



INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO PIAUÍ
CAMPUS FLORIANO
CURSO TECNÓLOGO EM ANÁLISE E DESENVOLVIMENTO DE SISTEMAS

ANDRÉ LUÍS LEITÃO DA SILVA

**Aplicação de modelos YOLO para detecção e contagem automática de pragas
agrícolas: uma análise bibliométrica**

FLORIANO - PI

2026

ANDRÉ LUÍS LEITÃO DA SILVA

**Aplicação de modelos YOLO para detecção e contagem automática de pragas
agrícolas: uma análise bibliométrica**

Trabalho de Conclusão de Curso (Monografia) apresentado como exigência parcial para obtenção do diploma do Curso Tecnólogo de Análise e Desenvolvimento de Sistemas do Instituto Federal de Educação, Ciência e Tecnologia do Piauí, Campus Floriano.

Orientador: Prof. Dr. Cícero Eduardo de Sousa Walter.

FLORIANO - PI

2026

ANDRÉ LUÍS LEITÃO DA SILVA

**Aplicação de modelos YOLO para detecção e contagem automática de pragas
agrícolas: uma análise bibliométrica**

Trabalho de Conclusão de Curso
(Monografia) apresentado como exigência
parcial para obtenção do diploma do
Curso Tecnólogo de Análise e
Desenvolvimento de Sistemas do Instituto
Federal de Educação, Ciência e
Tecnologia do Piauí, Campus Floriano.

Aprovado em: ____/____/____.

BANCA EXAMINADORA

Prof. Dr. Cícero Eduardo de Sousa Walter (Orientador)
Instituto Federal do Piauí (IFPI)

Prof. Me. Robson Pires Borges
Instituto Federal do Piauí (IFPI)

Prof. Dr. Rafael Ângelo Santos Leite
Instituto Federal do Piauí (IFPI)

RESUMO

As pragas agrícolas constituem um dos principais fatores responsáveis pela redução da produtividade das culturas, tornando indispensável o desenvolvimento de tecnologias capazes de otimizar seu monitoramento e controle. Nesse contexto, os modelos da família YOLO (*You Only Look Once*) destacam-se como uma das principais abordagens baseadas em Inteligência Artificial para detecção de objetos em tempo real, apresentando aplicações promissoras na agricultura. Diante do crescente volume de publicações sobre o tema, este trabalho teve como objetivo analisar o panorama científico da aplicação de modelos YOLO na detecção e contagem de pragas agrícolas por meio de uma análise bibliométrica da literatura publicada entre 2021 e 2026. A pesquisa foi conduzida na base de dados Scopus, seguindo critérios sistemáticos de busca, seleção e análise dos documentos. Para o tratamento dos dados foi empregado o pacote Bibliometrix, por meio da interface Biblioshiny, possibilitando a obtenção de indicadores de produção científica, impacto, colaboração e estrutura temática. Os resultados evidenciaram crescimento contínuo das publicações no período analisado, com concentração da produção em um conjunto reduzido de periódicos, autores, instituições e países, além da consolidação de temas relacionados à visão computacional, ao *deep learning*, à detecção de objetos e à agricultura de precisão. As análises temáticas também permitiram identificar linhas de investigação especializadas e temas emergentes, indicando oportunidades para o desenvolvimento de novas pesquisas. Conclui-se que a produção científica sobre modelos YOLO aplicados à detecção e contagem de pragas agrícolas apresenta expansão e diversificação, refletindo o crescente interesse da comunidade científica e fornecendo subsídios para futuras investigações e para o desenvolvimento de soluções mais eficientes voltadas à agricultura de precisão.

Palavras-chave: análise bibliométrica; YOLO; agricultura de precisão; detecção de pragas; inteligência artificial.

ABSTRACT

Agricultural pests are among the main factors responsible for reducing crop productivity, making the development of technologies capable of improving pest monitoring and control increasingly necessary. In this context, the YOLO (*You Only Look Once*) family of models has emerged as one of the leading Artificial Intelligence approaches for real-time object detection, showing promising applications in agriculture. Given the growing volume of scientific publications on this topic, this study aimed to analyze the scientific landscape of the application of YOLO models to agricultural pest detection and counting through a bibliometric analysis of the literature published between 2021 and 2026. The research was conducted using the Scopus database, following systematic criteria for document search, selection, and analysis. Data were processed using the Bibliometrix package through the Biblioshiny interface, enabling the analysis of scientific production, impact, collaboration, and thematic structure indicators. The results revealed a continuous increase in scientific publications throughout the analyzed period, with research concentrated in a limited number of journals, authors, institutions, and countries, as well as the consolidation of themes related to computer vision, deep learning, object detection, and precision agriculture. The thematic analyses also identified specialized research lines and emerging topics, highlighting opportunities for future investigations. It is concluded that the scientific production on YOLO models applied to agricultural pest detection and counting has experienced continuous growth and diversification, reflecting the increasing interest of the scientific community and providing valuable support for future research and the development of more efficient solutions for precision agriculture.

Keywords: bibliometric analysis; YOLO; precision agriculture; pest detection; artificial intelligence.

1 INTRODUÇÃO

As pragas agrícolas representam um dos principais desafios para a garantia da segurança alimentar global, sendo responsáveis por perdas significativas na produtividade e impactos econômicos expressivos nas lavouras (Khalid *et al.*, 2023). Segundo Khalid *et al.* (2023), o monitoramento e a identificação precoce desses organismos são etapas cruciais para o manejo fitossanitário eficiente. Contudo, os métodos tradicionais de inspeção visual manual são frequentemente limitados por exigirem elevado tempo de execução, apresentarem dependência da experiência do avaliador e estarem sujeitos à ocorrência de erros humanos (Khalid *et al.*, 2023; Sun *et al.*, 2024).

Nesse cenário, a Inteligência Artificial (IA), especialmente por meio do aprendizado profundo (*deep learning*), tem se consolidado como um dos principais pilares da agricultura inteligente (*smart agriculture*) (Ghazal; Munir; Qureshi, 2024). Conforme destacam Wang e Su (2022), diferentemente das abordagens clássicas de processamento de imagens, os modelos de *deep learning* possuem a capacidade de aprender representações hierárquicas diretamente dos dados, eliminando a necessidade de extração manual de características e proporcionando maior capacidade de generalização. Li *et al.* (2024) reforçam que as Redes Neurais Convolucionais (*Convolutional Neural Networks* – CNN) tornaram-se a abordagem predominante para tarefas de visão computacional em ambiente agrícola, dada sua eficácia no processamento de imagens de alta dimensão.

Entre as arquiteturas baseadas em CNN, a família YOLO (*You Only Look Once*) destaca-se pelo equilíbrio entre velocidade de inferência e precisão, tornando-se uma das principais arquiteturas empregadas em aplicações de detecção de objetos em tempo real (Khalid *et al.*, 2023; Li *et al.*, 2024). Na agricultura, os modelos YOLO têm sido amplamente utilizados na detecção de pragas, doenças, plantas daninhas e na contagem de frutos (Li *et al.*, 2024; Tian *et al.*, 2023).

Entretanto, a implementação desses modelos em ambientes agrícolas ainda enfrenta desafios relacionados às variações de iluminação, à complexidade do cenário, aos ruídos de fundo, à oclusão de alvos e à detecção de organismos de pequenas dimensões (Li *et al.*, 2024; Sun *et al.*, 2024; Tian *et al.*, 2023). Essas limitações têm impulsionado o desenvolvimento de adaptações arquiteturais, como

mecanismos de atenção e técnicas de fusão de características, visando aumentar a robustez e a precisão dos modelos em condições reais de campo (Li *et al.*, 2024; Tian *et al.*, 2023).

