

Millena Lira de Andrade Sousa
Orientadora: Alcilene Dalília de Sousa

Identificação do ácaro Varroa em abelhas através do processamento e classificação de imagens

Picos - PI
26 de junho de 2025

Millena Lira de Andrade Sousa
Orientadora: Alcilene Dalília de Sousa

Identificação do ácaro *Varroa* em abelhas através do processamento e classificação de imagens

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

S725i Sousa, Millena Lira de Andrade.

Identificação do ácaro varroa em abelhas através do processamento e classificação de imagens / Millena Lira de Andrade Sousa – 2025.
42 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. Recuperação da informação – monitoramento. I. Sousa, Millena Lira de Andrade. II. Sousa, Alcilene Dalília de. III. Título.

CDD 005.7

Elaborada por Maria Letícia Cristina Alcântara Gomes
Bibliotecária CRB nº 03/1835

Identificação do ácaro Varroa em abelhas através do processamento e classificação de imagens

Millena Lira de Andrade Sousa

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 21:15:49-0300
Verifique em <https://validar.iti.gov.br>

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

Documento assinado digitalmente
 **FLAVIO HENRIQUE DUARTE DE ARAUJO**
Data: 01/07/2025 16:02:15-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Flávio Henrique Duarte de Araújo

Documento assinado digitalmente
 **JOSE DENES LIMA ARAUJO**
Data: 01/07/2025 15:18:45-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. José Denes Lima Araújo

Agradecimentos

Agradeço primeiramente a Deus, pela força e sabedoria concedidas ao longo dessa jornada, por sempre ser meu guia nos momentos mais difíceis.

Agradeço profundamente aos meus pais, Adenilton Andrade e Rosemar Lira, que são meu exemplo de força, dedicação e generosidade. Obrigada por cada palavra de incentivo, por cada gesto de cuidado, por acreditarem em mim mesmo quando eu duvidava. Vocês são a base de tudo o que sou, e este momento também é de vocês. Ao meu irmão, Afonso Lira, meu companheiro, obrigada por ser meu alívio em meio ao caos, por sua presença tranquila e apoio sincero que sempre me deram forças para continuar. Ao meu esposo, Victor Emanuel, meu amor e parceiro de todos os dias. Obrigada por estar ao meu lado em cada momento, por me encorajar, sua presença foi fundamental nessa caminhada.

Agradeço também pelas pessoas incríveis que passaram pelo meu caminho durante a graduação, meu quarteto, Milene, Bianca, Matheus e Vinícius. Foram eles que dividiram comigo os longos anos de vários desafios. Sou imensamente grata por ter compartilhado essa etapa da vida com vocês, guardo todas as memórias que construímos juntos. À Iane e Kaylane, minhas companheiras de apartamento, minhas irmãs. Dividir o lar com vocês foi uma das melhores coisas que me aconteceu. Obrigada por cada conversa no final do dia, por cada risada, por cada bagunça, por cada momento, levo comigo cada memória.

Agradeço a minhas amigas do coração, Luclécia e Isabela que estão sempre comigo independente de qualquer circunstância. A presença de vocês é um presente que a vida me deu, e sou imensamente grata por isso.

Em especial, agradeço à minha duplinha - Milenrs. Que sorte a minha ter dividido esse caminho com você. Foram tantos momentos compartilhados — de nervosismo principalmente — que seria impossível imaginar essa etapa sem a sua presença. Obrigada por ser parceria e coragem quando eu mais precisei. Te levo no coração.

À minha orientadora, Alcilene Dalília minha sincera gratidão por toda orientação, dedicação e apoio durante a construção deste trabalho. Muito obrigada por caminhar comigo nessa jornada.

Agradeço a todos que, de forma direta ou indireta, contribuíram para minha jornada acadêmica. À vocês o meu muito obrigada!

Jimi Hendrix

O conhecimento fala, mas a sabedoria escuta.

Resumo

O ácaro *Varroa destructor* diminui significativamente a força da colônia, aumenta a mortalidade de abelhas adultas e reduz a produção de mel. Seu controle é desafiador porque o ácaro tem resistido aos pesticidas comumente usados, e os métodos manuais apresentam eficácia limitada e variável. Assim, foi proposto uma metodologia de ponta a ponta para a identificação do ácaro *Varroa destructor* em imagens de colmeias, visando apoiar os apicultores no manejo eficiente dos apiários. Este estudo utiliza a base de dados *VarroaDataset* para investigar a extração de características rasas a partir de arquiteturas neurais leves para descrever a presença do *Varroa destructor*. Para isso, foi aplicado uma etapa de pré-processamento que inclui normalização dos pixels e aumento dos dados. Após a extração das características rasas e profundas das arquiteturas YOLOv5n e DenseNet201, os algoritmos de aprendizado de máquina foram utilizados para classificar e avaliar esses modelos à luz de diferentes métricas de desempenho. Os resultados indicam que as características rasas extraídas da arquitetura YOLOv5, combinadas com o classificador Random Forest, alcançaram o melhor desempenho em todos os cenários testados, atingindo resultados superiores a 98% nas métricas acurácia, precisão, *recall* e F1-score.

Palavras-chaves: visão computacional, *varroa destructor*, abelhas, aprendizado profundo, monitoramento de colmeias.

Abstract

The *Varroa destructor* mite significantly weakens bee colonies, increases adult bee mortality, and reduces honey production. Its control remains challenging due to growing resistance to commonly used pesticides and the limited effectiveness of manual methods. To address this, an end-to-end methodology is proposed for the identification of *Varroa destructor* in hive images, aiming to support beekeepers in efficient apiary management. This study employs the *VarroaDataset* to investigate shallow feature extraction using lightweight neural architectures for mite detection. A preprocessing stage including pixel normalization and data augmentation was applied. Shallow and deep features were extracted from YOLOv5n and DenseNet201 architectures and then classified using machine learning algorithms. The results show that shallow features extracted from the YOLOv5n architecture combined with the Random Forest classifier achieved the best performance across all evaluated scenarios, reaching over 98% in accuracy, precision, recall, and F1-score.

Lista de ilustrações

Figura 1 – Amostras do VarroaDataset: A imagem da esquerda representa uma abelha saudável e a imagem da direita representa uma abelha infectada.	16
Figura 2 – Representação de uma arquitetura CNN (DESAI, 2024).	19
Figura 3 – Etapas do método proposto. A 1ª etapa consiste na aquisição das imagens, na 2ª etapa ocorre o pré-processamento, na 3ª etapa as características são extraídas, a 4ª etapa compreende o uso de algoritmos de classificação distintos e a 5ª etapa corresponde à validação.	26
Figura 4 – Amostras do dataset: (a-c) abelhas saudáveis que apresentam abdômen liso e uniforme, sem a presença de ácaros, (d-f) abelhas infectadas por ácaros <i>Varroa destructor</i> , caracterizados por sua forma achatada de cor marrom avermelhada, situados no abdômen das abelhas.	27
Figura 5 – Aplicação de técnicas de augmentation no conjunto de treino: A imagem original (a) é seguida por quatro imagens aumentadas, cada uma com um tipo diferente de transformação aplicada. Nas imagens (b) e (c) foram aplicadas o espelhamento horizontal e vertical, que inverte a imagem na horizontal e vertical respectivamente. A imagem (d) é uma rotação de 180 graus, que gira a imagem 180 graus no sentido horário, e por fim, a imagem (e) é um exemplo do aumento de contraste em 30%.	27

Lista de tabelas

Tabela 1 – Distribuição do dataset com a divisão 80/20 (80% para o treinamento e 20% para o teste) sem o balanceamento das classes.	25
Tabela 2 – Propriedades dos descritores	29
Tabela 3 – Parâmetros definidos pelo Grid Search (em negrito estão os melhores resultados)	30
Tabela 4 – Resultados da detecção do ácaro <i>Varroa destructor</i> com e sem aumento de dados, considerando as deep features extraídas por arquiteturas neurais leves (em negrito estão os melhores resultados).	31
Tabela 5 – Resultados da detecção do ácaro <i>Varroa destructor</i> com e sem aumento de dados, considerando as deep features extraídas por arquiteturas neurais densas (em negrito estão os melhores resultados).	32
Tabela 6 – Resultados da detecção do ácaro <i>Varroa destructor</i> com e sem aumento de dados, considerando as shallow features extraídas por arquiteturas neurais leves (em negrito estão os melhores resultados).	32
Tabela 7 – Resultados da identificação do ácaro <i>Varroa destructor</i> com e sem aumento de dados, considerando características rasas extraídas por arquiteturas neurais densas (em negrito estão os melhores resultados).	33
Tabela 8 – Comparação dos resultados obtidos por trabalhos do estado da arte com o descritor proposto (em negrito) para a identificação do ácaro <i>Varroa destructor</i>	35

Lista de abreviaturas e siglas

ML	Machine Learning
DL	Deep Learning
AI	Artificial Intelligence
RNA	Artificial Neural Network
CNN	Convolutional Neural Network
SVM	Support Vector Machine
SSD	Single Shot Multibox Detector
YOLO	You Only Look Once
MFCC	Coefficientes Cepstrais em Frequência Mel
MLFM	Multichannel Legendre–Fourier Moments
RGB	Red, Green, Blue
HSV	Hue, Saturation, Value
YCbCr	Y: Luminance, Cb: Chrominance-Blue, Cr: Chrominance-Red
GLCM	Gray-Level Co-Occurrence Matrix
KF-PLS	Kernel Flows–Partial Least Squares
RF	Random Forest
LGBM	LightGBM
MLP	Multi-layer Perceptro
VGG	Visual Geometry Group

Sumário

1	Introdução	12
1.1	Objetivos	13
1.1.1	Objetivos Específicos	13
1.2	Organização do Trabalho	13
2	Referencial Teórico	14
2.1	Apicultura	14
2.1.1	Abelhas	14
2.2	Ácaro	15
2.3	Imagens Digitais	16
2.3.1	Pré-processamento	16
2.4	Classificação	17
2.4.1	Aprendizado de Máquina	17
2.4.2	Aprendizado Profundo	17
2.4.3	Redes Neurais Convolucionais	18
2.5	Medidas de Avaliação	19
2.5.1	Acurácia	19
2.5.2	Precisão	20
2.5.3	Recall	20
2.5.4	F1-score	20
3	Trabalhos Relacionados	21
4	Metodologia	25
4.1	Aquisição das Imagens	25
4.2	Pré-processamento	25
4.3	Extração de características	28
4.4	Classificação	29
4.5	Validação	29
5	Resultados	31
5.1	Comparação com a literatura	33
6	Conclusão	36
	Referências	37

1 Introdução

As abelhas melíferas *Apis Mellifera* é uma espécie nativa da África, Europa e Ásia Ocidental; seu manejo contribuiu para a presença desta espécie em todos os continentes, exceto na Antártida e em algumas ilhas oceânicas. São vitais como polinizadores, visitando mais de 90% das principais culturas do mundo (NORIEGA-ESCAMILLA et al., 2023). As populações de abelhas melíferas têm enfrentado desafios significativos, incluindo doenças, parasitas, pesticidas e perda de habitat, que têm levado a preocupações crescentes sobre seu declínio populacional e suas consequências para a segurança alimentar e a sustentabilidade ambiental.

