

UNIVERSIDADE PAULISTA
PROGRAMA DE MESTRADO EM ENGENHARIA DE PRODUÇÃO

LUANA DOS SANTOS CORDEIRO

**CLASSIFICAÇÃO DA QUALIDADE DE MORANGOS COM REDE NEURAL
CONVOLUCIONAL YOLOV8.**

SÃO PAULO

2025

LUANA DOS SANTOS CORDEIRO

**CLASSIFICAÇÃO DA QUALIDADE DE MORANGOS COM REDE NEURAL
CONVOLUCIONAL YOLOV8.**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Paulista – UNIP, para a obtenção do título de Mestre em Engenharia de Produção.

Área de concentração: Gestão de sistemas de operação.

Linha de pesquisa: Redes de empresas e planejamento da produção

Projeto de pesquisa: Gestão da Produção e Inovação na Agricultura, Indústria e Serviços

Orientador: Prof. Dr. Marcelo Tsuguio Okano.

SÃO PAULO

2025

Cordeiro, Luana dos Santos.

Classificação da qualidade de morangos com Rede Neural Convolutacional YOLOv8 / Luana dos Santos Cordeiro. – 2025.
103 f. : il. color. + CD-ROM.

Dissertação de Mestrado Apresentada ao Programa de Pós- Graduação em Engenharia de Produção da Universidade Paulista, São Paulo, 2025.

Área de concentração: Gestão de Sistemas de Operação.
Orientador: Prof. Dr. Marcelo Tsuguio Okano.

1. Morango. 2. Visão computacional. 3. Rede Neural Convolutacional YOLOv8. 4. Pós-colheita. I. Okano, Marcelo Tsuguio (orientador). II. Título.

LUANA DOS SANTOS CORDEIRO

**CLASSIFICAÇÃO DA QUALIDADE DE MORANGOS COM REDE NEURAL
CONVOLUCIONAL YOLOV8.**

Dissertação apresentada ao Programa de Pós-graduação em Engenharia de Produção da Universidade Paulista – UNIP, para a obtenção do título de Mestre em Engenharia de Produção.

Aprovado(a) em: ____/____/____

BANCA EXAMINADORA

Prof. Dr. Marcelo Tsuguio Okano
Universidade Paulista – UNIP

Profa. Dra. Irenilza de Alencar Nääs
Universidade Paulista - UNIP

Profa. Dra. Márcia Ito
Unidade de Pós-Graduação, Extensão e Pesquisa - Centro Estadual de Educação
Tecnológica Paula Souza

DEDICATÓRIA

Dedico este trabalho aos meus pais, pelo amor incondicional, pelo exemplo de força e pela presença positiva e constante em todas as etapas da minha vida.

Dedico-o à minha sobrinha Ísis, que ela possa ressignificar ao longo da vida suas inseguranças sabendo que todos os sonhos são possíveis.

Dedico-o aos meus amigos, pela amizade sincera, pelo incentivo nos momentos de dificuldade e pela confiança em meu potencial, atitudes e sentimentos que me motivaram a seguir em frente.

Dedico-o também aos meus professores, pela generosidade em compartilhar conhecimentos e pela dedicação em orientar meu aprendizado com sabedoria ao longo desta jornada.

Dedico-o ainda a todos os que me acompanharam até aqui, gente a quem sou grata e a quem admiro.

AGRADECIMENTOS

Expresso primeiramente minha sincera gratidão a todos aqueles que, direta ou indiretamente, contribuíram para a realização deste trabalho.

Em sequência, agradeço ao meu orientador, professor Marcelo Okano, por sua inestimável orientação, paciência e dedicação. Suas valiosas contribuições foram o pilar para o desenvolvimento e a conclusão da minha pesquisa.

Agradeço de modo especial à professora Irenilza pelo seu acolhimento e suas sugestões generosas que positivamente moldaram o percurso da minha pesquisa e enriqueceram significativamente a minha trajetória acadêmica.

Agradeço a todos os professores e colegas de curso pela troca de conhecimento, pelo incentivo e apoio, fatos fundamentais para o desenvolvimento da minha pesquisa.

Agradeço à minha amiga Suely pelo companheirismo e suporte constante e incondicional. Sua presença e suas atitudes encorajadoras fizeram uma grande e positiva diferença nesta jornada.

Agradeço as amigas Mada e Fernanda pelas contribuições e apoio ao longo desses dois anos que foram essenciais para a finalização desse projeto.

