

Milene de Sousa Fialho
Orientadora: Alcilene Dalíia de Sousa

Monitoramento de Colmeias em Imagens Utilizando Aprendizado Profundo: Uma Revisão Sistemática

Picos - PI
26 de junho de 2025

Milene de Sousa Fialho
Orientadora: Alcilene Dalília de Sousa

Monitoramento de Colmeias em Imagens Utilizando Aprendizado Profundo: Uma Revisão Sistemática

Monografia submetida ao Curso de Bacharelado em Sistemas de Informação como requisito parcial para obtenção de grau de Bacharel em Sistemas de Informação.

Universidade Federal do Piauí
Campus Senador Heuvídio Nunes de Barros
Bacharelado em Sistemas de Informação

Picos - PI
26 de junho de 2025

FICHA CATALOGRÁFICA
Serviço de Processamento Técnico da Universidade Federal do Piauí
Biblioteca José Albano de Macêdo

F439m Fialho, Milene de Sousa.

Monitoramento de colmeiras em imagens utilizando aprendizado profundo: uma revisão sistemática / Milene de Sousa Fialho – 2025.
45 f.

1 Arquivo em PDF.

Indexado no catálogo *online* da biblioteca José Albano de Macêdo-CSHNB
Aberto a pesquisadores, com restrições da Biblioteca.

Trabalho de Conclusão de Curso (Graduação) – Universidade Federal do
Piauí, Curso de Bacharelado em Sistemas de Informação, Picos, 2025.
“Orientadora: Alcilene Dalília de Sousa”

1. Sistemas informacionais. 2. Visão computacional. 3. Análise de
imagens-monitoramento. I. Fialho, Milene de Sousa. II. Sousa, Alcilene Dalília
de. III. Título.

CDD 005.7

Elaborada por Maria Letícia Cristina Alcântara Gomes
Bibliotecária CRB n° 03/1835

Monitoramento de Colmeias em Imagens Utilizando Aprendizado Profundo: Uma Revisão
Sistemática

Milene de Sousa Fialho

Monografia aprovada como exigência parcial para obtenção do grau de Bacharel em Sistemas
de Informação.

Data de Aprovação

Picos – PI, 26 de junho de 2025

Documento assinado digitalmente
 **ALCILENE DALÍLIA DE SOUSA**
Data: 02/07/2025 10:43:31-0300
Verifique em <https://validar.iti.gov.br>

Prof^a. Dra. Alcilene Dalília de Sousa - Orientadora

Documento assinado digitalmente
 **LEONARDO PEREIRA DE SOUSA**
Data: 01/07/2025 21:42:58-0300
Verifique em <https://validar.iti.gov.br>

Prof. Me. Leonardo Pereira de Sousa

Documento assinado digitalmente
 **JOSE DENES LIMA ARAUJO**
Data: 01/07/2025 15:13:59-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. José Denes Lima Araújo

Agradecimentos

Em primeiro lugar, agradeço a Deus, fonte de toda a minha força, por me conceder saúde, paciência e coragem para seguir em frente até o fim de mais essa etapa da minha vida. Foi ele quem sustentou meus passos, acolheu minhas orações e acalmou meu coração diante dos desafios. Como diz a tua palavra em Isaías 41:10: “Não temas, porque eu sou contigo; não te assombres, porque eu sou o teu Deus; eu te fortaleço, e te ajudo, e te sustento com a destra da minha justiça.”.

Agradeço profundamente aos meus pais, Maria Rita e Messias Raimundo, e à minha avó, Rita Maria, pelo apoio incondicional, tanto emocional quanto financeiro. Sou grata por cada palavra de amor e conforto nos momentos em que mais precisei, por celebrarem comigo cada conquista, por menor que fosse, e por nunca deixarem de me incentivar e acreditar no meu potencial, mesmo quando eu mesma duvidava. Se consegui chegar até aqui, saibam que foi por causa de vocês.

Sou imensamente grata também aos meus irmãos Marciel, Lena, Márcia e Mislene, que sempre torceram por mim e me apoiaram em cada etapa dessa jornada. Nunca estive sozinha, pois vocês sempre estiveram presentes em todos os meus passos, sendo os exemplos mais reais de amor, carinho e companheirismo. Vocês me ensinam todo dia o valor da união familiar e que não importa o tamanho do desafio, com amor e apoio tudo se torna mais leve. Vocês são parte essencial dessa vitória, e essa conquista é tão minha quanto de vocês.

Aos meus sobrinhos Wesley, Nicolas e Lara, que tantas vezes foram minha motivação para seguir em frente. Em cada abraço apertado, recebi amor genuíno e orgulho sincero, e isso fez toda a diferença. Vocês, com sua pureza e amor incondicional, foram luz nos momentos escuros e esperança nos dias cansativos. Tia ama vocês. Aos meus cunhados Mikael, Alane e Alexandre, deixo minha sincera gratidão por cada palavra de apoio, incentivo e carinho ao longo do caminho.

Às minhas primas Lívia, Dapenha, Dayana, Tamara e Tiará, meu mais sincero agradecimento. Mesmo com a distância física que separa algumas de vocês, o carinho, o apoio e a presença de cada uma se fizeram sentir de forma intensa e verdadeira em todos os momentos dessa caminhada. Vocês são as pessoas que me mostram que laços de sangue também podem ser laços de alma. Levo cada uma comigo nessa conquista.

Não poderia deixar de agradecer também aos meus amigos Matheus Victor, Bianca e Vinicius, que caminharam ao meu lado durante toda essa jornada. Pessoas incríveis com quem tive o privilégio de contar nos momentos difíceis e nas alegrias do dia a dia. Agradeço por cada risada fácil, por cada conversa leve e por todos os momentos vividos juntos na nossa segunda "casa", a UFPI.

Agradeço também a Millena Lira, minha parceira de todas as horas. Entramos juntas

e, com fé em Deus, sairemos juntas, concluindo mais esse sonho. Como diz o Provérbios 17:17: “Em todo o tempo ama o amigo e para a hora da angústia nasce o irmão”, e foi exatamente isso que você se tornou na minha vida, uma irmã de coração.

Às minhas amigas, Jaine, Rainara e Maria Eduarda, gratidão por cada gesto de amor, paciência e amizade. Por nunca soltarem minhas mãos, mesmo nos momentos mais difíceis. Obrigada por cada vez que deixaram seus próprios compromissos de lado para me ouvir, aconselhar ou simplesmente estar ali, dividindo o silêncio, o choro ou a alegria. Vocês foram meu porto seguro em tantas fases, e é impossível pensar na minha caminhada sem lembrar da força que recebi de vocês. Vocês são e sempre serão do meu coração.

Às meninas com quem tive o prazer de compartilhar o AP, Ísis, Maria Clara, Márcia Fernandes e Yorrana, meu sincero agradecimento por todos os momentos vividos. Esse tempo que passamos juntas foi muito mais do que uma convivência, foi construção de laços, troca de aprendizados e formação de uma pequena família longe de casa. As experiências que vivemos e os desafios que enfrentamos juntas se transformaram em memórias valiosas que levarei comigo para sempre.

Um agradecimento especial à minha orientadora, professora Alcilene Dalília, por toda a sua orientação, paciência e dedicação ao longo dessa trajetória. Sua disponibilidade em ouvir, esclarecer dúvidas e apontar caminhos com firmeza e sensibilidade foram fundamentais para que eu conseguisse concluir essa etapa com segurança e confiança.

Gostaria de expressar minha profunda gratidão a todos os professores do curso de Sistemas de Informação, que ao longo dessa jornada compartilharam seus conhecimentos com dedicação, paciência e entusiasmo. Cada aula, orientação e desafio proposto contribuiu significativamente para minha formação acadêmica e pessoal. Muito obrigado por fazerem parte dessa conquista.

Por fim, agradeço a todos, que de alguma forma, contribuíram para a realização desse sonho. A todos vocês meus sincero muito obrigada!

Consagre ao senhor todos os teus sonhos, e tudo que você for fazer, você será bem sucedido em todos eles.

Provérbio 16:3

Resumo

As abelhas desempenham um papel essencial no equilíbrio dos ecossistemas, sendo responsáveis por aproximadamente 75% da polinização das culturas alimentares no mundo. Contudo, colmeias têm enfrentado ameaças crescentes devido à Desordem do Colapso da Colônia, caracterizada pela perda súbita e inexplicável de 60% a 90% das abelhas operárias. Nesse contexto, o uso de processamento de imagens aliado ao aprendizado profundo tem se mostrado uma abordagem promissora na apicultura, permitindo detectar padrões visuais, avaliar comportamentos e identificar anomalias ou pragas nas colmeias. Esta revisão sistemática reuniu os principais estudos da área, com foco em técnicas de classificação e detecção aplicadas ao monitoramento visual de abelhas. Os resultados quantitativos revelam que modelos baseados em redes neurais convolucionais, como VGG, ResNet, MobileNet e YOLO, apresentaram alto desempenho, alcançando métricas de até 99% de acurácia e F1-score em tarefas de classificação, e mAP superior a 97% em detecção. A metodologia adotada envolveu a análise comparativa de métricas extraídas dos artigos selecionados, como acurácia, F1-score, precisão, revocação, mAP e IoU. Como benefícios, este trabalho fornece uma síntese atualizada das abordagens mais eficazes, auxiliando pesquisadores e apicultores na escolha de soluções mais adequadas para o monitoramento de colmeias. Além disso, a revisão identifica lacunas existentes na literatura, incentivando o desenvolvimento de ferramentas tecnológicas mais acessíveis e robustas, contribuindo para a preservação das abelhas e a sustentabilidade da apicultura.

Palavras-chaves: abelhas, colmeias, imagens, aprendizado profundo, revisão sistemática.

Abstract

Bees play an essential role in the balance of ecosystems, being responsible for approximately 75% of the pollination of food crops worldwide. However, beehives have faced increasing threats due to Colony Collapse Disorder, characterized by the sudden and unexplained loss of 60% to 90% of worker bees. In this context, the use of image processing combined with deep learning has shown to be a promising approach in beekeeping, allowing the detection of visual patterns, the evaluation of behaviors and the identification of anomalies or pests in hives. This systematic review brought together the main studies in the area, focusing on classification and detection techniques applied to visual monitoring of bees. The quantitative results reveal that models based on convolutional neural networks, such as VGG, ResNet, MobileNet and YOLO, presented high performance, achieving metrics of up to 99% accuracy and F1-score in classification tasks, and mAP higher than 97% in detection. The adopted methodology involved the comparative analysis of metrics extracted from the selected articles, such as accuracy, F1-score, precision, recall, mAP and IoU. As benefits, this work provides an updated synthesis of the most effective approaches, assisting researchers and beekeepers in choosing the most appropriate solutions for hive monitoring. In addition, the review identifies gaps in the literature, encouraging the development of more accessible and robust technological tools, contributing to the preservation of bees and the sustainability of beekeeping.