No entanto, elas enfrentam várias ameaças, como pragas, doenças, e mudanças nas paisagens. Entre as pragas, destacamos um ácaro ectoparasita chamado *Varroa destructor*, responsável pela perda de 43% das colmeias nos Estados Unidos entre abril de 2019 e abril de 2020 (INSOLIA et al., 2022) e de 24.5% das colmeias na Espanha no inverno entre 2018 e 2019 (GRAY et al., 2020). Esse ácaro se liga ao corpo da abelha e a enfraquece sugando o tecido adiposo do corpo, ele se aloja no tórax e no abdômen com o intuito de se alimentar de hemolinfa (GREGORC; SAMPSON, 2019). O *Varroa* também transmite vários vírus, como o vírus da paralisia aguda das abelhas e o vírus da asa deformada, que podem causar graves problemas de saúde nas colmeias (BERKAYA; GUNAL; GUNAL, 2021). Além disso, o parasitismo causado por esse ácaro pode prejudicar o crescimento e desenvolvimento normal das crias, levando à abelhas malformadas, com pesos e tamanhos reduzidos (KOLEOGLU et al., 2017).

A infestação do ácaro *Varroa destructor* pode levar a uma diminuição drástica na força da colônia, mortalidade de abelhas adultas e redução na produção de mel. Se a infestação não for controlada, há o risco de ocorrer a morte da colmeia (HRISTOV et al., 2020). O controle dos ácaros *Varroa destructor* é um desafio, devido à resistência a pesticidas frequentemente utilizados. Além disso, a eficácia de outros métodos manuais, como a remoção manual dos ácaros, é limitada e variável. Por exemplo, embora a técnica de escovação dos ácaros *Varroa destructor* possa reduzir temporariamente a infestação, ela requer uma atenção meticulosa e pode não ser totalmente eficaz, especialmente em colmeias com uma alta taxa de infestação. Outra abordagem manual é o uso de armadilhas de fundo, que capturam ácaros que caem naturalmente da colmeia, mas sua eficácia pode ser influenciada pela localização da colmeia e pelas condições ambientais (WARNER et al., 2023).

Devido aos problemas mencionados, o monitoramento da colmeia é essencial para os apicultores tomarem as contramedidas apropriadas. Na apicultura tradicional, existem vários métodos de monitoramento da colmeia, a maioria sendo métodos manuais, como por exemplo, o teste de rolo com açúcar em pó ou farinha de soja torrada utilizados para

detectar as infestações pelo *Varroa destructor* (OGIHARA et al., 2020). No entanto, esses métodos são demorados e interrompem o ciclo de vida da colmeia, o que podem ser uma fonte de estresse para as abelhas (OSKAY et al., 2023).

Diante disso, torna-se essencial explorar novas abordagens para a identificação da presença do *Varroa destructor* visando uma maior precisão. O uso de técnicas de processamento, visão computacional e aprendizado de máquina, em substituição aos métodos tradicionais, possibilita um monitoramento automático e não-intrusivo (DEBAUCHE et al., 2018) que auxiliará os apicultores responsáveis pelas colmeias a detectar de maneira eficiente as infestações, permitindo uma identificação precoce e a implementação de estratégias para reduzir os impactos na criação e no bem-estar das abelhas.

1.1 Objetivos

O objetivo geral deste trabalho é desenvolver um método de processamento e classificação de imagens para a identificação automática do ácaro *Varroa destructor* em abelhas, visando auxiliar no monitoramento e controle de infestações em colmeias.

1.1.1 Objetivos Específicos

- Utilização de uma base pública de imagens de abelhas saudáveis e infectadas pelo ácaro *Varroa destructor*.
- Aplicação de técnicas de aprendizado profundo para a identificação do ácaro *Varroa destructor*.
- Avaliação dos diferentes algoritmos de aprendizado de máquina e redes neurais na classificação, destacando o que obteve o melhor desempenho.

1.2 Organização do Trabalho

Este trabalho está organizado em seis seções. Na Seção 2 é apresentado o referencial teórico abordando os principais conceitos relacionados aos métodos de identificação do ácaro. A Seção 3 aborda trabalhos relevantes sobre a aplicação da visão computacional no monitoramento do comportamento das abelhas. A Seção 4 descreve a metodologia adotada para detectar a presença do ácaro *Varroa destructor*. Na Seção 5 são apresentados os resultados dos experimentos. E por fim, no capítulo 6 são apresentadas as conclusões e perspectivas para trabalhos futuros.

2 Referencial Teórico

Esta Seção apresenta o referencial teórico que fundamenta os temas tratados neste estudo, oferecendo recursos para a compreensão e desenvolvimento desta pesquisa.

2.1 Apicultura

A apicultura (BERNARDO et al., 2023) pode ser definida como a criação racional de abelhas exóticas *Apis Mellifera*, tendo como objetivo, por exemplo, fins comerciais e de lazer. Além disso, há a produção de mel, própolis, geleia real, pólen, cera de abelha e apitoxina. Essa atividade tem se mostrado como uma excelente alternativa para a diversificação agrícola, representando uma significativa fonte de renda para os agricultores familiares e sendo considerada uma tarefa de baixo impacto ambiental, que contribui diretamente para a preservação do ecossistema (COLLICCHIO; ROCHA, 2022).

Os principais produtos apícolas encontrados são o mel, a própolis, a cera, a geleia real, o pólen e a apitoxina. Esses produtos apresentam diversas propriedades nutricionais, antimicrobianas e terapêuticas, sendo, assim, amplamente comercializados. Ao final de seus respectivos processamentos, os produtos apícolas devem apresentar máxima qualidade exigida pela legislação, sem alterações que danifiquem a composição ou que prejudiquem a saúde do consumidor (FEITOSA et al., 2020).

2.1.1 Abelhas

As abelhas possuem grande importância no serviço da polinização cruzada, que representa uma relevante adaptação evolutiva das plantas. Esse processo contribui para o aumento do vigor das espécies, possibilita novas combinações de fatores hereditários e promove o aumento da produção de frutos e sementes (BACAXIXI et al., 2011). A maior eficiência das abelhas como polinizadoras deve-se tanto à sua abundância na natureza quanto à sua excelente adaptação às complexas estruturas florais. No Brasil, existem mais de 300 espécies de abelhas sem ferrão, distribuídas por todo o território nacional, além de grande parte de toda a faixa tropical e subtropical do planeta. Encontramos esses grupos de abelhas sem ferrões nas Américas, desde o norte do México até a região central da Argentina.

As abelhas são animais pertencentes ao Reino *Animalia*, *Filo Arthropoda*, Classe *Insecta*, Ordem *Hymenoptera* e Superfamília *Apoidea*, que se divide em três famílias principais: *Apidae*, *Anthophoridae* e *Megachilidae*. As abelhas produtoras de mel são pertencentes à família *Apidae* (BACAXIXI et al., 2011), como as abelhas *Apis Mellifera* que

popularizaram-se no Brasil e hoje é a principal espécie utilizada na apicultura (BERNARDO et al., 2023).

2.2 Ácaro

O ácaro ectoparasita *Varroa destructor* é considerado uma grande preocupação na apicultura mundial. Embora seja um parasita comum à abelha *Apis Cerana*, problemas relacionados à sua virulência só começaram a se manifestar quando ele entrou em contato com o novo hospedeiro, *Apis Mellifera*. Este ácaro foi introduzido no Brasil em 1972 por meio da importação de rainhas e crias infestadas vindas do Paraguai. O ácaro *Varroa destructor* realiza parte do seu ciclo de vida nas células de crias de operárias, zangões e rainhas. A fêmea desse ácaro entra na célula de cria antes da mesma ser selada com cera, vai até o fundo da célula posicionando-se de forma que possa se alimentar da hemolinfa da cria. O período de desenvolvimento antes e depois da célula selada é diferente em operárias, zangões e rainhas (WIELEWSKI et al., 2013).

O ácaro *Varroa destructor* aloja-se geralmente no tórax e abdômen de zangões e operárias para se alimentar conforme mostra a Figura 1. Pode causar sérios danos à saúde das abelhas, principalmente pelo comprometimento da absorção e armazenamento corporal de proteínas, conseqüentemente afetando ação do sistema imunológico e longevidade, bem como no crescimento e desenvolvimento normal das crias, o que gera indivíduos adultos mal formados e de peso e tamanho reduzidos (AMDAM et al., 2004), além da possibilidade de haver a transmissão de forma vertical e horizontal de vírus (SUMPTER; MARTIN, 2004). Altas infestações do ácaro *Varroa destructor* podem levar ao aumento das taxas de mortalidade, à redução das áreas de criação, à diminuição da produção de mel e, por fim, ao colapso das colônias em poucos anos, se não forem controladas (MAVRIDIS et al., 2025).

Para minimizar os efeitos da infestação do ácaro, vários acaricidas sintéticos foram desenvolvidos, como os organofosforados e piretroides. Entretanto, nos últimos anos, o uso contínuo desses produtos tem acarretado altos níveis de resistência às populações de ácaros (LODESANI, 2004), além da possibilidade de esses produtos contaminarem o mel e a cera no interior da colônia (BOGDANOV, 2006). Tal situação tem incentivado estratégias para minimizar a resistência e o acúmulo desses resíduos químicos na cera e no mel. Assim, é crescente o interesse de pesquisadores e apicultores por alternativas de combate às doenças e pragas, entre as quais está o controle do ácaro *Varroa destructor* (CASTAGNINO; ORSI, 2012).



Figura 1 – Amostras do VarroaDataset: A imagem da esquerda representa uma abelha saudável e a imagem da direita representa uma abelha infectada.

2.3 Imagens Digitais

O processamento de imagens digitais é uma área da ciência da computação e da engenharia elétrica que estuda a manipulação de imagens por meio de técnicas computacionais. Seu principal objetivo é melhorar a qualidade visual da imagem, extrair informações relevantes ou prepará-la para análises posteriores, como reconhecimento de padrões, detecção de objetos ou classificação automatizada (GONZALEZ; WOODS, 2000). É constituído por várias etapas, onde cada uma delas se concentra em realizar alguma tarefa visando a próxima etapa ou o resultado final. Existem etapas onde estamos preocupados em aproximar a imagem digital da imagem original, ou melhorar alguns atributos para que melhor apresentem as características interessantes. Outras etapas preocupam-se em extrair as informações contidas nas imagens (LINS et al., 2018).

2.3.1 Pré-processamento

O pré-processamento de imagens consiste na aplicação de técnicas para realce de imagens, que visam destacar uma região dentro da imagem, permitindo a sua visualização com mais detalhes, de modo que a imagem resultante seja mais apropriada para uma aplicação específica do que a imagem original (SOUZA; CORREIA, 2007). A filtragem de uma imagem é utilizada para corrigir e realçar detalhes. Enquanto a correção é a remoção das características indesejáveis, o realce é a acentuação das características desejáveis. A equalização do histograma procura redistribuir as intensidades do histograma original, de modo a obter um histograma uniforme, com praticamente todas as intensidades com o mesmo percentual. Segmentação pode ser definida como a simplificação da imagem, reduzindo-a em seus componentes básicos, ou objetos, sem descartar suas características relevantes. Apesar da detecção de pixels e linhas serem certamente os elementos de qualquer discussão de segmentação, detecção de borda é certamente a abordagem mais comum para detecção significativa em níveis de cinza descontínuos. A detecção de bordas é implementada por filtros espaciais (SANTOS, 2009).

2.4 Classificação

A classificação trata-se do problema de atribuir uma categoria a cada item. A classificação de imagens consiste em atribuir a cada imagem uma categoria como carro, navio, avião, por exemplo. O número de categorias em tais tarefas costuma ser menor do que algumas centenas, mas pode ser muito maior em algumas tarefas difíceis (ASSUNÇÃO, 2022).