Agradeço à minha família, merecedora do meu mais profundo reconhecimento pelo incentivo constante, pela compreensão nos momentos de ausência e por acreditar em mim inabalavelmente.

Por fim, agradeço ao apoio financeiro da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001, essencial para a concretização deste estudo.

RESUMO

O morango é uma fruta altamente perecível e apresenta elevada suscetibilidade a perdas durante a pós-colheita, especialmente em entrepostos como a CEAGESP, onde a triagem é majoritariamente manual e sujeita à variabilidade entre classificadores. A necessidade de processos mais padronizados e eficientes motiva o uso de tecnologias de visão computacional para apoiar a avaliação da qualidade dos frutos. Assim, esta pesquisa teve como objetivo desenvolver e validar um modelo baseado na arquitetura YOLOv8, integrado a um protótipo de aplicativo móvel, para auxiliar a classificação pós-colheita de morangos. A metodologia compreendeu quatro etapas: revisão da literatura; prova de conceito utilizando o YOLOv8m para detecção inicial; desenvolvimento completo do modelo de classificação multiclasse com YOLOv8n; e aplicação da abordagem *Design Science Research* (DSR) para criação e avaliação de um aplicativo funcional. O *dataset* final reuniu 5.663 imagens distribuídas em oito classes de qualidade, maturação, defeitos e doenças, com aplicação de técnicas de data augmentation. Os experimentos foram conduzidos em ambiente *Google Colab Pro* com suporte de GPU. Os resultados demonstraram que o modelo YOLOv8n atingiu desempenho satisfatório, com mAP50 de 0,79, precisão de 0,744 e *recall* de 0,777, além de tempo médio de inferência de 1 ms, viabilizando seu uso em dispositivos móveis. As classes de doenças apresentaram melhor desempenho, enquanto categorias associadas à maturação mostraram maior sobreposição visual. O protótipo móvel apresentou boa aceitação inicial, indicando potencial de uso na triagem de morangos. Conclui-se que a solução proposta contribui para reduzir perdas, apoiar classificadores e aumentar a eficiência logística, alinhando-se aos Objetivos de Desenvolvimento Sustentável (ODS 9 e 12). Recomenda-se, para estudos futuros, *ampliar* o dataset e validar a solução em escala operacional.

Palavras-chave: Morango. Visão computacional. Rede Neural Convolutacional YOLOv8. Pós-colheita

ABSTRACT

Strawberries are highly perishable fruits and exhibit significant susceptibility to post-harvest losses, especially in wholesale centers such as CEAGESP, where sorting is predominantly manual and subject to variability among graders. The need for more standardized and efficient processes drives the use of computer vision technologies to support fruit quality assessment. Thus, this study aimed to develop and validate a model based on the YOLOv8 architecture, integrated into a prototype mobile application, to assist in the post-harvest classification of strawberries. The methodology comprised four stages: a literature review; a proof of concept using YOLOv8m for initial detection; full development of a multiclass classification model using YOLOv8n; and application of the Design Science Research (DSR) approach for the creation and evaluation of a functional application. The final dataset contained 5,663 images distributed across eight classes of quality, ripeness, defects, and diseases, with the application of data augmentation techniques. Experiments were conducted in the Google Colab Pro environment with GPU support. The results showed that the YOLOv8n model achieved satisfactory performance, with a mAP50 of 0.79, precision of 0.744, and recall of 0.777, as well as an average inference time of 1 ms, enabling its use on mobile devices. Disease-related classes achieved better performance, while categories associated with ripeness displayed greater visual overlap. The mobile prototype received positive initial feedback, indicating potential for use in strawberry sorting. It is concluded that the proposed solution helps reduce losses, supports graders, and increases logistical efficiency, aligning with Sustainable Development Goals (SDGs 9 and 12). For future studies, it is recommended to expand the dataset and validate the solution at an operational scale.

Keywords: Strawberry. Computer vision. YOLOv8 Convolutional Neural Network. Postharvest.

UTILIDADE

No âmbito social e ambiental, o trabalho responde aos desafios de sustentabilidade, ao propor uma solução que contribui para a redução do desperdício de alimentos, estimado em mais de 26 milhões de toneladas por ano no Brasil (CEDES, 2018). Ao mitigar perdas na cadeia de suprimentos, o estudo dialoga diretamente com os Objetivos de Desenvolvimento Sustentável (ODS), em especial o ODS 9 (Indústria, inovação e infraestrutura) e o ODS 12 (Consumo e produção responsáveis). Fortalece ainda o papel da pesquisa científica na promoção de sistemas alimentares mais eficientes e sustentáveis. Assim, a investigação é relevante por seu caráter inovador, aplicável e interdisciplinar. Ela integra conhecimentos, com potencial de impacto tanto no meio acadêmico, quanto no setor produtivo.

