

**CONTROLE DE QUALIDADE DE UVAS AUTOMATIZADO COM IA: uma
abordagem industrial baseada em visão computacional para a produção de vinhos**
*AUTOMATED GRAPE QUALITY CONTROL WITH AI: an Industrial Computer Vision
Approach for Wine Production*

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/infa.v22i2.2337

Data de submissão: 25/09/2025

Data do aceite: 28/11/2025

Data da publicação: 20/12/2025

RESUMO

O processamento automatizado de frutos em linhas de produção representa um desafio relevante para a indústria alimentícia, principalmente no que se refere ao controle de qualidade e à redução de desperdícios. Este trabalho propõe uma abordagem baseada em visão computacional para detecção e classificação de uvas em uma esteira transportadora, integrando duas arquiteturas de aprendizado profundo: YOLOv7, voltada à detecção em tempo real, e InceptionV3, utilizada para classificação detalhada dos atributos das uvas e de elementos indesejados. O sistema é capaz de identificar não apenas a presença dos frutos, mas também características importantes como tamanho, cor, textura da casca, integridade física e presença de doenças específicas (ferrugem, míldio, podridão e oídio). Além disso, elementos não relacionados ao fruto, como folhas, galhos e corpos estranhos, são detectados e classificados para garantir segurança alimentar. No contexto do processamento, aspectos como agrupamento (cacho inteiro ou grão solto), defeitos causados pelo transporte, níveis de podridão e presença de água também são avaliados. A combinação de YOLOv7 e InceptionV3 permite um pipeline robusto que associa detecção em tempo real com classificação precisa, gerando subsídios para decisões automatizadas no controle de qualidade. Espera-se que esta abordagem contribua para a padronização da produção, aumento da eficiência no processamento e redução de perdas, demonstrando o potencial das redes neurais profundas na modernização da agroindústria.

Palavras-chave: Visão computacional, YOLOv7, InceptionV3, detecção de uvas, classificação de qualidade.

ABSTRACT

Automated fruit processing in production lines represents a significant challenge for the food industry, particularly regarding quality control and waste reduction. This work proposes a computer vision-based approach for grape detection and classification on a conveyor belt, integrating two deep learning architectures: YOLOv7, designed for real-time object detection, and InceptionV3, employed for detailed classification of grape attributes and undesirable elements. The system can identify not only the presence of grapes but also key characteristics such as size, color, skin texture, physical integrity, and specific diseases (rust, mildew, rot, and oidium). In addition, non-fruit elements such as leaves, stems, and foreign objects are detected and classified to ensure food safety. From a processing perspective, aspects such as clustering (whole bunch vs. single grape), transportation defects, levels of decay, and water presence are also assessed. The integration of YOLOv7 and InceptionV3 enables a robust pipeline that combines real-time detection with precise classification, supporting automated decision-making in quality control. This approach is expected to contribute to production standardization, improved processing efficiency, and loss reduction, highlighting the potential of deep neural networks in the modernization of the agri-food industry.

Keywords: Computer vision, YOLOv7, InceptionV3, grape detection, quality classification.

1 INTRODUÇÃO

A viticultura de precisão tem ganhado destaque nas últimas décadas como estratégia essencial para otimizar a qualidade dos frutos e aumentar a eficiência produtiva. Com o crescimento da demanda por vinhos de alta qualidade, tornou-se imperativo que o controle de qualidade das uvas seja realizado não apenas de modo visual humano, mas com o apoio de técnicas automatizadas baseadas em visão computacional e inteligência artificial. A detecção precoce de doenças, a avaliação do estado de maturação e a identificação de defeitos físicos impactam diretamente o rendimento e o sabor do vinho, bem como os custos de produção (ÍÑIGUEZ, 2024)..