Lista de ilustrações

Figura 1 – Metodologia	23
Figura 2 – Distribuição das aplicações de monitoramento visual de colmeias.	29
Figura 3 – Quantidade de Estudos por Tipo de Base de Dados.	31
Figura 4 – Tipos de Pré-Processamento.	32
Figura 5 – Desempenho do modelo de Classificação por artigo.	34
Figura 6 – Desempenho do modelo de Detecção por artigo.	35

Lista de tabelas

Tabela 1 – Trabalhos Relacionados (<i>I - Turyagyenda et al. (2025); II - Abdollahi, Giovenazzo e Falk (2022); III - Bilik et al. (2024); IV - Costa et al. (2025); V - (HADDAOUI et al., 2024); VI - Hadjur, Ammar e Lefèvre (2022)</i>)	22
Tabela 2 – String de Buscas	25
Tabela 3 – Critérios de Inclusão e Critérios de Exclusão	25
Tabela 4 – Formulário de Extração dos Dados	27
Tabela 5 – Tabela de Classificação	34
Tabela 6 – Tabela de Detecção	35

Lista de abreviaturas e siglas

CCD	Colony Collapse Disorder
CNN	Convolutional Neural Networks
DETR	Detection Transformer
DL	Deep Learning
IoT	Internet of Things
IoU	Intersection over Union
ML	Machine learning
MAP	Mean Average Precision
MLP	Multilayer Perceptron
RGB	Red, Green, Blue
RNN	Recurrent Neural Networks
TI	Tecnologia da Informação
VGG	Visual Geometry Group
YOLO	You Only Look Once

Sumário

1	Introdução	14
1.1	Objetivos	15
1.2	Organização do Trabalho	15
2	Referencial Teórico	16
2.1	Monitoramento de Colmeias	16
2.2	Aprendizado de Máquina	16
2.2.1	Aprendizado Profundo	17
2.3	Visão Computacional	18
2.3.1	Imagens	18
2.3.2	Pré-processamento	19
2.3.3	Detecção	19
2.3.4	Classificação	20
3	Trabalhos Relacionados	21
4	Metodologia	23
4.1	Definição do Protocolo	24
4.2	Pesquisa Inicial	24
4.3	Filtragem	25
4.4	Classificação	25
4.5	Extração de dados	26
5	Resultados	28
5.1	Aplicações do monitoramento baseado em imagens	28
5.1.1	Detecção de invasão de insetos e ácaro Varroa	28
5.1.2	Rastreamento de Abelhas	29
5.1.3	Monitoramento da saúde das colmeias	29
5.1.4	Reconhecimento de Anomalias em Colmeias	29
5.1.5	Contagem de Abelhas e Ácaros Varroa	30
5.1.6	Classificação do Ácaro Varroa	30
5.2	Aquisição dos Dados	30
5.3	Pré-Processamento	31
5.4	Extração de Características	32
5.5	Modelos Utilizados e Validação	33
5.5.1	Classificação	33

5.5.2	Detecção	33
6	Desafios de Pesquisa e Direções	36
6.1	Aquisição das imagens	36
6.2	Processamento da imagem	37
6.3	Aprendizado profundo	38
7	Conclusão	39
	Referências	41

1 Introdução

As abelhas desempenham uma função crucial e insubstituível no ecossistema como polinizadoras, elas são responsáveis por polinizar cerca de 75% das culturas alimentícias do mundo (LANDAVERDE; RODRIGUEZ; PARRELLA, 2023), (SAMMATARO; GERSON; NEEDHAM, 2000). Seu papel vai além da produção de mel, influenciando diretamente a reprodução de diversas plantas e garantindo a manutenção da biodiversidade. Culturas como amêndoas, maçãs e até mesmo brócolis dependem desse processo, e estima-se que sua contribuição para a economia seja de pelo menos 20 bilhões de dólares (HAMZA et al., 2023).

Nos últimos anos, colmeias ao redor do mundo têm enfrentado desafios significativos devido a uma série de fatores que, em determinado momento, foram referidos como Desordem do Colapso da Colônia (*Colony Collapse Disorder* - CCD). Esse fenômeno é caracterizado por uma perda rápida e inexplicável de 60% a 90% da população adulta da colmeia, comprometendo sua sobrevivência e funcionalidade (BRAGA et al., 2021). Embora as causas exatas do CCD ainda não sejam completamente compreendidas, acredita-se que diversos fatores possam estar envolvidos, incluindo mudanças climáticas, uso indiscriminado de pesticidas, disseminação de doenças, ação de predadores naturais e até mesmo estresse causado por práticas intensivas de apicultura (LIANG, 2024).

Considerando a sua importância para a humanidade, entender e preservar as colmeias sempre foi essencial e continua sendo nos dias atuais (ZAMAN; DORIN, 2023). Para alcançar esse objetivo, é fundamental adotar técnicas de monitoramento menos invasivas, como a automação dos métodos tradicionais, que muitas vezes se mostram ineficazes ou limitados (KONGSILP; TAETRAGOOL; DUANGPHAKDEE, 2024). Dessa forma, é possível respeitar o papel vital das abelhas nos ecossistemas, ao mesmo tempo em que minimizem os impactos negativos sobre suas colônias.

O monitoramento automatizado do comportamento das abelhas oferece novas perspectivas para a gestão de colmeias (ZHENG et al., 2024), permitindo uma análise mais precisa e contínua da saúde das colônias. Essa abordagem possibilita a detecção precoce de problemas, como alterações no padrão de voo, variações na temperatura interna da colmeia e mudanças na taxa de atividade das abelhas, fatores que podem indicar doenças ou até mesmo o risco de colapso da colônia (GURUPRASAD; LEIDING, 2024). Além disso, a automação reduz a necessidade de intervenções humanas frequentes, minimizando o estresse sobre as abelhas e tornando o manejo mais eficiente e sustentável.

O processamento de imagens tornou-se uma das principais técnicas utilizadas para monitoramento, pois consiste em um processo menos invasivo que pode ser aplicado em diversos cenários. Proporcionando benefícios significativos aos apicultores, pois eles podem obter dados críticos e *insights* sobre a saúde de suas colmeias com mais regularidade e

confiança. Além disso, possibilita a identificação de variações de temperatura e a detecção de pragas e parasitas (LIU; LIN, 2022), como o ácaro *Varroa* (DIVASÓN et al., 2024).

Nesse contexto, este trabalho visa realizar uma revisão sistemática das abordagens que utilizam aprendizado profundo aliado ao processamento de imagens no monitoramento de colmeias. A aplicação dessas tecnologias tem se mostrado promissora, permitindo não apenas a identificação de padrões comportamentais e condições anormais nas colônias, mas também a classificação de espécies, contagem de abelhas e detecção de eventos críticos com alta precisão.

1.1 Objetivos

O objetivo desta pesquisa é realizar uma revisão sistemática sobre o uso de técnicas de aprendizado profundo para o monitoramento de colmeias por meio de imagens, buscando mapear, analisar e sintetizar os métodos, aplicações, desafios e tendências atuais nessa área. Especificamente, pretende-se:

1. Identificar os principais algoritmos de aprendizado profundo aplicados ao monitoramento de colmeias em imagens;
2. Classificar os tipos de monitoramento realizados;
3. Analisar as bases de dados utilizadas nos estudos;
4. Avaliar os resultados e métricas de desempenho reportados;
5. Investigar os desafios técnicos e limitações enfrentados pelos pesquisadores;
6. Apontar lacunas na literatura, sugerindo direções futuras de pesquisa na aplicação de aprendizado profundo nesse domínio.

1.2 Organização do Trabalho

Este trabalho está organizado da seguinte forma: a Seção 2 aborda os fundamentos teóricos sobre aprendizado profundo e monitoramento de colmeias; a Seção 3 apresenta os trabalhos relacionados já desenvolvidos na área; a Seção 4 descreve a metodologia da revisão sistemática; a Seção 5 traz a análise e discussão dos resultados; a Seção 6 apresenta os desafios de pesquisa; e a Seção 7 apresenta as considerações finais e sugestões para pesquisas futuras.

2 Referencial Teórico

Para um melhor entendimento dos termos abordados e da metodologia proposta, esta Seção apresenta uma breve revisão da literatura relacionada ao monitoramento de colmeias por meio de imagens e à aplicação de redes neurais profundas na extração e análise de características visuais.

2.1 Monitoramento de Colmeias

Os sistemas modernos de monitoramento aplicados à apicultura têm se destacado como ferramentas essenciais para a gestão eficiente das colmeias. Utilizando sensores (HAMZA et al., 2023), câmeras (BRAGA et al., 2021) e sinais de áudios (SIMONE et al., 2024), esses sistemas permitem ao apicultor o acompanhamento em tempo real de diversos parâmetros relevantes, como temperatura interna, umidade, atividade das abelhas, presença de intrusos e integridade estrutural da colmeia (MEZQUIDA; MARTÍNEZ, 2009). A partir da análise desses dados, é possível obter diagnósticos precisos sobre o estado da colônia, identificando comportamentos anormais, sinais de doenças ou fatores ambientais que possam comprometer o bem-estar das abelhas.

Com essas informações em mãos, o apicultor pode tomar decisões mais rápidas e embasadas, adotando medidas corretivas ou preventivas sempre que necessário. Isso não apenas contribui para a manutenção da saúde das colônias, como também favorece o aumento da produtividade, reduz perdas e otimiza o manejo apícola. Além disso, ao minimizar a necessidade de inspeções físicas frequentes, os sistemas de monitoramento promovem uma abordagem menos invasiva e mais sustentável no cuidado com as abelhas.

2.2 Aprendizado de Máquina

Machine learning (ML) é um ramo dentro da Inteligência Artificial que se concentra na criação de sistemas capazes de aprender com dados. Esses sistemas buscam aprimorar seu desempenho em determinadas tarefas por meio da experiência (SOUTO et al., 2003), em vez de serem explicitamente programados para isso. Para alcançar esse objetivo, é necessário expor o sistema a uma grande quantidade de exemplos, dos quais ele extrai conhecimento. Esse conhecimento é representado por hipóteses geradas a partir dos dados (LUDERMIR, 2021), permitindo que o sistema melhore sua capacidade de realizar tarefas específicas. Os modelos de AM possuem tipos de aprendizados, que orientam o treinamento e o funcionamento dos algoritmos, sendo os três tipos principais: Supervisionado, Semi-supervisionado e por Reforço.

No Aprendizado Supervisionado, para cada exemplo apresentado ao algoritmo de aprendizado é necessário apresentar a resposta desejada (ou seja, um rótulo informando a que classe o exemplo pertence, no caso de um problema de classificação de imagens, por exemplo, como distinguir imagens de gatos e de cachorros). Cada exemplo é descrito por um vetor de valores (atributos) e pelo rótulo da classe associada. O objetivo do algoritmo é construir um classificador que possa determinar corretamente a classe de novos exemplos ainda não rotulados (LUDERMIR, 2021).

No Aprendizado Semi-supervisionado, os exemplos são fornecidos ao algoritmo sem rótulos. O algoritmo agrupa os exemplos pelas similaridades dos seus atributos. O algoritmo analisa os exemplos fornecidos e tenta determinar se alguns deles podem ser agrupados de alguma maneira, formando, agrupamentos ou *clusters*. Após a determinação dos agrupamentos, em geral, é necessária uma análise para determinar o que cada agrupamento significa no contexto do problema que está sendo analisado (LUDERMIR, 2021).

No Aprendizado por Reforço, o algoritmo não recebe a resposta correta, mas recebe um sinal de reforço, de recompensa ou punição. O algoritmo faz uma hipótese baseada nos exemplos e determina se essa hipótese foi boa ou ruim.

2.2.1 Aprendizado Profundo

O aprendizado profundo tem se consolidado como uma ferramenta poderosa para o reconhecimento de padrões em dados de alta dimensionalidade, sendo amplamente utilizado em diversos domínios da ciência, do setor empresarial e do governo (MARQUES, 2016). Trata-se de uma classe de técnicas dentro do aprendizado de máquina, área que pode ser considerada como uma interseção entre redes neurais, modelagem gráfica, otimização, reconhecimento de padrões e processamento de sinais (PEREIRA et al., 2017).

Aprendizado profundo (do inglês, *Deep Learning* - DL), é uma subárea do aprendizado de máquina que utiliza redes neurais artificiais compostas por múltiplas camadas para modelar e extrair padrões complexos a partir de grandes volumes de dados. Essas redes são inspiradas na estrutura e no funcionamento do cérebro humano, permitindo que os computadores aprendam a reconhecer padrões em imagens, sons, textos e outros tipos de dados de maneira autônoma (FRANÇA; GAGLIARDI, 2025).

Além disso, o DL se beneficia de arquiteturas específicas, como as redes neurais convolucionais (do inglês, *Convolutional Neural Networks* - CNNs), largamente utilizadas em aplicações de visão computacional (SANTOS et al., 2017), e as redes neurais recorrentes (do inglês, *Recurrent Neural Networks* - RNNs) eficazes em tarefas sequenciais como o processamento de linguagem natural e análise de séries temporais (CAPANEMA; SILVA; SILVA, 2020). Essas arquiteturas especializadas aumentam a eficiência e a precisão dos modelos, tornando-se ferramentas versáteis e adaptáveis a problemas complexos.