2.4.1 Aprendizado de Máquina

Aprendizado de Máquina é uma área de pesquisa da Inteligência Artificial que visa o desenvolvimento de softwares com a capacidade de aprender a executar uma dada tarefa com sua própria experiência (FACELI et al., 2021). Isso leva ao desenho de programas capazes de aprender por si sós, utilizando-se um conjunto de dados que representam experiências passadas. Trata-se de uma área de pesquisa multidisciplinar que engloba inteligência artificial, probabilidade e estatística, teoria da complexidade computacional e teoria da informação (CERRI; FERREIRA et al., 2019).

O Aprendizado de máquina (do inglês, *Machine Learning* - ML) é um termo geral utilizado para definir uma série de algoritmos que extraem informação a partir de um conjunto de dados, sem ser necessário definir um modelo matemático específico. A partir de um conjunto de dados de treinamento, estes algoritmos buscam um padrão relacionando entradas e saídas, permitindo utilizar este padrão para realizar previsões. Dependendo da forma como estes dados são fornecidos, os algoritmos são classificados em diferentes categorias (FONTANA, 2020). Existem três tipos principais de Aprendizado de Máquina: 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). O objetivo do algoritmo é construir um classificador que possa determinar corretamente a classe de novos exemplos ainda não rotulados. No Aprendizado Não Supervisionado, os exemplos são fornecidos ao algoritmo sem rótulos. O algoritmo agrupa-os pelas similaridades dos seus atributos, analisa os exemplos fornecidos e tenta determinar se alguns deles podem ser agrupados de alguma maneira. E no Aprendizado por Reforço, o algoritmo não recebe a resposta correta, mas recebe um sinal de reforço, de recompensa. O algoritmo faz uma hipótese baseada nos exemplos e determina se essa hipótese foi boa ou ruim (LUDERMIR, 2021).

2.4.2 Aprendizado Profundo

O aprendizado profundo se tornou uma poderosa ferramenta para reconhecer padrão em dados de alta-dimensão, sendo muito aplicável em muitos domínios da ciência, empresas e governos (MARQUES, 2016). A aprendizagem profunda (do inglês, *Deep Learning*

- DL), permite que modelos computacionais compostos de várias camadas de processamento possam aprender apresentações de dados com múltiplos níveis de abstração. Sendo assim, o aprendizado profundo é representado por funções de grande complexidade, onde adicionando mais camadas e unidades entre aquelas chega-se ao resultado o qual as redes profundas se tornam muito eficientes em tarefas que consistem em mapear o vetor de entradas em vetor de saídas (LECUN; BENGIO; HINTON, 2015).

Métodos que utilizam aprendizado profundo buscam descobrir um modelo (regras, parâmetros, padrões) utilizando um conjunto de dados e um método para guiar o aprendizado do modelo a partir desses exemplos, isto é, encontrar padrões complexos em diferentes tipos de entradas (imagens, textos, áudios), e relacionar a saída desses exemplos com padrões presentes no conjunto de entrada. Ao final do processo de aprendizado tem-se uma função capaz de receber por entrada os dados brutos e fornecer como saída uma representação adequada para o problema em questão (PIRES, 2017).

Deep Learning é a aplicação de uma quantidade massiva de camadas de processamento em um algoritmo de rede neural. Com o aumento da quantidade de dados e do poder computacional, o DL se torna bastante viável para diversas áreas, tornando a AI aplicável no mundo real. Atualmente, as técnicas de DL são ferramentas importantes para a análise de dados não categorizados, fazendo uso das redes neurais em processamento de imagens, reconhecimento de voz, mineração de dados, classificação de doenças, entre outras (PACHECO, 2018).

2.4.3 Redes Neurais Convolucionais

As Redes Neurais Artificiais (do inglês, *Artificial Neural Networks* - RNAs) são modelos de aprendizagem de máquina baseados na atividade das redes de neurônios biológicos, assim como as do cérebro humano. Existe um estímulo em pesquisar a forma de como o cérebro processa as informações por este ser complexo, não-linear e paralelo (HAYKIN, 2001). Rede Neural Computacional é uma técnica que mostrou grande potencial no campo de *Machine Learning*. A técnica é feita aplicando uma série de camadas que atuam de maneira análoga a um neurônio, executando o processamento de uma pequena parte da informação total (PACHECO, 2018).

Uma rede neural convolucional (do inglês, *Convolutional Neural Network* - CNN) é uma classe de rede neural artificial. As CNNs são usadas para classificar imagens, realizar reconhecimento de objetos ou até mesmo o reconhecimento de áudios (SILVA, 2018). Na camada convolucional, os neurônios funcionam como filtros que são aplicados aos dados de entrada. Um filtro é uma matriz de pesos. O objetivo principal da convolução em uma CNN é extrair *features* da imagem de entrada (RASCHKA SEBASTIAN E MIRJALILI, 2019).

Em termos de topologia, para implementarmos uma rede neural devemos determinar as seguintes variáveis: (a) o número de nós na camada de entrada, (b) o número de

camadas escondidas e o número de neurônios a serem colocados nessas camadas, (c) o número de neurônios na camada de saída. Estes parâmetros afetam o desempenho da RNA, devendo ser cuidadosamente escolhidos. Ao implementarmos uma rede neural, normalmente o conjunto de dados é separado em dois conjuntos: conjunto de treinamento e conjunto de teste. O conjunto de treinamento é utilizado para o treinamento da rede e ajuste dos parâmetros e o conjunto de teste é utilizado para verificar a capacidade de generalização da rede sob condições reais de utilização (SANTOS et al., 2005).

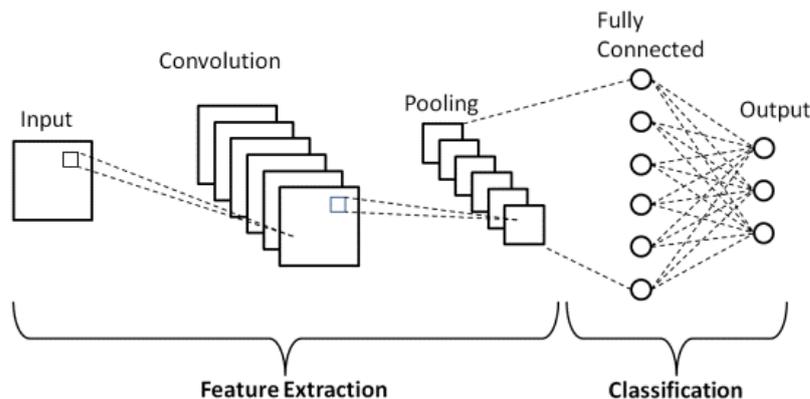


Figura 2 – Representação de uma arquitetura CNN (DESAI, 2024).

2.5 Medidas de Avaliação

As métricas de avaliação são elementos cruciais na verificação e no aprimoramento de modelos de classificação. Elas são indispensáveis para compreender como o modelo está se comportando em relação à tarefa proposta. Por meio dessas métricas, é possível obter uma análise quantitativa e objetiva sobre a precisão e a eficiência do modelo ao separar corretamente os dados em suas respectivas categorias.

2.5.1 Acurácia

A acurácia (BARATLOO et al., 2015) fornece uma medida geral de precisão do modelo. Calculada como a proporção de previsões corretas em relação ao total de previsões (Equação 2.1) e quanto mais o valor se aproxima a 1, melhor é o seu o resultado. Essa métrica é amplamente utilizada para avaliar o desempenho global de um modelo de classificação.

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.1)$$

Onde:

- TP representa os verdadeiros positivos (*True Positives*).

- TN representa os verdadeiros negativos (*True Negatives*).
- FP representa os falsos positivos (*False Positives*).
- FN representa os falsos negativos (*False Negatives*).

2.5.2 Precisão

A precisão é uma métrica fundamental em contextos onde o custo de falsos positivos é elevado (Equação 2.2). Ela quantifica a proporção de verdadeiros positivos e verdadeiros negativos em todos os casos avaliados (BARATLOO et al., 2015).

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2.2)$$

Onde:

- TP representa os verdadeiros positivos (*True Positives*).
- FP representa os falsos positivos (*False Positives*).

2.5.3 Recall

O recall (STRAUSS; JÚNIOR; FERREIRA, 2022) é uma métrica que indica a capacidade do modelo em identificar corretamente as instâncias positivas. Ela mede a proporção de casos positivos que foram corretamente reconhecidos pelo modelo, entre todos os casos que realmente pertencem à classe positiva, como mostra na (Equação 2.3).

$$\text{Recall} = \frac{TP}{TP + FN} \quad (2.3)$$

Onde:

- TP representa os verdadeiros positivos (*True Positives*).
- FN representa os falsos negativos (*False Negatives*).

2.5.4 F1-score

Essa métrica representa a média harmônica entre as métricas de Precisão e de Recall (Equação 2.4). Média harmônica é um tipo de média utilizada quando precisa-se representar valores que se comportam de maneira inversamente proporcional, como no caso do Precisão e Recall, em um único número (STRAUSS; JÚNIOR; FERREIRA, 2022).

$$\text{F1-score} = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (2.4)$$

3 Trabalhos Relacionados

Nesta Seção, são apresentados os trabalhos que se relacionam com a presente pesquisa. A Tabela 3 apresenta um resumo comparativo dos trabalhos relacionados, levando em consideração quatro aspectos principais: a utilização de base pública, o tipo de descritor, o modelo de classificação empregado, e as métricas utilizadas.

No trabalho de [Berkaya, Gunal e Gunal \(2021\)](#), os pesquisadores propuseram diferentes modelos de classificação de imagens baseados em aprendizado profundo para o monitoramento de colmeias. Esses modelos são capazes de reconhecer diversas condições, incluindo abelhas saudáveis, abelhas carregando pólen e abelhas com anomalias. Foram utilizados três conjuntos de dados públicos de imagens, incluindo o VarroaDataset [Schurischuster e Kampel \(2020\)](#), totalizando 19.393 imagens de abelhas coletadas em diferentes condições. Sete Redes Neurais Convolucionais (CNNs) pré-treinadas testaram quatro cenários: (i) aprendizado por transferência (transfer learning); (ii) extração de características profundas com o classificador Support Vector Machine (SVM); (iii) extração de características rasas com SVM; e (iv) classificação com SVM utilizando um descritor formado pela combinação de características rasas e profundas. Na etapa de pré-processamento, apenas o redimensionamento das imagens foi realizado, sem aplicação de outras técnicas, como aumento de dados (data augmentation) ou normalização. A análise conjunta dos três conjuntos de dados nos cenários propostos não identificou uma rede neural específica com melhor desempenho. Nos experimentos com o VarroaDataset, a abordagem com aprendizado por transferência se destacou, com a arquitetura VGG19 obtendo uma média de 0,95 nas quatro métricas de avaliação. Nos cenários em que as redes são utilizadas como descritores — assim como neste trabalho —, foram obtidas médias de 0,78 com a ResNet101 e 0,87 com a AlexNet, considerando características rasas e profundas, respectivamente.

Em seu estudo, [Schurischuster e Kampel \(2020\)](#) realizou uma análise comportamental de abelhas, classificando-as como "saudáveis" ou "infectadas" pela presença do ácaro Varroa destructor. Uma câmera foi posicionada na entrada da colmeia para capturar imagens e criar um conjunto de dados, o VarroaDataset, totalizando 13.509 amostras rotuladas, fornecendo uma base robusta para os experimentos. Esse conjunto de dados foi utilizado para comparar dois métodos de classificação com aprendizado por transferência, utilizando as redes pré-treinadas AlexNet e ResNet-101, além de uma abordagem de segmentação com a arquitetura DeepLabV3, também pré-treinada. Cada modelo foi avaliado quanto à sua eficácia na identificação da presença do ácaro Varroa destructor nas abelhas. Após a captura, separação e rotulagem das amostras, não foi aplicado nenhum pré-processamento adicional às imagens, que foram mantidas em seu tamanho original de 280×160 pixels para os experimentos subsequentes. A DeepLabV3 obteve o melhor resultado, com um F1-score de 0,95, identificando com precisão os pixels pertencentes aos ácaros, o que se mostrou

crucial para a tarefa de detecção. A escolha de não aplicar um pré-processamento adicional pode ter influenciado os resultados, sugerindo que um tratamento mais sofisticado das imagens poderia melhorar o desempenho dos modelos de classificação e segmentação.