Além dos avanços tecnológicos, a adoção de sistemas inteligentes para o monitoramento de pragas contribui para a promoção de uma agricultura mais sustentável, ao possibilitar intervenções localizadas e direcionadas, reduzindo a aplicação indiscriminada de defensivos agrícolas e, conseqüentemente, os impactos ambientais, os custos de produção e os riscos à saúde humana (Ghazal; Munir; Qureshi, 2024; Khalid *et al.*, 2023).

Paralelamente ao avanço dessas tecnologias, observa-se uma expansão da produção científica relacionada à aplicação de modelos YOLO na agricultura, tornando necessária a organização e a sistematização do conhecimento produzido. Segundo Araújo (2006), a bibliometria consiste em um conjunto de técnicas quantitativas destinadas à análise da produção científica, permitindo compreender a estrutura e a evolução de um determinado campo do conhecimento. De forma complementar, Quevedo-Silva *et al.* (2016) destacam que a análise bibliométrica constitui uma metodologia capaz de gerar indicadores sobre produtividade científica, impacto das publicações e redes de colaboração entre autores, instituições e países, contribuindo para a compreensão da dinâmica de desenvolvimento de uma área de pesquisa.

Dessa forma, o presente trabalho tem como objetivo geral analisar o panorama científico da aplicação de modelos YOLO na detecção e contagem de pragas agrícolas, por meio de uma análise bibliométrica da literatura publicada entre 2021 e 2026. Para alcançar esse objetivo, foram definidos os seguintes objetivos específicos:

- a) levantar e selecionar os estudos publicados sobre a temática no período considerado;
- b) caracterizar a evolução da produção científica, identificando os principais autores, periódicos, instituições e países envolvidos;
- c) identificar os temas predominantes na literatura, analisando sua frequência, sua evolução temporal e suas relações com os demais elementos da produção científica;
- d) evidenciar temas consolidados, especializados e emergentes, bem como oportunidades para futuras investigações.

2 REFERENCIAL TEÓRICO

2.1 Inteligência artificial e deep learning na agricultura de precisão

Segundo Dai *et al.* (2024), a integração de tecnologias de Inteligência Artificial na agricultura tem transformado o monitoramento de cultivos, promovendo a transição de métodos manuais tradicionais para sistemas automatizados de alta precisão. Os autores demonstram que a aplicação de modelos de *deep learning* permite que máquinas identifiquem padrões complexos de doenças e pragas diretamente de imagens digitais, superando a subjetividade inerente à inspeção humana. Nesse contexto, enquanto algoritmos de *machine learning* clássicos dependiam da extração manual de características — como cor ou textura —, as Redes Neurais Convolucionais (CNN) estabeleceram um novo paradigma ao aprenderem automaticamente representações hierárquicas a partir dos dados, fator determinante para lidar com a alta variabilidade visual típica do ambiente de campo.

2.2 A arquitetura YOLO para detecção de objetos em tempo real

Conforme apontam Tian *et al.* (2023), a família YOLO (*You Only Look Once*) consolidou-se como um marco na visão computacional ao reformular a detecção de objetos como um problema de regressão única, permitindo que a predição ocorra em uma única passagem pela rede neural. Em seu estudo sobre o modelo MD-YOLO, os autores explicam que a eficácia dessa arquitetura reside na capacidade de integrar redes de extração de características com mecanismos de fusão multiescala, possibilitando a predição simultânea da classe e da localização precisa dos alvos.

Segundo os pesquisadores, é justamente esse design otimizado que torna o YOLO o estado da arte para aplicações em tempo real, cenário no qual o equilíbrio entre a velocidade de processamento e a precisão da detecção é determinante para a viabilidade de sistemas autônomos.

2.3 Desafios técnicos na detecção de pragas: pequenos alvos e ambientes complexos

A aplicação de arquiteturas YOLO em ambientes agrícolas reais impõe desafios que, conforme apontam Sun *et al.* (2024), transcendem as condições ideais de laboratório, sendo a detecção de pragas de dimensões diminutas e o fenômeno

da oclusão os obstáculos mais críticos para o desempenho do modelo. Os autores destacam que a alta mobilidade das pragas e a capacidade de camuflagem na vegetação exigem que a arquitetura base do YOLO passe por modificações estruturais para manter a acurácia. Segundo Sun *et al.* (2024), a implementação de mecanismos de atenção, como o SimAM, ou de redes de pirâmide de características (*Feature Pyramid Networks* – FPN), torna-se indispensável para que o modelo consiga focar em alvos de pequenas dimensões (*small target detection*). Essa otimização é apresentada pelos autores como a solução para reduzir a taxa de falsos negativos em infestações densas, sendo este o ponto de partida necessário para viabilizar a contagem automática de populações de pragas com confiabilidade.

2.4 Métricas de desempenho em visão computacional

Para assegurar a validade científica na análise de modelos de detecção de objetos, é imprescindível a utilização de métricas padronizadas que quantifiquem tanto a acurácia quanto a eficiência do sistema. Conforme discutido por Tian *et al.* (2023), o desempenho dos modelos em cenários de detecção de pragas é avaliado primordialmente pela *mean Average Precision* (mAP), que consolida a média da precisão em diferentes limites de intersecção sobre a união (*Intersection over Union* – IoU). Complementarmente, os autores destacam que as métricas de precisão (*precision*) e revocação (*recall*) são determinantes para medir a capacidade do algoritmo em identificar corretamente os alvos e minimizar a perda de detecções em infestações densas.

Em paralelo, Li *et al.* (2024) enfatizam que a aplicabilidade prática dos modelos de visão computacional — especialmente para a implementação em sistemas de monitoramento em tempo real — é intrinsecamente dependente da velocidade de inferência. Segundo os autores, a taxa de quadros por segundo (*Frames Per Second* – FPS) constitui, portanto, uma métrica de desempenho indispensável, definindo a viabilidade técnica do modelo para o processamento de fluxos de vídeo em ambientes agrícolas. Assim, a combinação dessas métricas permite que pesquisadores identifiquem não apenas o modelo com maior precisão teórica, mas também aquele capaz de equilibrar o custo computacional com a confiabilidade necessária para a automação no campo.

3 METODOLOGIA

Esta investigação utilizou a análise bibliométrica como o procedimento metodológico central. A adoção desta técnica justifica-se pela sua capacidade de mensurar o desenvolvimento científico e mapear a disseminação do conhecimento, permitindo uma compreensão aprofundada da comunicação científica e do impacto das pesquisas em uma área específica (Grácio *et al.*, 2020).

No que tange à classificação metodológica, o presente trabalho caracteriza-se como uma pesquisa exploratória e de abordagem quantitativa. A natureza exploratória é evidenciada pela busca de identificar tendências e lacunas de investigação ainda não consolidadas pela literatura, enquanto a abordagem quantitativa é definida pela aplicação de mensuração estatística sobre indicadores bibliométricos, procedimento consolidado nas ciências sociais aplicadas para facilitar a familiaridade com o estado da arte do tema (Quevedo-Silva *et al.*, 2016).

