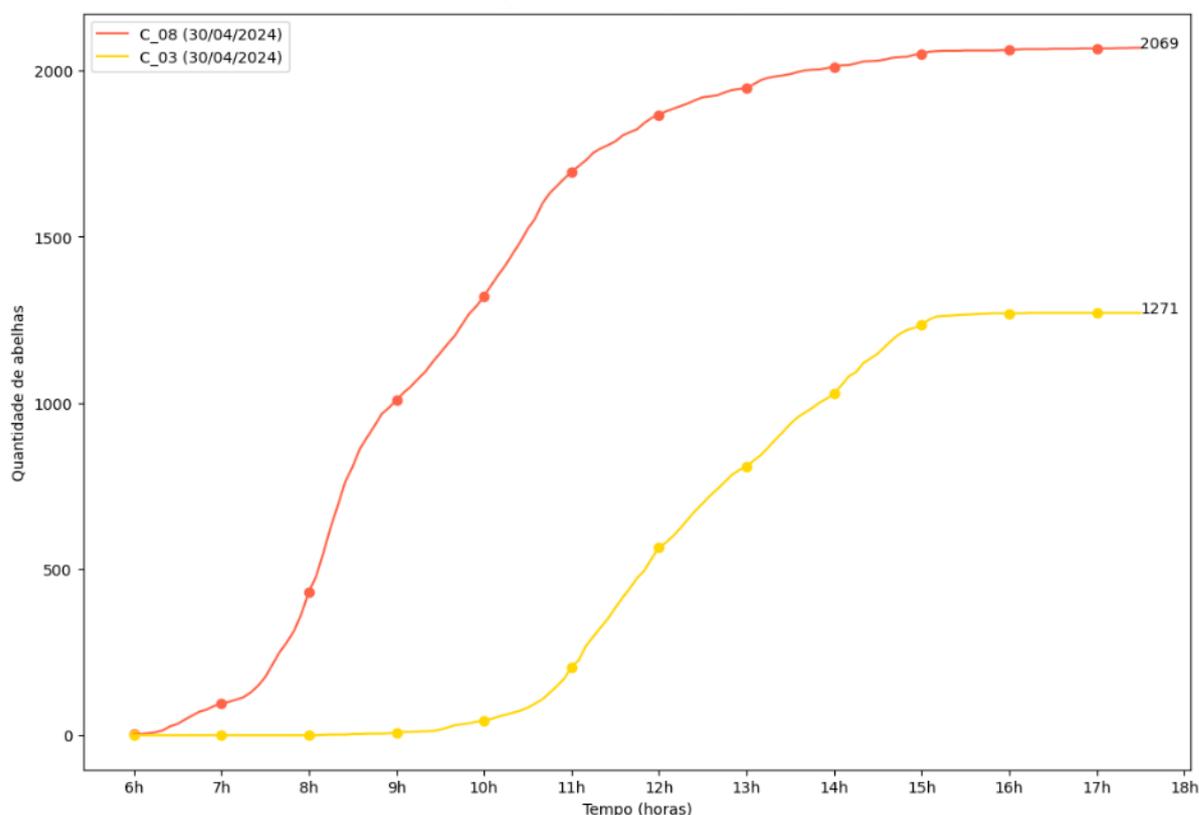


Os resultados apresentados na figura 50 apresentam resultados promissores para mensuração do comportamento higiênico, fazendo-se necessário o desenvolvimento de um trabalho específico para validar o resultado com o procedimento tradicional de avaliação de comportamento higiênico.

4.6.4 Comportamento Forrageiro

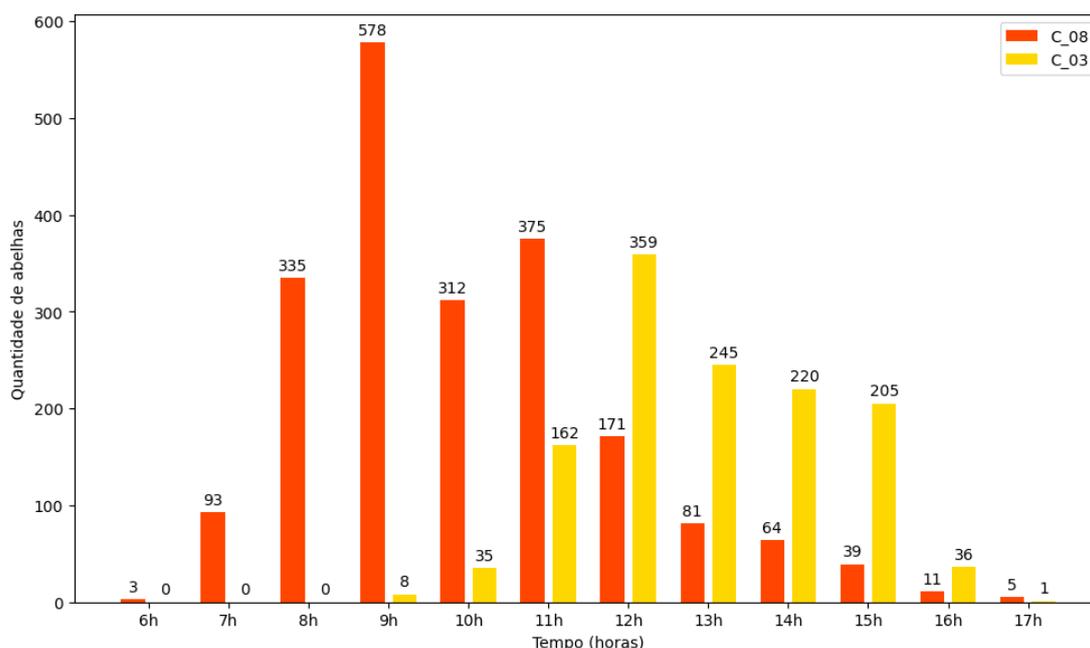
Analisando o gráfico cumulativo da Figura 51, é possível extrair informações importantes sobre o comportamento forrageiro das abelhas *Scaptotrigona*, onde são apresentadas as informações de entrada de pólen de duas colmeias. A primeira colmeia é a C_08, que possui características de uma colmeia com população grande, e a segunda C_03 possui características de uma colmeia com população pequena. Observando a linha laranja, referente à colmeia C_08, nota-se que a entrada de pólen ocorreu com grande intensidade logo nas primeiras horas do dia, se estendendo até as 12h. Esse comportamento difere do observado na colmeia C_03, representada pela linha amarela, onde a entrada de pólen ocorreu com maior frequência entre as 11h e as 15h.