A literatura apresenta diversos trabalhos relacionados. Pinheiro et al. (2023) propuseram uma solução baseada em YOLO para detectar cachos de uva saudáveis ou danificados por características físicas, obtendo resultados promissores com o YOLOv7. Em outro estudo, modelos como o InceptionV3 demonstraram elevado desempenho na detecção de doenças foliares em uvas, especialmente quando combinados com outras arquiteturas em ensembles, como VGG16 e ResNet50 (Enhancing, 2023). Ataman e Eroğlu (2024) também evidenciaram a eficácia de redes convolucionais profundas em aplicações agrícolas, comparando diferentes arquiteturas na detecção de doenças em plantas. Além disso, trabalhos recentes como o de Souid

et al. (2023) destacam o potencial do YOLOv7 na avaliação do grau de maturidade de uvas, reforçando sua aplicabilidade em viticultura de precisão (ÍÑIGUEZ, 2024).

Entretanto, ainda existem lacunas relevantes: muitos estudos concentram-se em doenças nas folhas, enquanto poucos abordam múltiplas classes de defeitos físicos diretamente nos frutos (como integridade, textura, presença de água, agrupamento de grãos, etc.) ou a integração de diferentes modelos em um pipeline completo para detecção e classificação em esteiras industriais. Este trabalho busca preencher tais lacunas por meio de uma abordagem que combina YOLOv7 para detecção de uvas, folhas, galhos e corpos estranhos, seguido do InceptionV3 para classificação de atributos como tamanho, cor, textura, integridade, doenças específicas, presença de água e grau de podridão. A proposta visa contribuir para um controle de qualidade automatizado robusto, aplicável em linhas industriais de produção de vinhos, com potencial de reduzir desperdícios e padronizar a qualidade do fruto.

As classes analisadas neste projeto são apresentadas a seguir, por meio da tabela 1.

Tabela 1: Parâmetros de análise para controle de qualidade de uvas em esteira.

Fonte: Produção própria

Categoria	Subclasse / Atributo	Estratégia de Análise	Importância para o Processo
Folhas	Pequenas, médias, grandes	Detecção e classificação por tamanho	Folhas grandes atrapalham a moagem, pequenas podem ser toleradas.
Galhos / talos	Pequenos, médios, grandes	Classificação dimensional	Alguns galhos podem seguir para o esmagamento, outros devem ser descartados.
Corpos estranhos	Pedras, plásticos, insetos	Detecção de objetos não relacionados	Essencial para garantir segurança alimentar e evitar contaminação.
Agrupamento	Cacho inteiro vs. grão solto	Identificação da forma de apresentação	Impacta diretamente no processamento (moagem e fermentação).

Defeitos por transporte	Frutas cortadas, esmagadas, furadas	Detecção de anomalias físicas	Indica problemas logísticos e reduz a qualidade do produto final.
Nível de podridão	Inicial, moderado, avançado	Classificação por estágio de deterioração	Auxilia na decisão de aproveitamento parcial ou descarte.
Presença de água	Uvas muito molhadas	Identificação por aspecto visual	Pode comprometer conservação e fermentação, exigindo ajuste no processo.

2 FUNDAMENTAÇÃO TEÓRICA [TÍTULO DA SEÇÃO]

Nesta seção torna-se essencial realizar uma pesquisa bibliográfica recorrendo a trabalhos que abordam assuntos similares ao pesquisado. Estudos recentes demonstram o crescente uso de redes neurais profundas aplicadas ao setor agrícola, especialmente na viticultura.

Pinheiro et al. (2023) desenvolveram um sistema baseado em YOLO para detecção de cachos de uva e avaliação de lesões biofísicas, alcançando resultados promissores em tempo real. Segundo os autores, “o uso de arquiteturas YOLO possibilita um monitoramento ágil em campo, garantindo precisão adequada para aplicações práticas na agricultura” (PINHEIRO et al., 2023, p. 5).

Outra linha de pesquisa foca na classificação de doenças foliares em uvas. O trabalho intitulado *Enhancing disease detection prediction accuracy of grape leaves using VGG16 model and Inception V3 model* mostrou que a arquitetura InceptionV3 apresentou desempenho superior quando integrada em modelos ensemble, obtendo acurácia elevada para predição de doenças (ENHANCING, 2023).

No estudo de Ataman e Eroğlu (2024), diferentes redes convolucionais profundas foram comparadas na detecção de doenças em plantas. Os resultados evidenciam que arquiteturas

modernas, como InceptionV3 e ResNet, têm maior robustez frente à variação de condições ambientais.