A pesquisa é, primordialmente, de natureza bibliográfica, baseando-se na análise de dados secundários extraídos da literatura científica. A fonte de informação escolhida para a coleta foi a base de dados Scopus. Esta escolha é fundamentada pelo fato de a Scopus constituir um repositório de dados bibliométricos curado, de alta qualidade e essencial para a realização de estudos quantitativos científicos, garantindo a robustez dos dados utilizados para o processamento estatístico (Baas *et al.*, 2020).

O processo de busca foi executado por meio de uma *string* de busca combinada com operadores booleanos: (TITLE-ABS-KEY("YOLO" AND "Agriculture" AND "AI") AND (LIMIT-TO(DOCTYPE,"ar")) AND (LIMIT-TO(LANGUAGE,"English")) AND (LIMIT-TO(OA,"all"))). A pesquisa foi realizada nos campos de título, resumo e palavras-chave da base Scopus, sendo considerados apenas artigos científicos, publicados em inglês e disponíveis em acesso aberto. Após a recuperação dos registros e sua importação para o ambiente RStudio, o conjunto de dados processado compreendeu 80 artigos científicos indexados entre 2021 e 2026, período que corresponde ao recorte temporal efetivamente representado no *corpus* analisado.

Os dados bibliográficos foram processados no *software* RStudio (versão 2026.06.0), utilizando o pacote Bibliometrix, por meio da interface Biblioshiny (Aria; Cuccurullo, 2017), o que permitiu a extração de indicadores bibliométricos como

produtividade científica, colaboração entre autores e demais métricas empregadas na análise.

4 RESULTADOS E DISCUSSÃO

Esta seção apresenta os resultados e a discussão dos mesmos. De forma detalhada, são evidenciados os principais atributos bibliométricos da área de investigação em análise.

4.1 Panorama geral e evolução da produção científica

Figura 1 – Panorama geral da produção científica sobre a aplicação de modelos YOLO na agricultura



Fonte: Elaborado pelo autor (2026).

A Figura 1 apresenta um panorama geral da base bibliográfica analisada, sintetizando os principais indicadores da produção científica sobre a aplicação de modelos YOLO na agricultura. O conjunto de dados é composto por 80 artigos científicos, publicados entre 2021 e 2026, distribuídos em 43 periódicos. Observa-se uma taxa de crescimento anual de 69,52%, evidenciando a rápida expansão das pesquisas na área, impulsionada pelos avanços em Inteligência Artificial e agricultura de precisão.


A produção científica analisada reúne 410 autores, com média de 5,28 coautores por documento, indicando um elevado nível de colaboração entre pesquisadores. Além disso, aproximadamente 33,75% das publicações resultam de cooperação internacional, evidenciando o interesse global pelo desenvolvimento de soluções baseadas em modelos YOLO para aplicações agrícolas.

Em relação ao conteúdo da base, foram identificadas 306 palavras-chave dos autores e um total de 3.847 referências bibliográficas. A idade média dos documentos foi de 1,06 ano, refletindo a atualidade da temática, enquanto a média

de 15,15 citações por artigo demonstra que as publicações vêm alcançando relevância na comunidade científica.

De modo geral, os indicadores evidenciam uma área de pesquisa recente, em rápida expansão e caracterizada por intensa colaboração científica, constituindo uma base consistente para as análises bibliométricas apresentadas nas seções seguintes.

Figura 2 – Produção científica ao longo dos anos




Fonte: Elaborado pelo autor (2026).

A Figura 2 apresenta a evolução anual da produção científica relacionada à aplicação de modelos YOLO na agricultura durante o período analisado. Observa-se que, entre 2021 e 2023, o número de publicações permaneceu reduzido, indicando uma fase inicial de consolidação do tema na literatura científica.

A partir de 2024, verifica-se um crescimento expressivo da produção científica, culminando no maior volume de publicações em 2025. No último ano do período analisado, observa-se uma redução no número de artigos indexados em relação ao ano anterior. Entretanto, esse comportamento deve ser interpretado com cautela, uma vez que pode estar relacionado à indexação parcial das publicações na base consultada ou ao fato de o ano de 2026 ainda estar em andamento no momento da coleta dos dados.


De modo geral, a tendência observada evidencia o crescente interesse da comunidade científica pela aplicação de modelos YOLO na agricultura, refletindo os avanços da visão computacional e da agricultura de precisão.

Figura 3 – Média de citações por ano



Fonte: Elaborado pelo autor (2026).

A Figura 3 apresenta a média de citações dos artigos conforme o ano de publicação. Observa-se que 2023 apresentou a maior média de citações entre os anos analisados, indicando que os estudos publicados nesse período alcançaram maior impacto científico. Em contrapartida, a partir de 2024 verifica-se uma redução gradual da média de citações, sendo o menor valor observado em 2026. Esse comportamento é esperado em estudos bibliométricos, pois publicações mais recentes ainda dispõem de menos tempo para serem citadas. Dessa forma, a menor média de citações nos anos finais do período analisado não representa, necessariamente, menor relevância científica, mas reflete a influência do fator temporal sobre o acúmulo de citações.

Figura 4 – Frequência das palavras-chave ao longo do tempo

Fonte: Elaborado pelo autor (2026).

A Figura 4 apresenta a evolução da frequência acumulada das principais palavras-chave empregadas nas publicações analisadas. Observa-se que *deep learning* se destaca como o termo de maior ocorrência ao longo do período, evidenciando seu papel central nas pesquisas relacionadas à aplicação de modelos YOLO na agricultura. Também se observa crescimento expressivo dos termos *precision agriculture*, YOLO e *object detection*, refletindo o aumento do interesse por técnicas de visão computacional aplicadas ao monitoramento agrícola. Além disso, palavras-chave como *computer vision*, *artificial intelligence* e *agriculture* apresentaram crescimento contínuo, indicando a consolidação dessas temáticas como pilares das pesquisas desenvolvidas na área. De modo geral, a evolução das palavras-chave evidencia o fortalecimento das aplicações de Inteligência Artificial e detecção de objetos na agricultura de precisão ao longo dos anos analisados.


Figura 5 – Nuvem de palavras-chave da produção científica analisada



Fonte: Elaborado pelo autor (2026).

A Figura 5 apresenta a nuvem de palavras-chave dos artigos analisados, em que o tamanho dos termos é proporcional à sua frequência de ocorrência na literatura. Como os termos são extraídos diretamente dos registros indexados, apresentam-se em língua inglesa. Observa-se o predomínio das palavras-chave *deep learning*, *precision agriculture*, *computer vision*, *YOLO*, *object detection* e *artificial intelligence*, evidenciando que a aplicação de técnicas de Inteligência Artificial e visão computacional constitui o principal eixo das pesquisas na área. Além disso, termos como *smart agriculture*, *plant disease*, *weed detection* e *machine learning* também apresentam destaque, indicando a diversidade de aplicações dos modelos de detecção de objetos no contexto agrícola. De modo geral, a distribuição das palavras-chave demonstra a forte integração entre agricultura de precisão, aprendizado profundo e técnicas de detecção de objetos como base para o desenvolvimento de soluções voltadas ao monitoramento automatizado de cultivos.

4.2 Fontes, autores e instituições


Figura 6 – Produção dos autores ao longo dos anos

Fonte: Elaborado pelo autor (2026).

