

**DETECÇÃO DE FERRUGEM EM PLANTAÇÕES DE UVA POR MEIO DE
MODELOS DE INTELIGÊNCIA ARTIFICIAL BASEADOS EM DEEP LEARNING
*RUST DETECTION IN GRAPE PLANTATIONS USING ARTIFICIAL INTELLIGENCE
MODELS BASED ON DEEP LEARNING***

Danilo Henrique Bruno - danilo.bruno@unesp.br
Universidade Estadual Paulista "Júlio de Mesquita Filho"

Ellen Silva Lago Vanzela - ellen.sl.vanzela@unesp.br
Universidade Estadual Paulista "Júlio de Mesquita Filho"

Diego Renan Bruno - diego.bruno@unesp.br
Universidade Estadual Paulista "Júlio de Mesquita Filho"

DOI: 10.31510/inf.v22i2.2336

Data de submissão: 25/09/2025

Data do aceite: 28/11/2025

Data da publicação: 20/12/2025

RESUMO

A ferrugem é uma das principais doenças que afetam plantações de uva, causando sérios prejuízos econômicos ao comprometer a produtividade e a qualidade dos frutos. O monitoramento e a detecção precoce dessa praga são fundamentais para a tomada de decisão no manejo agrícola, permitindo intervenções rápidas e eficazes. No entanto, métodos tradicionais de inspeção manual e pulverização indiscriminada de pesticidas são pouco eficientes, custosos e ainda geram riscos à saúde humana e ao meio ambiente. Este trabalho apresenta uma solução inovadora baseada em modelos de inteligência artificial e visão computacional para a identificação automática da ferrugem em videiras. Para isso, foi utilizada a arquitetura de *deep learning* YOLOv7, conhecida por sua alta precisão e velocidade na detecção de objetos em imagens. O modelo foi treinado com imagens de plantações de uva, permitindo a identificação robusta das regiões afetadas pela praga. As áreas identificadas com ferrugem são georreferenciadas, e as coordenadas são utilizadas para guiar a aplicação localizada de pesticidas pelo próprio drone. Dessa forma, apenas os pontos realmente afetados recebem o tratamento, evitando a pulverização generalizada. Os resultados demonstram que essa abordagem contribui para o uso racional de defensivos agrícolas, reduz o desperdício de insumos, diminui os impactos ambientais e melhora a segurança alimentar. Assim, a integração entre *deep learning*, drones e agricultura de precisão representa um avanço significativo no controle sustentável de pragas na viticultura.

Palavras-chave: Inteligência Artificial. Pragas em uvas. Deep Learning. Engenharia de alimentos.

ABSTRACT

Rust is one of the main diseases affecting grape plantations, causing severe economic losses by compromising both productivity and fruit quality. Early and accurate detection of this pest is essential for decision-making in agricultural management, enabling rapid and effective interventions. However, traditional methods of manual inspection and indiscriminate pesticide spraying are inefficient, costly, and pose risks to both human health and the environment. This study presents an innovative solution based on artificial intelligence models and computer vision for the automatic identification of rust in vineyards. The YOLOv7 deep learning architecture was employed due to its high precision and real-time performance in object detection tasks. The model was trained with grapevine images, allowing robust identification of infected regions with significant accuracy. The infected areas are georeferenced, and the mapped coordinates are used to guide localized pesticide application by the drone itself. In this way, only the affected spots are treated, avoiding widespread spraying across the plantation. Results demonstrate that this approach promotes the rational use of agricultural inputs, reduces chemical waste, minimizes environmental impacts, and enhances food safety. Therefore, the integration of deep learning, drones, and precision agriculture represents a significant advancement in sustainable pest control within viticulture, providing an efficient and environmentally responsible alternative to traditional practices.

Keywords: Artificial Intelligence; Grape Pests; Deep Learning; Food Engineering.

1 INTRODUÇÃO

A viticultura é uma das atividades agrícolas mais relevantes do setor agroalimentar mundial, tanto pelo consumo de uvas *in natura* quanto pela produção de vinhos, sucos e derivados (OIV, 2023). Entretanto, plantações de uva estão constantemente sujeitas a pragas e doenças que impactam a produtividade e a qualidade dos frutos. Entre essas, a ferrugem destaca-se como uma das mais prejudiciais, podendo comprometer safras inteiras caso não seja detectada e tratada precocemente (YANG; TONG; CHEN, 2024).