LISTA DE FIGURAS

Figura 1 – Plataforma Roboflow utilizada para organização, anotação e aplicação de <i>data augmentation</i>	29
Figura 2 – Plataforma <i>Roboflow</i> : organização do conjunto de dados	30
Figura 3 – Ambiente Expo: interface do aplicativo <i>BerryScan</i>	34
Figura 4 – Fluxo metodológico da pesquisa baseado em <i>Design Science Research</i> (DSR)	35
Figura 5 – Processo geral da pesquisa	36
Figura 6 – Exemplo de imagem utilizada no teste	38
Figura 7 – Curvas de <i>F1-score</i> por classe	39
Figura 8 – Matriz de confusão	40
Figura 9 – Mapa conceitual da cadeia de suprimentos	42
Figura 10 – Fotos da visita aos produtores de Atibaia (SP).....	58
Figura 11 – Fotos de Monte Alegre do Sul (SP).....	59
Figura 12 – Telas do aplicativo móvel em desenvolvimento.....	61

LISTA DE QUADROS

Quadro 1 – Comparação dos artigos	37
Quadro 2 – Resumo do treinamento: evolução das métricas YOLOv8m	38
Quadro 3 – Principais desafios por classe	40
Quadro 4 – Comparação dos modelos YOLOv8	41
Quadro 5 – Comparação entre os artigos desenvolvidos na pesquisa	47

LISTA DE ABREVIações

ABNT – Associação Brasileira de Normas Técnicas

BoxP – *Box Precision* (Precisão da Caixa)

CAPES – Coordenação de Aperfeiçoamento de Pessoal de Nível Superior

CEAGESP – Companhia de Entrepósitos e Armazéns Gerais de São Paulo

CEDES – Centro de Estudos e Debates Estratégicos

CNN – *Convolutional Neural Network* (Rede Neural Convolucional)

DL – *Deep Learning* (Aprendizado Profundo)

DSR – *Design Science Research*

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária

FAO – *Food and Agriculture Organization* (Organização das Nações Unidas para Alimentação e Agricultura)

GPU – *Graphics Processing Unit* (Unidade de Processamento Gráfico)

IA – Inteligência Artificial

IoT – *Internet of Things* (Internet das Coisas)

mAP – *mean Average Precision* (Média da Precisão Média)

ML – *Machine Learning* (Aprendizado de Máquina)

NIR – *Near Infrared* (Infravermelho Próximo)

ODS – Objetivos de Desenvolvimento Sustentável

ONU – Organização das Nações Unidas

RGB – *Red, Green, Blue* (Vermelho, Verde, Azul)

SIMPEP – Simpósio de Engenharia de Produção

SWIR – *Short-Wave Infrared* (Infravermelho de Ondas Curtas)

YOLO – *You Only Look Once*

SUMÁRIO

1 INTRODUÇÃO	15
1.1 Problema de Pesquisa	16
1.2 Justificativa	16
1.3 Objetivos	17
1.3.1 Objetivo Geral	17
1.3.2 Objetivos Específicos	17
1.4 Estrutura da Dissertação	18
2 FUNDAMENTAÇÃO TEÓRICA	20
2.1 Contexto da Produção de Morangos, Importância Econômica, Perecibilidade e Perdas Pós-colheita	20
2.2 Transformação Digital na Agricultura e Contribuições da Visão Computacional	21
2.3 Redes Neurais Convolucionais.....	22
2.4 Evolução dos Detectores de Objetos e Consolidação do YOLOv8.....	23
2.5 Visão Computacional Aplicada ao Morango: Maturação, Qualidade e Doenças	23
3 METODOLOGIA	26
3.1 Levantamento Bibliográfico	26
3.2 Análise Metodológica do Artigo 1 e sua Relevância para esta Pesquisa....	27
3.3 Análise Metodológica do Artigo 2 e sua Contribuição ao Estudo	27
3.4 <i>Design Science Research</i> (DSR).....	30
3.4.1 Identificação do Problema e Motivação	30
3.4.2 Definição dos Objetivos	31
3.4.3 Desenho e Desenvolvimento do Artefato	31
3.4.3.1 Desenvolvimento (Aplicativo <i>Android</i> e Versão <i>Web</i>)	32
3.4.4 Demonstração	34
3.4.5 Avaliação	34
3.4.6 Comunicação	35
3.5 Fluxo Metodológico do Processo de <i>Design Science Research</i>	35
4 RESULTADOS	36
4.1 Integração dos Estudos	36