A Figura 6 apresenta a evolução da produção científica dos autores ao longo do período analisado, evidenciando o intervalo em que cada pesquisador publicou trabalhos relacionados ao tema. Observa-se que autores como Lan Y. e Tahir M. N. mantiveram publicações distribuídas entre 2023 e 2026, demonstrando a continuidade de suas contribuições. Da mesma forma, Wang J. apresenta produção entre 2024 e 2025, enquanto Christakakis P., Kapetas D. e Pechlivani E. M. registram publicações entre 2025 e 2026.

Além do período de atuação, o gráfico permite observar o volume de publicações por meio do tamanho dos círculos, indicando que alguns autores apresentaram maior produtividade em determinados anos. A tonalidade dos marcadores representa o número de citações por ano, sendo que os tons mais escuros correspondem a artigos com maior repercussão científica. Nesse contexto, destaca-se Wang J., que apresenta o marcador de maior intensidade, indicando maior número de citações no período representado.

De modo geral, os resultados evidenciam a participação contínua de diferentes pesquisadores na evolução das pesquisas sobre a aplicação de modelos YOLO na agricultura, demonstrando que a produção científica da área está distribuída entre diversos autores e grupos de pesquisa.

Figura 7 – Produção dos países ao longo do tempo


Fonte: Elaborado pelo autor (2026).

A Figura 7 apresenta a evolução da produção científica dos países ao longo do período analisado. Observa-se que a China se destaca como o país com maior crescimento no número de publicações, assumindo a liderança a partir de 2024 e alcançando o maior volume de artigos em 2026. Os Estados Unidos também apresentam crescimento contínuo ao longo dos anos, consolidando-se como o segundo país com maior produção científica.

A Índia demonstra um aumento mais expressivo a partir de 2025, enquanto o Brasil registra crescimento até 2024, mantendo posteriormente um volume estável de publicações. O Paquistão, embora apresente menor produção em comparação aos demais países, também evidencia evolução gradual durante o período analisado.

De modo geral, os resultados demonstram que a produção científica sobre a aplicação de modelos YOLO na agricultura encontra-se concentrada principalmente na China e nos Estados Unidos, refletindo o protagonismo desses países no desenvolvimento de pesquisas voltadas à Inteligência Artificial e à agricultura de precisão, ao mesmo tempo em que evidenciam a ampliação da participação de outros países na temática.

Figura 8 – Distribuição dos periódicos segundo a Lei de Bradford




Fonte: Elaborado pelo autor (2026).

A Figura 8 apresenta a distribuição dos periódicos que compõem o *corpus* analisado segundo a Lei de Bradford, princípio bibliométrico segundo o qual um pequeno núcleo de periódicos concentra a maior parte dos artigos de uma área, enquanto os demais se dispersam por um número crescente de fontes (Grácio *et al.*, 2020). Observa-se que o núcleo (*core*) é formado por cinco periódicos, responsáveis por concentrar a maior parte dos artigos, enquanto a Zona 2 reúne 12 periódicos e a Zona 3 compreende 26, evidenciando uma distribuição progressiva das publicações entre um número crescente de fontes.

Os resultados indicam que o conhecimento produzido encontra-se concentrado em um conjunto reduzido de periódicos, ao passo que os demais estudos estão distribuídos entre diversas fontes de publicação. Esse comportamento demonstra a consolidação do tema em periódicos de referência e, simultaneamente, sua expansão para diferentes veículos científicos, evidenciando o crescente interesse da comunidade científica pela área de pesquisa.

Após identificar a concentração das publicações em um número reduzido de periódicos, torna-se pertinente analisar quais são essas fontes e sua participação na produção científica, conforme apresentado na Figura 9.

Figura 9 – Periódicos com maior número de publicações



Fonte: Elaborado pelo autor (2026).

Observa-se que o periódico *Smart Agricultural Technology* ocupa a primeira posição, com oito publicações, seguido por *Scientific Reports*, com sete, e *Frontiers in Plant Science*, com seis. Em seguida, destacam-se *IEEE Access* e *Sensors*, ambos com cinco publicações.

Os periódicos *Agriculture (Switzerland)*, *AgriEngineering* e *Computers and Electronics in Agriculture* registram quatro publicações cada, enquanto *Applied Sciences (Switzerland)* e *IAES International Journal of Artificial Intelligence* apresentam duas publicações. Esses resultados evidenciam que a produção científica está concentrada em periódicos voltados às áreas de agricultura de precisão, visão computacional, inteligência artificial e tecnologias aplicadas ao setor agrícola.

Além da identificação dos principais periódicos, também é importante analisar os pesquisadores responsáveis por essa produção científica. A Figura 10 apresenta os autores mais produtivos do *corpus*.

Figura 10 – Autores mais produtivos




Fonte: Elaborado pelo autor (2026).

A Figura 10 apresenta os autores com maior número de publicações no *corpus* analisado. Observa-se que Xu J. se destaca com três publicações, sendo o pesquisador mais produtivo entre os autores identificados. Os demais autores, entre eles Christakakis P., Deng B., Kapetas D., Kumar S., Lan Y., Lu Y., Pechlivani E. M., Tahir M. N. e Wang J., apresentam duas publicações cada.

Os resultados evidenciam que a produção científica encontra-se distribuída entre diferentes pesquisadores, sem predominância expressiva de um único autor. Esse cenário demonstra que o desenvolvimento da área ocorre de forma colaborativa, com contribuições de diversos pesquisadores que atuam na consolidação e expansão do conhecimento.

Complementando a análise dos pesquisadores, a Figura 11 apresenta as instituições às quais esses autores estão vinculados, permitindo identificar os principais centros responsáveis pela produção científica.


Figura 11 – Instituições com maior número de publicações

Fonte: Elaborado pelo autor (2026).

Observa-se que a *Kansas State University* lidera o número de publicações, com seis artigos, seguida pela *PMAS-Arid Agriculture University*, com quatro publicações. As demais instituições, entre elas *China Agricultural University*, Instituto Federal Goiano – Campus Ceres, *Ibn Zohr University*, *International Center for Tropical Agriculture*, *North Dakota State University*, *Seoul National University*, *Sri Lanka Institute of Information Technology* e *University of Sri Jayewardenepura*, registram três publicações cada.

Os resultados evidenciam que a produção científica está distribuída entre diferentes instituições de ensino e pesquisa, indicando a participação de universidades e centros de pesquisa de diversos países no desenvolvimento da área. Essa diversidade institucional demonstra o interesse crescente da comunidade científica e o fortalecimento das colaborações voltadas ao avanço das pesquisas.

Após identificar as principais instituições responsáveis pelas publicações, a análise retorna aos periódicos para observar como sua produção evoluiu ao longo do período analisado, conforme apresentado na Figura 12.

Figura 12 – Produção acumulada das fontes ao longo do tempo


Fonte: Elaborado pelo autor (2026).

Observa-se que o periódico *Frontiers in Plant Science* iniciou sua participação mais cedo e manteve crescimento contínuo desde 2021. Por outro lado, *Smart Agricultural Technology* apresentou crescimento mais acentuado a partir de 2025, tornando-se o periódico com maior número acumulado de publicações em 2026.

Os periódicos *Scientific Reports*, *Sensors* e *IEEE Access* também registraram aumento gradual no número de publicações ao longo dos anos, acompanhando a expansão da área de pesquisa. De modo geral, os resultados evidenciam que, embora alguns periódicos tenham iniciado suas publicações em anos anteriores, o crescimento mais expressivo ocorreu a partir de 2024, indicando uma intensificação da produção científica e maior interesse das fontes especializadas pela temática.