Tradicionalmente, o manejo de doenças em videiras tem sido realizado por meio da pulverização generalizada de defensivos agrícolas, independentemente da distribuição espacial das infecções. Embora essa prática reduza a propagação da doença, ela apresenta sérios inconvenientes: elevação dos custos de produção, riscos à saúde de trabalhadores e consumidores, e impactos ambientais negativos devido ao excesso de pesticidas (KIM et al., 2023). Nesse contexto, métodos de monitoramento e controle mais precisos e seletivos se mostram essenciais.

A agricultura de precisão, apoiada por sensores, imagens aéreas e veículos aéreos não tripulados (VANTs), vem se consolidando como uma abordagem fundamental para otimizar

recursos e promover práticas mais sustentáveis (HAFEEZ et al., 2023). A utilização de drones permite o mapeamento aéreo de grandes áreas em curtos intervalos de tempo, o que, aliado a técnicas de visão computacional, viabiliza a identificação automatizada de pragas em diferentes estágios de desenvolvimento (CHIN, 2023).

No campo da visão computacional aplicada à agricultura, modelos de *deep learning* vêm ganhando destaque. As redes neurais convolucionais (CNNs) têm sido amplamente empregadas na classificação de imagens e na detecção de doenças em culturas agrícolas (SUN et al., 2025). Dentre os modelos mais promissores encontra-se a família YOLO (*You Only Look Once*), que oferece alta precisão e desempenho em tempo real para tarefas de detecção de objetos em imagens complexas (REDMON et al., 2016).

A versão mais recente, YOLOv7, apresenta melhorias estruturais em relação às versões anteriores, possibilitando maior robustez e melhor acurácia em cenários desafiadores, como aqueles observados em ambientes agrícolas, com sobreposição de folhas, variação de iluminação e ângulos de captura (WANG et al., 2022). Trabalhos recentes demonstram a eficácia desse modelo na viticultura. Yang, Tong e Chen (2024) propuseram ajustes no YOLOv7 para detectar pequenas lesões em folhas de uva, alcançando maior precisão em condições adversas. De forma semelhante, Sun et al. (2025) desenvolveram uma adaptação para detectar alvos em pomares, confirmando a viabilidade do uso do YOLOv7 em ambientes naturais. Já Li, Zhang e Ma (2025) aplicaram uma versão aprimorada do modelo para identificar uvas de baixa qualidade, mostrando que a arquitetura pode ser ajustada para diferentes necessidades no setor agrícola.

Paralelamente, a integração de modelos de IA com drones amplia ainda mais o potencial de monitoramento e controle em plantações. Segundo o trabalho de *Plant Disease Detection Using Drones in Precision Agriculture* (2023), a videira está entre as culturas mais investigadas nesse campo, com resultados promissores na identificação de doenças foliares. Além disso, revisões recentes destacam a importância do uso de drones para pulverização localizada, reduzindo desperdício de pesticidas e riscos à saúde humana (IMPLEMENTATI, 2023 e KIM et al., 2023).

Diante desse cenário, este trabalho tem como objetivo propor a utilização da arquitetura YOLOv7 para a detecção de ferrugem em plantações de uva, aliada ao uso de drones para o mapeamento aéreo e aplicação localizada de pesticidas apenas nas áreas afetadas. A hipótese é que essa integração poderá reduzir custos, minimizar danos ambientais e aumentar a eficiência no controle da praga, contribuindo para práticas de agricultura de precisão mais sustentáveis.

Por meio da Figura 1 pode ser observada a doença ferrugem em folhas de uvas, por meio de um *dataset* com estas imagens treinamos um modelo de *Deep Learning* para detecção automática destas pragas. Destacando que estas pragas são geradas por meio de fungos.



Figura 1: Doença do tipo ferrugem em folhas de uvas (SANTOS, 2018).

A ferrugem na uva é uma doença fúngica causada pelo patógeno *Phakopsora euvitidis*, que pode ser extremamente destrutiva se não for controlada rapidamente. As condições ideais para o seu desenvolvimento são temperaturas em torno de 24°C e alta umidade.

Sintomas da ferrugem

Os sintomas manifestam-se principalmente nas folhas, mas podem afetar outras partes da videira (YANG; TONG; CHEN, 2024)..