Figura 51: Gráfico de comportamento Forrageiro



O gráfico de barras da Figura 52 apresenta esse comportamento em números, permitindo-nos obter informações quantitativas sobre o número de abelhas que entraram com pólen em determinados momentos. Dessa forma, é possível visualizar e comparar a atividade de entrada de pólen entre diferentes tipos de colmeias ao longo do dia, identificando os períodos de maior intensidade para cada uma delas.

Figura 52: Gráfico de barra com Entrada de Pólen



Ao realizar uma análise mais aprofundada dos gráficos 53 e 54 apresentados acima, foram identificados dois tipos de pólen com colorações diferentes entrando nas colmeias em horários distintos. A partir dos resultados das análises do modelo, percebeu-se que a colmeia C_08 coletou pólen de coloração mais alaranjada logo nas primeiras horas do dia (Figura 44), enquanto a colmeia C_03 apresentou um pólen de coloração mais clara (Figura 45).

Figura 53: Pólen C08

Figura 54: Pólen C03

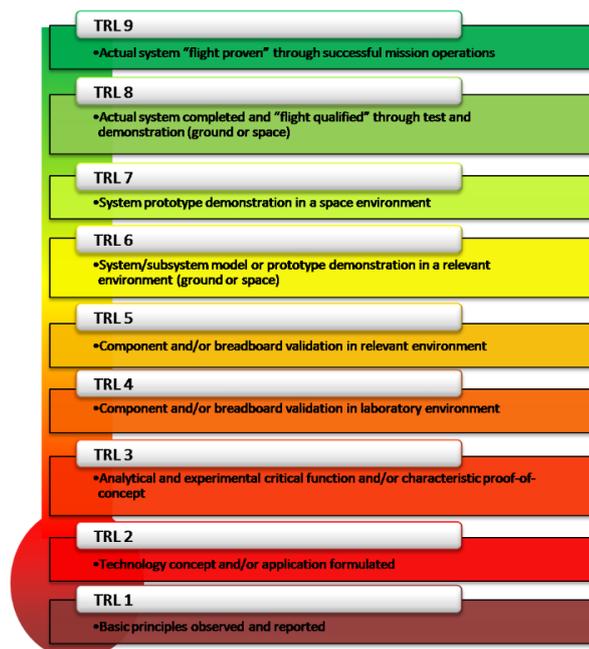


Essas observações fornecem informações valiosas, pois, com esses modelos de redes neurais, é possível explorar a hipótese de períodos de abertura de floradas de determinadas espécies de plantas, contribuindo para o setor botânico. Além disso, os modelos permitem identificar as preferências alimentares específicas de determinadas colmeias. Dessa forma, os produtores podem utilizar essas ferramentas para selecionar colmeias que favoreçam culturas específicas, potencializando o processo de polinização e aumentando a eficiência na produção agrícola.

4.7 Resultados dos Projetos de Pesquisa, Desenvolvimento e Inovação (PD&I) segundo o Modelo Embrapa

A Embrapa utiliza o modelo de *Technology Readiness Levels* (TRL) inspirado na NASA (Figura 55) para avaliar a maturidade das tecnologias desenvolvidas em seus projetos. Esse sistema ajuda a mensurar o avanço das inovações, desde a concepção inicial até a aplicação prática. Geralmente os resultados da Embrapa se concentra tipicamente até o TRL 6, que corresponde a um estágio em que a tecnologia é demonstrada em um ambiente relevante, o que é crucial para a transferência de tecnologia e sua adoção no setor agrícola. Esse foco permite à Embrapa garantir que suas soluções sejam eficazes e viáveis para os desafios enfrentados na agricultura, promovendo assim um impacto significativo no desenvolvimento rural. O grau de maturidade deste trabalho encontra-se no nível TRL 5.