2.3 Visão Computacional

Visão computacional é o campo científico encarregado da capacidade de uma máquina reconhecer e compreender o ambiente ao seu redor através da análise de imagens capturadas por câmeras de vídeo, sensores, scanners e outros dispositivos. Essa análise extrai informações relevantes que possibilitam o reconhecimento, a manipulação e a interpretação dos objetos presentes em uma imagem. Em outras palavras, ela fornece ao sistema computacional uma vasta gama de dados detalhados provenientes de imagens e vídeos, capacitando o computador a realizar tarefas sofisticadas, emulando e se aproximando da cognição humana (MILANO; HONORATO, 2010).

2.3.1 Imagens

O uso de imagens no monitoramento de colmeias tem se mostrado uma abordagem eficaz e promissora para a apicultura, permitindo a captura de dados visuais que refletem o comportamento das abelhas, a estrutura interna e externa da colmeia (TORKY; NASR; HASSANIEN, 2023), além da identificação de possíveis anomalias, como infestação por pragas (LIU; LIN, 2022) e ácaros (DIVASÓN et al., 2024), presença de corpos estranhos ou degradação estrutural. Câmeras estrategicamente posicionadas tanto no interior quanto na entrada das colmeias possibilitam a aquisição contínua de imagens as quais são posteriormente analisados por sistemas computacionais.

Esses sistemas, baseados em algoritmos de visão computacional, possibilitam a detecção automática de padrões comportamentais, como o fluxo de entrada e saída de abelhas, aglomerações anormais ou ausência de atividade. Essa abordagem não apenas reduz a necessidade de intervenções humanas frequentes, como também evita o estresse causado às colônias pelas inspeções físicas tradicionais (BRAGA et al., 2021).

Além da definição da posição das câmeras, a escolha do tipo de imagem capturada desempenha um papel importante na eficácia do monitoramento. Imagens *Red, Green, Blue* (RGB) são amplamente utilizadas para observação geral do comportamento das abelhas e identificação visual de alterações no ambiente da colmeia. Já imagens em infravermelho ou térmicas permitem detectar variações de temperatura (SANTOS, 2010) que podem indicar problemas como aquecimento anormal, presença de umidade excessiva ou a ausência da abelha-rainha. A captura dessas imagens pode ser realizada de forma contínua ou em intervalos regulares, e os dados armazenados localmente ou transmitidos via redes sem fio para posterior análise em servidores ou na nuvem, otimizando o acompanhamento remoto das colmeias.

2.3.2 Pré-processamento

De acordo com [SOUZA e CORREIA \(2007\)](#), o pré-processamento constitui uma etapa fundamental no processo de aquisição de dados em sistemas de visão computacional. Nessa fase, são aplicadas técnicas específicas com o objetivo de melhorar a qualidade da imagem e realçar regiões de interesse, de modo a evidenciar características relevantes e suprimir informações irrelevantes ou ruidosas.

Entre as principais técnicas de pré-processamento, destacam-se o uso de filtros (como médias ou mediana) para redução de ruídos ([MARENGONI; STRINGHINI, 2009](#)), o redimensionamento de imagens ([RODRIGUEZ-LOZANO et al., 2024](#)) para padronização das entradas em modelos, a remoção de ruído impulsivo ([MARENGONI; STRINGHINI, 2009](#)), bem como o aumento de dados (do inglês, *data augmentation*) ([RODRIGUEZ-LOZANO et al., 2024](#)), que consiste na geração de variações artificiais das imagens originais. A escolha adequada dessas técnicas deve considerar diretamente o problema a ser tratado, uma vez que intervenções inadequadas podem comprometer a extração de características, resultando em impactos positivos ou negativos no desempenho do sistema.

Além disso, o pré-processamento de imagens pode ser dividido em duas abordagens principais: realce e restauração. O realce tem como objetivo melhorar a visualização de determinadas características da imagem, tornando-as mais evidentes para o observador. As alterações promovidas por essa técnica são perceptíveis visualmente, como no caso do ajuste de contraste ou da aplicação da equalização de histograma. Por outro lado, a restauração visa recuperar a imagem original ou partes específicas dela, com base em informações prévias sobre a natureza da degradação sofrida. Técnicas de filtragem, por exemplo, estão diretamente associadas à abordagem de restauração ([SIQUEIRA, 2010](#)).

2.3.3 Detecção

A detecção de objetos é uma das tarefas centrais da visão computacional, responsável por localizar e identificar instâncias de objetos semânticos pertencentes a categorias específicas dentro de imagens ou vídeos digitais ([LEOCÁDIO et al., 2021](#)). Esse processo envolve não apenas reconhecer a presença de um objeto, mas também determinar com precisão sua localização por meio de caixas delimitadoras (*bounding boxes*).

A detecção possibilita a classificação e a localização de mais de um objeto por imagem ([ROMÃO, 2023](#)). Essa tarefa é fundamental em aplicações de visão computacional, como monitoramento automatizado ([PEINADO et al., 2025](#)), veículos autônomos ([COUTO, 2012](#)), e análise de imagens médicas ([ROSA, 2025](#)). Em contextos como o monitoramento de colmeias por imagens, por exemplo, a detecção pode identificar abelhas, intrusos, estruturas danificadas ou alterações no padrão de comportamento, contribuindo para diagnósticos mais precisos e intervenções mais eficazes. Além disso, técnicas modernas de detecção, como a *You Only Look Once* (YOLO) ([LEOCÁDIO et al., 2021](#)) e *Detection*

Transformer (DETR) (DAI et al., 2022), permitem realizar essa tarefa de forma eficiente e em tempo real, mesmo em cenários complexos e com múltiplos objetos de diferentes tamanhos.

2.3.4 Classificação

Classificar imagens consiste em atribuir rótulos específicos a imagens com base em categorias previamente definidas durante o processo de treinamento (ERTHAL et al., 1991). O processo de classificação de imagens inclui a coleta e o pré-processamento dos dados, como normalização e redimensionamento, seguido da divisão em conjuntos de treinamento, validação e teste. Após a escolha do modelo, como redes neurais convolucionais (CNNs) ou árvores de decisão, o modelo é treinado para reconhecer padrões e avaliado com base em sua capacidade de generalização (SOUZA, 2024).

Na tarefa de classificação de imagens, diversos modelos de redes neurais podem ser empregados, cada um com características específicas. A *Multilayer Perceptron* - MLP (LIMA, 2024) é uma rede neural simples e eficaz para tarefas menos complexas. A *Visual Geometry Group* (VGG-16) (SILVA, 2018) utiliza múltiplas camadas com pequenas convoluções para extrair padrões detalhados, enquanto a ResNet (SILVA, 2018) emprega conexões residuais que facilitam o treinamento de redes mais profundas, melhorando o desempenho em classificações mais complexas.

3 Trabalhos Relacionados

Esta Seção apresenta um conjunto de trabalhos relacionados, onde foi realizado um comparativo considerando três aspectos principais: o contexto em que os trabalhos estão inseridos, o número de artigos selecionados em cada estudo e o tipo de estudo especificamente desenvolvido em cada pesquisa. Foram levantados seis trabalhos situados na área de monitoramento de colmeias por meio de imagens, com características de estudos secundários e foco no levantamento sistemático da literatura. Como mostra a Tabela 1

O primeiro critério, aborda as áreas específicas em que cada trabalho está inserido dentro do campo de monitoramento de colmeias. Já o segundo critério, apresenta o número de artigos selecionados em cada um dos estudos analisados.

O terceiro critério refere-se ao tipo de estudo desenvolvido pelos trabalhos. Consideramos quatro tipos de estudos: (1) Revisão – que consiste apenas em um levantamento bibliográfico sem rigor no processo; (2) Survey – estudo que coleta e analisa dados de forma estruturada sobre determinado tema; (3) Revisão Sistemática – um levantamento rigoroso e objetivo da literatura; e (4) Revisão da Literatura – levantamento dos principais trabalhos já publicados, geralmente com foco em contextualização e identificação de lacunas.

Foi identificado que a maioria dos estudos concentra-se na apicultura de precisão, utilizando IoT e aprendizado de máquina para a análise visual automatizada de colmeias [Turyagyenda et al. \(2025\)](#) [Haddaoui et al. \(2024\)](#) [Hadjur, Ammar e Lefèvre \(2022\)](#). Esses estudos adotam abordagens amplas, combinando diversas técnicas. Outros trabalhos [Abdollahi, Giovenazzo e Falk \(2022\)](#) [Bilik et al. \(2024\)](#) [Costa et al. \(2025\)](#) exploram aspectos mais específicos, como visão computacional, monitoramento acústico ou efeitos de pesticidas, focando em recortes particulares dentro do monitoramento por imagens.

Tabela 1 – Trabalhos Relacionados (I - *Turyagyenda et al. (2025)*; II - *Abdollahi, Giovenazzo e Falk (2022)*; III - *Bilik et al. (2024)*; IV - *Costa et al. (2025)*; V - (*HADDAOUI et al., 2024*); VI - *Hadjur, Ammar e Lefèvre (2022)*)

Ref	Contexto	Quantidade	Tipo de Estudo
I	Revisão do uso de IoT e aprendizado de máquina para aprimorar o monitoramento da apicultura de precisão	8	Revisão
II	Revisa as principais metodologias para o monitoramento automatizado de colmeias por análise acústica	61	Revisão da Literatura
III	Monitoramento de colmeias utilizando visão computacional com o foco na detecção de pólen, ácaros Varroa e no monitoramento do tráfego de abelhas	63	Survey
IV	Avaliar a contaminação por pesticidas em abelhas e produtos apícolas brasileiros	15	Revisão Sistemática
V	Avanços impulsivos no monitoramento de abelhas por meio de estratégias baseadas em dados	15	Revisão
VI	Descreve os avanços recentes na apicultura de isolamento como sistemas e serviços	86	Survey

4 Metodologia

Esta Revisão Sistemática apresenta uma coleta das informações disponíveis na literatura. Para isso, foi seguido uma sequência de passos, assim como sugerido em [Keele et al. \(2007\)](#). Nas subseções a seguir, detalha-se a execução de cada uma dessas etapas. Como mostra a Figura 1, o processo é composto por cinco fases principais: definição do escopo, busca inicial, filtragem, categorização dos artigos e extração das informações. Na fase de definição do escopo, foram elaboradas perguntas que orientaram as buscas, seguidas pelo estabelecimento de critérios para filtragem e classificação dos artigos. Por fim, são apresentados os resultados obtidos a partir desse processo.