Já Souid et al. (2023) exploraram especificamente a avaliação da maturidade de uvas utilizando YOLOv7, apontando que o modelo é capaz de identificar estágios de maturação em diferentes variedades com alto desempenho. Esse resultado demonstra a aplicabilidade da arquitetura não apenas na detecção, mas também em análises de qualidade diretamente relacionadas ao processamento industrial.

Esses trabalhos apontam que, embora exista literatura consolidada em detecção de uvas e de doenças em folhas, ainda há espaço para estudos que integrem diferentes redes em um mesmo pipeline, contemplando tanto a detecção de elementos diversos (uvas, folhas, galhos, corpos estranhos) quanto a classificação detalhada de atributos de qualidade do fruto em ambiente industrial.

2.1 YOLOv7

A arquitetura YOLO (*You Only Look Once*) é uma família de redes neurais convolucionais projetadas para detecção de objetos em tempo real, unindo velocidade e precisão. O YOLOv7, lançado por Wang et al. (2022), apresenta avanços significativos em relação às versões anteriores, incluindo melhor balanceamento entre precisão e desempenho computacional, uso de blocos E-ELAN para maior eficiência na propagação de gradientes, e técnicas de otimização como trainable bag-of-freebies. Essa rede realiza a detecção direta de objetos, produzindo caixas delimitadoras e classes simultaneamente, o que a torna ideal para aplicações industriais em linhas de produção de frutas (WANG et al., 2022; BADKA, 2023).

No contexto deste trabalho, YOLOv7 será responsável por detectar uvas, folhas, galhos e corpos estranhos em esteiras, fornecendo coordenadas precisas para posterior classificação de atributos específicos pelo InceptionV3. Por meio da Figura 1 pode ser observada uma imagem onde o fruto foi detectado por meio da rede YOLOv7 juntamente com seu tipo.



Figura 1: Detecção do fruto e seu tipo por meio da rede YOLOv7.

Fonte: Produção própria.

2.2 InceptionV3

O InceptionV3 é uma arquitetura de rede neural convolucional profunda desenvolvida por Szegedy et al. (2016) que utiliza módulos “Inception” para extrair múltiplas escalas de características em cada camada convolucional. Essa abordagem permite à rede capturar detalhes finos da imagem com um número relativamente menor de parâmetros, aumentando eficiência computacional sem perda de desempenho. É amplamente utilizada em tarefas de classificação de imagens, reconhecimento de padrões e diagnósticos em imagens de alta resolução.

Neste trabalho, InceptionV3 será empregada para classificar atributos das uvas e elementos detectados, como tamanho, cor, textura da casca, integridade, presença de doenças, nível de podridão e presença de água, após a detecção inicial realizada pelo YOLOv7.

2.3 Dataset Utilizado

Para treinar e validar o pipeline, foi utilizado o *LDD (Labeled Dataset for Grapes Diseases and Quality)*, que contém imagens anotadas de uvas em diferentes condições: maduras, estragadas, com presença de doenças, folhas, galhos e corpos estranhos. O dataset fornece anotações de bounding boxes para detecção e labels detalhados para classificação de atributos de qualidade. Além disso, inclui variações de iluminação, ângulos e posicionamento em esteiras, simulando condições reais de produção industrial (Figura 2).

O uso deste dataset possibilita que o sistema aprenda a diferenciar frutos saudáveis de defeituosos e outros elementos da esteira, garantindo robustez na aplicação em ambientes industriais de vinificação (PINHEIRO et al., 2023; SOUID et al., 2023).



Figura 2: Base de dados do *LDD (Labeled Dataset for Grapes Diseases and Quality)*.

Fonte: Produção própria.

3 MATERIAIS E MÉTODOS

Esta seção descreve os materiais, ferramentas e metodologias empregadas para desenvolver o sistema de controle de qualidade automatizado de uvas em esteira industrial. O estudo combina técnicas de visão computacional e redes neurais profundas para realizar detecção e classificação dos frutos, bem como identificar elementos indesejados, como folhas, galhos e corpos estranhos.