4.2 Resultados do Modelo YOLOv8m: Detecção de Morangos	37
4.3 Resultados do Modelo YOLOv8n: Classificação da Qualidade	39
4.3.1 Desempenho por Classe	39
4.4 Comparação entre as Variantes do YOLOv8	41
4.5 Aplicação dos Resultados na Cadeia de Suprimentos do Morango	41
5 DISCUSSÃO	43
5.1 Integração entre Detecção e Classificação na Avaliação Automatizada de Morangos.....	43
5.2 Desempenho do YOLOv8n e Complexidade da Classificação de Qualidade.....	43
5.3 Limitações Observadas e Implicações para a Expansão da Metodologia	44
5.4 Adequação dos Modelos YOLOv8 para Aplicações Reais na Cadeia Logística	45
5.5 Contribuições do Modelo para a Cadeia de Suprimentos do Morango.....	46
6 CONSIDERAÇÕES FINAIS	48
REFERÊNCIAS	50
APÊNDICE A – Quadro 1: Comparação de Trabalhos Correlatos sobre Detecção e Classificação de Morangos	57
APÊNDICE B – Relato de Visitas Técnicas em Atibaia e Monte Alegre do Sul (SP)	58
APÊNDICE C – Imagens do Protótipo Inicial do Aplicativo Mobile	61
APÊNDICE D – Artigos Publicados	62
Utilização de IA E Rede Neural para a Identificação de Morangos.....	62
Smart Postharvest Management of Strawberries: YOLOv8-Driven Detection of Defects, Diseases, and Maturity.....	78
APÊNDICE E – Questionário de Avaliação do Aplicativo de Classificação da Qualidade de Morangos	99
ANEXO 1 – Documentação do Registro de <i>Software</i>	101

1 INTRODUÇÃO

O morango (*Fragaria × ananassa*) destaca-se como uma das frutas de maior relevância econômica e social, tanto no Brasil quanto no cenário internacional. De acordo com dados da Organização das Nações Unidas para Agricultura e Alimentação (FAO, 2024), a produção mundial de morangos ultrapassou 9 milhões de toneladas em 2022, sendo o Brasil responsável por aproximadamente 183.923 toneladas. Esse volume posiciona o país entre os principais produtores mundiais de frutas, cuja produção anual total supera 45 milhões de toneladas (EMBRAPA, 2023).

A cadeia produtiva do morango apresenta relevância crescente no cenário agrícola brasileiro, impulsionada tanto pela expansão do consumo, quanto pela adoção de práticas tecnológicas para produzir frutos de maior qualidade (CONCEIÇÃO *et al.*, 2025; EMBRAPA, 2023). Contudo, trata-se de uma fruta altamente perecível, cujas características fisiológicas, como elevado teor de umidade e baixa resistência à manipulação, tornam o processo de pós-colheita um ponto crítico (HU *et al.*, 2023). A deterioração rápida resulta perdas expressivas ao longo da cadeia de suprimentos, especialmente nos estágios de distribuição e de comercialização, perdas agravadas pela variabilidade das condições ambientais e pelo manuseio inadequado (PRIYADARSHI *et al.*, 2024). Esses fatores impactam diretamente a durabilidade e o valor de mercado do produto.

A triagem manual ainda é predominante em entrepostos de distribuição, como a CEAGESP, e depende da experiência individual dos classificadores, o que torna a triagem suscetível a inconsistências e a subjetividades (PATHMANABAN *et al.*, 2023). O alto volume de carga e a necessidade de rapidez intensificam essas limitações operacionais. Consequentemente, a padronização da classificação torna-se difícil de ser alcançada. A ausência de ferramentas tecnológicas acessíveis e adaptadas ao ambiente operacional reforça a necessidade de soluções inovadoras que apoiem o processo decisório nesse contexto (LIU *et al.*, 2025).

Avanços recentes em visão computacional e aprendizado profundo ampliaram as possibilidades de automação em atividades agrícolas, especialmente na detecção, na segmentação e na classificação de frutas (XIAO *et al.*, 2023; AL RABBANI ALIF e HUSSAIN, 2024). Modelos baseados em redes neurais convolucionais têm demonstrado elevado desempenho em diferentes aplicações, com destaque para arquiteturas YOLO (*You Only Look Once*), reconhecidas pela eficiência e pela

velocidade de inferência (BADGUJAR *et al.*, 2024; LIU *et al.*, 2023). A integração dessas técnicas a dispositivos móveis representa uma vertente promissora, apoiada por arquiteturas leves, como *MobileNet* (HOWARD *et al.*, 2019) e *EfficientNetV2* (TAN e LE, 2022), capazes de aproximar tecnologias avançadas do uso prático, o que favorece intervenções ágeis e a tomada de decisão em campo.