No trabalho de [Mahajan et al. \(2023\)](#), foi proposto um sistema composto por dois métodos para o monitoramento da saúde de colmeias utilizando imagem e áudio. O primeiro método é baseado em imagens, no qual foram comparadas três versões da arquitetura You Only Look Once (YOLO) (v5, v7 e v8) com o Single Shot Multibox Detector (SSD) para detectar o ácaro *Varroa destructor*. Notavelmente, as versões das redes não foram pré-treinadas, o que resultou em um custo computacional mais elevado para o treinamento dos modelos. Para isso, foi utilizado o VarroDataset, com as amostras redimensionadas para 640×640 e técnicas simples de aumento de dados aplicadas como pré-processamento para balancear as classes. Nos resultados, o YOLOv5 obteve o melhor desempenho, atingindo 0,96 tanto para as métricas de precisão quanto de revocação, 0,97 para a Métrica de Precisão Média (mAP)[0.5], e 0,40 para mAP[0.5:0.95]. A segunda abordagem é baseada em áudio para prever a saúde das colmeias. Para isso, foram coletadas 8.142 amostras de áudio com duração de 1 segundo, utilizando um microfone em seis colmeias da espécie *Apis cerana indica*. Essas amostras foram rotuladas como "Strong Beehive" (colmeia forte) e "Weak Beehive" (colmeia fraca). Nesse cenário, foi utilizada uma rede neural personalizada, com os Coeficientes Cepstrais em Frequência Mel (MFCCs) e o espectrograma Mel como entrada, obtendo uma média de 0,99 nas métricas de avaliação.

O estudo proposto por [Noriega-Escamilla et al. \(2023\)](#) apresenta um método para identificar o ácaro *Varroa destructor* em abelhas melíferas utilizando a técnica *Multichannel Legendre-Fourier Moments* (MLFM). Os descritores derivados desta abordagem possuem características distintivas, como rotação e invariância de escala, e resistência a ruído, permitindo a representação de imagens digitais com descritores mínimos. A proposta avalia a eficiência do algoritmo utilizando diferentes modelos de cores (RGB - (*Red, Green, Blue*), HSV - (*Hue, Saturation, Value*) e YCbCr - (*Y: Luminance, Cb: Chrominance-Blue, Cr: Chrominance-Red*)), aplicados às imagens do *VarroaDataset*, resultando na geração de três modelos distintos. Além disso, para comparação, as arquiteturas CNN *DeepLabV3* e *YOLOv5* pré-treinadas foram testadas seguindo uma abordagem padronizada com os três modelos de cores, utilizando os mesmos conjuntos de validação. Durante esses testes, nenhuma forma de pré-processamento nas imagens foi aplicada, mantendo-se o tamanho original. Não foram avaliados os impactos do uso de filtros, como remoção de ruído, e outras técnicas mais simples, como a Matriz de Co-Ocorrência de Níveis de Cinza (do inglês, *Gray-Level Co-Occurrence Matrix* - GLCM), também não foram exploradas. Entre as comparações realizadas com cada modelo, observou-se que a MLFM combinada com o sistema de cor YCbCr apresentou o melhor desempenho, alcançando uma pontuação de 0.96 nas métricas de F1-score e precisão.

No trabalho de [Duma et al. \(2024\)](#), foi proposto um método baseado em estatística

multivariada para detectar ácaros parasitas *Varroa destructor* no corpo das abelhas utilizando imagens hiperespectrais. A abordagem utilizou métodos não supervisionados (K-means++) e supervisionados (Kernel Flows–Partial Least Squares, KF-PLS). A pesquisa também demonstrou que é possível reduzir um conjunto inicial de 204 comprimentos de onda para apenas 4 essenciais ou 12 selecionados, melhorando, assim, a eficiência da detecção. Como resultado, os métodos supervisionados (KF-PLS) mostraram-se mais eficientes com o R2 de 86%, sem exigir pré-processamento significativo dos dados, em contraste com os métodos não supervisionados, que demandam um manuseio mais cuidadoso devido à interferência de fundo nas imagens.

Em seu estudo, [Sledević e Plonis \(2023\)](#) propuseram o uso de redes neurais convolucionais (CNNs) para detectar abelhas na entrada da colmeia, com o objetivo de identificar padrões comportamentais que reflitam a condição da colônia. Todas as detecções são rastreadas dentro de uma zona poligonal que cobre a tábua de pouso da colmeia. Os trajetos registrados formam padrões que são apresentados como mapas de calor (heatmaps) ou mapas de trajetória. Os descritores utilizaram um conjunto de dados coletado a partir de vídeos públicos, incluindo imagens de abelhas envolvidas em diversas atividades, como forrageamento e guarda da colmeia. Três modelos YOLO (nano, small e medium) foram treinados no mesmo conjunto de dados para comparação de precisão. O modelo YOLOv8 foi treinado e avaliado em relação às demais variantes, demonstrando desempenho superior, alcançando uma precisão média máxima de 0,97 com o modelo médio (YOLOv8m) e uma Média de Precisão Média com 97% (mAP) [0.5:0.97] e recall de 97%, com uma precisão de 98%. Comportamentos significativos, como a ventilação (fanning) e o acúmulo de abelhas na entrada durante a enxameação, são discutidos como indicadores críticos da saúde da colônia.

Os estudos discutidos nesta seção apresentam resultados promissores quanto à aplicação de técnicas de aprendizado de máquina e redes neurais para a identificação da presença do ácaro *Varroa*. A análise dos trabalhos mencionados permite identificar lacunas e oportunidades de melhoria. Primeiramente, nenhum dos estudos explorou completamente o potencial do pré-processamento de imagens, o que poderia ter contribuído para melhorar o desempenho dos modelos. [Berkaya, Gunal e Gunal \(2021\)](#) limitou-se apenas ao redimensionamento das imagens, enquanto [Mahajan et al. \(2023\)](#) utilizou técnicas simples de aumento de dados (data augmentation) e redimensionamento para melhorar a generalização dos modelos. Já [Schurischuster e Kampel \(2020\)](#) e [Noriega-Escamilla et al. \(2023\)](#) mantiveram as imagens em seu tamanho original, sendo que este último apenas testou a variação de modelos de cores como parte do modelo proposto. Apenas [Mahajan et al. \(2023\)](#) realizou o treinamento das arquiteturas, enquanto os demais estudos utilizaram modelos pré-treinados.

[Duma et al. \(2024\)](#) e [Sledević e Plonis \(2023\)](#) reforçam ainda mais o potencial da combinação entre aprendizado de máquina e visão computacional para a detecção de insetos

TRABALHO	BASE PÚBLICA	OBJETIVO	MODELO	MÉTRICAS
BERKAYA; GUNAL; GUNAL, 2021	SIM	Monitorar a saúde das colmeias utilizando modelos de classificação baseados em aprendizagem profunda	AlexNet/SVM	Acc: 0,932 Pre: 0,949 Rec: 0,972 F1-score: 0,950
SCHURISCHUSTER; KAMPEL, 2020	SIM	Sistema automatizado para detectar o Varroa destructor em abelhas contribuindo no monitoramento das colônias.	DeepLabV3/ResNet-101	Acc: 0,908 F1-score: 0,950
MAHANJA, 2023	SIM	Deteção visual da infestação pelo ácaro Varroa destructor	YOLOv5	Pre: 0,962 Rec: 0,967
NORIEGA-ESCAMILLA et al., 2023	SIM	Identificar o Varroa nas abelhas com menos dependência de dados e sem a necessidade de pré-processamento.	MLFM/YCbCr	Pre: 0,960 F1-score: 0,960
DUMA, 2024	SIM	Identificar o ácaro Varroa destructor no corpo das abelhas para facilitar o monitoramento contínuo das colmeias	KF-PLS	R2: 0,860
SLEDEVIĆ; PLONIS, 2023	SIM	Detectar e rastrear as abelhas, reconhecendo padrões de comportamento como forrageamento, guarda e ventilação	YOLOv8/YOLOv8m	mAP: 0,970 Pre: 0,98 Rec: 0,970

e análise de comportamento. [Duma et al. \(2024\)](#) demonstrou que técnicas de redução de dimensionalidade e métodos estatísticos multivariados, como o KF-PLS, podem alcançar alta acurácia na detecção de ácaros utilizando imagens hiperespectrais, mesmo sem a necessidade de pré-processamento intensivo dos dados. Por sua vez, [Sledević e Plonis \(2023\)](#) evidenciaram a eficácia de arquiteturas leves e otimizadas de CNNs, como a YOLOv8, para a detecção de abelhas em tempo real, utilizando um conjunto de dados prático e análise comportamental com base em mapas de calor. Além disso, embora comparações entre diferentes arquiteturas de redes neurais tenham sido realizadas, apenas [Berkaya, Gunal e Gunal \(2021\)](#) investigou o impacto de características rasas (shallow features) e profundas (deep features) combinadas ao classificador SVM. No entanto, os pesquisadores ainda não compararam diretamente as características extraídas por redes leves e densas. Portanto, esta pesquisa propõe preencher essa lacuna realizando uma comparação nesse cenário, utilizando essas características combinadas a diferentes algoritmos de aprendizado de máquina e empregando técnicas de pré-processamento, como o aumento de dados, para balancear as classes e melhorar a robustez dos modelos.

4 Metodologia

Nesta Seção, é descrito a metodologia adotada para o desenvolvimento do descritor proposto, detalhando cada passo em cinco etapas sequenciais apresentados na Figura 3, onde cada etapa utiliza o resultado da anterior. A primeira etapa consiste na aquisição das imagens, adquiridas através de uma base de dados pública. A segunda etapa consiste no pré-processamento, visando a normalização dos pixels e a realização do balanceamento das classes através da geração de novas imagens. A terceira etapa corresponde a extração de características. Na quarta etapa as características extraídas são classificadas e por fim, na quinta etapa, as diferentes métricas são utilizadas para avaliar o desempenho dos modelos de classificação.

4.1 Aquisição das Imagens

Para a aquisição, as imagens foram adotadas de uma base de dados pública o Varroa-Dataset (SCHURISCHUSTER; KAMPEL, 2020), composto de 13509 imagens no formato RGB e com 280×160 de resolução. Esse conjunto de dados é composto por duas classes: infectada (3947 imagens) e saudável (9562 imagens). Exemplos de amostras desse conjunto de dados são apresentados na Figura 4, onde encontramos três imagens de abelhas saudáveis (a-c) e três amostras de abelha infectadas(d-f), que apresentam um ou mais ácaros *Varroa destructor*, caracterizados pela forma de botão plana de cor marrom avermelhada situada na imagem no abdômen da abelha (TRAYNOR et al., 2020). O conjunto de dados foi dividido em 80% para treinamento dos modelos e 20% teste, ou seja, para a avaliação do desempenho dos modelos, a distribuição por classes é apresentada na Tabela 1.

Tabela 1 – Distribuição do dataset com a divisão 80/20 (80% para o treinamento e 20% para o teste) sem o balanceamento das classes.