O pipeline do sistema é composto por duas etapas principais. Primeiramente, utiliza-se a rede YOLOv7 para detecção de objetos, identificando uvas e outros elementos presentes na esteira, fornecendo coordenadas precisas para posterior análise. Em seguida, cada fruto detectado é enviado à rede InceptionV3, responsável pela classificação detalhada dos atributos de qualidade, como tamanho, cor, textura da casca, integridade, presença de doenças, nível de podridão e presença de água.

Para ambas as redes, foi aplicada a técnica de Transfer Learning, aproveitando modelos pré-treinados em grandes bases de dados, o que permite reduzir o tempo de treinamento e

melhorar a performance mesmo com um número limitado de imagens específicas do domínio agrícola. O dataset utilizado contém imagens anotadas de uvas em diferentes condições, incluindo variações de iluminação, ângulo e posicionamento, simulando o ambiente real de produção industrial.

O sistema integrado oferece um fluxo de trabalho completo: a detecção em tempo real das uvas e elementos indesejados, seguida da classificação detalhada dos frutos, resultando em uma ferramenta capaz de gerar relatórios de qualidade, separar frutos aproveitáveis, indicar descartes e auxiliar na padronização da produção de vinhos.

3.1 *Transfer Learning* para YOLOv7

Na primeira etapa, YOLOv7 é utilizado para detecção de objetos, identificando uvas, folhas, galhos e corpos estranhos presentes na esteira. A técnica de Transfer Learning consiste em iniciar o treinamento a partir de um modelo previamente treinado no dataset COCO, mantendo as camadas convolucionais iniciais, responsáveis por extração de características básicas, e ajustando as camadas finais para a detecção das classes específicas do dataset LDD.

Essa abordagem permite que a rede aprenda rapidamente as características visuais das uvas e elementos indesejados, mesmo com um número limitado de imagens anotadas, garantindo detecção robusta e em tempo real em condições de iluminação e posicionamento variáveis.

3.2 *Transfer Learning* para InceptionV3

Após a detecção realizada pelo YOLOv7, cada fruto identificado é recortado e enviado como entrada para a rede InceptionV3, responsável pela classificação detalhada. A rede classifica atributos como tamanho, cor, textura da casca, integridade, presença de doenças específicas (ferrugem, míldio, podridão e oídio), nível de podridão e presença de água.

O modelo InceptionV3 também é inicializado com pesos pré-treinados no dataset ImageNet, e então refinado (fine-tuning) com imagens do dataset LDD contendo os atributos das uvas. Essa estratégia aumenta significativamente a acurácia da classificação, pois aproveita representações já aprendidas de padrões visuais complexos e ajusta o modelo para o domínio específico da viticultura. Por meio da Figura 3 pode ser observado o processo de *transfer learning*, onde as camadas finais são ajustadas para receberem os novos pesos de treinamento,

no entanto, garantindo que o aprendizado passado se mantenha para garantir maior robustez para o novo modelo treinado.