A análise das fontes evidencia onde a produção científica foi publicada e como ela evoluiu ao longo do tempo. Em seguida, o foco desloca-se para os autores, buscando compreender o padrão de produtividade dos pesquisadores que compõem o campo analisado. Para isso, a Figura 13 apresenta a distribuição da produção científica segundo a Lei de Lotka.

Figura 13 – Distribuição da produtividade dos autores segundo a Lei de Lotka



Fonte: Elaborado pelo autor (2026).

A Figura 13 apresenta a distribuição da produtividade dos autores, fundamentada na Lei de Lotka, um dos princípios clássicos da bibliometria utilizado para avaliar os padrões de produção científica. Conforme discutem Grácio *et al.* (2020), essa lei estabelece que a maior parte dos pesquisadores tende a publicar apenas um trabalho em determinado tema, enquanto um número reduzido de autores concentra múltiplas publicações.


Conforme observado, aproximadamente 97% dos autores publicaram apenas um documento, enquanto cerca de 2,5% publicaram dois trabalhos e uma parcela inferior a 1% publicou três documentos. Esse comportamento evidencia uma elevada concentração de autores ocasionais e um grupo bastante restrito de pesquisadores com produção recorrente na temática investigada.

Além disso, o elevado ajuste do modelo à distribuição observada ($R^2 = 0,9997$) e os valores do teste de Kolmogorov-Smirnov ($p > 0,05$) indicam que os dados apresentam forte aderência ao padrão previsto pela Lei de Lotka, reforçando que o campo de pesquisa ainda é caracterizado por ampla dispersão da autoria e baixa concentração de pesquisadores altamente produtivos.

Os resultados da Lei de Lotka evidenciam que a produção científica sobre inteligência artificial aplicada à agricultura é concentrada em um amplo conjunto de

autores com baixa recorrência de publicações, característica típica de áreas em expansão e fortemente multidisciplinares. Além da distribuição da produtividade entre os pesquisadores, torna-se relevante identificar como essa produção está distribuída entre as instituições de pesquisa ao longo do tempo. Nesse contexto, a Figura 14 apresenta a evolução da produção das principais afiliações presentes na amostra, permitindo identificar os centros de pesquisa que vêm contribuindo de forma mais consistente para o desenvolvimento da área.

Figura 14 – Produção das principais afiliações ao longo do tempo



Fonte: Elaborado pelo autor (2026).

Observa-se que diferentes afiliações passaram a contribuir para o desenvolvimento da temática em momentos distintos, evidenciando a expansão gradual da pesquisa sobre inteligência artificial aplicada à agricultura.

Entre as instituições com maior continuidade de produção destaca-se a *Kansas State University*, que inicia sua participação em 2022 e mantém crescimento constante, alcançando seis publicações acumuladas em 2026. Também se sobressaem a *PMAS-Arid Agriculture University*, a *North Dakota State University*, o *International Center for Tropical Agriculture* (CIAT) e a *University of Sri Jayewardenepura*, que apresentam evolução progressiva ao longo do período analisado. Outras instituições, como a *China Agricultural University*, a *Ibn Zohr University* e o Instituto Federal Goiano, passam a contribuir de forma mais


expressiva nos anos mais recentes, indicando a incorporação de novos grupos de pesquisa ao campo investigado.

De maneira geral, o comportamento observado revela que a produção científica encontra-se distribuída entre diferentes universidades e centros de pesquisa localizados em distintas regiões do mundo, reforçando o caráter internacional e multidisciplinar da área. O crescimento simultâneo de diversas instituições sugere que o avanço da inteligência artificial aplicada à agricultura não está concentrado em um único polo de pesquisa, mas resulta da atuação conjunta de universidades e centros especializados que vêm ampliando suas contribuições nos últimos anos.

4.3 Impacto científico

A análise das principais afiliações evidencia as instituições que vêm contribuindo de forma mais consistente para o avanço das pesquisas sobre inteligência artificial aplicada à agricultura, demonstrando a distribuição geográfica e institucional da produção científica. Entretanto, compreender apenas quem produz esse conhecimento não é suficiente para caracterizar a estrutura da área. Também é necessário identificar os periódicos que concentram as publicações de maior relevância e influência científica. Nesse contexto, a Figura 15 apresenta o impacto local das principais fontes de publicação, mensurado por meio do índice H, permitindo avaliar quais periódicos combinam maior produtividade com maior reconhecimento dentro da coleção bibliográfica analisada.

Figura 15 – Impacto local dos periódicos segundo o índice H



Fonte: Elaborado pelo autor (2026).

Observa-se que *Frontiers in Plant Science* e *Scientific Reports* apresentam os maiores índices H ($H = 4$), indicando que essas revistas reúnem um conjunto consistente de artigos que alcançaram elevado impacto dentro do *corpus* analisado. Esse resultado evidencia que ambas se consolidaram como importantes veículos para a divulgação de pesquisas relacionadas à aplicação de inteligência artificial, aprendizado profundo e visão computacional na agricultura.

Em um segundo nível de impacto encontram-se *Agriculture (Switzerland)*, *Computers and Electronics in Agriculture* e *IEEE Access*, todas com índice H igual a 3. Embora apresentem um impacto ligeiramente inferior ao dos dois periódicos líderes, essas fontes demonstram significativa relevância científica e desempenham papel importante na disseminação do conhecimento na área, reunindo estudos frequentemente utilizados como referência pelas pesquisas subsequentes.


Na sequência, *AgriEngineering*, *Applied Sciences (Switzerland)*, *Sensors* e *Smart Agricultural Technology* registram índice H igual a 2, enquanto *Actuators* apresenta índice H igual a 1. Esses resultados sugerem que, apesar de possuírem menor influência relativa dentro do conjunto analisado, esses periódicos também contribuem para o desenvolvimento da temática, especialmente por meio da

publicação de pesquisas mais especializadas ou de inserção mais recente no campo.

De forma geral, a distribuição dos índices H evidencia que o impacto científico das fontes não depende exclusivamente do volume de publicações, mas também da capacidade dos artigos publicados em gerar repercussão e servir como referência para novos estudos. Em conjunto com a análise apresentada na Figura 12, esses resultados demonstram que alguns dos periódicos mais produtivos também figuram entre os de maior impacto científico, reforçando sua importância para a consolidação e disseminação do conhecimento sobre aplicações de inteligência artificial na agricultura.

Após a identificação dos periódicos com maior impacto local na amostra, a análise avança para o nível dos artigos individuais, permitindo identificar quais estudos exercem maior influência na literatura internacional sobre o tema. A Figura 16 apresenta os documentos mais citados globalmente na base analisada, evidenciando os estudos que alcançaram maior repercussão na literatura científica internacional.

Figura 16 – Documentos mais citados globalmente




Fonte: Elaborado pelo autor (2026).

Observa-se uma concentração significativa de citações em dois trabalhos recentes, com destaque para Sapkota *et al.* (2025), publicado na *Artificial*

Intelligence Review, que acumula 223 citações, seguido por Rai *et al.* (2023), publicado na *Computers and Electronics in Agriculture*, com 221 citações. Em um segundo nível aparecem Adami, Ojo e Giordano (2021) , com 80 citações, e Quach *et al.* (2024), com 69 citações, enquanto os demais documentos apresentam entre 38 e 61 citações.