Figura 55: Technology Readiness Levels



Segundo o documento orientador da Embrapa, os resultados dos projetos devem ser expressos qualitativa e/ou quantitativamente de forma concreta e mensurável. A Embrapa classifica os resultados de projetos em três categorias e, dentro de cada categoria, em diferentes tipos. Os resultados deste trabalho são apresentados no apêndice B deste documento.

Neste capítulo, foram apresentados os resultados obtidos ao longo do trabalho. Onde foram feitas análises sobre o desempenho do modelo de detecção de objetos, assim como os resultados de comportamento higiênico, forrageamento das colmeias e estimador populacional das colmeias.

5 Conclusões

Este trabalho desenvolveu um novo método para monitorar a dinâmica das colmeias de abelhas *Scaptotrigona spp.* menos invasivo, com o apoio de um modelo de detecção de objetos utilizando a rede neural YOLOv8s. Para atingir o objetivo, foram desenvolvidas plataformas em impressão 3D, instaladas nas entradas das colmeias, com a finalidade de auxiliar na aquisição, transmissão e armazenamento de imagens. Isso permitiu a criação de um banco de dados inédito dessas abelhas, além de possibilitar transmissões em tempo real das colmeias.

As análises dos resultados evidenciaram diversos comportamentos das abelhas estudadas, como o período em que elas retiram o lixo da colmeia com maior frequência, os impactos das condições climáticas no cotidiano das abelhas, o período e a preferência da abelha canudo por determinados tipos de pólen, e, por fim, o trabalho permitiu analisar a dinâmica geral de entrada e saída dessa espécie, fazendo correlações com a quantidade populacional e gerando subsídios para diferenciar as colmeias mais higiênicas de acordo com o tamanho da população.

Adicionalmente, verificou-se que o modelo desenvolvido atingiu as expectativas do trabalho, apresentando uma precisão de 96% na classificação das três classes de interesse. Além disso, o modelo demonstrou ser uma excelente ferramenta para a contagem automática de abelhas em comparação com os métodos existentes, proporcionando *insights* importantes com o potencial de auxiliar em trabalhos para estimar o tamanho da população e de melhoramento genético, com a finalidade de seleção das colmeias mais higiênicas e melhores polinizadoras, além de servir como ferramenta na detecção de doenças e auxílio no manejo.

5.1 Trabalhos Futuros

- Realizar trabalhos com outras espécies de abelhas nativas, fornecendo informações inéditas para a promoção e conservação dessas espécies;
- Utilizar ferramentas de IA para criar plataformas educacionais que contribuam para o treinamento de novos produtores e o manejo sustentável dessas espécies;
- Desenvolver modelos multicritério para apoio à tomada de decisão;
- Desenvolver modelos originais inspirados no tipo YOLO;
- Desenvolver modelos para a detecção de doenças quarentenárias em abelhas;
- Desenvolver modelos que identifiquem o tipo de pólen entrando na colmeia;

- Desenvolver estimadores de morte de abelhas;
- Correlacionar a entrada de pólen com a floração de espécies em horários específicos.

5.2 Publicações

NETO, Manoel F. C. et al. **Native Bee Scan: App Inteligente para Identificação de Abelhas Nativas Utilizando Técnicas de IA**. In: Anais da III Escola Regional de Alto Desempenho Norte 2 e III Escola Regional de Aprendizado de Máquina e Inteligência Artificial Norte 2, 2023. Sociedade Brasileira de Computação (SBC), p. 29-32.

CAMPOS NETO, Manoel F. et al. **Desenvolvimento de Plataforma de Monitoramento do Comportamento de Duas Espécies de Abelhas Nativas da Amazônia Utilizando Ferramentas de IoT**. 2023. Relatório técnico.

Referências

KULIK, E. **A Meliponicultura como uma Perspectiva de Educação Popular: Rompendo Barreiras Epistemológicas**. Americana – SP: Americana – SP, 2019.

KERR, W. E.; CARVALHO, G.A.; NASCIMENTO, V. A. **A abelha uruçú: biologia, manejo e conservação**. Belo Horizonte: Acangaú, 1996. 144p.

PEDRO, Silvia R. M. **The stingless bee fauna in Brazil (Hymenoptera: Apidae)**. Sociobiology, v. 61, n. 4, p. 348-354, 2014.

FILHO, J. M. **A Revolução das Abelhas sem Ferrão**. Revista Página 22, nº 2019.

MUTO, Nilton Akio et al. **Impact of the introduction of stingless bee colonies (Scaptotrigona aff. postica) on the productivity of acai (Euterpe oleracea)**. Revista Verde de Agroecologia e Desenvolvimento Sustentável, v. 15, n. 3, 2020.

MAUES, M. M. et al. **Rede de pesquisa em polinização de frutíferas do Norte e Nordeste**. 2021.

WOLOWSKI, e outros. **Relatório Temático sobre polinização, polinizadores e produção de alimentos no Brasil**. Campinas, SP: 2019. 184p.