Classe	Treino	Teste	Total
saudável	7650	1912	9562
infectada	3158	789	3947

4.2 Pré-processamento

Na etapa de pré-processamento, as imagens foram normalizadas subtraindo a média dos valores dos pixels e dividindo pelo desvio padrão, com o objetivo de padronizar os pixels e otimizar a convergência durante o treinamento dos modelos. Isso significa que,

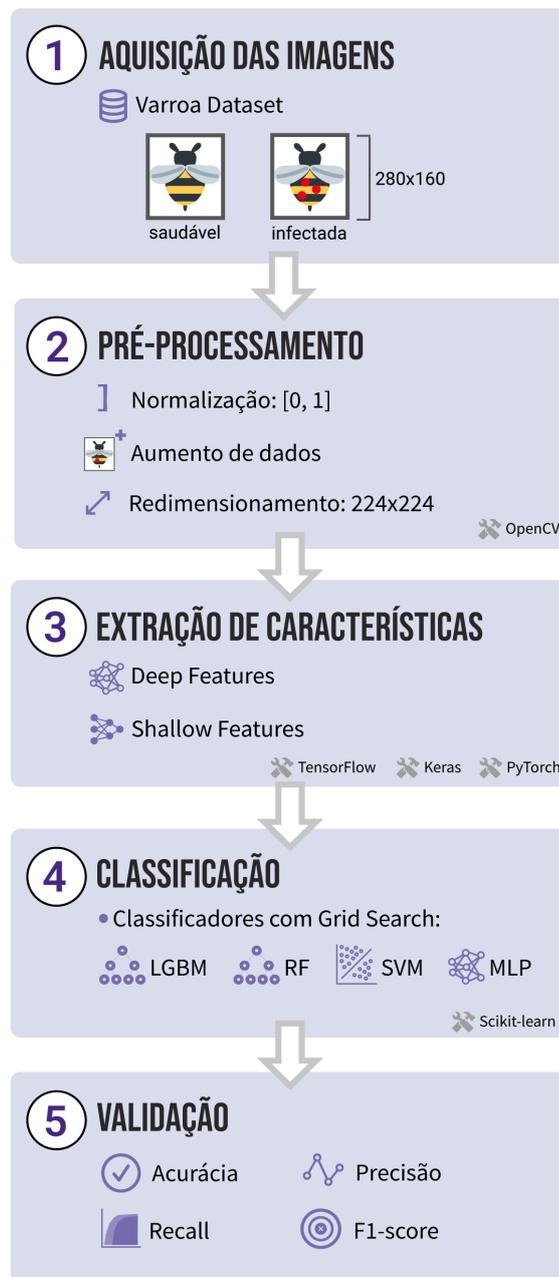


Figura 3 – Etapas do método proposto. A 1ª etapa consiste na aquisição das imagens, na 2ª etapa ocorre o pré-processamento, na 3ª etapa as características são extraídas, a 4ª etapa compreende o uso de algoritmos de classificação distintos e a 5ª etapa corresponde à validação.

após a normalização, os valores dos pixels estarão distribuídos uniformemente no intervalo $[0, 1]$.

Em seguida, para a classe infectada, foram geradas novas imagens a partir das originais a fim de balancear as classes e aumentar os dados. Foram utilizadas 2035 imagens, e as outras 1912 amostras foram preservadas para garantir que o novo conjunto de teste tivesse apenas imagens originais. A partir de cada imagem de treino, foram criadas quatro novas amostras utilizando os seguintes métodos: espelhamento horizontal, espelhamento

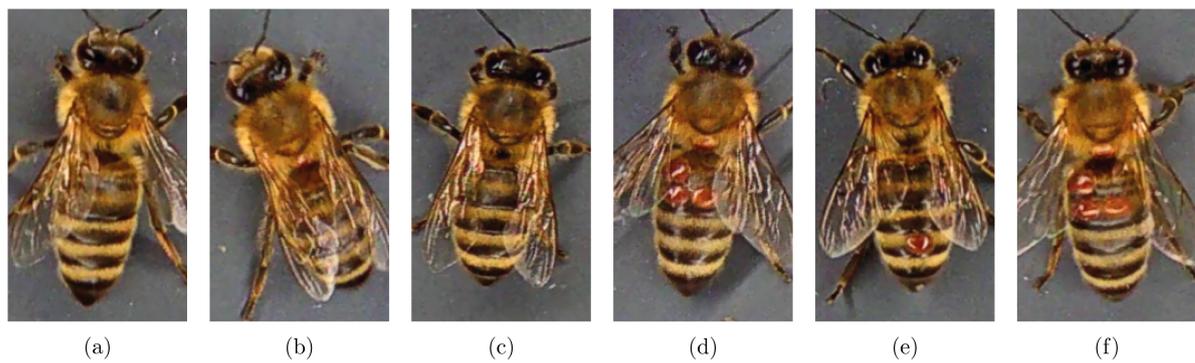


Figura 4 – Amostras do dataset: (a-c) abelhas saudáveis que apresentam abdômen liso e uniforme, sem a presença de ácaros, (d-f) abelhas infectadas por ácaros *Varroa destructor*, caracterizados por sua forma achatada de cor marrom avermelhada, situados no abdômen das abelhas.

vertical, rotação de 180° e aumento de contraste em 30%, conforme ilustrado na Figura 5. A escolha dessas transformações baseou-se em sua eficácia comprovada na introdução de variações realistas nos dados de treinamento (SHORTEN; KHOSHGOFTAAR, 2019). Nesse processo, o conjunto de treino da classe infectada ficou com 8140 amostras. Para que o conjunto de treino da classe saudável tivesse o mesmo tamanho, foram descartadas de forma aleatória 490 imagens do conjunto de treino da classe infectada. Assim, o novo conjunto ficou com 19124 imagens no total, sendo 9562 para cada classe.

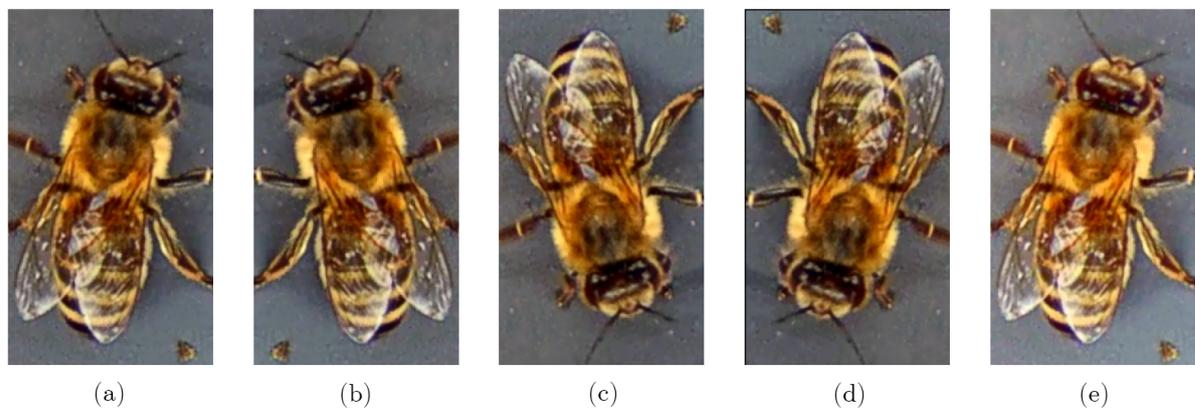


Figura 5 – Aplicação de técnicas de augmentation no conjunto de treino: A imagem original (a) é seguida por quatro imagens aumentadas, cada uma com um tipo diferente de transformação aplicada. Nas imagens (b) e (c) foram aplicadas o espelhamento horizontal e vertical, que inverte a imagem na horizontal e vertical respectivamente. A imagem (d) é uma rotação de 180 graus, que gira a imagem 180 graus no sentido horário, e por fim, a imagem (e) é um exemplo do aumento de contraste em 30%.

Após o balanceamento das classes, as imagens foram redimensionadas para o tamanho 224×224 , com interpolação bilinear, onde a imagem é esticada de forma proporcional para ajustá-la às novas dimensões. Esse processo garante que as imagens estejam em um formato adequado e padronizado de entrada para as CNNs na etapa de extração de características.

4.3 Extração de características

As Redes Neurais Convolucionais (CNNs) são arquiteturas de redes de aprendizado profundo populares devido à sua capacidade em aprender padrões complexos em imagens. Assim, elas têm sido amplamente utilizadas como descritores em tarefas de classificação de imagens (RAWAT; WANG, 2017). Nesse trabalho foram extraídos dois tipos de características a partir das CNNs: *deep features* e *shallow features*.

As *deep features* são extraídas das camadas finais da CNN, onde as imagens são representadas por características de nível superior, que captam informações sobre objetos ou partes de objetos, por exemplo, uma característica de nível superior para uma imagem de uma abelha pode diferenciar o ácaro *Varroa destructor* das listras no abdômen. Essas características são geralmente mais abstratas e menos informativas do que as *shallow features*, porém tem uma capacidade melhor de generalizar para novos dados, pois são menos dependentes dos detalhes específicos da imagem. As *shallow features* são extraídas das camadas iniciais da CNN, onde as imagens são representadas por características de nível inferior, como bordas, textura e padrões espaciais. É necessária uma quantidade maior de dados para extrair *shallow features* que *deep features*. Isso ocorre porque as características rasas são mais específicas e, portanto, requerem mais exemplos para serem aprendidas pelo algoritmo de classificação (SUN; LV, 2019).

Utilizamos as imagens dos conjuntos com e sem balanceamento, com a resolução de 224×224 , como entrada para as arquiteturas pré-treinadas com ImageNet (RUSSAKOVSKY et al., 2015), dividindo-as em duas categorias: redes leves e redes densas. As redes leves são as arquiteturas que possuem uma menor quantidade de parâmetros, o que as torna mais rápidas e eficientes computacionalmente, nessa categoria foram utilizadas as seguintes redes: MobileNet (HOWARD et al., 2017), YOLOv5n (ZHANG et al., 2022) e EfficientNetB0 (TAN; LE, 2019). Já as redes densas apresentam uma maior quantidade de parâmetros, o que as torna mais poderosas para aprender padrões complexos, as arquiteturas usadas foram: DenseNet201 (HUANG et al., 2017), AlexNet (KRIZHEVSKY; SUTSKEVER; HINTON, 2012) e GoogLeNet (SZEGEDY et al., 2015). Essa divisão pela quantidade de parâmetros foi feita para analisar os diferentes *trade-offs* entre desempenho e eficiência das CNNs. Esse tipo de avaliação é pertinente visto que, em alguns cenários, o monitoramento da colmeia *in loco* no apiário é necessário e dispositivos de computação em borda possuem restrições computacionais (SINGH; GILL, 2023).

Nesse contexto, a Tabela 2 apresenta as propriedades de cada arquitetura com base no número de parâmetros e do descritor em termos de tamanho. Essas arquiteturas são classificadas como densas ($>20M$) ou leves ($<10M$), dependendo do número de parâmetros que possuem (KAMAL et al., 2019). A DenseNet201 destaca-se como a mais densa, com 20,2 milhões de parâmetros, enquanto a YOLOv5n é a mais leve, contendo 1,9 milhões de parâmetros. Em relação às dimensões dos descritores, a AlexNet se destaca com as maiores dimensões: 2048 e 256 para as *deep e shallow features*, respectivamente. As archi-

teturas leves se beneficiaram especialmente da utilização das *shallow features*, reduzindo os descritores para 62 e 32, em comparação com as *deep features* que possuem dimensões superiores a 1000. Descritores compactos, como as *shallow features*, têm o potencial de serem mais eficientes, melhorando o desempenho em aplicações que demandam alto processamento, como reconhecimento de imagem em tempo real. Além disso, podem reduzir o tamanho do modelo, facilitando seu armazenamento e uso. Isso pode ser benéfico para aplicações em dispositivos com recursos limitados, como smartphones e drones.