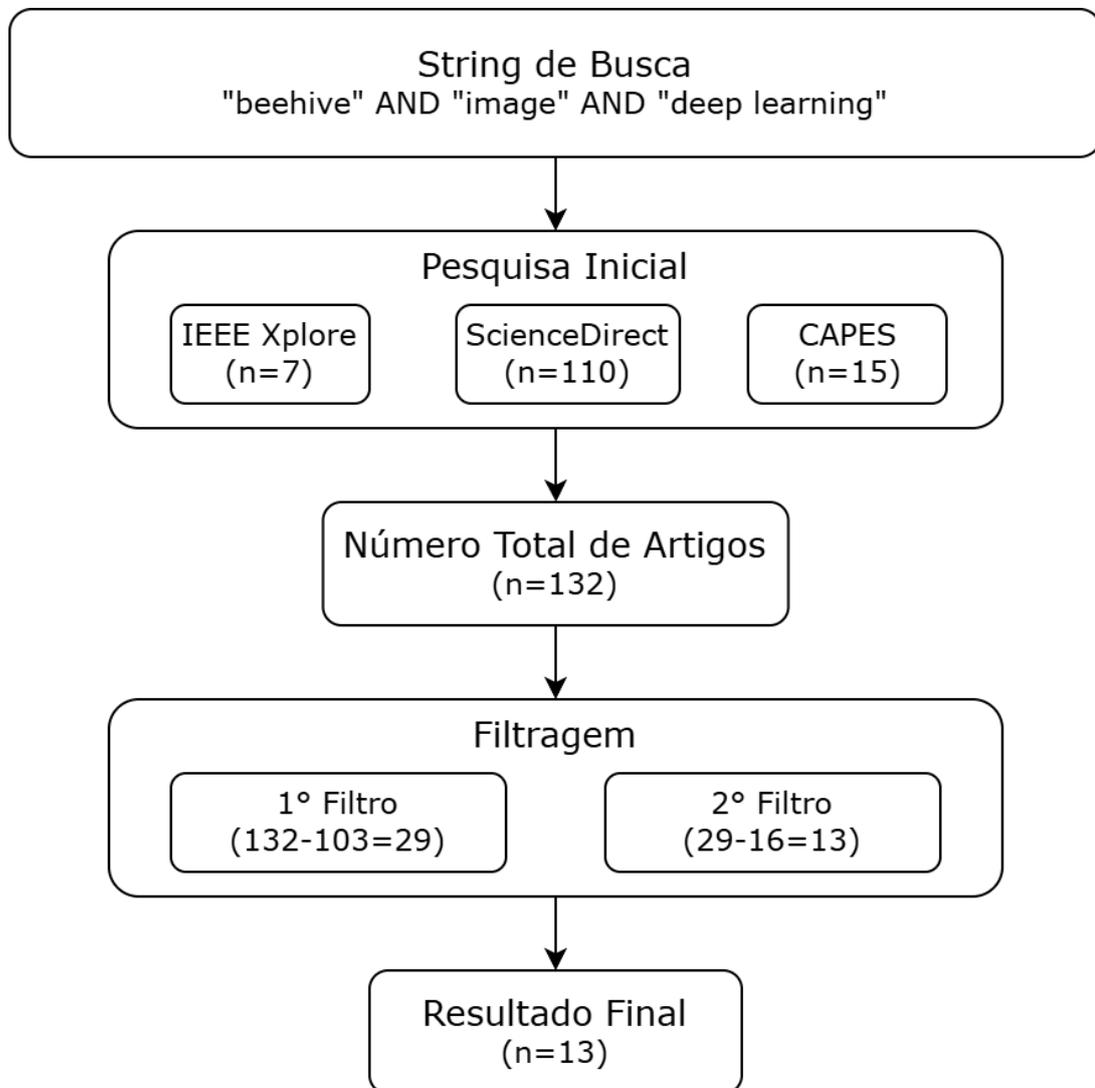


Figura 1 – Metodologia

4.1 Definição do Protocolo

A primeira etapa concentrou-se na Definição do Protocolo. Onde foram definidas as perguntas de pesquisa que se deseja responder. Tais perguntas delimitaram o escopo do trabalho e nortearam a busca por estudos primários. Antes de elaborá-las, procurou-se abranger tópicos relevantes para a comunidade científica, especialmente no que diz respeito às principais técnicas de monitoramento de colmeias por meio do processamento de imagens, utilizando métodos de aprendizado profundo. Com o objetivo de dar maior fundamentação à proposta da pesquisa, as seguintes questões foram elaboradas:

QG- Quais são as abordagens existentes na literatura que utilizam imagens e aprendizado profundo para monitorar colmeias e avaliar suas condições de saúde e funcionamento?

Q1- Quais são os principais métodos de processamento de imagem utilizados para identificar o estado das colmeias?

Q2- Quais são os objetivos mais recorrentes dos sistemas desenvolvidos com base em imagens para o monitoramento de colmeias?

Q3- Que tipo de informação é extraída das imagens e como essa informação é utilizada para caracterizar o comportamento, a saúde ou o funcionamento das colônias?

4.2 Pesquisa Inicial

Na segunda etapa foi realizada a Pesquisa Inicial. Nessa fase, foram definidos os termos de busca, que foram aplicados em diferentes bases de dados, iniciando-se assim a coleta dos artigos. Foi então elaborada a string de busca utilizada nesta revisão, conforme descrito a seguir: identificação, por meio de grafias alternativas e sinônimos para os principais termos, além da verificação das palavras-chave presentes em documentos relevantes.

Após a definição dos termos, foi gerada uma string de busca genérica, conforme apresentado na Tabela 2. Em seguida, ela foi formatada de acordo com as bibliotecas virtuais utilizadas: IEEE Xplore, ScienceDirect e Portal Periódicos da CAPES. Tais bases foram selecionadas devido à relevância e ao prestígio de seus periódicos e anais de conferência. A partir das buscas realizadas, foram obtidos 132 artigos, os quais passaram por um processo de filtragem, resultando na seleção apenas dos estudos considerados relevantes para esta pesquisa, conforme ilustrado na Figura 1.

As buscas foram realizadas durante o período de 2024 - 2025, sendo restritas às publicações feitas entre os anos de 2021 a 2025. Além disso, o idioma foi limitado ao inglês, que possuíam como objetivo o monitoramento de colmeias por meio do processamento de imagens utilizando métodos de aprendizado profundo.

Tabela 2 – String de Buscas

Repositórios Virtual	String de Busca
IEEE Explore	"beehive"AND "image"AND "deep learning"
ScienceDirect	"beehive"AND "image"AND "deep learning"
CAPES	"beehive"AND "image"AND "deep learning"

Tabela 3 – Critérios de Inclusão e Critérios de Exclusão

Critérios de Inclusão
I.1 Quando as palavras-chave predefinidas existem no seu conjunto ou, pelo menos, no título, nas palavras-chave ou na secção do resumo do documento.
I.2 O trabalho deve ser redigido em língua inglesa.
I.3 O artigo deve ser um estudo primário e apresentar resultados.
I.4 Artigos que utilizam imagens como base de análise.
I.5 Artigo que utilizam métodos de aprendizado profundo.
Critérios de Exclusão
E.1 Artigos que estão duplicados nos documentos de pesquisa.
E.2 Artigos publicados antes de 2021.
E.3 Documentos que não são acessíveis.

4.3 Filtragem

A terceira etapa engloba o processo de Filtragem, cujo objetivo é mapear os trabalhos encontrados e reduzir o número de arquivos que precisam ser lidos integralmente. Nesse sentido, a estratégia de filtragem foi desenvolvida com base em critérios de inclusão e exclusão, os quais estão detalhados na Tabela 3.

4.4 Classificação

Na quarta etapa, realiza-se a classificação dos artigos em aceitos ou rejeitados. Esse processo é conduzido por meio da aplicação de três fases de filtragem, com base nos critérios de inclusão e exclusão descritos na Seção 4.3.

Na primeira fase, aplica-se os critérios de exclusão E.1, E.2 e E.3. Um artigo é automaticamente classificado como rejeitado se atender a qualquer um desses critérios. Na segunda fase, são utilizados os critérios de inclusão I.1, I.2 e I.3, e na terceira fase, são considerados os critérios de inclusão I.4 e I.5, etapa em que é realizada a leitura completa do artigo.

Para que um trabalho seja classificado como aceito e avance para a próxima etapa, ele não deve atender a nenhum dos critérios de exclusão e deve satisfazer todos os critérios de inclusão. Após a classificação, os artigos aceitos são analisados individualmente, e suas informações são organizadas conforme o formulário de extração de dados descrito na Seção 4.5.

4.5 Extração de dados

Com o objetivo de extrair as informações mais relevantes de cada estudo analisado, foi elaborado um formulário de extração de dados, estruturado a partir das diretrizes definidos na Seção 4.1. Esse formulário é composto por uma sequência de perguntas organizadas em cinco seções: Monitoramento de dados, Pré-processamento, Extração de características, Classificação e Validação. Uma visão geral do conteúdo de cada uma dessas etapas pode ser encontrada na Tabela 4.

A etapa 1 refere-se ao processo de aquisição de dados. Ela contém questões que buscam obter informações detalhadas sobre a base de dados utilizada no estudo, como sua natureza (pública ou privada), o ambiente em que as imagens foram capturadas, a frequência de coleta, a quantidade de amostras disponíveis, a espécie de abelha monitorada e o tipo de imagem empregada. Essas informações são fundamentais porque permitem avaliar a qualidade, a diversidade e a representatividade dos dados, além de fornecer suporte para a reprodutibilidade e comparabilidade entre diferentes estudos.

A etapa 2 trata do pré-processamento das imagens coletadas. São investigadas as técnicas aplicadas antes da extração de características, como normalização, redimensionamento e remoção de ruído. Também se avalia o uso de aumento de dados, com métodos como rotações ou espelhamentos, e como as imagens foram divididas entre treino, validação e teste, aspectos essenciais para garantir a qualidade e a generalização dos modelos.

A etapa 3 do formulário trata da extração de características, buscando entender como essa etapa foi conduzida em cada estudo. Especificamente, investiga-se se as características foram extraídas manualmente, por meio de atributos definidos pelos autores, ou automaticamente, com o uso de redes neurais. Quando redes neurais são utilizadas, a seção identifica qual arquitetura foi empregada nesse processo. Além disso, verifica-se se foram aplicadas técnicas de redução de dimensionalidade, o que pode indicar uma preocupação com a simplificação do modelo e o aumento da eficiência computacional.

As etapas 4 e 5 do formulário investigam os métodos de classificação e avaliação dos modelos. Elas buscam identificar qual algoritmo ou arquitetura de classificação foi utilizado, se a tarefa foi tratada como binária ou multiclasse, e se houve ajuste de hiperparâmetros. Também é analisado se o modelo foi treinado do zero ou por meio de transferência de aprendizado. Em relação à avaliação, são levantadas as métricas de desempenho empregadas, as estratégias de validação adotadas, e se os testes foram realizados apenas com dados do conjunto experimental ou também com dados reais, o que contribui para avaliar a aplicabilidade prática do modelo.

Tabela 4 – Formulário de Extração dos Dados

Aquisição de Dados	<p>O conjunto de dados é público ou privado?</p> <p>Em que condições ambientais as imagens foram capturadas?</p> <p>Qual é a frequência ou periodicidade da coleta de imagens?</p> <p>Quantas amostras tem a base?</p> <p>Qual espécie de abelha está sendo monitorada?</p> <p>Qual tipo de imagem é utilizada?</p>
Pré-processamento	<p>Quais técnicas de pré-processamento foram aplicadas às imagens?</p> <p>Houve aumento de dados? Se sim, quais métodos foram utilizados?</p> <p>Como os dados foram divididos para treinamento, validação e teste?</p>
Extração de Característica	<p>A tarefa é sobre classificação?</p> <p>As características foram extraídas manualmente ou por meio de redes neurais?</p> <p>Se extraídas manualmente, quais atributos foram considerados?</p> <p>Se redes neurais foram usadas, qual arquitetura foi utilizada para extração?</p> <p>Houve uso de técnicas de redução de dimensionalidade?</p>
Classificação	<p>Qual modelo ou algoritmo de classificação foi utilizado?</p> <p>A classificação foi binária ou multiclasse?</p> <p>Houve ajuste de hiperparâmetros?</p> <p>O modelo foi treinado do zero ou fez uso de transferência de aprendizado?</p>
Validação	<p>Quais métricas foram utilizadas para avaliar o desempenho?</p> <p>O modelo foi validado com quais estratégias?</p>

5 Resultados

Nesta Seção, são apresentadas as informações extraídas dos artigos que atenderam a todos os requisitos definidos nesta revisão, conforme descrito na Seção 4. A busca inicial resultou em 132 artigos identificados por meio de descritores específicos. Após a exclusão de 103 trabalhos que não cumpriam os critérios estabelecidos, 29 artigos seguiram para a etapa de análise detalhada. Ao final do processo, 13 artigos foram selecionados e incluídos na revisão sistemática.

Para facilitar a compreensão dos resultados, eles foram organizados nos seguintes tópicos: aplicações do monitoramento, aquisição dos dados, pré-processamento, extração de características, classificação e validação. Em cada tópico, é apresentado um resumo das informações e técnicas mais frequentemente abordadas nos trabalhos selecionados.

5.1 Aplicações do monitoramento baseado em imagens

Os artigos selecionados utilizaram técnicas de processamento de imagens para diferentes finalidades, tais como: detecção de insetos e pragas, rastreamento de abelhas, monitoramento da saúde das colmeias, classificação do ácaro Varroa, reconhecimento de anomalias e contagem de abelhas e parasitas. O gráfico apresentado na Figura 2 mostra a distribuição dessas aplicações, evidenciando que a detecção de insetos e pragas é a tarefa mais abordada na literatura, seguida pelo monitoramento da saúde das colmeias, contagem de abelhas e parasitas e classificação do ácaro Varroa. Rastreamento de abelhas e reconhecimento de anomalias aparecem com menor frequência, indicando que essas áreas ainda possuem potencial para maior exploração e desenvolvimento. Nas subseções seguintes, cada uma dessas aplicações será detalhada, juntamente com os trabalhos que as têm como foco principal.