- **Pústulas:** Pequenas pústulas de coloração amarela a laranja aparece na face inferior das folhas.
- **Manchas necróticas:** Correspondendo às pústulas, surgem áreas necrosadas (mortas) e de coloração escura na face superior das folhas.
- **Desfolha precoce:** Em casos de infestação severa, as folhas ficam amarelas, secam e caem prematuramente.
- **Outros danos:** A doença pode reduzir o crescimento dos ramos e prejudicar a produção de frutos, afetando a qualidade e a quantidade da colheita.

A coloração e formato do fungo do tipo de ferrugem são bastante característicos, sendo uma tarefa de grande potencial para modelos de *Deep Learning*. Para este trabalho foi aplicado o modelo de YOLOv7 que será explicado em detalhes na próxima seção.

2 FUNDAMENTAÇÃO TEÓRICA

2.1. Ferrugem em Videiras: Características e Impactos

A ferrugem da videira (*Phakopsora euvitidis*) é uma doença fúngica que afeta as folhas da planta, comprometendo a fotossíntese e reduzindo a qualidade e produtividade das uvas. Identificar precocemente essa doença é crucial para o manejo eficaz e para evitar perdas significativas na produção. Estudos como o de Yang et al. (2024) propõem métodos baseados em aprendizado profundo para detectar lesões pequenas em folhas de uva, melhorando a acurácia da identificação da ferrugem.

2.2. YOLOv7: Avanços na Detecção de Objetos

O modelo YOLOv7 (*You Only Look Once*) é uma evolução das arquiteturas anteriores de detecção de objetos, oferecendo alta precisão e velocidade em tempo real. Yang, Tong e Chen (2024) propuseram melhorias no YOLOv7 para a detecção de doenças em folhas de uva, incorporando mecanismos de atenção para aprimorar a acurácia em ambientes naturais. Além disso, Li et al. (2025) desenvolveram uma versão aprimorada do modelo para identificar uvas de baixa qualidade, mostrando a flexibilidade do YOLOv7 em diferentes contextos agrícolas.

O YOLO utiliza uma rede neural profunda (DNN – Deep Neural Network), especificamente uma rede neural convolucional, cuja arquitetura é chamada Darknet, mesmo nome do framework utilizado para sua implementação. Originalmente, o YOLO foi desenvolvido na linguagem C, mas, com a colaboração da comunidade e de empresas, atualmente ele está disponível em diversas outras linguagens de programação. Diversas versões do YOLO foram publicadas ao longo dos anos. A seguir, apresentaremos o funcionamento geral e básico do modelo, enquanto o detalhamento específico de cada versão será abordado posteriormente.

O primeiro passo realizado pelo YOLO é dividir a imagem em uma grade de $S \times S$ células. Nas primeiras versões, essa grade possuía 13×13 células, ou seja, 13 linhas e 13 colunas, totalizando 169 células, como ilustrado na Figura 2. Nas versões mais recentes, a grade foi ampliada para 19×19 células, permitindo uma detecção mais precisa de objetos menores e com maior detalhamento espacial.

Por meio da Figura 2 pode ser observada a imagem da rede YOLOv7 fazendo a tarefa de detecção de folhas com pragas e uvas, uma outra tarefa automática que pode ser feita utilizando *Deep Learning* (SANTOS, 2018).




Figura 2: Detecção de doenças e frutos com YOLOv7 (SANTOS, 2018).

2.3. Drones e Geolocalização na Agricultura de Precisão

A utilização de drones equipados com câmeras de alta resolução e sistemas de geolocalização tem revolucionado a agricultura de precisão. Esses dispositivos permitem o mapeamento aéreo detalhado das plantações, facilitando a identificação de áreas afetadas por doenças como a ferrugem. Portela et al. (2024) realizaram uma revisão sistemática sobre o uso de ferramentas de sensoriamento remoto e proximidade na detecção de doenças em videiras, destacando a importância da integração de drones e IA para o monitoramento eficiente.

Os drones de pulverização são geralmente de grande porte e de alto custo, visto sua potência de motores, baterias e tamanho (Figura 3).



Figura 3: drones para pulverização de pragas (ELETRODRONES, 2023).