Tabela 2 – Propriedades dos descritores

CNN	Parâmetros	Características profundas	Características rasas	Categoria
YOLOv5n	1.9M	1728	64	leves
MobileNet	4.3M	1024	32	leves
EfficientNetB0	5.3M	1280	32	leves
DenseNet201	20.2M	1920	64	densas
AlexNet	61.2M	2048	256	densas
GoogLeNet	66.2M	1024	128	densas

4.4 Classificação

Para avaliar o desempenho dos descritores, utilizamos quatro classificadores com características distintas, que são amplamente adotados na literatura: Random Forest (RF) (BREIMAN, 2001), LightGBM (LGBM) (KE et al., 2017), Support Vector Machine (SVM) (CORTES; VAPNIK, 1995) e o Multi-layer Perceptron (MLP) (WINDEATT, 2008). O Random Forest combina vários modelos de árvore de decisão para obter maior precisão e evitar o sobreajuste. O LightGBM utiliza a técnica de aumento de gradiente para melhorar a velocidade e eficiência do treinamento. Já o SVM encontra um plano de separação entre as classes e é um dos classificadores mais utilizados na literatura. E o MLP é um classificador neural que pode aprender funções não lineares. Os experimentos com os descritores foram feitos em dois cenários (com e sem balanceamento das classes) usando a divisão 80/20, que foi aplicada na primeira etapa. Para encontrar os melhores valores dos parâmetros dos classificadores dentro de um espaço de busca, foi utilizado o algoritmo Grid Search (BERGSTRA; BENGIO, 2012). A Tabela 3 mostra os parâmetros selecionados pelo algoritmo, em negrito, e seu respectivo espaço de busca para cada classificador.

4.5 Validação

Conforme abordado no Capítulo 2, a avaliação dos modelos de classificação no presente estudo empregou quatro métricas de validação amplamente utilizadas na literatura: acurácia, precisão, *recall* e F1-score que foram calculadas com a biblioteca scikit-learn. A

Tabela 3 – Parâmetros definidos pelo Grid Search (em negrito estão os melhores resultados)

Classificador	Intervalo dos parâmetros
RF	número de estimadores: [100, 200, 300, 400, 500 , 700], profundidade máxima: [3, 5, 7, 9 , 11, 13]
LGBM	número de estimadores: [100, 200, 300, 500, 700], profundidade máxima: [3, 5, 7 , 9, 11, 13]
SVM	kernel: [linear , rbf, poly, sigmoid], C: [0.1, 0.5, 0.7, 1.0]
MLP	solver: [adam , lbfgs, sgd], função de ativação: [relu , tanh, logistic, identity]

acurácia representa a proporção de predições corretas em relação ao total de predições feitas pelo modelo (BARATLOO et al., 2015). Já a métrica de precisão calcula a proporção de verdadeiros positivos (previsões corretas de abelhas infectadas) em relação ao total de positivos previstos pelo modelo, sendo útil quando o foco está na minimização de falsos positivos (o modelo classifica de forma incorreta uma abelha saudável como infectada). O recall, por sua vez, quantifica a capacidade do modelo de identificar corretamente todas as amostras positivas, sendo a proporção de verdadeiros positivos em relação ao total de positivos reais. Por fim, o F1-score é a média harmônica entre precisão e *recall*, fornecendo uma única medida que combina ambos os aspectos (OLSON; DELEN, 2008).

5 Resultados

As Tabelas 4 e 5 apresentam os resultados da classificação utilizando as *deep features* para as redes leves e densas respectivamente, destacando os melhores desempenhos em negrito. Os resultados mais promissores foram alcançados no conjunto de dados com aumento, onde a combinação da YOLOv5 com o RF obteve 0.99 de acurácia e 0.98 nas métricas precision, recall e f1-score. Ao considerar as redes densas, a AlexNet combinada com o SVM teve os melhores resultados, sendo 0.95 nas métricas acurácia, recall e f1-score, e 0.94 no recall. Por outro lado, os piores resultados foram observados nos classificadores SVM e MLP, especialmente no cenário sem balanceamento, marcando abaixo de 0.80 para as redes leves (efficientnet e mobilenet) assim como para as redes densas (AlexNet e GoogLeNet). Esses resultados podem ser atribuídos a diversos fatores, como a robustez dos classificadores e a capacidade das CNNs em extrair características relevantes. O aumento de dados melhora o desempenho dos descritores das arquiteturas leves, que tem uma menor capacidade de aprendizado em comparação com redes mais densas, já que, uma variedade maior de exemplos de treinamento, permite que essas redes identifiquem padrões mais relevantes nas imagens. Enquanto as redes densas, têm uma arquitetura mais profunda e uma quantidade maior de parâmetros, as redes leves, são projetadas para serem mais eficientes em termos de processamento e implementação em um cenário embarcado, o que permite que se adaptem melhor a um conjuntos de dados específicos.

Tabela 4 – Resultados da detecção do ácaro *Varroa destructor* com e sem aumento de dados, considerando as deep features extraídas por arquiteturas neurais leves (em negrito estão os melhores resultados).

CNN	Classificação	Não balanceado				Balanceado			
		Acc	Precisão	Recall	F1-score	Acc	Precisão	Recall	F1-score
YOLOv5n	LGBM	0.9391	0.9226	0.9302	0.9221	0.9915	0.9856	0.9802	0.9840
	RF	0.9305	0.9354	0.9340	0.9341	0.9820	0.9841	0.9840	0.9861
	SVM	0.9341	0.9361	0.9381	0.9270	0.9672	0.9526	0.9513	0.9517
	MLP	0.9307	0.9244	0.9384	0.9366	0.9413	0.9492	0.9319	0.9405
MobileNet	LGBM	0.8057	0.7562	0.7455	0.7607	0.8503	0.7625	0.7270	0.7443
	RF	0.9002	0.9326	0.9204	0.9197	0.9320	0.9438	0.9076	0.9253
	SVM	0.8335	0.7508	0.7511	0.7577	0.9078	0.9280	0.9475	0.9378
	MLP	0.8113	0.7971	0.7823	0.7845	0.8796	0.8046	0.7819	0.7931
EfficientNetB0	LGBM	0.8068	0.8005	0.7834	0.7968	0.9372	0.9343	0.9363	0.9444
	RF	0.7980	0.7846	0.7838	0.8064	0.9362	0.9384	0.9336	0.9412
	SVM	0.7840	0.7970	0.8041	0.7977	0.9373	0.9402	0.9444	0.9379
	MLP	0.7937	0.7879	0.7984	0.8189	0.9388	0.9345	0.9315	0.9410

As Tabelas 6 e 7 apresentam os resultados dos classificadores obtidos por meio das *shallow features* para as redes leves e densas. Os resultados alcançados com o balanceamento das classes foram próximos aos melhores resultados obtidos com as deep features para as redes leves e superiores às redes densas. Mesmo reduzindo o tamanho do descritor em 96%, obtivemos um desempenho de 0.98 em todas as métricas para a YOLOv5n com o RF e a DenseNet201 com o MLP, nas redes leves e densas, respectivamente. O

Tabela 5 – Resultados da detecção do ácaro *Varroa destructor* com e sem aumento de dados, considerando as deep features extraídas por arquiteturas neurais densas (em negrito estão os melhores resultados).

CNN	Classificação	Não balanceado				Balanceado			
		Acc	Precisão	Recall	F1-score	Acc	Precisão	Recall	F1-score
DenseNet201	LGBM	0.8786	0.8442	0.8915	0.8602	0.8237	0.8405	0.8992	0.8693
	RF	0.9164	0.9238	0.9037	0.9153	0.9264	0.9179	0.9126	0.9075
	SVM	0.8719	0.8395	0.7676	0.7437	0.8864	0.8628	0.8684	0.8800
	MLP	0.8631	0.7595	0.7434	0.7513	0.8537	0.8258	0.8206	0.8232
AlexNet	LGBM	0.8049	0.8103	0.8183	0.8108	0.9493	0.9390	0.9475	0.9503
	RF	0.8027	0.8042	0.8122	0.7844	0.9300	0.9422	0.9547	0.9474
	SVM	0.7802	0.8036	0.7998	0.8022	0.9597	0.9433	0.9598	0.9541
	MLP	0.7843	0.7884	0.7833	0.8173	0.9406	0.9386	0.9414	0.9499
GoogLeNet	LGBM	0.8032	0.8077	0.8027	0.8090	0.9024	0.9153	0.9080	0.9149
	RF	0.8156	0.8017	0.8006	0.8072	0.9096	0.9034	0.9015	0.9152
	SVM	0.7845	0.7805	0.8030	0.8021	0.9046	0.9112	0.9168	0.9133
	MLP	0.8085	0.7902	0.7928	0.8012	0.9123	0.9172	0.9143	0.9174

Tabela 6 – Resultados da detecção do ácaro *Varroa destructor* com e sem aumento de dados, considerando as shallow features extraídas por arquiteturas neurais leves (em negrito estão os melhores resultados).

CNN	Classificação	Não balanceado				Balanceado			
		Acc	Precisão	Recall	F1-score	Acc	Precisão	Recall	F1-score
YOLOv5n	LGBM	0.8655	0.8633	0.8694	0.8756	0.9637	0.9594	0.9588	0.9490
	RF	0.8603	0.8644	0.8524	0.8602	0.9883	0.9854	0.9857	0.9861
	SVM	0.8660	0.8631	0.8791	0.8687	0.9494	0.9391	0.9398	0.9384
	MLP	0.8710	0.8686	0.8798	0.8641	0.9196	0.9284	0.9285	0.9285
MobileNet	LGBM	0.6022	0.5923	0.5782	0.5683	0.7764	0.8005	0.7364	0.7671
	RF	0.7320	0.6557	0.6655	0.6553	0.7824	0.7882	0.7725	0.7802
	SVM	0.8608	0.8510	0.8700	0.8570	0.9597	0.9356	0.9200	0.9270
	MLP	0.8871	0.8751	0.8707	0.8791	0.9613	0.9590	0.9738	0.9656
EfficientNetB0	LGBM	0.7086	0.6990	0.7423	0.7050	0.8946	0.8948	0.8985	0.8828
	RF	0.7698	0.7402	0.6825	0.7560	0.8925	0.8887	0.8869	0.8896
	SVM	0.7227	0.7509	0.7632	0.6969	0.8953	0.8880	0.8935	0.8958
	MLP	0.6900	0.7089	0.7107	0.7320	0.8890	0.8894	0.8888	0.8900

cenário sem balanceamento revelou os piores resultados, destacando-se o MobileNet com o LGBM, que registrou valores abaixo de 0.60 em todas as métricas, e a GoogLeNet com o RF nas redes densas, atingindo 0.70 na acurácia, recall e f1-score, e 0.71 de precision. Além disso, foi repetido o padrão observado nas deep features, onde os resultados apresentaram melhorias significativas com o aumento de dados, o que demonstra o impacto positivo do balanceamento das classes.