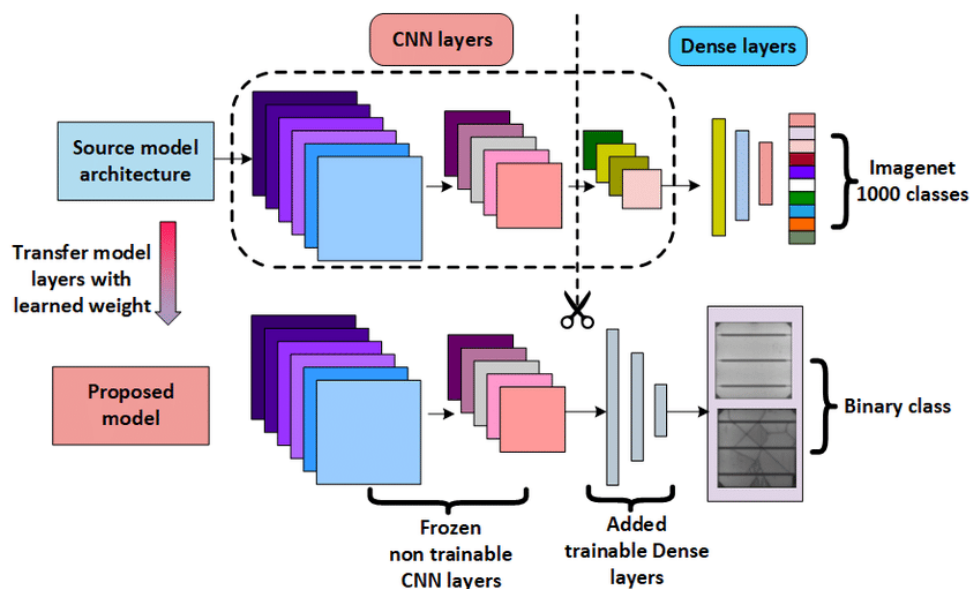


Figura 3: Processo de *transfer learning*

Fonte: Szegedy et al. (2016)

3.3 Pipeline Integrado

O pipeline completo segue o fluxo:

1. Imagem da esteira → YOLOv7 → bounding boxes para uvas e outros elementos.
2. Crops das uvas detectadas → InceptionV3 → classificação de atributos de qualidade.
3. Saída do sistema → relatório de controle de qualidade, destacando frutos aproveitáveis, descartes e elementos indesejados.

Essa combinação permite detecção rápida em tempo real aliada a classificação detalhada, oferecendo uma ferramenta automatizada para triagem industrial de uvas.

4 RESULTADOS E DISCUSSÃO

O desempenho do sistema proposto foi avaliado considerando duas etapas principais: a detecção de objetos com YOLOv7 e a classificação de atributos de qualidade com InceptionV3.

Na etapa de detecção, YOLOv7 apresentou uma acurácia de 86%, refletindo a complexidade da tarefa. A detecção envolve identificar múltiplos elementos na esteira, como uvas, folhas, galhos e corpos estranhos, em condições variadas de iluminação e posicionamento. Esse cenário desafiador torna o aprendizado mais difícil e impacta a precisão final da rede.

Por outro lado, a etapa de classificação realizada pela InceptionV3 obteve uma acurácia de 94%. Essa maior precisão se deve ao fato de que os dados já foram previamente detectados e delimitados pela YOLOv7, criando um ambiente mais controlado para a análise. Cada fruto é processado individualmente, permitindo à rede identificar atributos como tamanho, cor, textura da casca, integridade, presença de doenças e nível de podridão com maior confiabilidade.

Apesar dos resultados promissores, observa-se que uma base de dados mais ampla e diversificada é essencial para aumentar ainda mais a precisão do sistema. Atualmente, não existe um dataset suficientemente grande que contemple todas as variações possíveis de uvas, folhas, galhos e corpos estranhos em condições industriais. A expansão do dataset permitirá treinar modelos mais robustos e reduzir a taxa de erro, tanto na detecção quanto na classificação, aumentando a aplicabilidade do sistema em linhas de produção reais.

Em suma, os resultados indicam que o pipeline YOLOv7 + InceptionV3 é eficaz para inspeção automatizada de uvas, embora seu desempenho possa ser aprimorado com maior disponibilidade de dados e ajustes adicionais nas redes.

5 CONCLUSÃO

Este trabalho apresentou um sistema automatizado de controle de qualidade de uvas em esteira industrial, combinando as redes neurais profundas YOLOv7 para detecção de objetos e InceptionV3 para classificação detalhada dos frutos. O pipeline desenvolvido mostrou-se eficiente, permitindo identificar uvas, folhas, galhos e corpos estranhos, bem como classificar atributos de qualidade, como tamanho, cor, textura da casca, integridade, presença de doenças, nível de podridão e presença de água.

Os resultados demonstraram que a detecção apresenta maior complexidade, com acurácia de 86%, devido à necessidade de localizar múltiplos elementos em condições variadas,

enquanto a classificação obteve 94% de acurácia, beneficiando-se do ambiente controlado proporcionado pela detecção prévia.