5.1.1 Detecção de invasão de insetos e ácaro Varroa

Estudos como os de Liu e Lin (2022) empregou algoritmos de aprendizado profundo para detectar a invasão de insetos nas colmeias e analisar o comportamento das colônias de abelhas em seis apiários. Já Liu et al. (2023), Voudiotis, Moraiti e Kontogiannis (2022), Mahajan et al. (2023) e Kriouile et al. (2024) empregaram câmeras e técnicas de visão computacional, aliadas ao aprendizado profundo, para identificar padrões característicos de infestação na imagens, oferecendo uma abordagem não invasiva, precisa e eficiente para o monitoramento contínuo das condições das colmeias.

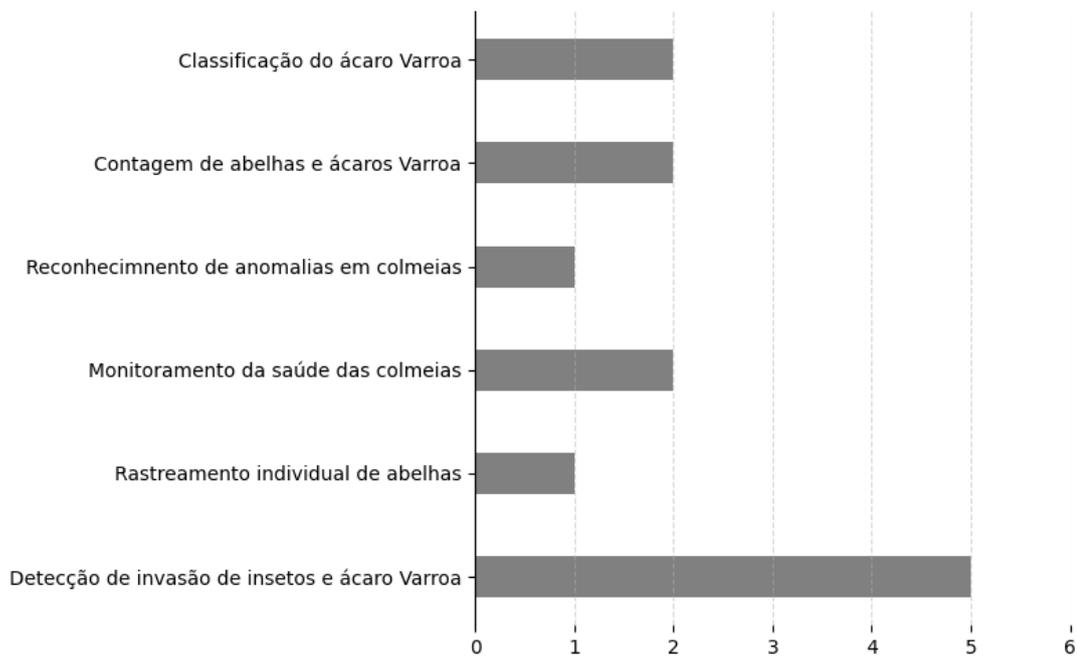


Figura 2 – Distribuição das aplicações de monitoramento visual de colmeias.

5.1.2 Rastreamento de Abelhas

O estudo de [Kongsilp, Taetrageool e Duangphakdee \(2024\)](#) propôs uma solução mais eficiente, utilizando algoritmos de aprendizado profundo e um filtro de Kalman, para identificar e acompanhar as abelhas de forma automatizada. Essas abordagens oferecem informações valiosas sobre a dinâmica das colmeias, apoiando tanto o avanço da pesquisa científica quanto práticas mais eficazes no manejo apícola.

5.1.3 Monitoramento da saúde das colmeias

Em [Braga et al. \(2021\)](#), é apresentado um sistema de monitoramento da saúde da colmeia baseado em técnicas de processamento de imagens, no qual um modelo é responsável por detectar abelhas nas imagens e outro realiza a classificação do estado de saúde das abelhas identificadas. Por sua vez, [Berkaya, Gunal e Gunal \(2021\)](#) propõe um modelo de classificação visual treinado para examinar abelhas registradas no interior das colmeias, sendo capaz de identificar diferentes condições relacionadas a esses insetos.

5.1.4 Reconhecimento de Anomalias em Colmeias

Em seu estudo, [Torky, Nasr e Hassanien \(2023\)](#) propôs o uso de um modelo de aprendizado profundo baseado em uma rede móvel para identificar automaticamente anomalias na saúde das colmeias. Esse tipo de solução visual oferece monitoramento frequente, preciso e de baixo impacto, contribuindo para ações rápidas e eficazes no manejo apícola.

5.1.5 Contagem de Abelhas e Ácaros Varroa

No estudo de [Bilik et al. \(2024\)](#), três métodos de contagem automatizada de abelhas foram comparados utilizando dois conjuntos de dados próprios. Já [Divasón et al. \(2024\)](#) propôs uma abordagem baseada em aprendizado profundo para localizar e contar ácaros Varroa por meio de imagens de tábuas adesivas capturadas com câmeras de smartphones, oferecendo uma alternativa eficiente e acessível para o controle sanitário das colônias.

5.1.6 Classificação do Ácaro Varroa

O ácaro *Varroa destructor* é um dos principais parasita responsáveis pela queda na população de abelhas em todo o mundo [Mavridis et al. \(2025\)](#), sendo capaz de transmitir vírus e enfraquecer a colônia ao se alimentar da hemolinfa das abelhas. A identificação precisa do ácaro é essencial para a tomada de decisões no manejo apícola, como a aplicação de tratamentos ou medidas preventivas. A abordagem automatizada para a classificação desse parasita tem se destacado por substituir os métodos manuais, que frequentemente se mostram ineficazes, especialmente em cenários com grande concentração de insetos nas colmeias. Essa automação permite um processo mais preciso, ágil e escalável, tornando o monitoramento mais confiável e menos dependente da intervenção humana. Em seus estudos, [Noriega-Escamilla et al. \(2023\)](#) propõe um método baseado em aprendizado profundo para classificar abelhas como infectadas ou saudáveis a partir da análise de imagens. Já [Kaur et al. \(2022\)](#) apresenta uma abordagem inovadora para a identificação do *Varroa destructor* em abelhas, utilizando multicanais de Legendre-Fourier como técnica de extração de características.

5.2 Aquisição dos Dados

Durante a condução da revisão sistemática, identificou-se a natureza dos conjuntos de dados utilizados em cada um dos artigos selecionados, classificando-os como públicos ou privados. Com base nos resultados apresentados na Figura 3, observa-se que a maioria dos estudos, sete de treze, utilizou bases de dados públicas, enquanto os outros seis recorreram a bases privadas. Como exemplo de bases públicas utilizadas, podem ser mencionadas a Varroa Dataset e a BeeImage. O Varroa Dataset, utilizado por [Noriega-Escamilla et al. \(2023\)](#) consistem em imagens capturadas de colmeias infestadas pelo ácaro *Varroa destructor*, geralmente obtidas por meio de câmeras posicionadas diretamente nas colônias ou sobre quadros de crias, em condições controladas ou a campos. Já a BeeImage, utilizado por [Berkaya, Gunal e Gunal \(2021\)](#) reúne imagens de abelhas em diferente estágio e condições, capturadas com câmeras digitais em apiários, com o foco na coleta de dados visuais para identificação automática de espécies ou anomalias.

Em relação ao formato das imagens utilizada em cada artigo, todas as bases disponibilizaram as amostras no padrão RGB, o que indica que elas possuem três canais de cor (vermelho, verde e azul). O uso dessas imagens neste formato permite um maior detalhamento de informações visuais, sendo especialmente útil para os modelos que dependem de nuances de cor para realizar classificações ou detecções.

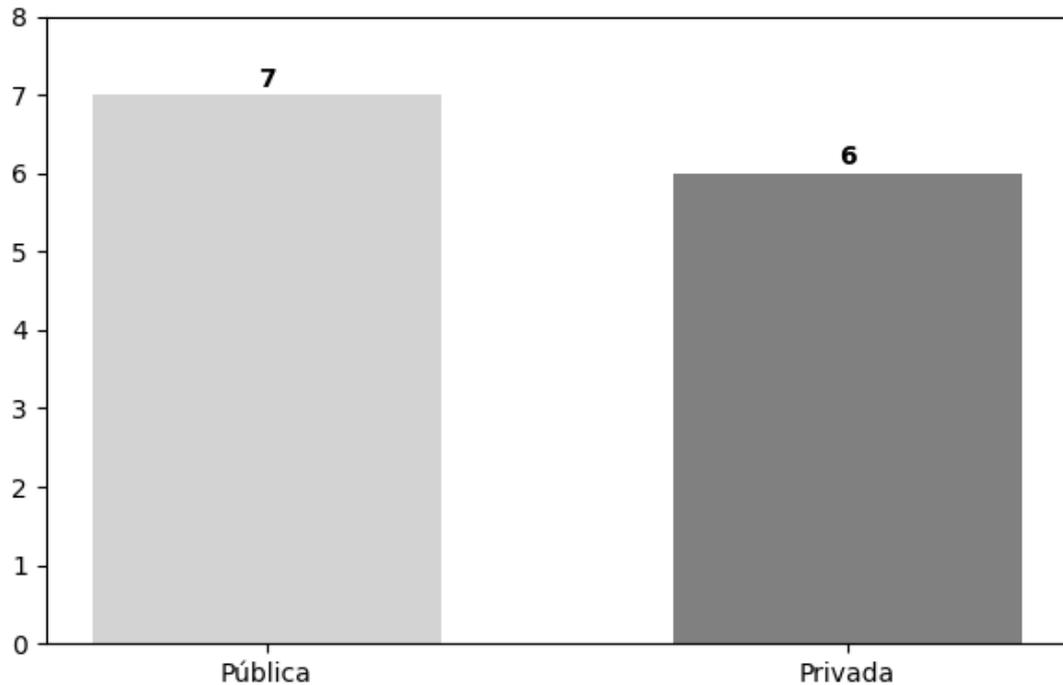


Figura 3 – Quantidade de Estudos por Tipo de Base de Dados.

5.3 Pré-Processamento

A análise dos estudos indica que as técnicas mais empregadas nessa fase incluem o redimensionamento das imagens e o aumento de dados (*data augmentation*), além de outras abordagens específicas, como apresentada na Figura 4.

O redimensionamento foi a técnica mais comum, presente em seis dos artigos analisados. Essa prática visa padronizar as dimensões das imagens para atender aos requisitos de entrada dos modelos, garantindo consistência no treinamento e otimizando o uso de recursos computacionais. Estudos como os de Braga et al. (2021), Torky, Nasr e Hassanien (2023), Bilik et al. (2024), Divasón et al. (2024), Mahajan et al. (2023) e Berkaya, Gunal e Gunal (2021) utilizaram esse tipo de pré-processamento em sua metodologia.

O aumento de dados, utilizado em quatro estudos, contribuiu para a ampliação do conjunto de dados por meio de transformações artificiais, como rotação, espelhamentos e mudanças de brilho. Essa técnica é especialmente útil em contextos como poucos dados rotulados, pois melhora a generalização dos modelos e reduz o risco de *overfitting*. Pesquisa

como as de Braga et al. (2021), Kaur et al. (2022), Liu et al. (2023) e Mahajan et al. (2023) adotaram essa técnica em sua metodologia.

Outras técnicas de pré-processamento foram abordada em quatro dos artigos, englobando a normalização de pixels até filtragens específicas e remoção de ruídos. Muitas vezes, essas técnicas são combinadas para potencializar seus efeitos, garantindo que os dados estejam na melhor qualidade possível para o treinamento dos modelos, como observado nos estudos de Kongsilp, Taetragool e Duangphakdee (2024), Vouliotis, Moraiti e Kontogiannis (2022), Kriouile et al. (2024) e Noriega-Escamilla et al. (2023).

Dentre os trabalhos analisados na revisão, apenas o estudo de Liu e Lin (2022) não especificou de forma clara o tipo de pré-processamento aplicado aos dados. A ausência dessa informação compromete a reprodutibilidade do estudo e dificulta a avaliação do impacto das etapas de preparação dos dados sobre o desempenho do modelo.