Dessa forma, ao analisar os resultados, percebe-se que a YOLOv5, se destacou em todos os cenários, principalmente as *shallows features* com balanceamento das classes, devido à sua capacidade de identificar objetos variados em diferentes escalas e tamanhos. Essa versatilidade se revela especialmente eficaz na detecção de elementos pequenos, como o ácaro *Varroa destructor*. Por outro lado, o desempenho menos satisfatório foi registrado com a MobileNet e o LGBM no conjunto de dados desbalanceado, onde as *shallow features* ficaram abaixo de 0.60. Esse resultado se deve à escassez de amostras na classe infectada, prejudicando a capacidade do modelo em identificar o ácaro *Varroa destructor* de forma precisa. Nas arquiteturas densas, a DenseNet201 obteve o melhor desempenho com as *shallow features*, superando até mesmo os resultados alcançados pelas deep features. Assim, o desempenho na classificação com as arquiteturas leves e densas, sugere que as

Tabela 7 – Resultados da identificação do ácaro *Varroa destructor* com e sem aumento de dados, considerando características rasas extraídas por arquiteturas neurais densas (em negrito estão os melhores resultados).

CNN	Classificação	Não balanceado				Balanceado			
		Acc	Precisão	Recall	F1-score	Acc	Precisão	Recall	F1-score
DenseNet201	LGBM	0.7353	0.7786	0.7865	0.7766	0.8158	0.8013	0.8046	0.8079
	RF	0.8744	0.8657	0.8620	0.8631	0.8854	0.8708	0.8733	0.8615
	SVM	0.7653	0.7535	0.7465	0.7486	0.9585	0.9055	0.9095	0.9069
	MLP	0.7108	0.7296	0.7016	0.7032	0.9849	0.9750	0.9733	0.9656
AlexNet	LGBM	0.8077	0.8395	0.8381	0.8273	0.9375	0.9364	0.9179	0.9361
	RF	0.7200	0.7257	0.7348	0.7138	0.9126	0.9043	0.9292	0.9313
	SVM	0.8088	0.7870	0.7961	0.7806	0.9083	0.9155	0.9104	0.9263
	MLP	0.7032	0.7608	0.7492	0.7446	0.9085	0.9227	0.9211	0.9140
GoogLeNet	LGBM	0.7442	0.7650	0.7449	0.7372	0.8639	0.8858	0.8699	0.8660
	RF	0.7070	0.7138	0.7021	0.7073	0.8113	0.8074	0.8015	0.8012
	SVM	0.7941	0.7808	0.7837	0.7713	0.8701	0.8648	0.8613	0.8891
	MLP	0.7573	0.7270	0.7560	0.7221	0.8711	0.8860	0.8804	0.8801

camadas iniciais da rede contêm informações mais cruciais para a resolução do problema. Além disso, o balanceamento das classes teve um impacto significativo nos resultados, especialmente nas *shallow features*, onde os resultados foram comparáveis aos das deep features, porém com um descritor consideravelmente menor, com uma redução de 96.2% na YOLOv5n. Portanto, a extração das *shallow features* a partir da arquitetura YOLOv5n combinada com o classificador RF pode ser uma solução promissora para detectar a presença do ácaro *Varroa destructor*, principalmente por se tratar de uma arquitetura leve, com apenas 1.9 milhões de parâmetros, sendo uma alternativa viável para cenários que apresentem limitações de recursos de hardware. Além disso, por gerar descritores de características rasas com baixa dimensionalidade, essa abordagem também se destaca pela sua simplicidade computacional mesmo em contextos sem restrições de processamento.

5.1 Comparação com a literatura

A Tabela 8 apresenta uma compilação dos modelos propostos na literatura para a detecção do ácaro *Varroa destructor* em abelhas, juntamente com os melhores desempenhos alcançados usando as métricas relevantes. Todos os trabalhos analisados empregaram o Varroa Dataset, e somente [Mahajan et al. \(2023\)](#) utilizou técnicas de *augmentation* para o balanceamento entre as classes. Neste trabalho, propomos um descritor baseado na rede leve YOLOv5 focando na extração de características rasas. A abordagem com YOLOv5n combinada ao RF alcançou uma performance de 98% em todas as métricas avaliadas, estes resultados superaram os modelos previamente propostos na literatura.

[Berkaya, Gunal e Gunal \(2021\)](#) também utilizaram redes neurais convolucionais (CNNs) para extrair características rasas e profundas, combinadas com SVM, realizando a classificação por meio de aprendizado por transferência. O melhor resultado foi alcançado com a VGG19 utilizando transferência de aprendizado, obtendo uma média de 95% nas métricas de avaliação. Ao analisar os modelos baseados em características rasas, em comparação

com o descritor proposto neste trabalho, notamos diferenças nas métricas, sugerindo que um alto valor de *recall* (100%) e uma baixa precisão (72,36%) indicam uma tendência a falsos positivos. No entanto, as métricas dos modelos deste estudo apresentaram resultados mais equilibrados, reduzindo a probabilidade desses falsos positivos ao aplicar o modelo em diferentes conjuntos de dados. Além disso, o nosso descritor também superou o modelo baseado em características profundas, que obteve 90% com a arquitetura Alex-Net. Os melhores resultados obtidos por [Mahajan et al. \(2023\)](#) foram com a arquitetura YOLOv5, utilizada como descritor e classificador, alcançando valores superiores a 96,0% nas métricas de precisão, revocação e F1-score, apesar de ser uma rede leve. No entanto, a predição ainda pode apresentar um custo computacional mais elevado do que o nosso descritor, que extrai características apenas das camadas iniciais.

Os trabalhos de [Schurischuster e Kampel \(2020\)](#) e [Noriega-Escamilla et al. \(2023\)](#) aplicaram experimentos com arquiteturas de CNNs para segmentação. [Schurischuster e Kampel \(2020\)](#) foi responsável por coletar e disponibilizar publicamente o conjunto de dados utilizado neste trabalho, no qual a arquitetura de segmentação DeepLabV3 alcançou um F1-score de 95%. Em [Noriega-Escamilla et al. \(2023\)](#), as CNNs de segmentação não obtiveram o melhor resultado, destacando-se o modelo MLFM empregado no espaço de cor YCbCr, que alcançou 96,0% nas métricas de avaliação. Essa abordagem surge como uma alternativa para cenários com limitações de hardware. Assim, os valores das métricas obtidos com o descritor proposto também superaram esses resultados.

Portanto, as principais diferenças entre este trabalho e os demais encontrados na literatura são: (1) a análise do impacto das características rasas em dois cenários, com e sem balanceamento de classes, em contraste com características profundas; (2) a comparação de desempenho entre redes leves e densas; (3) a utilização de diferentes algoritmos de classificação, avaliados de forma robusta com base em quatro métricas. Assim, os resultados alcançados neste estudo sugerem um descritor eficaz e compacto, baseado em características rasas extraídas da rede YOLOv5, para a detecção do ácaro *Varroa destructor* em abelhas.

Tabela 8 – Comparação dos resultados obtidos por trabalhos do estado da arte com o descritor proposto (em negrito) para a identificação do ácaro *Varroa destructor*.

Referências	Modelo	Aumento	Métricas
Berkaya, Gunal e Gunal (2021)	VGG19 (transfer learning)	Não	Acc: 93.22% Precisão: 94.93% Recall: 95.74% F1 score: 95.34%
	ResNet101+SVM (shallow feats)	Não	Acc: 72.36% Precisão: 72.36% Recall: 100% F1 score: 83.96%
	AlexNet+SVM (deep feats)	Não	Acc: 82.66% Precisão: 85.91% Recall: 90.96% F1 score: 88.36%
Mahajan et al. (2023)	YOLOv5	Sim	Precisão: 96.2% Recall: 96.7% mAP[0.5]: 97.4% mAP[0.5:0.95]: 40.4%
Schurischuster e Kappel (2020)	DeepLabV3	Não	F1 score: 95.0%
Noriega-Escamilla et al. (2023)	MLFM-YCbCr	Não	F1 score: 96.6% Precisão: 96.7%
Proposta	YOLOv5 + RF (shallow feats)	Sim	Acc: 98.83% Precisão: 98.54% Recall: 98.57% F1 score: 98.61%
	DenseNet201 + MLP (shallow feats)	Sim	Acc: 98.49% Precisão: 97.50% Recall: 97.33% F1 score: 96.56%

6 Conclusão

Neste trabalho, foi realizado um estudo sobre a identificação do ácaro *Varroa destructor* em imagens de abelhas, combinando técnicas de processamento de imagem com técnicas clássicas e profundas de aprendizado de máquina. Especificamente, investigamos o uso de características rasas extraídas de redes leves para o cenário de classificação abordado.

Os resultados mostram que o balanceamento de classes é essencial para a metodologia de identificação, especialmente em apiários onde ocorrem eventos intermitentes de infestação. As características rasas obtiveram os melhores resultados com a arquitetura YOLOv5, oferecendo um descritor compacto e preciso para a detecção da infestação pelo ácaro *Varroa destructor* em colmeias. Esses resultados destacam o potencial da associação entre características rasas e arquiteturas leves, mostrando-se promissora para o diagnóstico em tempo real das colônias, considerando dispositivos com restrições computacionais.

A principal limitação deste estudo reside na necessidade de generalizar os descritores para outros conjuntos de dados. Como possíveis trabalhos futuros, pretende-se investigar o desempenho dos descritores na identificação de outros tipos de pragas, como o besouro *Aethina Tumida* e a vespa *Trichogramma Evanesceus*, por exemplo. Além disso, serão investigados algoritmos de redução de dimensionalidade para melhorar a eficiência computacional no processo de classificação, mantendo ou até aprimorando a qualidade dos resultados. Essas melhorias serão essenciais para fortalecer a capacidade de generalização dos descritores e expandir sua aplicabilidade para uma gama mais ampla de conjuntos de dados.

Referências

- AMDAM, G. V. et al. Altered physiology in worker honey bees (hymenoptera: Apidae) infested with the mite varroa destructor (acari: Varroidae): a factor in colony loss during overwintering? *Journal of economic entomology*, Oxford University Press Oxford, UK, v. 97, n. 3, p. 741–747, 2004. Citado na página 15.
- ASSUNÇÃO, D. S. d. *Classificação automática de espécies de abelhas utilizando rede neural convolucional com técnicas de aumento de dados e transferência de aprendizado*. Tese (Doutorado) — Universidade de São Paulo, 2022. Citado na página 17.
- BACAXIXI, P. et al. A importância da apicultura no Brasil. *Revista Científica Eletrônica de Agronomia*, v. 10, n. 20, p. 1–6, 2011. Citado na página 14.
- BARATLOO, A. et al. Part 1: simple definition and calculation of accuracy, sensitivity and specificity. *Emergency*, v. 3, n. 2, p. 48, 2015. Citado 3 vezes nas páginas 19, 20 e 30.
- BERGSTRA, J.; BENGIO, Y. Random search for hyper-parameter optimization. *Journal of machine learning research*, v. 13, n. 2, 2012. Citado na página 29.
- BERKAYA, S. K.; GUNAL, E. S.; GUNAL, S. Deep learning-based classification models for beehive monitoring. *Ecological Informatics*, v. 64, p. 101353, 2021. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S1574954121001448>>. Citado 6 vezes nas páginas 12, 21, 23, 24, 33 e 35.
- BERNARDO, É. D. et al. Sem abelhas, sem alimento: sensibilização acerca da importância das abelhas e da apicultura na comunidade escolar de currais novos/rn. *Meio Ambiente, Sustentabilidade e Tecnologia*, p. 73–79, 2023. Citado 2 vezes nas páginas 14 e 15.
- BOGDANOV, S. Contaminants of bee products. *Apidologie*, EDP Sciences, v. 37, n. 1, p. 1–18, 2006. Citado na página 15.
- BREIMAN, L. Random forests. *Machine learning*, Springer, v. 45, p. 5–32, 2001. Citado na página 29.
- CASTAGNINO, G. L. B.; ORSI, R. d. O. Produtos naturais para o controle do ácaro varroa destructor em abelhas africanizadas. *Pesquisa Agropecuária Brasileira*, SciELO Brasil, v. 47, p. 738–744, 2012. Citado na página 15.
- CERRI, R.; FERREIRA, A. C. P. de L. et al. Aprendizado de máquina: breve introdução e aplicações. *Cadernos de Ciência Tecnologia*, v. 34, n. 3, p. 297–313, 2019. Citado na página 17.
- COLLICCHIO, E.; ROCHA, H. R. d. Agricultura e mudanças do clima no estado do tocantins: vulnerabilidades, projeções e desenvolvimento. 2022. Citado na página 14.
- CORTES, C.; VAPNIK, V. Support-vector networks. *Machine learning*, Springer, v. 20, p. 273–297, 1995. Citado na página 29.