PDG BRASIL. **[Home page]**. Disponível em: <https://perfectdailygrind.com/pt/2021/06/07/abelhas-no-cafezal-como-a-integracao-entre-cafe-e-polinizadores-contribuem-com-a-productividade-da-fazenda/#:~:text=Cr%C3%A9dito%3A%20Cristiano%20Menezes.,incrementar%20a%20presen%C3%A7a%20de%20a%C3%A7%C3%BAcares>. Acesso em: 24 jul. 2024.

HEARD, T. A. **The role of stingless bees in crop pollination**. Ann. Rev. Entomol., v. 44, p. 183-206, 1999.

FREITAS, B. M.; NUNES-SILVA, P. **Polinização Agrícola e sua Importância no Brasil**. In: **Polinizadores no Brasil - contribuição e perspectivas para a biodiversidade, uso sustentável, conservação e serviços ambientais**. São Paulo: EDUSP, p. 103-118, 2012.

POTTS, S. G.; BIESMEIJER, J. C.; KREMEN, C.; NEUMANN, P.; SCHWEIGER, O.; KUNIN, W. E. **Global pollinator declines: trends, impacts and drivers**. Trends in Ecology & Evolution, Elsevier, v. 25, n. 6, p. 345–353, 2010.

BRASIL. Ministério da Ciência, Tecnologia, Inovações e Comunicações. **Portaria MCTI nº 4.617, de 06 de abril de 2021**. Disponível em: https://antigo.mctic.gov.br/mctic/opencms/legislacao/portarias/Portaria_MCTI_n_4617_de_06042021.html. Acesso em: 24 jul. 2024.

NOGUEIRA-NETO, Paulo. **Vida e criação de abelhas indígenas sem ferrão**. In: **Vida e criação de abelhas indígenas sem ferrão**. 1997. p. 446-446.

- RIBEIRO, Generosa Sousa. **Meliponicultura básica para iniciantes**. Vitória da Conquista-BA: Editora EX'Launch, 1. ed., p. 11, 2020.
- KREMEN, C. **Ecosystem services provided by native pollinators**. Ecology Letters, v. 10, n. 4, p. 299-314, 2007.
- YAMAMOTO, Marcela et al. **The role of bee diversity in pollination and fruit set of yellow passion fruit (*Passiflora edulis* forma *flavicarpa*, Passifloraceae) crop in Central Brazil**. Apidologie, v. 43, p. 515-526, 2012.
- GHAZOUL, Jaboury. **Buzziness as usual? Questioning the global pollination crisis**. Trends in Ecology & Evolution, v. 20, n. 7, p. 367-373, 2005.
- AIZEN, Marcelo A.; MORALES, Carolina L.; MORALES, Juan M. **Invasive mutualists erode native pollination webs**. PLoS Biology, v. 6, n. 2, p. e31, 2008.
- KERR, Warwick Estevam; ZILSE, Gislene Almeida Carvalho; NASCIMENTO, Vania Alves. **Abelha uruçú: biologia, manejo e conservação**. 1996.
- AIDAR, D. S. **A mandacari: biologia de abelhas, manejo e multiplicação artificial de colônias de *Melipona quadrifasciata***. Ribeirão Preto: Sociedade Brasileira de Genética, 1996.
- MOURE, J. S. **O gênero *Scaptotrigona***. Revista Brasileira de Entomologia, v. 2, n. 3, p. 65-89, 1942.
- LOIOLA, Nilson dos Santos. **Avaliação da atividade antimicrobiana da própolis da abelha nativa *Tubi*, *Scaptotrigona* aff. *postica* (LATREILLE, 1807) frente às bactérias *Listeria monocytogenes*, *Staphylococcus aureus*, *Streptococcus mutans* e *Escherichia coli***. 2020.
- DUARTE, O. M. P. **Citogenética de espécies do gênero *Scaptotrigona* (Moure, 1942) *Hymenoptera*, *Apidae***. Dissertação (Mestrado em Biologia Molecular) - Universidade Estadual de Santa Cruz, Ilhéus, Bahia, Brasil, 2008.
- ROUBIK, David W. **Stingless bee nesting biology**. Apidologie, v. 37, n. 2, p. 124-143, 2006.
- MICHENER, C. D. **The Bees of the World**. 2nd Edition, Baltimore: The Johns Hopkins University Press, 2007.
- LEÃO, Kamila Leão et al. **Colony development and management of the stingless bee *Scaptotrigona* aff. *postica* (Apidae, Meliponini) in different hive models**. Sociobiology, v. 63, n. 4, p. 1038-1045, 2016.
- VENTURIERI, Giorgio Cristino et al. **Meliponicultura no Brasil: situação atual e perspectivas futuras para o uso na polinização agrícola**. Polinizadores no Brasil: contribuição e perspectivas para a biodiversidade, uso sustentável, conservação e serviços ambientais, p. 489 il, 201