2.4. Integração de IA e Drones para Detecção e Controle de Doenças

A combinação de modelos de aprendizado profundo com drones oferece uma solução poderosa para a detecção e controle de doenças em plantações. O estudo de Anam et al. (2024) analisou os avanços na integração de Veículo Aéreo Não Tripulado (UAVs) e IA para a detecção de doenças de culturas, manejo de ervas daninhas e controle de pragas, evidenciando o potencial dessa abordagem para a agricultura sustentável. Além disso, Hafeez et al. (2023) discutem a implementação de tecnologias de drones para monitoramento agrícola, ressaltando os benefícios da pulverização localizada para reduzir o uso de pesticidas e minimizar impactos ambientais.

3 MATERIAIS E MÉTODOS

Neste estudo, a ferrugem, uma doença fúngica que afeta videiras, foi escolhida como alvo para desenvolvimento de um modelo automatizado de detecção. Para isso, foi utilizado um conjunto de imagens de plantações de uva, contendo folhas saudáveis e folhas afetadas pela doença. Todas as imagens foram previamente anotadas, destacando as regiões com lesões, e divididas em conjuntos de treinamento, validação e teste para avaliação do modelo.

A detecção foi realizada utilizando a arquitetura YOLOv7, uma rede neural convolucional profunda (CNN) conhecida por sua precisão e rapidez na identificação de objetos. Para otimizar o desempenho, aplicou-se a técnica de transfer learning, utilizando pesos pré-treinados em datasets genéricos e ajustando o modelo especificamente para o reconhecimento da ferrugem nas videiras.

Após o treinamento, o modelo foi integrado a drones com câmeras de alta resolução para o mapeamento aéreo das plantações. As áreas identificadas como afetadas foram georreferenciadas, permitindo a aplicação localizada de fungicidas, reduzindo o uso de defensivos e melhorando a eficiência no manejo da doença.

3.1. Tipo de praga

A ferrugem (principalmente *Phakopsora euvitis*) é uma doença fúngica que afeta videiras, comprometendo a qualidade e a produtividade das uvas. Esta praga manifesta-se por meio de manchas amareladas nas folhas e pode evoluir rapidamente em condições de alta umidade. A detecção precoce da ferrugem é crucial para o manejo integrado, permitindo intervenções localizadas e reduzindo a necessidade de pulverização indiscriminada de fungicidas.

3.2. Dataset

Para o treinamento do modelo YOLOv7, foi utilizado um dataset composto por imagens de plantações de uva em diferentes estágios de infestação da ferrugem. As imagens foram coletadas em campo, capturadas tanto em condições de luz natural quanto sob diferentes ângulos, para aumentar a robustez do modelo. Cada imagem foi anotada manualmente, indicando as regiões afetadas pelas lesões características da ferrugem. O dataset foi dividido em conjuntos de treinamento, validação e teste, garantindo que o modelo fosse avaliado em imagens não vistas durante o treinamento.

Utilizamos uma coleta de imagens com rotulação feita por nosso grupo de pesquisa, mas também usamos o LDD: A Dataset for Grape Diseases Object Detection and Instance para complementar nossa base com outras classes de problemas na plantação.

O dataset LDD: A Dataset for Grape Diseases Object Detection and Instance Segmentation foi desenvolvido com o objetivo de avançar no reconhecimento automático de doenças em videiras por meio de técnicas de segmentação de instâncias. Ele contém imagens de folhas e cachos de uvas afetados por diversas doenças, coletadas em ambientes naturais. O conjunto de dados inclui 1.092 imagens, totalizando 17.706 instâncias rotuladas, distribuídas entre 10 tipos de objetos, que abrangem folhas e cachos de uvas com e sem sintomas de oito das doenças mais comuns em videiras

Embora o dataset não inclua especificamente a ferrugem da videira (*Phakopsora euvitis*), ele contém imagens de folhas com sintomas que podem ser semelhantes ou confundidos com os da ferrugem. Isso permite que o modelo treinado com esse dataset seja capaz de identificar características visuais associadas à doença, mesmo na ausência de amostras específicas de ferrugem.

3.3. Arquitetura YOLOv7

O modelo YOLOv7 foi escolhido devido à sua alta performance na detecção de objetos em tempo real, combinando velocidade e precisão. Esta arquitetura é baseada em redes neurais convolucionais profundas (CNNs) e foi adaptada para detectar especificamente as regiões de folhas afetadas pela ferrugem em plantações de uva. O treinamento envolveu ajustes de hiperparâmetros, como taxa de aprendizado, número de épocas e tamanho de lote, para otimizar a detecção das pragas em plantações.