Os resultados indicam que determinados estudos assumiram posição de referência na área, tornando-se importantes marcos para pesquisas posteriores. O elevado número de citações dos trabalhos de Sapkota *et al.* (2025) e Rai *et al.* (2023) evidencia que essas publicações abordam temas de grande relevância e atualidade — respectivamente, a revisão histórica da família YOLO e as aplicações do aprendizado profundo no manejo de plantas daninhas —, consolidando-se como referências para pesquisadores que investigam o tema. Além disso, observa-se que os artigos mais influentes estão distribuídos entre periódicos de elevado impacto, como *Artificial Intelligence Review*, *Computers and Electronics in Agriculture*, *IEEE Access*, *Scientific Reports* e *Frontiers in Plant Science*, reforçando a estreita relação entre a qualidade das fontes de publicação e a visibilidade alcançada pelos estudos.

Após identificar os documentos de maior repercussão internacional, a análise passa a examinar os autores mais citados localmente na própria coleção bibliográfica. Enquanto as citações globais refletem o reconhecimento de um estudo pela comunidade científica em geral, as citações locais evidenciam quais pesquisadores exercem maior influência intelectual especificamente sobre o conjunto de trabalhos que compõem esta revisão. A Figura 17 apresenta esses autores.

Figura 17 – Autores mais citados localmente

Fonte: Elaborado pelo autor (2026).


Observa-se o predomínio de Redmon J., com 54 citações locais, posicionando-se de forma bastante destacada em relação aos demais autores. Em seguida aparecem Bochkovskiy A. e Wang C.-Y., ambos com 20 citações, enquanto Liu W. e Ren S. registram 15 e 14 citações, respectivamente. Os demais autores listados apresentam 13 citações locais, indicando participação relevante na fundamentação teórica do conjunto analisado.

Esse padrão evidencia que a base bibliográfica utilizada na literatura apresenta um núcleo relativamente concentrado de referências recorrentes, especialmente em torno de pesquisadores responsáveis por importantes avanços na área de visão computacional e detecção de objetos, tecnologias amplamente empregadas em aplicações de inteligência artificial na agricultura. O destaque de Redmon J. demonstra a forte presença de estudos fundamentados na família de algoritmos YOLO (*You Only Look Once*), amplamente utilizada para tarefas de identificação, monitoramento e classificação em ambientes agrícolas. Dessa forma, as citações locais revelam não apenas os autores mais influentes dentro da amostra analisada, mas também as principais bases metodológicas que sustentam o desenvolvimento recente das pesquisas na área.

4.4 Estrutura temática

Após a análise dos indicadores de impacto científico, torna-se pertinente examinar a estrutura temática da produção científica analisada. Enquanto as figuras anteriores evidenciaram os principais autores, periódicos e documentos de maior influência, a Figura 18 apresenta as palavras-chave de maior recorrência nos estudos selecionados, permitindo identificar os temas predominantes que caracterizam esse campo de pesquisa.

Figura 18 – Palavras mais relevantes da produção científica



Fonte: Elaborado pelo autor (2026).

Conforme observado na Figura 18, o termo *deep learning* apresentou a maior frequência, com 36 ocorrências, evidenciando que as técnicas de aprendizado profundo constituem a principal base tecnológica das pesquisas sobre a aplicação de modelos YOLO na agricultura. Em seguida, destacam-se *precision agriculture* (31 ocorrências) e YOLO (27 ocorrências), confirmando que os estudos concentram-se no desenvolvimento e na aplicação de modelos de detecção em cenários de agricultura de precisão.


Entre os demais termos de maior relevância estão *object detection* (22 ocorrências), *computer vision* (21), *artificial intelligence* (19) e *agriculture* (16), demonstrando a forte integração entre inteligência artificial, visão computacional e técnicas de detecção de objetos voltadas para aplicações agrícolas. Também aparecem *object recognition* e *objects detection*, ambos com 11 ocorrências, além de

smart agriculture, com 9 ocorrências, indicando a presença de pesquisas direcionadas à automação, ao monitoramento inteligente e à digitalização das atividades agrícolas.

De maneira geral, a distribuição das palavras-chave evidencia que a produção científica analisada está fortemente estruturada em torno da aplicação de técnicas de aprendizado profundo e visão computacional para a detecção de objetos no contexto da agricultura de precisão. Esse resultado reforça o caráter interdisciplinar da área, que combina avanços em inteligência artificial com soluções voltadas ao aumento da eficiência, da automação e da sustentabilidade dos sistemas agrícolas.

Embora a frequência das palavras-chave permita identificar os principais temas abordados pela literatura, essa análise não evidencia como esses assuntos evoluíram ao longo do período investigado. Para complementar essa perspectiva, a Figura 19 apresenta a evolução temporal dos principais tópicos de pesquisa, permitindo observar o surgimento, a permanência e a consolidação das tendências temáticas na aplicação dos modelos YOLO à agricultura.

Figura 19 – Evolução temporal dos principais tópicos de pesquisa



Fonte: Elaborado pelo autor (2026).

Conforme observado na Figura 19, os tópicos *deep learning*, YOLO e *precision agriculture* destacam-se como os principais eixos temáticos da produção científica recente. Esses termos apresentam maior frequência de ocorrência e

permanecem ativos ao longo do período analisado, evidenciando sua consolidação como fundamentos das pesquisas relacionadas à aplicação de modelos YOLO no contexto agrícola.


Além desses temas centrais, observa-se a presença de tópicos como *image processing*, *plant diseases* e *learning systems*, que passam a ganhar destaque em publicações mais recentes. Esse comportamento indica uma diversificação das aplicações dos modelos baseados em aprendizado profundo, abrangendo tarefas específicas, como o processamento de imagens agrícolas, o diagnóstico automatizado de doenças em plantas e o desenvolvimento de sistemas inteligentes de apoio à produção.

Por outro lado, o tema *weed detection* apresenta ocorrência ao longo de praticamente todo o período analisado, demonstrando que a identificação automática de plantas daninhas permanece como uma das aplicações mais consolidadas da visão computacional e dos modelos YOLO na agricultura. Esse resultado evidencia que, embora novas linhas de investigação tenham emergido recentemente, determinadas aplicações continuam desempenhando papel central no desenvolvimento da área.

De forma geral, a evolução dos tópicos revela uma transição de estudos inicialmente concentrados em aplicações específicas para pesquisas cada vez mais orientadas ao emprego integrado de técnicas de aprendizado profundo, visão computacional e agricultura de precisão, refletindo o amadurecimento e a expansão do campo de pesquisa.

A evolução dos tópicos permite compreender quais temas vêm orientando a produção científica ao longo do tempo. Entretanto, para uma visão mais integrada da estrutura do campo, torna-se necessário analisar como esses temas se relacionam com os principais autores e países envolvidos nas pesquisas. Nesse contexto, a Figura 20 apresenta o *Three-Fields Plot*, evidenciando as conexões entre países, autores e palavras-chave predominantes na literatura analisada.

Figura 20 – Relação entre autores, países e palavras-chave da produção científica (Three-Fields Plot)



Fonte: Elaborado pelo autor (2026).

Observa-se que os autores analisados estão vinculados a instituições localizadas em diversos países, com destaque para Estados Unidos, China, Índia e Paquistão, que concentram o maior número de conexões com os pesquisadores representados. Também aparecem contribuições provenientes de Brasil, Canadá, Reino Unido, Itália, Japão, Turquia, Arábia Saudita, Sri Lanka, Egito, Grécia, Hong Kong, Coreia, Marrocos, Letônia e Uzbequistão, indicando que as pesquisas sobre aplicação de modelos YOLO na agricultura possuem caráter internacional e envolvem diferentes centros de pesquisa.