- MENEZES, Cristiano; FONSECA, Vera Lucia Imperatriz. **A produção de rainhas e a multiplicação de colônias em *Scaptotrigona aff. depillis* (Hymenoptera, Apidae, Meliponini)**. 2010.
- SILVA, R. A. **SOS abelhas nativas do Brasil**. SEABDERAL – Departamento de Economia Rural. Paraná, Ano II, n. 19, p. 1 – 9, 2009.
- SANCHES, Márcia A. **Ação da própolis de *Scaptotrigona aff. postica* (Latreille, 1807) (hymenoptera, apidae, meliponini) em diferentes linhagens de células tumorais**. 2014, 87 f. Tese (Doutorado) – Programa de Pós-Graduação em Biologia Celular e Estrutural da Universidade de Viçosa, Minas Gerais, 2014.
- FERREIRA, Janaina de Cássia Brito. **Comportamento higiênico na abelha sem ferrão *Scaptotrigona aff. postica* (Apidae: Meliponini)**. Trabalho de Conclusão de Curso – Universidade Federal Rural da Amazônia, 2019.
- SOUSA, Yasmin Gomes de. **Comportamento higiênico em duas abelhas sem ferrão (Apidae, Meliponini) economicamente relevantes na Amazônia Oriental: uma abordagem comparativa**. Trabalho de Conclusão de Curso – Universidade Federal Rural da Amazônia, 2019.
- ROTHENBUHLER, W. C. **A technique for studying genetics of colony behavior in honey bees**. *Am. Bee J.* 100, 176, 198.
- ROTHENBUHLER, W. C. **Behaviour genetics of nest cleaning in honey bees. I. Responses of four inbred lines to disease-killed brood**. *Animal Behaviour*, v. 12, n. 4, p. 578–583, 1964b.
- PARK, O. W. **Testing for resistance to American foulbrood in honeybees**. *J. econ. Entomol.*, 30, 504-512, 1937.
- ARATHI, H. S.; BURNS, I.; SPIVAK, M. **Ethology of Hygienic Behaviour in the Honey Bee *Apis mellifera* L. (Hymenoptera: Apidae): Behavioural repertoire of Hygienic bees**. *Ethology*, v. 106, n. 4, p. 365–379, abr. 2000.
- GRAMACHO, K. P.; SPIVAK, M. **Differences in olfactory sensitivity and behavioral responses among honey bees bred for hygienic behavior**. *Behavioral Ecology and Sociobiology*, v. 54, n. 5, p. 472–479, 2003.
- BOUTIN, S. et al. **Differential gene expression between hygienic and non-hygienic honeybee (*Apis mellifera* L.) hives**. *BMC Genomics*, v. 16, n. 1, p. 1–13, 2015.
- LAPIDGE, K. L.; OLDROYD, B. P.; SPIVAK, M. **Seven suggestive quantitative trait loci influence hygienic behavior of honey bees**. *Naturwissenschaften*, v. 89, n. 12, p. 565–568, 2002.

- SPIVAK, M.; DOWNEY, D. L. **Field Assays for Hygienic Behavior in Honey Bees (Hymenoptera: Apidae)**. Journal of Economic Entomology, v. 91, n. 1, p. 64–70, 1998.
- GRAMACHO, K. P.; GONÇALVES, L. S. **Estudo comparativo dos métodos de congelamento e perfuração de crias para avaliação do comportamento higiênico em abelhas africanizadas**. In: Congresso Latinoiberoamericano de Apicultura, 4. Anais. Cordoba, Argentina, p. 45.
- AL TOUFALIA, H. et al. **Hygienic behaviour in Brazilian stingless bees**. Biology Open, v. 5, n. 11, p. 1712–1718, 2016.
- DE JESUS, J. N. et al. **Hygienic behavior in *Melipona quadrifasciata anthidioides* (Apidae, Meliponini)**. Apidologie, v. 48, n. 4, p. 504–512, 2017.
- MEDINA, L. M.; HART, A. G.; RATNIEKS, F. L. W. **Hygienic behavior in the stingless bees *Melipona beecheii* and *Scaptotrigona pectoralis* (Hymenoptera: Meliponini)**. Genetics and Molecular Research, v. 8, n. 2, p. 571–576, 2009.
- NUNES-SILVA, P.; IMPERATRIZ-FONSECA, V. L.; GONÇALVES, L. S. **Hygienic behavior of the stingless bee *Plebeia remota* (Holmberg, 1903) (Apidae, Meliponini)**. Genetics and Molecular Research, v. 8, n. 2, p. 649–654, 2009.
- GONÇALVES, L. S.; GRAMACHO, K. P. **Seleção de abelhas para resistência a doenças de crias através do comportamento higiênico**. Mensagem Doce, n. 52, p. 2-7, 1999.
- PEDRO, S. R. M. **The Stingless Bee Fauna In Brazil (Hymenoptera: Apidae)**. Sociobiology. doi: 10.13102/sociobiology.v61i4.348-354, 2014.
- ASCHER, J. S.; PICKERING, J. **Discover life: bee species guide and world checklist (Hymenoptera: Apoidea: Anthophila)**. 2021. Disponível em: http://www.discoverlife.org/mp/20q?guide=Apoidea_species&flags=HAS. Acesso em: 24 jul. 2024.
- MICHENER, C. D. **The social Behavior of the bees: A comparative study**. Harvard Univ. Press. Cambridge, MA, 1974.
- SAKAGAMI, S. F. **Stingless bees**. In: HERMANN, R. H. (ed.). Social insects. New York: Academic Press, 1982. v. 3, p. 316-423.
- BRODSCHNEIDER, R.; CRAILSHEIM, K. **Nutrition and health in honey bees**. Apidologie, v. 41, p. 278-294, 2010. doi: 10.1051/apido/2010012.
- BIESMEIJER, J. C.; BORN, M.; LUKÁCS, S.; SOMMEIJER, M. J. **The response of the stingless bee *Melipona beecheii* to experimental pollen stress, worker loss, and different levels of information input**. Journal of Apicultural Research, v. 38, n. 1-2, p. 33-41, 1999.