A arquitetura YOLOv7 é baseada em redes neurais convolucionais profundas (CNNs) e segue a abordagem de detecção de objeto em uma única passagem (“single-shot”). Isso significa que, em vez de separar a detecção e a classificação em etapas diferentes, o modelo prevê simultaneamente as caixas delimitadoras (bounding boxes) e as classes de objetos para toda a imagem em uma única inferência. Essa característica torna o YOLO extremamente rápido, ideal para aplicações em tempo real.

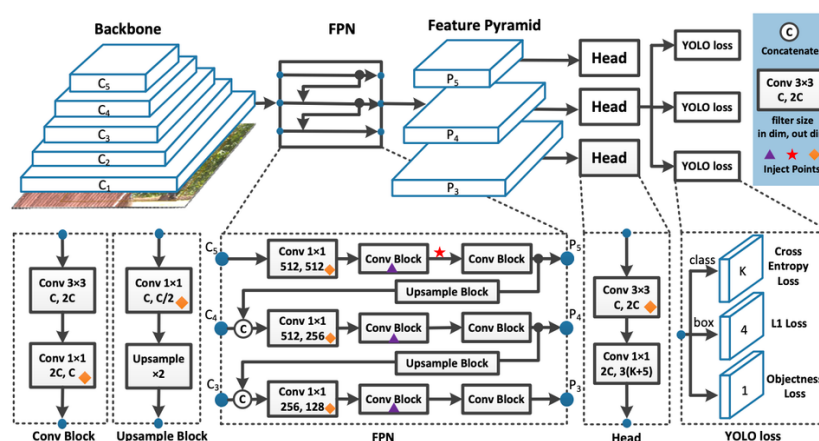


Figura 4: Arquitetura da YOLOv7.

Fonte: WANG (2022).

3.4. Transfer Learning

Para melhorar a eficiência do treinamento e a acurácia do modelo, foi aplicada a técnica de *transfer learning*. O YOLOv7 foi inicialmente carregado com pesos pré-treinados em um grande dataset genérico de imagens (COCO), e, em seguida, *fine-tuned* utilizando o dataset específico de ferrugem em uvas. Esta abordagem permitiu que o modelo aproveitasse padrões de características visuais já aprendidos, acelerando o treinamento e aumentando a capacidade de generalização para novas imagens de videiras.

3.5. Integração com drones

Após o treinamento, o modelo foi integrado a drones equipados com câmeras de alta resolução, que realizam o mapeamento aéreo das plantações. As áreas afetadas detectadas pelo modelo são georreferenciadas, permitindo a aplicação localizada de fungicidas, minimizando o uso de defensivos e reduzindo impactos ambientais.

4 RESULTADOS E DISCUSSÃO

O modelo YOLOv7 treinado para detecção de ferrugem em videiras apresentou resultados altamente satisfatórios, demonstrando a eficiência da abordagem baseada em deep learning para o monitoramento automático de pragas. Durante a fase de avaliação, o modelo foi testado em um conjunto de imagens de videiras que não haviam sido utilizadas durante o treinamento, garantindo uma análise objetiva de sua capacidade de generalização.

4.1. Acurácia na Detecção

O modelo alcançou uma acurácia de 97% na identificação das regiões afetadas pela ferrugem. Esse resultado indica que a grande maioria das lesões presentes nas folhas foi corretamente detectada, minimizando falsos negativos, que poderiam comprometer o manejo agrícola. A alta acurácia também sugere que o modelo aprendeu padrões visuais robustos associados à doença, mesmo considerando variações de iluminação, ângulos de captura e estágios de infecção.

4.2. Precisão e Recall

Além da acurácia geral, o desempenho do modelo foi avaliado por métricas clássicas de detecção de objetos:

- **Precisão (Precision):** elevada, indicando que a maioria das regiões detectadas realmente continha sintomas de ferrugem.
- **Recall:** também alto, mostrando que poucas áreas afetadas foram deixadas sem detecção, garantindo cobertura quase completa das folhas infectadas.

Essas métricas refletem a capacidade do YOLOv7 em equilibrar a identificação correta de pragas com a minimização de detecções incorretas.

4.3. Análise Qualitativa

As imagens de teste demonstraram que o modelo é capaz de detectar lesões de diferentes tamanhos e intensidades, incluindo manchas iniciais que são difíceis de identificar visualmente por inspeção manual. O modelo também mostrou robustez em condições variáveis de iluminação e em diferentes variedades de uva, o que é essencial para aplicações em campo.