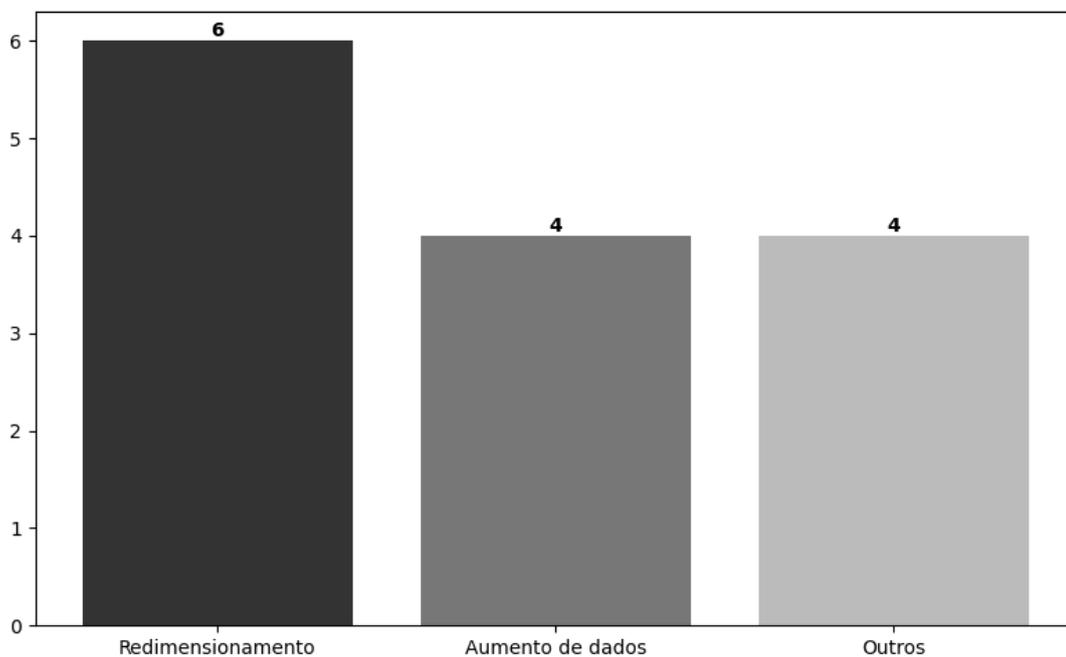


Figura 4 – Tipos de Pré-Processamento.

5.4 Extração de Características

Nos artigos incluídos na revisão sistemática, a etapa de extração de característica foi fundamental para preparar os dados a serem utilizados nos modelos de classificação. A maioria dos estudos que adotam essa tarefa emprega redes neurais convolucionais (CNNs) como o principal método para extração automática de característica. As CNNs são capazes de aprender representações complexas e hierárquicas diretamente das imagens, dispensando a necessidade de extração manual de descritores tradicionais.

Nos trabalhos de [Braga et al. \(2021\)](#) e [Kaur et al. \(2022\)](#) demonstram essa abordagem ao utilizarem as redes neurais convolucionais para realizar a extração automática de características em tarefas de classificação relacionadas à apicultura. Nesses trabalhos as CNNs foram empregadas para identificar abelhas, detectar anomalias ou doenças e classificar comportamento com alta precisão, mostrando a eficácia desse modelo na análise de imagens complexas.

5.5 Modelos Utilizados e Validação

Os estudos realizados nesta revisão sistemática aplicaram modelos de aprendizado profundo, com o foco principal em tarefas de classificação e detecção. A escolha das técnicas variou de acordo com os objetivos específicos de cada pesquisa. A etapa de validação, por sua vez, envolveu métricas como acurácia, precisão, revocação, F1-score, *Mean Average Precision* (MAP) e *Intersection over Union* (IoU). Essas métricas foram utilizadas para avaliar o desempenho e a capacidade de generalização dos modelos aplicados, fornecendo uma visão abrangente sobre sua eficácia em diferentes contextos e tipos de dados.

5.5.1 Classificação

Os modelos de classificação foram utilizados para identificar abelhas, distinguir entre indivíduos saudáveis e doente, ou categorizar comportamentos específicos, como coleta de pólen. Como apresentado na Tabela 5, grande parte dos estudos empregou arquiteturas CNN, como VGG, ResNet e MobileNet, que se destacam pela extração automática de características relevantes das imagens. A validação desses modelos foi realizada com conjuntos de dados rotulados, utilizando métrica de desempenho para avaliar a capacidade de generalização do modelo, como exemplificado no estudo de [Berkaya, Gunal e Gunal \(2021\)](#). Dentre as métricas aplicadas, a acurácia e o F1-score destacaram-se por apresentarem os melhores resultados na maioria dos trabalhos.

A Figura 5, compara as métricas dos modelos analisados. O artigo IV obteve a maior acurácia (99,07%), enquanto o artigo III teve o maior F1-score (99%), evidenciando equilíbrio entre precisão e revocação — crucial na identificação de doenças. O artigo V, por sua vez, apresentou os melhores valores de precisão (96,7%) e F1-score (96,6%), indicando alta eficiência na classificação. Esses resultados reforçam a robustez das abordagens baseadas em redes neurais convolucionais (CNN) na classificação de imagens no contexto da apicultura de precisão.

5.5.2 Detecção

Na tarefa de detecção, os modelos foram aplicados para localizar e contar abelhas em imagens ou vídeos, identificar ácaros sobre o corpo das abelhas ou detectar eventos

Tabela 5 – Tabela de Classificação

Artigo	Modelo	Métricas
I - (BRAGA et al., 2021)	CNN personalizada Mask R-CNN	Acurácia 95% F1-score 95% Precisão 95% Revocação 95%
II - (TORKY; NASR; HASSANIEN, 2023)	MobileNet	Acurácia 95%
III - (KAUR et al., 2022)	CNN otimizada + DCGAN	F1-score 99%
IV - (BERKAYA; GUNAL; GUNAL, 2021)	VGG19 ResNet101 + SVM AlexNet + SVM	Acurácia 99.07% F1-score > 0.95
V - (NORIEGA-ESCAMILLA et al., 2023)	MFM-YCbCr	F1-score 96.6% Precisão 96.7%

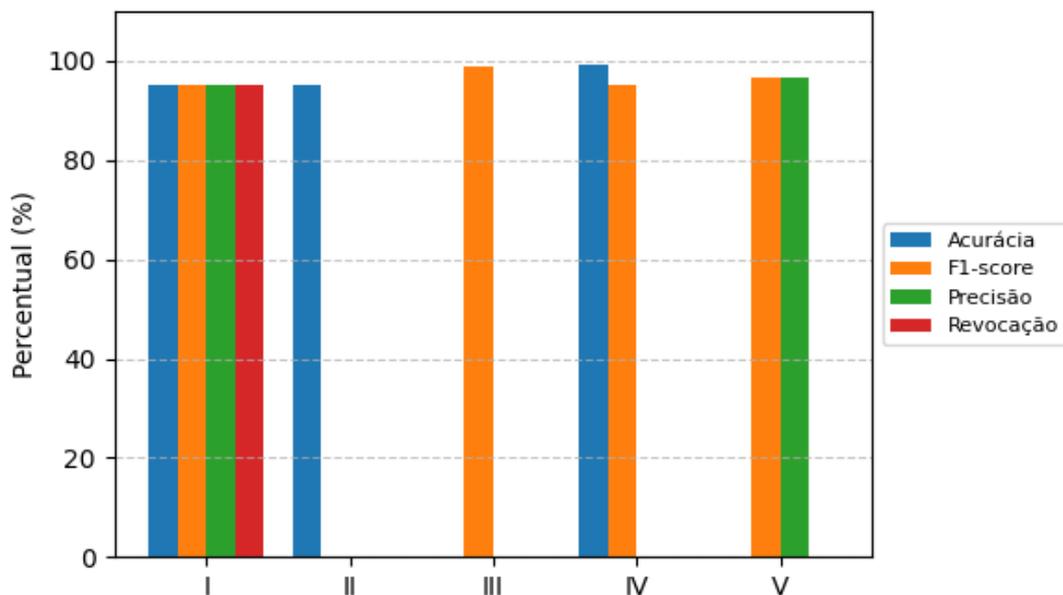


Figura 5 – Desempenho do modelo de Classificação por artigo.

específicos, como entrada e saída das colmeias. Como mostra a Tabela 6, arquitetura como *You Only Look Once* (YOLO), Faster R-CNN e ResNet foram os mais recorrentes, dada a sua eficiência na detecção em tempo real. Eles também mostraram um bom desempenho na identificação de múltiplos objetos em uma mesma imagem, ainda que, em ambientes com ruídos visual, como no trabalho de Kongsilp, Taetragool e Duangphakdee (2024). Na maioria dos estudos, a validação foi feita com base em caixas delimitadoras (*bounding box*), sendo a métrica MAP a principal medida de desempenho, como exemplificado no estudo de Divasón et al. (2024).

Os resultados apresentado na Figura 6 mostram variações significativas no desempenho dos modelos de detecção entre os estudos analisados. O artigo VII obteve os melhores indicadores, com altos valores de precisão (96,2%), revocação (96,7%) e mAP (97,4%), evi-

Tabela 6 – Tabela de Detecção

Artigo	Modelo	Métricas
I - (LIU; LIN, 2022)	CNN personalizada	Não Específica
II - (DIVASÓN et al., 2024)	Faster R-CNN com FPN	MAP: 0.9073
III - (KONGSILP; TAETRAGOOOL; DUANGPHAKDEE, 2024)	Mask R-CNN +ResNet-101 + Kalman Filter	MAP: 0.85 Revocação: 80.30%
IV - (BLIK et al., 2024)	Resnet-50	Acurácia 93%
V - (VOUDIOTIS; MORAITI; KONTOGIANNIS, 2022)	CNN personalizada	Acurácia ~70%
VI - (LIU et al., 2023)	YOLOX com Coordinate Attention + FCN	MAP superior;1.13% infestação detectada (vs 1.19% real)
VII - (MAHAJAN et al., 2023)	YOLOv5	Precisão 96.2% Revocação 96.7% MAP[0.5] 97.4% MAP[0.5:0.95] 40.4%
VIII - (KRIOUILE et al., 2024)	Mask R-CNN + ResNet (Res4)	1.9% em precisão varroa; -28% tempo exec.; -23% uso memória
IX - (BRAGA et al., 2021)	CNN personalizada Mask R-CNN	IoU 67% Acurácia 82%

denciando um modelo bem ajustado e eficiente. Os artigos II e III também se destacaram no mAP (90,73% e 85%, respectivamente), enquanto o artigo IV teve a maior acurácia (93%). Em contraste, os artigos VI e VIII apresentaram desempenho insatisfatório, com mAP de apenas 1,13% e precisão de 1,9%, respectivamente, sugerindo dificuldades na detecção correta dos alvos.

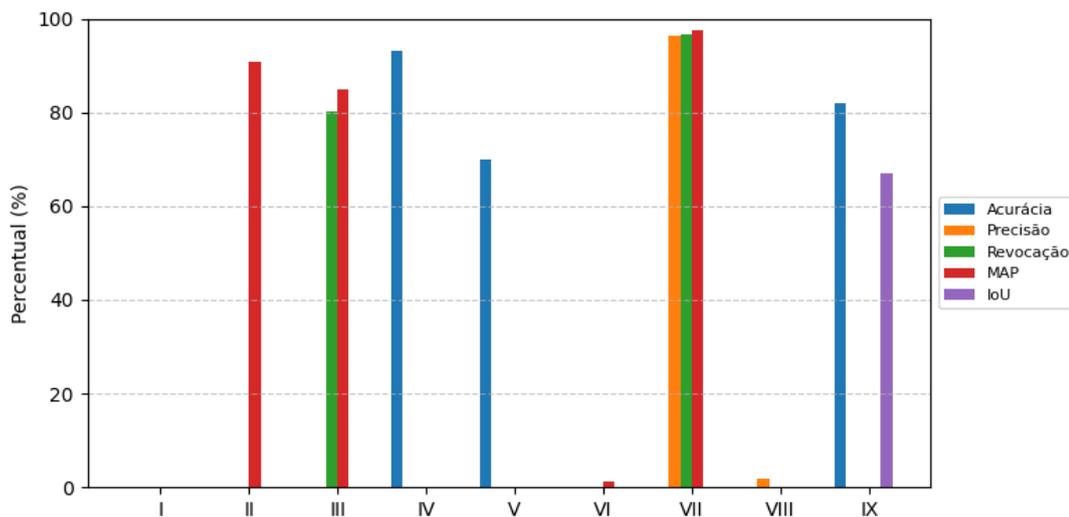


Figura 6 – Desempenho do modelo de Detecção por artigo.