KLEINERT, A. M. P. **Native and Non-Native Supergeneralist Bee Species Have Different Effects on Plant-Bee Networks**. PLoS One, 2015. doi: 10.1371/journal.pone.0137198.

RAMALHO, M.; IMPERATRIZ-FONSECA, V. L.; GIANNINI, T. C. **Within-colony size variation of foragers and pollen load capacity in the stingless bee *Melipona quadrifasciata anthidioides* Lepeletier (Apidae, Hymenoptera)**. Apidologie, v. 29, p. 221-228, 1998. doi: 10.1051/apido:19980302.

ARAÚJO, E. D.; COSTA, M.; CHAUD-NETTO, J.; FOWLE, H. G. **Body size and flight distance in stingless bees (Hymenoptera: Meliponini): Inference of flight range and possible ecological implications**. Braz. J. Biol, v. 64, p. 563–568, 2004.

GIANNINI, T. C.; GARIBALDI, L. A.; ACOSTA, A.; SILVA, J. S.; MAIA, K. P.; SARAIVA, A. M.; GUIMARÃES, P. R.; KLEINERT, A. M. P. **Native and Non-Native Supergeneralist Bee Species Have Different Effects on Plant-Bee Networks**. PLoS One, 2015. doi: 10.1371/journal.pone.0137198.

SOMERVILLE, D. **Honey bee nutrition and supplementary feeding**. Agnote DAI/178, NSW. Agriculture, 2000.

LEÃO, Kamila Leão et al. **Desenvolvimento colonial em abelhas nativas sem ferrão Amazônicas (Apidae: Meliponini): Tamanho populacional, nutrição e alocação fenotípica**. 2019.

DORNHAUS, A.; POWELL, S.; BENGSTON, S. **Group size and its effects on collective organization**. Annual Review of Entomology, 2012. doi: 10.1146/annurev-ento-120710-100604.

DEGRANDI-HOFFMAN, G.; ROTH, S. A.; LOPER, G. L.; ERICKSON, E. H. Jr. **BEEPOP: a honey bee population dynamics simulation model**. Ecological Modelling, 1989. doi: 10.1016/0304-3800(89)90088-4.

MALHAM, J. P.; REES, J. S.; ALSPACH, P. A.; BEGGS, J. R.; MOLLER, H. **Traffic rate as an index of colony size in *Vespula* wasps**. New Zealand Journal of Zoology, v. 18, n. 2, p. 105-109, 1991. doi: 10.1080/03014223.1991.10757956.

DUARTE, R. S.; SOUZA, J.; SOARES, A. E. E. **Nest architecture of *Tetragona clavipes* (Fabricius) (Hymenoptera: Apidae: Meliponini)**. Sociobiology, v. 63, p. 813-818, 2016. doi: 10.13102/sociobiology.v63i2.1019.

ROLDÃO-SBORDONI, Y. S.; NASCIMENTO, F. S.; MATEUS, S. **Estimating colonies of *Plebeia droryana* (Friese, 1900) (Hymenoptera: Apidae: Meliponini): adults, brood and nest structure**. Sociobiology, 2018. doi: 10.13102/sociobiology.v65i2.2345.

MECCA, Gláucya de Figueiredo; BEGO, Luci Rolandi. **O comportamento forrageiro das operárias de *Scaptotrigona aff. depilis* (Hymenoptera, Apidae, Meliponini), relacionado a fatores climáticos**. 2003.

LI, Zewen et al. **A survey of convolutional neural networks: analysis, applications, and prospects**. *IEEE Transactions on Neural Networks and Learning Systems*, v. 33, n. 12, p. 6999-7019, 2021.

SCHMIDHUBER, J. **Deep learning in neural networks: An overview**. *Elsevier Neural Networks*, v. 61, 2015.

CHEVTCHENKO, S. **A Convolutional Neural Network with Feature Fusion for Real-Time Hand Posture Recognition**. Dissertação (Mestrado) — Universidade Federal Rural de Pernambuco, 2018.

HONG, JiUn; ARSLAN, Saad; LEE, TaeGeon; KIM, HyungWon. **Design of power-efficient training accelerator for convolution neural networks**. *Journal of Low Power Electronics and Applications*, v. 9, n. 4, p. 1-15, 2019. Disponível em: <https://www.mdpi.com/2079-9268/9/4/35>. Acesso em: 21 out. 2024.