No conjunto das palavras-chave, destacam-se *deep learning*, *precision agriculture*, YOLO, *object detection*, *computer vision*, *artificial intelligence* e *agriculture*, que recebem conexões provenientes de diversos países e autores. Esse padrão reforça que essas temáticas constituem o núcleo conceitual da área, sendo recorrentes independentemente da origem geográfica das pesquisas. Além desses termos centrais, também aparecem tópicos mais específicos, como *crops*, *weed detection*, *plant diseases*, *image processing*, *object recognition*, *smart agriculture*, *algorithms* e *machine learning*, evidenciando a diversidade de aplicações desenvolvidas a partir da arquitetura YOLO.

De forma geral, o *Three-Fields Plot* demonstra que a produção científica sobre o uso de modelos YOLO na agricultura é sustentada por uma ampla rede internacional de pesquisadores e instituições, cujas contribuições convergem para

um conjunto consistente de temas centrais relacionados à visão computacional, ao aprendizado profundo e à agricultura de precisão.

Embora a Figura 20 evidencie as relações entre autores, países e temas de pesquisa, torna-se igualmente relevante compreender como esses temas se posicionam na estrutura do campo científico. Nesse sentido, a Figura 21 apresenta o mapa temático da produção científica analisada, permitindo identificar os temas consolidados, especializados e aqueles que ainda representam oportunidades para futuras investigações.

Figura 21 – Mapa temático da produção científica analisada



Fonte: Elaborado pelo autor (2026).

Observa-se que o quadrante superior direito, correspondente aos temas motores, reúne os tópicos *deep learning*, *precision agriculture* e *crops*, formando o principal núcleo de desenvolvimento da literatura. Esses temas apresentam simultaneamente elevada centralidade e densidade, indicando que exercem papel estruturante na área e possuem elevado grau de maturidade científica. Esse

resultado confirma as análises apresentadas nas Figuras 18 e 19, nas quais esses termos também se destacaram entre os mais frequentes e persistentes ao longo da evolução temporal da produção científica.

Ainda nesse quadrante, aparecem os termos *animals*, *image processing* e *smart agriculture*, evidenciando aplicações específicas que vêm apresentando crescente desenvolvimento e integração com o núcleo principal da pesquisa. Esses resultados sugerem uma ampliação das aplicações dos modelos YOLO para diferentes segmentos do setor agrícola, além da tradicional detecção de objetos em lavouras.

No quadrante inferior direito, referente aos temas básicos, destacam-se *object detection*, *objects detection* e *object recognition*. Embora apresentem elevada centralidade, sua menor densidade indica que representam fundamentos amplamente utilizados pela comunidade científica, servindo como base metodológica para diversas aplicações, mas ainda com potencial para aprofundamento em diferentes contextos agrícolas.

Por outro lado, o quadrante superior esquerdo, correspondente aos temas de nicho, concentra tópicos como *plant disease*, *plant diseases*, *plant leaf*, *artificial intelligence* e *remote sensing*. Esses temas apresentam elevado desenvolvimento interno, porém menor integração com o restante da literatura, indicando linhas de pesquisa especializadas e relativamente independentes do núcleo central do campo.

Finalmente, o quadrante inferior esquerdo reúne os temas emergentes ou em declínio, representados por *agricultural crops*, *you only look once model* e *intelligence models*. Considerando o crescimento recente da literatura analisada e a expansão das aplicações da inteligência artificial na agricultura, esses temas podem ser interpretados, predominantemente, como linhas emergentes de investigação, ainda pouco exploradas quando comparadas aos temas motores. Dessa forma, representam oportunidades promissoras para o desenvolvimento de novas pesquisas, especialmente voltadas à ampliação das aplicações dos modelos YOLO em diferentes culturas agrícolas e contextos produtivos.

Por fim, o mapa temático evidencia que, embora a aplicação de modelos YOLO na agricultura esteja fundamentada em temas consolidados, como *deep learning*, agricultura de precisão e detecção de objetos, ainda existem linhas de pesquisa especializadas e temas emergentes que apresentam menor grau de desenvolvimento. Esses resultados demonstram que o campo permanece em

evolução, indicando oportunidades para a ampliação das aplicações dos modelos YOLO em diferentes contextos agrícolas e reforçando a existência de lacunas que podem ser exploradas em estudos futuros.

5 CONSIDERAÇÕES FINAIS

O presente trabalho teve como objetivo analisar o panorama científico da aplicação de modelos YOLO na detecção e contagem de pragas agrícolas, por meio de uma análise bibliométrica da literatura publicada entre 2021 e 2026. Para isso, foram examinados indicadores de produção científica, impacto, colaboração e estrutura temática, permitindo compreender a evolução desse campo de pesquisa e identificar seus principais atores, tendências e oportunidades de investigação.

Os resultados evidenciaram um crescimento expressivo da produção científica ao longo do período analisado, indicando o aumento do interesse da comunidade científica pelo emprego de modelos YOLO em aplicações agrícolas. Esse avanço foi acompanhado pela consolidação de determinados autores, instituições, periódicos e países como referências na área, ao mesmo tempo em que se observou a ampliação da participação de novos grupos de pesquisa, demonstrando a expansão e o fortalecimento desse domínio científico.

A análise temática revelou que os estudos concentram-se, predominantemente, na aplicação de técnicas de visão computacional e de *deep learning* para detecção de objetos em ambientes agrícolas, tendo os modelos YOLO como uma das principais arquiteturas empregadas. Os mapas de palavras-chave, os tópicos em tendência e as relações entre autores, fontes e temas demonstraram que conceitos como *deep learning*, *object detection*, *computer vision* e *precision agriculture* constituem o núcleo consolidado da literatura, refletindo a maturidade dessas linhas de investigação.

Por outro lado, o mapa temático permitiu identificar que o campo permanece em constante evolução, apresentando temas especializados e linhas emergentes relacionadas ao aprimoramento das arquiteturas YOLO, ao desenvolvimento de modelos mais robustos para ambientes agrícolas complexos e à ampliação das aplicações da Inteligência Artificial em diferentes contextos da agricultura de precisão. Esses resultados evidenciam que, embora exista uma base científica consolidada, ainda permanecem oportunidades para o desenvolvimento de novas pesquisas capazes de ampliar a eficiência, a robustez e a aplicabilidade dessas soluções em condições reais de campo.

Os objetivos propostos para esta investigação foram alcançados. O levantamento e a seleção da literatura possibilitaram caracterizar a evolução da

produção científica, identificar os principais autores, periódicos, instituições e países envolvidos na temática, bem como compreender a organização dos temas predominantes e da estrutura intelectual desse campo de investigação. Dessa forma, o estudo fornece um panorama atualizado da produção científica sobre modelos YOLO aplicados à detecção e contagem de pragas agrícolas, contribuindo para a organização do conhecimento existente e para a identificação de tendências que poderão orientar futuras pesquisas.

Como limitação, destaca-se que a análise foi realizada a partir dos documentos indexados na base de dados Scopus e restrita ao período compreendido entre 2021 e 2026. Embora essa estratégia tenha permitido reunir um conjunto consistente e representativo de publicações, estudos indexados em outras bases ou publicados fora do intervalo temporal definido não foram contemplados, podendo apresentar resultados complementares. Registra-se, ainda, que a *string* de busca adotada recuperou a produção sobre modelos YOLO aplicados à agricultura de modo amplo, na qual a detecção de pragas se insere como uma das aplicações mais representativas.