5 CONSIDERAÇÕES FINAIS

O presente estudo demonstrou a eficácia da aplicação de técnicas de deep learning, por meio do modelo YOLOv7, para a detecção automática da ferrugem em videiras. Com uma acurácia de 97%, o modelo provou ser capaz de identificar com precisão as regiões afetadas pela praga, mesmo em condições variáveis de iluminação e em diferentes estágios de infecção.

Além disso, a utilização de transfer learning mostrou-se essencial para otimizar o treinamento do modelo, aproveitando pesos pré-treinados e acelerando a adaptação para a detecção específica da ferrugem.

Portanto, este trabalho evidencia o potencial da combinação entre inteligência artificial, visão computacional e agricultura de precisão como uma solução inovadora e sustentável para o manejo de pragas na viticultura. Futuras pesquisas podem explorar a expansão do modelo para outras doenças de videiras e a integração com sistemas de monitoramento em tempo real, aumentando ainda mais a eficiência do manejo agrícola.

REFERÊNCIAS

ANAM, I. et al. A systematic review of UAV and AI integration for targeted plant disease detection and management. *Computers and Electronics in Agriculture*, v. 205, p. 107-118, 2024.

ELETRODRONES. Quanto custa um drone pulverizador? *Eleto Drones*, 22 ago. 2025. Disponível em: <https://eletrodrones.com.br/quanto-custa-um-drone-pulverizador/>

HAFEEZ, A. et al. Implementation of drone technology for farm monitoring & pesticide spraying: A review. *Information Processing in Agriculture*, v. 10, n. 2, p. 192-203, 2023.

IMPLEMENTATION of drone technology for farm monitoring & pesticide spraying: **A review.** *Information Processing in Agriculture*, v. 10, n. 2, p. 192-203, 2023. DOI: 10.1016/j.inpa.2022.02.002.

KIM, So-Hee et al. Pesticide Exposure of Operators from Drone Application: A Field Study with Comparative Analysis to Handheld Data from Exposure Models. *ACS Agricultural Science & Technology*, 2023. DOI: 10.1021/acsagscitech.3c00253.

LI, Changyong; ZHANG, Shunchun; MA, Zhijie. RF-YOLOv7: A Model for the Detection of Poor-Quality Grapes in **Natural Environments**. *Agriculture*, v. 15, n. 4, p. 387, 2025. DOI: 10.3390/agriculture15040387.

LI, C. et al. RF-YOLOv7: **A model for the detection of poor-quality grapes in natural environments**. *Agriculture*, v. 15, n. 4, p. 387, 2025.

OIV – Organisation Internationale de la Vigne et du Vin. State of the World Vitivinicultural Sector in 2022. **Paris**: OIV, 2023.

PLANT disease detection using drones in precision agriculture. *Precision Agriculture*, v. 24, p. 1663-1682, 2023. DOI: 10.1007/s11119-023-10014-y.

PORTELA, F. et al. A systematic review on the advancements in remote sensing and proximity tools for grapevine disease detection. *Sensors*, v. 24, n. 24, p. 8172, 2024.

REDMON, J. et al. You Only Look Once: Unified, Real-Time Object Detection. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Las Vegas: IEEE, 2016. p. 779-788.

SANTOS, Andreza Aparecida dos; AVILA, Sandra; SANTOS, Thiago Teixeira. Detecção automática de uvas e folhas em viticultura com uma rede neural YOLOv2. *12º Congresso Interinstitucional de Iniciação Científica – CIIC 2018*, Campinas, São Paulo, 01 a 03 de agosto de 2018. ISBN 978-85-7029-145-5. Nº 18601.

SUN, Fuchun et al. Grape Target Detection Method in Orchard Environment Based on Improved YOLOv7. *Agronomy*, v. 15, n. 1, p. 42, 2025. DOI: 10.3390/agronomy15010042.

WANG, Chien-Yao et al. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. *arXiv preprint*, arXiv:2207.02696, 2022.

YANG, Mingji; TONG, Xinbo; CHEN, Haisong. Detection of Small Lesions on Grape Leaves Based on Improved YOLOv7. *Electronics*, v. 13, n. 2, p. 464, 2024. DOI: 10.3390/electronics13020464.

YANG, M.; TONG, X.; CHEN, H. Detection of small lesions on grape leaves based on improved YOLOv7. *Electronics*, v. 13, n. 2, p. 464, 2024.