GHAZAL, Sumaira; MUNIR, Arslan; QURESHI, Waqar S. **Computer vision in smart agriculture and precision farming: Techniques and applications**. *Artificial Intelligence in Agriculture*, 2024.

BROSNAN, T.; SUN, D. **Inspection and Grading of Agricultural and Food Products by Computer Vision Systems: a Review**. *Computers and Electronics in Agriculture*, v. 36, p. 193-213, 2002. Disponível em: <https://www.sciencedirect.com/science/article/>.

BROSNAN, T.; SUN, D. **Improving Quality Inspection of Food Products by Computer Vision: a Review**. *Journal of Food Engineering*, v. 61, p. 3-16, 2004. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0260877403001833>. Acesso em: 24 jul. 2024.

SUN, D. **Computer Vision Technology for Food Quality Evaluation**. Academic Press, 17 dez. 2007. DOI: <https://doi.org/10.1016/B978-0-12-373642-0.X5001-7>.

SYKES, Jamie R.; DENBY, Katherine J.; FRANKS, Daniel W. **Computer vision for plant pathology: A review with examples from cocoa agriculture**. *Applications in Plant Sciences*, v. 12, n. 2, p. e11559, 2024.

SALDAÑA, E.; SICHE, R.; LUJÁN, M.; QUEVEDO, R. **Review: Computer Vision applied to the Inspection and Quality Control of Fruits and Vegetables**. *Brazilian Journal of Food Technology*, v. 16, p. 254-272, 2013. Disponível em: <https://www.scielo.br/j/bjft/a/y5bZb5gBbdYS4SKrkGyZ7qr/?lang=em>. Acesso em: 24 jul. 2024.

CHOPDE, S.; PATIL, M.; SHAIKH, A.; CHAVHAN, B.; DESHMUKH, M. **Developments in Computer Vision System, Focusing on Its Applications in Quality Inspection of Fruits and Vegetables: A Review**. *Agricultural Reviews*, v. 38, p. 94-102, 2017. Disponível em: <https://arccjournals.com/journal/agricultural-reviews/R-1668>. Acesso em: 24 jul. 2024.

SÁ, P. C. A.; PRATES, R. M. **Ciência de Dados na Indústria Vitivinícola: Compreensão, Pesquisa e Maturação Tecnológica**. XVI Brazilian Conference on Computational Intelligence

(CBIC 2023), Salvador, 8 a 11 out. 2023. Disponível em: https://sbic.org.br/wp-content/uploads/2023/10/ST05/CBIC_2023_paper174.pdf. Acesso em: 24 jul. 2024.

HUANG, R.; PEDOEEM, J.; CHEN, C. **Yolo-lite: a real-time object detection algorithm optimized for non-gpu computers**. In: IEEE. 2018 IEEE International Conference on Big Data (Big Data). [S.l.], 2018. p. 2503–2510.

REDMON, J. et al. **You only look once: Unified, real-time object detection**. In: Proceedings of the IEEE conference on computer vision and pattern recognition. [S.l.: s.n.], 2016. p. 779–788.

LAN, W.; DANG, J.; WANG, Y.; WANG, S. **Pedestrian detection based on YOLO network model**. In: IEEE INTERNATIONAL CONFERENCE ON MECHATRONICS AND AUTOMATION (ICMA), 2018. Proceedings... IEEE, 2018. p. 1547-1551. Published as a Journal paper at Machine Learning and Knowledge Extraction.

HSU, W.-Y.; LIN, W.-Y. **Adaptive fusion of multi-scale YOLO for pedestrian detection**. IEEE Access, v. 9, p. 110063-110073, 2021.

SHINDE, S.; KOTHARI, A.; GUPTA, V. **YOLO based human action recognition and localization**. Procedia Computer Science, v. 133, p. 831-838, 2018.

ASHRAF, A. H. et al. **Weapons detection for security and video surveillance using CNN and YOLO-v5s**. CMC-Comput. Mater. Contin., v. 70, p. 2761-2775, 2022.

ZHENG, Y.; ZHANG, H. **Video analysis in sports by lightweight object detection network under the background of sports industry development**. Computational Intelligence and Neuroscience, v. 2022, 2022.

MA, H.; CELIK, T.; LI, H. **Fer-YOLO: Detection and classification based on facial expressions**. In: IMAGE AND GRAPHICS: 11th International Conference, ICIG 2021, Haikou, China, August 6–8, 2021, Proceedings, Part I 11. Springer, 2021. p. 28-39.

TIAN, Y. et al. **Apple detection during different growth stages in orchards using the improved YOLO-v3 model**. Computers and Electronics in Agriculture, v. 157, p. 417-426, 2019.

WU, D. et al. **Using channel pruning-based YOLO v4 deep learning algorithm for the real-time and accurate detection of apple flowers in natural environments**. Computers and Electronics in Agriculture, v. 178, p. 105742, 2020.