Como perspectivas para trabalhos futuros, recomenda-se ampliar a cobertura das bases de dados analisadas, incorporar estudos publicados em períodos posteriores e realizar investigações bibliométricas comparativas envolvendo diferentes arquiteturas de detecção de objetos aplicadas à agricultura. Além disso, estudos de natureza técnica poderão aprofundar a avaliação do desempenho das diferentes versões do YOLO em cenários agrícolas específicos, relacionando aspectos como precisão, velocidade de processamento, robustez e capacidade de detecção de alvos de pequenas dimensões.

Por fim, espera-se que os resultados apresentados contribuam para a compreensão da evolução científica da aplicação de modelos YOLO na detecção e contagem de pragas agrícolas, servindo como referência para pesquisadores e profissionais interessados na utilização de técnicas de Inteligência Artificial voltadas ao desenvolvimento de soluções mais eficientes, sustentáveis e inovadoras para a agricultura de precisão.

REFERÊNCIAS

ADAMI, D.; OJO, M. O.; GIORDANO, S. *Design, development and evaluation of an intelligent animal repelling system for crop protection based on embedded edge-AI*. **IEEE Access**, v. 9, p. 132125-132139, 2021. DOI: <https://doi.org/10.1109/ACCESS.2021.3114503>. Acesso em: 20 maio 2026.

ARAÚJO, C. A. Bibliometria: evolução histórica e questões atuais. **Em Questão**, Porto Alegre, v. 12, n. 1, p. 11-32, 2006. Disponível em: <http://www.redalyc.org/articulo.oa?id=465645954002>. Acesso em: 20 maio 2026.

ARIA, M.; CUCCURULLO, C. *bibliometrix: an R-tool for comprehensive science mapping analysis*. **Journal of Informetrics**, v. 11, n. 4, p. 959-975, 2017. DOI: <https://doi.org/10.1016/j.joi.2017.08.007>. Acesso em: 20 maio 2026.

BAAS, J.; SCHOTTEN, M.; PLUME, A.; CÔTÉ, G.; KARIMI, R. *Scopus as a curated, high-quality bibliometric data source for academic research in quantitative science studies*. **Quantitative Science Studies**, v. 1, n. 1, p. 377-386, 2020. DOI: https://doi.org/10.1162/qss_a_00019. Acesso em: 17 maio 2026.

DAI, G.; TIAN, Z.; FAN, J.; SUNIL, C. K.; DEWI, C. *DFN-PSAN: multi-level deep information feature fusion extraction network for interpretable plant disease classification*. **Computers and Electronics in Agriculture**, v. 216, art. 108481, 2024. DOI: <https://doi.org/10.1016/j.compag.2023.108481>. Acesso em: 17 maio 2026.

GHAZAL, S.; MUNIR, A.; QURESHI, W. S. *Computer vision in smart agriculture and precision farming: techniques and applications*. **Artificial Intelligence in Agriculture**, v. 13, p. 64-83, 2024. DOI: <https://doi.org/10.1016/j.aiia.2024.06.004>. Acesso em: 20 maio 2026.

GRÁCIO, M. C. C.; MARTÍNEZ-ÁVILA, D.; OLIVEIRA, E. F. T.; ROSAS, F. S. (org.). **Tópicos da bibliometria para bibliotecas universitárias**. São Paulo: Cultura Acadêmica, 2020. 291 p. DOI: <https://doi.org/10.36311/2020.978-65-86546-91-0>. Acesso em: 17 maio 2026.

KHALID, S.; OQAIBI, H. M.; AQIB, M.; HAFEEZ, Y. *Small pests detection in field crops using deep learning object detection*. **Sustainability**, v. 15, n. 8, art. 6815, 2023. DOI: <https://doi.org/10.3390/su15086815>. Acesso em: 18 maio 2026.

LI, R.; HE, Y.; LI, Y.; QIN, W.; ABBAS, A.; JI, R.; LI, S.; WU, Y.; SUN, X.; YANG, J. *Identification of cotton pest and disease based on CFNet-VoV-GCSP-LSKNet-YOLOv8s: a new era of precision agriculture*. **Frontiers in Plant Science**, v. 15, art. 1348402, 2024. DOI: <https://doi.org/10.3389/fpls.2024.1348402>. Acesso em: 19 maio 2026.

QUACH, L.-D.; QUOC, K. N.; QUYNH, A. N.; NGOC, H. T. *Tomato health monitoring system: tomato classification, detection, and counting system based on YOLOv8 model with explainable MobileNet models using Grad-CAM++*. **IEEE Access**, v. 12, p. 9719-9737, 2024. DOI: <https://doi.org/10.1109/ACCESS.2024.3351805>. Acesso em: 20 maio 2026.

QUEVEDO-SILVA, F.; SANTOS, E. B. A.; BRANDÃO, M. M.; VILS, L. Estudo bibliométrico: orientações sobre sua aplicação. **ReMark — Revista Brasileira de Marketing**, São Paulo, v. 15, n. 2, p. 246-262, 2016. DOI: <https://doi.org/10.5585/remark.v15i2.3274>. Acesso em: 17 maio 2026.

RAI, N.; ZHANG, Y.; RAM, B. G.; SCHUMACHER, L.; YELLAVAJJALA, R. K.; BAJWA, S.; SUN, X. *Applications of deep learning in precision weed management: a review*. **Computers and Electronics in Agriculture**, v. 206, art. 107698, 2023. DOI: <https://doi.org/10.1016/j.compag.2023.107698> . Acesso em: 20 maio 2026.

SAPKOTA, R.; FLORES-CALERO, M.; QURESHI, R.; BADGUJAR, C.; NEPAL, U.; POULOSE, A.; ZENO, P.; VADDEVOLU, U. B. P.; KHAN, S.; SHOMAN, M.; KARKEE, M. *YOLO advances to its genesis: a decadal and comprehensive review of the You Only Look Once (YOLO) series*. **Artificial Intelligence Review**, v. 58, n. 9, art. 274, 2025. DOI: <https://doi.org/10.1007/s10462-025-11253-3>. Acesso em: 20 maio 2026.

SUN, D.; ZHANG, K.; ZHONG, H.; XIE, J.; XUE, X.; YAN, M.; WU, W.; LI, J. *Efficient tobacco pest detection in complex environments using an enhanced YOLOv8 model*. **Agriculture**, v. 14, n. 3, art. 353, 2024. DOI: <https://doi.org/10.3390/agriculture14030353>. Acesso em: 19 maio 2026.

TIAN, Y.; WANG, S.; LI, E.; YANG, G.; LIANG, Z.; TAN, M. *MD-YOLO: multi-scale dense YOLO for small target pest detection*. **Computers and Electronics in Agriculture**, v. 213, art. 108233, 2023. DOI: <https://doi.org/10.1016/j.compag.2023.108233>. Acesso em: 19 maio 2026.

WANG, Y.-H.; SU, W.-H. *Convolutional neural networks in computer vision for grain crop phenotyping: a review*. **Agronomy**, v. 12, n. 11, art. 2659, 2022. DOI: <https://doi.org/10.3390/agronomy12112659>. Acesso em: 20 maio 2026.