6 Desafios de Pesquisa e Direções

O monitoramento da saúde das colmeias por meio da análise de imagens é uma área de pesquisa promissora, porém ainda enfrenta diversos desafios relevantes. Nesta seção, serão discutidos os principais obstáculos identificados nesta revisão, relacionados tanto à aquisição e tratamento de imagens quanto às dificuldades encontradas na aplicação de aprendizado profundo.

6.1 Aquisição das imagens

Durante a revisão sistemática, os autores identificaram diversos desafios relacionados ao uso de visão computacional no monitoramento de colmeias. Um dos principais obstáculos está associado à interferência do ambiente e à complexidade visual das cenas, como a sobreposição de abelhas, sombras e variações de iluminação, que dificultam a detecção precisa dos eventos de interesse. Outro desafio importante é a própria captura das imagens, especialmente quando são utilizados sensores e câmeras no interior da colmeia. Nessas situações, é fundamental garantir que esses dispositivos não alterem o comportamento natural das abelhas, por exemplo, evitando o aumento da temperatura ou a intrusão no espaço da colmeia.

Ao longo da pesquisa, também foi observado que a localização das colmeias pode ser um fator relevante a ser considerado, uma vez que frequentemente estão situadas em áreas remotas ou de difícil acesso, o que dificulta a instalação de dispositivos de monitoramento por imagem. Outro desafio está relacionado ao ambiente ao redor das colmeias, que pode conter elementos visuais complexos ou fontes de interferência, como movimento de vegetação, sombras, variações de iluminação natural ou a presença de outros insetos e animais, dificultando a obtenção de imagens de boa qualidade para análise precisa.

A atividade das abelhas pode variar ao longo do dia e ao longo das estações do ano, o que impacta diretamente a quantidade e a qualidade das imagens capturadas. Essa variação dificulta a obtenção de registros visuais consistentes para análises precisas. Além disso, as abelhas apresentam diferentes comportamentos visuais, como padrões de voo, interações e movimentos corporais, o que podem indicar diferentes estados ou situações. Para interpretar corretamente essas imagens e identificar os comportamentos observados, é necessário conhecimento especializado e preparo técnico adequado.

Por fim, é essencial considerar a segurança dos profissionais envolvidos nas atividades junto às colmeias. Esse ambiente pode apresentar riscos, especialmente para aqueles que não possuem experiência com o manejo de abelhas. Por isso, é indispensável que todos

os pesquisadores sejam devidamente treinados e façam uso de equipamentos de proteção apropriados, garantindo a integridade física da equipe e a preservação das colônias.

6.2 Processamento da imagem

Para que a classificação de imagens seja bem-sucedida, é necessário um conjunto de dados de treinamento amplo e diversificado, com uma variedade de classes e amostras representativas para cada uma delas. Além disso, a seleção adequada de características visuais e a escolha da arquitetura do modelo são fatores essenciais para garantir a exatidão da classificação.

Um dos principais desafios no monitoramento de colmeias por imagens é lidar com interferências visuais e ruídos no ambiente. As áreas ao redor das colmeias frequentemente apresentam variações de iluminação, sombras, movimento de folhas, presença de outros insetos ou animais, além de condições climáticas como chuva e vento. Esses fatores podem dificultar a captura de imagens nítidas e a identificação precisa das abelhas, suas atividades ou a presença de pragas, comprometendo a precisão das análises visuais automatizadas.

Outro desafio significativo está relacionado à complexidade e variedade das cenas de fundo, ao dinamismo dos movimentos individuais das abelhas e à semelhança visual entre o corpo da abelha e o ambiente da colmeia. Esses fatores dificultam a segmentação e o rastreamento preciso dos insetos nas imagens, especialmente em situações em que há grande densidade de indivíduos ou sobreposição entre eles. A identificação correta das atividades torna-se ainda mais desafiadora diante de pequenas transições de comportamento ou quando o fundo interfere diretamente na detecção visual.

Além disso, é fundamental levar em conta a diversidade de espécies de abelhas, pois cada uma pode apresentar padrões únicos, como variações de cor, tamanho, formato corporal e comportamento. Essas diferenças tornam necessário o desenvolvimento de abordagens flexíveis e adaptáveis, capazes de reconhecer com precisão as particularidades de cada espécie. Ignorar essa diversidade pode resultar em erros de classificação ou detecção, comprometendo a eficácia dos sistemas de monitoramento.

Por fim, a eficiência computacional é uma questão que não pode ser ignorada. Com o avanço das tecnologias de monitoramento de colmeias por meio de imagens, é fundamental desenvolver algoritmos que sejam computacionalmente eficientes, especialmente para aplicações em tempo real e em dispositivos de Internet das Coisas (IoT). Também é importante integrar as informações visuais com outros tipos de dados, como condições climáticas e padrões comportamentais das abelhas, para proporcionar uma análise mais completa e robusta do estado das colônias. Dessa forma, é possível entender melhor os fatores que impactam no bem-estar desses insetos e aprimorar as estratégias de manejo e conservação.

6.3 Aprendizado profundo

Aprendizado profundo têm apresentado avanços significativos e vêm sendo aplicados em diversas áreas. Na apicultura, essas tecnologias têm fornecido informações valiosas sobre o comportamento das abelhas, contribuindo para uma melhor compreensão de suas interações com o ambiente e oferecendo suporte tanto para apicultores quanto para pesquisadores. Contudo, ainda há desafios importantes que precisam ser superados.

Essas técnicas de aprendizado dependem fortemente da qualidade das informações de entrada para alimentar os modelos. Coletar dados em tempo real diretamente das colmeias pode ser uma tarefa complexa, exigindo a implementação de tecnologias adequadas, como sensores, câmeras, drones ou outros dispositivos de monitoramento. Além disso, é fundamental garantir a quantidade suficiente de amostras para lidar com o desequilíbrio entre classes no conjunto de treinamento, especialmente em situações que requerem rotulagem manual, a qual depende da colaboração de especialistas para assegurar a correta identificação dos dados.

A preparação dos dados é uma etapa fundamental antes de utilizá-las para construir os modelos. As imagens coletadas precisam ser devidamente pré-processadas, ajustadas e organizadas para garantir que a análise seja precisa e confiável. Entretanto, a variabilidade natural das colmeias e das abelhas representa um desafio adicional. Cada colmeia apresenta características próprias, o que pode dificultar a identificação de padrões relevantes no comportamento ou na saúde das abelhas. Por isso, os métodos utilizados devem ser capazes de lidar com essa diversidade e extrair informações significativas, mesmo diante das diferenças individuais entre as colmeias.

A superação desses desafios requer uma abordagem multidisciplinar, envolvendo apicultores, especialistas em aprendizado de máquina, pesquisadores e profissionais de TI. O desenvolvimento de soluções específicas para as demandas da apicultura, aliado ao compromisso com a coleta de dados de alta qualidade, é essencial para o sucesso da aplicação dessas técnicas no monitoramento de colmeias. Somente por meio de um esforço conjunto e cuidadoso será possível explorar todo o potencial dessas tecnologias para aprimorar a apicultura e contribuir para a preservação das abelhas.

7 Conclusão

Essa monografia apresentou os resultados de uma revisão sistemática sobre o monitoramento das colmeias baseadas em imagens por meio de aprendizado profundo. De modo geral, a maioria dos trabalhos concentrou-se nas tarefas de classificação e detecção, com ênfase na identificação de abelhas dentro e fora da colmeia, bem como na distinção entre diferentes comportamentos ou estados da colônia. Esses aspectos são considerados cruciais para que o apicultor possa identificar precocemente possíveis anomalias, tomar decisões preventivas e promover a manutenção da uniformidade e produtividade das colmeias.

A aquisição dos dados é uma etapa sensível e pode ser considerada uma das fases mais importante do processo. No entanto, enfrenta-se a limitação da disponibilidade de bases públicas de qualidade, muitas vezes desatualizadas ou com pouca variedade de cenários. Além disso, a rotulagem dos dados é um processo demorado e exige conhecimentos técnicos, especialmente no monitoramento de colmeias, onde a interpretação das imagens depende de critérios biológicos. Essas limitações comprometem o desempenho dos modelos de aprendizado profundo e dificultam sua aplicação em diferentes contextos.

O pré-processamento dos dados representa uma fase importante nos modelos de aprendizado profundo aplicados ao monitoramento de colmeias. As diferentes abordagens observadas nos estudos analisados, como redimensionamento, aumento de dados entre outros, evidenciam que não existe apenas uma única solução. É necessário adaptar as técnicas às características do problema e à quantidade de dados disponíveis. Além disso, a combinação de métodos tem se mostrado uma estratégia eficaz para aumentar a robustez dos modelos.

Em suma, duas ameaças à validade deste estudo foram identificadas. A primeira é o viés de seleção, não é possível garantir que todos os trabalhos relevantes tenham sido incluídos na revisão, uma vez que alguns podem não ter sido selecionados durante o processo de busca. Para mitigar essa ameaça, adotou-se a estratégia de rastreamento das referências presentes nos estudos classificados. A segunda ameaça refere-se à extração de dados, uma vez que a seleção dos trabalhos foi realizada com base no julgamento dos pesquisadores. Para minimizar possíveis erros de interpretação ou categorização indevida, foi realizada uma verificação cruzada em pares.

Baseado nas informações apresentadas, para trabalhos e testes futuros foi identificada a necessidade de aprimorar a eficiência e autonomia dos sistemas utilizados no monitoramento das colmeias. O aprendizado profundo melhorou significativamente esse monitoramento, porém ainda há limitações, como o alto custo computacional dos modelos e as restrições dos conjuntos de dados disponíveis. Nesse contexto, propõe-se o uso de sistemas embarcados e computação na borda (*edge computing*), possibilitando que a tarefa seja realizada mais próxima do usuário, sem dependência constante da nuvem. Além disso, a

integração com outras tecnologias, como sensores e áudio, pode tornar o sistema mais robusto e eficiente para aplicações em campo.

Referências

- ABDOLLAHI, M.; GIOVENAZZO, P.; FALK, T. H. Automated beehive acoustics monitoring: A comprehensive review of the literature and recommendations for future work. *Applied Sciences*, MDPI, v. 12, n. 8, p. 3920, 2022. Citado 3 vezes nas páginas 10, 21 e 22.
- BERKAYA, S. K.; GUNAL, E. S.; GUNAL, S. Deep learning-based classification models for beehive monitoring. *Ecological Informatics*, Elsevier, v. 64, p. 101353, 2021. Citado 5 vezes nas páginas 29, 30, 31, 33 e 34.
- BILIK, S. et al. Machine learning and computer vision techniques in continuous beehive monitoring applications: A survey. *Computers and Electronics in Agriculture*, Elsevier, v. 217, p. 108560, 2024. Citado 6 vezes nas páginas 10, 21, 22, 30, 31 e 35.
- BRAGA, D. et al. An intelligent monitoring system for assessing bee hive health. *IEEE Access*, IEEE, v. 9, p. 89009–89019, 2021. Citado 9 vezes nas páginas 14, 16, 18, 29, 31, 32, 33, 34 e 35.
- CAPANEMA, C. G. S.; SILVA, F. A.; SILVA, T. R. d. M. B. Mfa-rnn: Uma rede neural recorrente para predição de próximo local de visita com base em dados esparsos. In: SBC. *Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos (SBRC)*. [S.l.], 2020. p. 127–140. Citado na página 17.
- COSTA, A. L. G. et al. Unbounded bees: A systematic review and meta-analysis investigating pesticide contamination in brazilian bees and hive products. *Journal of Hazardous Materials Advances*, Elsevier, v. 17, p. 100632, 2025. Citado 3 vezes nas páginas 10, 21 e 22.
- COUTO, L. N. Sistema para localização robótica de veículos autônomos baseado em visão computacional por pontos de referência. 2012. Citado na página 19.
- DAI, L. et al. Ao2-detr: Arbitrary-oriented object detection transformer. *IEEE Transactions on Circuits and Systems for Video Technology*, IEEE, v. 33, n. 5, p. 2342–2356, 2022. Citado na página 20.
- DIVASÓN, J. et al. Analysis of varroa mite colony infestation level using new open software based on deep learning techniques. *Sensors*, MDPI, v. 24, n. 12, p. 3828, 2024. Citado 6 vezes nas páginas 15, 18, 30, 31, 34 e 35.
- ERTHAL, G. et al. Um sistema de segmentação e classificação de imagens de satélite. *São José dos Campos: Inpe*, 1991. Citado na página 20.
- FRANÇA, D. dos S.; GAGLIARDI, P. R. Proteção de dados e propriedade intelectual em projetos de aprendizado profundo (deep learning). *Revista Contemporânea*, v. 5, n. 2, p. e7430–e7430, 2025. Citado na página 17.
- GURUPRASAD, S. M.; LEIDING, B. Beeopen—an open data sharing ecosystem for apiculture. *Agriculture*, MDPI, v. 14, n. 3, p. 470, 2024. Citado na página 14.