LIPPI, M. et al. **A YOLO-based pest detection system for precision agriculture**. In: MEDITERRANEAN CONFERENCE ON CONTROL AND AUTOMATION (MED), 2021. Proceedings... IEEE, 2021. p. 342-347.

KHALID, Mahnoor et al. **Real-time plant health detection using deep convolutional neural networks**. Agriculture, v. 13, n. 2, p. 510, 2023.

BILIK, Simon et al. **Machine learning and computer vision techniques in continuous beehive monitoring applications: A survey**. Computers and Electronics in Agriculture, v. 217, p. 108560, 2024.

YANG, W.; JIACHUN, Z. **Real-time face detection based on YOLO**. In: IEEE INTERNATIONAL CONFERENCE ON KNOWLEDGE INNOVATION AND INVENTION (ICKII), 2018. Proceedings... IEEE, 2018. p. 221-224.

CHEN, W. et al. **YOLO-face: a real-time face detector**. The Visual Computer, v. 37, p. 805-813, 2021.

BOCHKOVSKIY, A.; WANG, C.; LIAO, H. M. **YOLOv4: Optimal Speed and Accuracy of Object Detection**. arXiv preprint arXiv:2004.10934, 2020.

HE, K.; ZHANG, X.; REN, S.; SUN, J. **Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition**. IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 37, p. 1904-1916, 2015. doi: 10.1109/TPAMI.2015.2389824.

RANGEKING; JOCHER, G. **Brief summary of YOLOv8 model structure**. GitHub Issue, 2023. Disponível em: <https://github.com/ultralytics/ultralytics/issues/189>. Acesso em: 27 abr. 2023.

SOHAN, Mupparaju et al. **A review on yolov8 and its advancements**. In: International Conference on Data Intelligence and Cognitive Informatics. Springer, Singapore, 2024. p. 529-545.

LIU, W.; HASAN, I.; LIAO, S. **Center and Scale Prediction: Anchor-free Approach for Pedestrian and Face Detection**. Pattern Recognition, v. 135, p. 109071, 2023. doi: 10.1016/j.patcog.2022.109071.

REZATOFIGHI, H. et al. **Generalized intersection over union: A metric and a loss for bounding box regression**. In: Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. [S.l.: s.n.], 2019. p. 658–666.

AKTOUF, Lotfi; SHIVANNA, Yathin; DHIMISH, Mahmoud. **High-Precision Defect Detection in Solar Cells Using YOLOv10 Deep Learning Model**. In: Solar. MDPI, 2024. p. 639-659.

DWYER, B., NELSON, J., HANSEN, T., et. al. (2024). Roboflow (Version 1.0) [Software]. Available from <https://roboflow.com>. [computer vision](#).

Apêndices

A Tabela de Cálculo de $CH\%$ para todas as colmeias

Tabela 7: Valor Percentual de CH de cada Colmeia

Numeração da Colmeia	Tamanho Populacional Estimado	Sintoma de Doença	Valor Percentual %
C_01	Média	Não	3.07
C_02	Pequena	Não	3.46
C_03	Pequena	Sim	3.57
C_05	Média	Sim	3.82
C_06	Pequena	Sim	3.31
C_07	Grande	Não	3.22
C_08	Grande	Não	3.15

Apêndices

B Resultados dos Projetos de Pesquisa, Desenvolvimento e Inovação (PD&I) da Embrapa

Tabela 8: Nível de Maturidade da Pesquisa TRL

Tipos de resultados	CATEGORIA DE RESULTADOS				
	Metodologia de Aquisição de Imagens	Plataforma 3D	Banco de dados de ASF	Algoritmos de IA	Dissertações Artigos
Ativos pré-tecnológicos ¹	✓		✓		
Ativos tecnológicos ²		✓		✓	
Apoio à inovação ³					
Comprovantes de Entrega ⁴					✓

¹ Para a categoria Ativo pré-tecnológico existem os seguintes tipos: Coleção biológica; Metodologia técnico-científica e Banco de dados, informações e análises.

² Para a categoria Ativo Tecnológico existe os tipos: Cultivar; Raça ou Grupo genético; Processo Agropecuário; Processo Industrial; Produto/Insumo Agropecuário ou Industrial; Máquinas e/ou implementos e Software para Clientes Externos.

³ Para a categoria Apoio a Inovação existem os tipos: Apoio à formulação ou à execução de políticas públicas; Arranjo institucional; Capacitação e atualização tecnológica de agentes multiplicadores; Capacitação interna em áreas estratégicas; Estudo socioeconômico ou de avaliação de impacto; Estudo prospectivo, organizacional ou gerencial; Processo, metodologia ou estudo técnico com fins organizacionais e gerenciais e Software corporativo para uso interno.

⁴ Para a categoria Comprovantes de Entrega, enquadram-se as publicações de caráter técnico e/ou científico, obtidas a partir de resultados de projetos de P&D&I, comunicação ou gestão, que tenham como público preferencial o setor produtivo agropecuário ou industrial, o meio técnico-científico ou outros agentes de interesse institucional. São exemplos deste tipo de comprovante: a) artigo completo em anais de congresso, b) artigo indexado, c) capítulo de livro, d) dissertação ou tese, e) publicações das séries.