- DEBAUCHE, O. et al. Web monitoring of bee health for researchers and beekeepers based on the internet of things. *Procedia computer science*, Elsevier, v. 130, p. 991–998, 2018. Citado na página 13.
- DESAI, U. *Mastering Convolutional Neural Networks (CNN) for Deep Learning Applications*. 2024. Disponível em: <<https://utsavdesai26.medium.com/mastering-convolutional-neural-networks-cnn-for-deep-learning-applications-16bc02eb2cf2>>. Citado 2 vezes nas páginas 8 e 19.
- DUMA, Z.-S. et al. Varroa destructor detection on honey bees using hyperspectral imagery. *Computers and Electronics in Agriculture*, v. 224, p. 109219, 2024. ISSN 0168-1699. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0168169924006100>>. Citado 3 vezes nas páginas 22, 23 e 24.
- FACELI, K. et al. *Inteligência artificial: uma abordagem de aprendizado de máquina*. [S.l.]: LTC, 2021. Citado na página 17.
- FEITOSA, A. d. N. A. et al. Produtos apícolas e saúde humana: uma revisão integrativa. *Brazilian Journal of Production Engineering*, v. 6, 2020. Citado na página 14.
- FONTANA, E. Introdução aos algoritmos de aprendizagem supervisionada. *Departamento de Engenharia Química, Universidade Federal do Paraná*, 2020. Citado na página 17.
- GONZALEZ, R. C.; WOODS, R. E. *Processamento de imagens digitais*. [S.l.]: Editora Blucher, 2000. Citado na página 16.
- GRAY, A. et al. Honey bee colony winter loss rates for 35 countries participating in the coloss survey for winter 2018–2019, and the effects of a new queen on the risk of colony winter loss. *Journal of Apicultural Research*, Taylor & Francis, v. 59, n. 5, p. 744–751, 2020. Citado na página 12.
- GREGORC, A.; SAMPSON, B. Diagnosis of varroa mite (varroa destructor) and sustainable control in honey bee (*apis mellifera*) colonies—a review. *Diversity*, MDPI, v. 11, n. 12, p. 243, 2019. Citado na página 12.
- HAYKIN, S. *Redes neurais: princípios e prática*. [S.l.]: Bookman Editora, 2001. Citado na página 18.
- HOWARD, A. G. et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*, 2017. Citado na página 28.
- HRISTOV, P. et al. Factors associated with honey bee colony losses: A mini-review. *Veterinary Sciences*, MDPI, v. 7, n. 4, p. 166, 2020. Citado na página 12.
- HUANG, G. et al. Densely connected convolutional networks. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2017. p. 4700–4708. Citado na página 28.
- INSOLIA, L. et al. Honey bee colony loss linked to parasites, pesticides and extreme weather across the united states. *Scientific reports*, Nature Publishing Group UK London, v. 12, n. 1, p. 20787, 2022. Citado na página 12.

- KAMAL, K. et al. Depthwise separable convolution architectures for plant disease classification. *Computers and electronics in agriculture*, Elsevier, v. 165, p. 104948, 2019. Citado na página 28.
- KE, G. et al. Lightgbm: A highly efficient gradient boosting decision tree. *Advances in neural information processing systems*, v. 30, 2017. Citado na página 29.
- KOLEOGLU, G. et al. Effect of varroa destructor, wounding and varroa homogenate on gene expression in brood and adult honey bees. *PLoS one*, Public Library of Science San Francisco, CA USA, v. 12, n. 1, p. e0169669, 2017. Citado na página 12.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, Curran Associates, Inc., v. 25, p. 1097–1105, 2012. Citado na página 28.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *nature*, Nature Publishing Group UK London, v. 521, n. 7553, p. 436–444, 2015. Citado na página 18.
- LINS, E. A. et al. Uma metodologia de contagem e classificação de afídeos utilizando visão computacional. Universidade de Passo Fundo, 2018. Citado na página 16.
- LODESANI, M. Control strategies against varroa mites. *Parassitologia*, v. 46, n. 1-2, p. 277–279, 2004. Citado na página 15.
- LUDERMIR, T. B. Inteligência artificial e aprendizado de máquina: estado atual e tendências. *Estudos Avançados*, SciELO Brasil, v. 35, p. 85–94, 2021. Citado na página 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 5 vezes nas páginas 22, 23, 33, 34 e 35.
- 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 15.
- NORIEGA-ESCAMILLA, A. et al. Varroa destructor classification using legendre–fourier moments with different color spaces. *Journal of Imaging*, v. 9, n. 7, p. 144, 2023. ISSN 2313-433X. Disponível em: <<https://www.mdpi.com/2313-433X/9/7/144>>. Citado 5 vezes nas páginas 12, 22, 23, 34 e 35.
- OGIHARA, M. H. et al. Dominant honeybee colony infestation by varroa destructor (acari: Varroidae) k haplotype in japan. *Applied Entomology and Zoology*, v. 55, n. 2, p. 189–197, 2020. Disponível em: <<http://link.springer.com/10.1007/s13355-020-00667-w>><http://link.springer.com/10.1007/s13355-020-00667-w>. Citado na página 13.

- OLSON, D. L.; DELEN, D. *Advanced data mining techniques*. [S.l.]: Springer Science & Business Media, 2008. Citado na página 30.
- OSKAY, G. S. et al. Impact of stress factors internal and external to the hive on honey bees and their reflection on honey bee products: a review. *Journal of Apicultural Research*, Taylor & Francis, p. 1–16, 2023. Citado na página 13.
- PACHECO, C. A. R. Deep learning conceitos e utilização nas diversas Áreas do conhecimento. 2018. Disponível em: <<http://repositorio.aee.edu.br/jspui/handle/aee/1104>><http://repositorio.aee.edu.br/jspui/handle/aee/1104>. Citado na página 18.
- PIRES, J. M. N. G. *Aprendizagem profunda: estudo e aplicações*. Dissertação (Mestrado) — Universidade de Évora, 2017. Citado na página 18.
- RASCHKA SEBASTIAN E MIRJALILI, V. *Aprendizado de máquina Python: aprendizado de máquina e aprendizado profundo com Python, scikit-learn e TensorFlow 2*. [S.l.]: Packt Publishing Ltd, 2019. Citado na página 18.
- RAWAT, W.; WANG, Z. Deep convolutional neural networks for image classification: A comprehensive review. *Neural computation*, MIT Press, v. 29, n. 9, p. 2352–2449, 2017. Citado na página 28.
- RUSSAKOVSKY, O. et al. Imagenet large scale visual recognition challenge. *International journal of computer vision*, Springer, v. 115, p. 211–252, 2015. Citado na página 28.
- SANTOS, A. M. d. et al. Usando redes neurais artificiais e regressão logística na predição da hepatite a. *Revista Brasileira de Epidemiologia*, SciELO Public Health, v. 8, p. 117–126, 2005. Citado na página 19.
- SANTOS, A. P. d. O. Desenvolvimento de descritores de imagens para reconhecimento de padrões de plantas invasoras (folhas largas e folhas estreitas). Universidade Federal de São Carlos, 2009. Citado na página 16.
- SCHURISCHUSTER, S.; KAMPEL, M. *VarroaDataset*. Zenodo, 2020. Disponível em: <<https://doi.org/10.5281/zenodo.4085043>>. Citado 5 vezes nas páginas 21, 23, 25, 34 e 35.
- SHORTEN, C.; KHOSHGOFTAAR, T. M. A survey on image data augmentation for deep learning. *Journal of big data*, SpringerOpen, v. 6, n. 1, p. 1–48, 2019. Citado na página 27.
- SILVA, R. E. V. d. Um estudo comparativo entre redes neurais convolucionais para a classificação de imagens. 2018. Citado na página 18.
- SINGH, R.; GILL, S. S. Edge ai: a survey. *Internet of Things and Cyber-Physical Systems*, Elsevier, 2023. Citado na página 28.
- SLEDEVIĆ, T.; PLONIS, D. Toward bee behavioral pattern recognition on hive entrance using yolov8. In: *2023 IEEE 10th Jubilee Workshop on Advances in Information, Electronic and Electrical Engineering (AIEEE)*. [S.l.: s.n.], 2023. p. 1–4. Citado 2 vezes nas páginas 23 e 24.

- 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 16.
- STRAUSS, E.; JÚNIOR, M. V. B.; FERREIRA, W. L. L. A importância de utilizar métricas adequadas de avaliação de performance em modelos preditivos de machine learning. *Projectus*, v. 7, n. 2, p. 52–62, 2022. Citado na página 20.
- SUMPTER, D. J.; MARTIN, S. J. The dynamics of virus epidemics in varroa-infested honey bee colonies. *Journal of Animal Ecology*, Wiley Online Library, v. 73, n. 1, p. 51–63, 2004. Citado na página 15.
- SUN, X.; LV, M. Facial expression recognition based on a hybrid model combining deep and shallow features. *Cognitive Computation*, Springer, v. 11, n. 4, p. 587–597, 2019. Citado na página 28.
- SZEGEDY, C. et al. Going deeper with convolutions. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2015. p. 1–9. Citado na página 28.
- TAN, M.; LE, Q. Efficientnet: Rethinking model scaling for convolutional neural networks. In: PMLR. *International conference on machine learning*. [S.l.], 2019. p. 6105–6114. Citado na página 28.
- TRAYNOR, K. S. et al. Varroa destructor: A complex parasite, crippling honey bees worldwide. *Trends in parasitology*, Elsevier, v. 36, n. 7, p. 592–606, 2020. Citado na página 25.
- WARNER, S. et al. A scoping review on the effects of varroa mite (varroa destructor) on global honey bee decline. *Science of The Total Environment*, Elsevier, p. 167492, 2023. Citado na página 12.
- WIELEWSKI, P. et al. Níveis de infestação do ácaro varroa destructor em colônias de abelhas *apis mellifera* l. africanizadas submetidas à produção de geleia real ou rainhas. *Magistra*, v. 25, n. 1, p. 14–23, 2013. Citado na página 15.
- WINDEATT, T. Ensemble mlp classifier design. In: *Computational Intelligence Paradigms: Innovative Applications*. [S.l.]: Springer, 2008. p. 133–147. Citado na página 29.
- ZHANG, Y. et al. Real-time vehicle detection based on improved yolo v5. *Sustainability*, MDPI, v. 14, n. 19, p. 12274, 2022. Citado na página 28.



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

Identificação do Tipo de Documento

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

Eu, Millena Lira de Andrade Sousa, 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 “Identificação do ácaro Varroa em abelhas através do processamento e classificação de imagens” 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, 05 de Julho de 2025.

Documento assinado digitalmente
gov.br MILLENA LIRA DE ANDRADE SOUSA
Data: 05/07/2025 17:30:39-0300
Verifique em <https://validar.iti.gov.br>

Assinatura