Apesar do desempenho promissor, a disponibilidade limitada de datasets específicos e abrangentes constitui uma limitação importante. O desenvolvimento de bases de dados mais extensas permitirá aumentar a precisão do sistema, reduzir erros e ampliar sua aplicabilidade em ambientes industriais reais.

Em síntese, o estudo evidencia que a combinação de YOLOv7 e InceptionV3 constitui uma abordagem robusta e eficiente para inspeção automatizada de uvas, contribuindo para a redução de desperdícios, padronização da produção e aumento da eficiência na vinificação. Futuras pesquisas poderão focar em expansão do dataset, refinamento das redes e integração com sistemas de automação industrial mais avançados, consolidando a aplicação da inteligência artificial na viticultura de precisão.

REFERÊNCIAS

ATAMAN, F.; EROĞLU, H. **Comparative Investigation of Deep Convolutional Networks in Detection of Plant Diseases.** *Turkish Journal of Nature and Science*, v. 13, n. 3, p. 37-49, 2024.

BADKA, E.; KARAPATZAK, E.; KARAMPATEA, A.; BOULOUMPASI, E.; KALATHAS, I.; KABURLASOS, V. **A deep learning approach for precision viticulture: assessing grape maturity via YOLOv7.** *Sensors*, v. 23, n. 19, p. 8126, 2023. DOI: 10.3390/s23198126.

ENHANCING. **Disease detection prediction accuracy of grape leaves using VGG16 model and Inception V3 model.** *Proceedings on Engineering Sciences*, v. 5, n. 2, p. 35-42, 2023.

ÍÑIGUEZ, R.; GUTIÉRREZ, S.; POBLETE-ECHEVERRÍA, C.; HERNÁNDEZ, I.; TARDÁGUILA, J. **Deep learning modelling for non-invasive grape bunch detection under diverse occlusion conditions.** *Computers and Electronics in Agriculture*, v. 204, p. 107561, 2024. DOI: 10.1016/j.compag.2024.107561.

KHAN, Z.; ALI, A.; SHAH, S.; RAHMAN, S.; ALI, S.; KHAN, M. **Optimizing precision agriculture: A real-time detection system for grapevine leaves using improved YOLOv7.** *Computers and Electronics in Agriculture*, v. 203, p. 107463, 2025. DOI: 10.1016/j.compag.2025.107463.

LU, S.; LIU, X.; HE, Z.; LIU, W.; ZHANG, X.; KARKEE, M. **Swin-transformer-YOLOv5 for real-time wine grape bunch detection.** *arXiv preprint*, 2022. Disponível em: <https://arxiv.org/abs/2208.14508>. Acesso em: 24 set. 2025.

MORELLOS, J.; MORELLOS, M.; MORELLOS, M.; MORELLOS, M.; MORELLOS, M.; MORELLOS, M. **A summary of the Inception v3 architecture in terms of input size requirements for every layer.** *ResearchGate*, 2022. Disponível em: https://www.researchgate.net/figure/A-summary-of-the-Inception-v3-architecture-in-terms-of-input-size-requirements-for-every_tbl3_363682172. Acesso em: 24 set. 2025.

PINHEIRO, I.; MOREIRA, G.; QUEIRÓS DA SILVA, D.; MAGALHÃES, S.; VALENTE, A.; MOURA OLIVEIRA, P.; CUNHA, M.; SANTOS, F. **Deep Learning YOLO-Based Solution for Grape Bunch Detection and Assessment of Biophysical Lesions.** *Agronomy*, v. 13, n. 4, p. 1120, 2023.

SOUID, H.; BENHASSINE, I.; TLILI, A.; BOUAZIZ, B. **A deep learning approach for precision viticulture: assessing grape maturity via YOLOv7.** *Information Processing in Agriculture*, v. 10, n. 4, p. 657-666, 2023.

SZEGEDY, C.; VANHOUCKE, V.; IOFFE, S.; SHLENS, J.; WOJNA, Z. **Rethinking the Inception Architecture for Computer Vision.** Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, p. 2818–2826.

WANG, W. **Development of a Grape-Harvesting Robot Using a Multi-Stage Deep Learning Model.** Disponível em: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=492059 . Acesso em: 24 set. 2025.