- HADDAOUI, S. et al. A comprehensive review of beekeeping datasets for precision apiculture research. In: IEEE. *2024 10th International Conference on Control, Decision and Information Technologies (CoDIT)*. [S.l.], 2024. p. 2043–2048. Citado 3 vezes nas páginas 10, 21 e 22.
- HADJUR, H.; AMMAR, D.; LEFÈVRE, L. Toward an intelligent and efficient beehive: A survey of precision beekeeping systems and services. *Computers and Electronics in Agriculture*, Elsevier, v. 192, p. 106604, 2022. Citado 3 vezes nas páginas 10, 21 e 22.
- HAMZA, A. S. et al. Beelive: The iot platform of beemon monitoring and alerting system for beehives. *Smart Agricultural Technology*, Elsevier, v. 6, p. 100331, 2023. Citado 2 vezes nas páginas 14 e 16.
- KAUR, M. et al. A cnn-based identification of honeybees' infection using augmentation. In: IEEE. *2022 International Conference on Electrical, Computer, Communications and Mechatronics Engineering (ICECCME)*. [S.l.], 2022. p. 1–6. Citado 4 vezes nas páginas 30, 32, 33 e 34.
- KEELE, S. et al. *Guidelines for performing systematic literature reviews in software engineering*. [S.l.], 2007. Citado na página 23.
- KONGSILP, P.; TAETRAGOOL, U.; DUANGPHAKDEE, O. Individual honey bee tracking in a beehive environment using deep learning and kalman filter. *Scientific reports*, Nature Publishing Group UK London, v. 14, n. 1, p. 1061, 2024. Citado 5 vezes nas páginas 14, 29, 32, 34 e 35.
- KRIOUILE, Y. et al. Nested object detection using mask r-cnn: application to bee and varroa detection. *Neural Computing and Applications*, Springer, v. 36, n. 35, p. 22587–22609, 2024. Citado 3 vezes nas páginas 28, 32 e 35.
- LANDAVERDE, R.; RODRIGUEZ, M. T.; PARRELLA, J. A. Honey production and climate change: Beekeepers' perceptions, farm adaptation strategies, and information needs. *Insects*, v. 14, n. 6, p. 493, maio 2023. ISSN 2075-4450. Disponível em: <<https://www.mdpi.com/2075-4450/14/6/493>>. Citado na página 14.
- LEOCÁDIO, R. R. et al. Detecção de abelhas nativas em colmeias em campo utilizando visão computacional. In: SBC. *Workshop de Computação Aplicada à Gestão do Meio Ambiente e Recursos Naturais (WCAMA)*. [S.l.], 2021. p. 59–68. Citado na página 19.
- LIANG, A. Developing a multimodal system for bee object detection and health assessment. *IEEE Access*, v. 12, p. 158703–158713, 2024. Citado na página 14.
- LIMA, M. D. P. Classificação de imagens usando combinação de características topológicas e redes neurais. 2024. Citado na página 20.
- LIU, C.; LIN, S. A pest intrusion detection in chinese beehive culture using deep learning. *Scientific Programming*, Wiley Online Library, v. 2022, n. 1, p. 4642995, 2022. Citado 5 vezes nas páginas 15, 18, 28, 32 e 35.
- LIU, M. et al. Detection of varroa destructor infestation of honeybees based on segmentation and object detection convolutional neural networks. *AgriEngineering*, MDPI, v. 5, n. 4, p. 1644–1662, 2023. Citado 3 vezes nas páginas 28, 32 e 35.

- LUDERMIR, T. B. Inteligência artificial e aprendizado de máquina: estado atual e tendências. *Estudos Avançados*, SciELO Brasil, v. 35, p. 85–94, 2021. Citado 2 vezes nas páginas 16 e 17.
- MAHAJAN, Y. et al. Neuralbee-a beehive health monitoring system. In: IEEE. *2023 International Conference on Communication System, Computing and IT Applications (CSCITA)*. [S.l.], 2023. p. 84–89. Citado 4 vezes nas páginas 28, 31, 32 e 35.
- MARENGONI, M.; STRINGHINI, S. Tutorial: Introdução à visão computacional usando opencv. *Revista de Informática Teórica e Aplicada*, v. 16, n. 1, p. 125–160, 2009. Citado na página 19.
- MARQUES, E. A. L. Estudo sobre redes neurais de aprendizado profundo com aplicações em classificação de imagens. 2016. Disponível em: <<https://bdm.unb.br/handle/10483-15147>>. Citado na página 17.
- MAVRIDIS, K. et al. Identification and functional characterization of cyp3002b2, a cytochrome p450 associated with amitraz and flumethrin resistance in the major bee parasite varroa destructor. *Pesticide Biochemistry and Physiology*, v. 210, 2025. ISSN 0048-3575. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S004835752500077X>>. Citado na página 30.
- MEZQUIDA, D. A.; MARTÍNEZ, J. L. Platform for bee-hives monitoring based on sound analysis. a perpetual warehouse for swarm apos; s daily activity. *Spanish journal of agricultural research*, v. 7, n. 4, p. 824–828, 2009. Citado na página 16.
- MILANO, D. de; HONORATO, L. B. Visão computacional. *Faculdade de Tecnologia, Universidade Estadual de Campinas*, 2010. Citado na página 18.
- NORIEGA-ESCAMILLA, A. et al. Varroa destructor classification using legendre–fourier moments with different color spaces. *Journal of Imaging*, MDPI, v. 9, n. 7, p. 144, 2023. Citado 3 vezes nas páginas 30, 32 e 34.
- PEINADO, H. S. et al. Detecção de guarda-corpo e rodapés em canteiro de obras utilizando drones e visão computacional. *Ambiente Construído*, SciELO Brasil, v. 25, p. e137986, 2025. Citado na página 19.
- PEREIRA, M. d. M. et al. Aprendizado profundo: Redes lstm. Universidade Federal da Grande Dourados, 2017. Citado na página 17.
- RODRIGUEZ-LOZANO, F. J. et al. Capped honey segmentation in honey combs based on deep learning approach. *Computers and Electronics in Agriculture*, Elsevier, v. 227, p. 109573, 2024. Citado na página 19.
- ROMÃO, B. Redes neurais convolucionais para a detecção de objetos. Pontifícia Universidade Católica de Campinas (PUC-Campinas), 2023. Citado na página 19.
- ROSA, A. A. D. Reconhecimento por imagem de lances de xadrez com visão computacional e redes neurais convolucionais. 2025. Citado na página 19.
- SAMMATARO, D.; GERSON, U.; NEEDHAM, G. Parasitic mites of honey bees: Life history, implications, and impact. *Annual Review of Entomology*, v. 45, n. 1, p. 519–548, jan. 2000. ISSN 0066-4170, 1545-4487. Disponível em: <<https://www.annualreviews.org/doi/10.1146/annurev.ento.45.1.519>>. Citado na página 14.

- SANTOS, A. et al. Uma abordagem de classificação de imagens dermatoscópicas utilizando aprendizado profundo com redes neurais convolucionais. In: *Anais do Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS)*. Sociedade Brasileira de Computação - SBC, 2017. Disponível em: <<https://sol.sbc.org.br/index.php/sbcas/article/view/3717>>. Citado na página 17.
- SANTOS, G. L. d. Análise e extração de características de imagens termográficas utilizando componentes principais. Universidade Estadual Paulista (Unesp), 2010. Citado na página 18.
- SILVA, R. E. V. d. Um estudo comparativo entre redes neurais convolucionais para a classificação de imagens. 2018. Citado na página 20.
- SIMONE, A. D. et al. Advancing beekeeping: Iot and tinyml for queen bee monitoring using audio signals. *IEEE Transactions on Instrumentation and Measurement*, IEEE, 2024. Citado na página 16.
- SIQUEIRA, M. L. d. Reconhecimento automático de padrões em imagens ecocardiográficas. 2010. Citado na página 19.
- SOUTO, M. D. et al. Técnicas de aprendizado de máquina para problemas de biologia molecular. *Sociedade Brasileira de Computação*, v. 1, n. 2, 2003. Citado na página 16.
- SOUZA, A. F. d. Geração de base de dados para classificadores visuais utilizando dados disponíveis da internet. Serra, 2024. Citado na página 20.
- SOUZA, T.; CORREIA, S. Estudo de técnicas de realce de imagens digitais e suas aplicações. In: *II Congresso de Pesquisa e Inovação da Rede Norte Nordeste de Educação Tecnológica*. [S.l.: s.n.], 2007. v. 2, p. 3–10. Citado na página 19.
- TORKY, M.; NASR, A. A.; HASSANIEN, A. E. Recognizing beehives' health abnormalities based on mobile net deep learning model. *International Journal of Computational Intelligence Systems*, Springer, v. 16, n. 1, p. 135, 2023. Citado 4 vezes nas páginas 18, 29, 31 e 34.
- TURYAGYENDA, A. et al. Iot and machine learning techniques for precision beekeeping: A review. *AI*, MDPI, v. 6, n. 2, p. 26, 2025. Citado 3 vezes nas páginas 10, 21 e 22.
- VOUDIOTIS, G.; MORAITI, A.; KONTOGIANNIS, S. Deep learning beehive monitoring system for early detection of the varroa mite. *Signals*, MDPI, v. 3, n. 3, p. 506–523, 2022. Citado 3 vezes nas páginas 28, 32 e 35.
- ZAMAN, A.; DORIN, A. A framework for better sensor-based beehive health monitoring. *Computers and Electronics in Agriculture*, Elsevier, v. 210, p. 107906, 2023. Citado na página 14.
- ZHENG, Y. et al. Intelligent beehive monitoring system based on internet of things and colony state analysis. *Smart Agricultural Technology*, Elsevier, v. 9, p. 100584, 2024. Citado na página 14.



TERMO DE AUTORIZAÇÃO PARA PUBLICAÇÃO DIGITAL NA BIBLIOTECA “JOSÉ ALBANO DE MACEDO”

Identificação do Tipo de Documento

- () Tese
- () Dissertação
- (X) Monografia
- () Artigo

Eu, Milene de Sousa Fialho, autorizo com base na Lei Federal nº 9.610 de 19 de Fevereiro de 1998 e na Lei nº 10.973 de 02 de dezembro de 2004, a biblioteca da Universidade Federal do Piauí a divulgar, gratuitamente, sem ressarcimento de direitos autorais, o texto integral da publicação “Monitoramento de Colmeias em Imagens Utilizando Aprendizado Profundo: Uma Revisão Sistemática” de minha autoria, em formato PDF, para fins de leitura e/ou impressão, pela internet a título de divulgação da produção científica gerada pela Universidade.

Picos-PI, 07 de Junho de 2025.

Documento assinado digitalmente
gov.br MILENE DE SOUSA FIALHO
Data: 07/07/2025 09:46:11-0300
Verifique em <https://validar.iti.gov.br>

Assinatura