Nesse cenário, a aplicação de um modelo de visão computacional, para apoiar a classificação pós-colheita de morangos na CEAGESP (Companhia de Entrepósitos e Armazéns Gerais de São Paulo), configura uma oportunidade de inovação científica e operacional, ao mesmo tempo em que responde a limitações observadas em estudos recentes que frequentemente se concentram em ambientes controlados ou em aplicações laboratoriais. A presente pesquisa busca contribuir para esse campo ao propor uma abordagem aplicada que combina modelagem computacional, solução móvel e validação em ambiente real.

Diante desse contexto, o próximo capítulo apresenta os fundamentos teóricos que sustentam esta dissertação, contextualizando os avanços em visão computacional, percepibilidade e classificação pós-colheita.

1.1 Problema de Pesquisa

A predominância de processos manuais de triagem em entrepostos de distribuição torna a classificação pós-colheita de morangos suscetível a inconsistências e a perdas. Considerando esse cenário, a questão central desta pesquisa é: De que modo um modelo de visão computacional baseado no YOLOv8, integrado a um aplicativo móvel, pode apoiar a classificação pós-colheita de morangos na CEAGESP e contribuir para a redução de perdas na cadeia de suprimentos?

1.2 Justificativa

A relevância deste estudo fundamenta-se em três eixos principais. O primeiro refere-se à importância econômica e social da cultura do morango no Brasil, cuja cadeia produtiva apresenta participação expressiva no abastecimento de mercados locais e regionais. O segundo diz respeito às limitações identificadas nos métodos tradicionais de classificação, que dependem intensamente de julgamento humano, estão sujeitos a variações subjetivas e resultam processos pouco padronizados,

sobretudo em ambientes de alta demanda como a CEAGESP. O terceiro eixo relaciona-se à lacuna científica observada na literatura recente, que aponta avanços significativos em modelos de visão computacional, mas evidencia a necessidade de estudos aplicados que integrem essas tecnologias a dispositivos móveis e avaliem seu desempenho em condições reais.

Visitas técnicas realizadas na CEAGESP reforçaram a observação de que a triagem de morangos ocorre em um ambiente dinâmico, com prazos curtos e grande fluxo de mercadorias. Nessas circunstâncias, tecnologias que ofereçam análises rápidas e consistentes têm potencial para apoiar os classificadores e contribuir para a redução de perdas. Assim, a inovação proposta por esta pesquisa não se limita ao desenvolvimento do modelo. Ela chega à disponibilização de uma ferramenta prática que pode ser utilizada diretamente no contexto operacional.

1.3 Objetivos

1.3.1 Objetivo Geral

Desenvolver e validar um modelo de visão computacional baseado no YOLOv8, integrado a um aplicativo móvel, para apoiar a classificação pós-colheita de morangos na CEAGESP.

1.3.2 Objetivos Específicos

1. Construir e rotular um conjunto de dados composto por imagens de morangos com diferentes padrões de qualidade.
2. Treinar e validar um modelo YOLOv8 para a classificação da qualidade de morangos.
3. Integrar o modelo treinado a um aplicativo móvel voltado ao apoio na triagem de morangos.
4. Avaliar o desempenho do modelo, a funcionalidade da aplicação e a sua usabilidade.

1.4 Estrutura da Dissertação

A presente dissertação foi organizada no formato de artigos, conforme permitido pelo Programa de Pós-Graduação em Engenharia de Produção da UNIP (Universidade Paulista). Essa estrutura busca integrar a produção científica derivada da pesquisa ao desenvolvimento metodológico e a análise dos resultados obtidos no estudo principal. Dois artigos foram produzidos no decorrer da investigação e ambos estão incluídos nos Apêndices; foram ainda incorporados de forma direta às seções metodológicas e analíticas desta dissertação.

O Artigo 1 – intitulado *Utilização de IA e Rede Neural para a Identificação de Morangos* – contribuiu especialmente para a fase inicial da pesquisa. Seu conteúdo fundamenta o procedimento experimental preliminar, voltado ao treinamento exploratório de um modelo YOLOv8m para identificação de morangos em imagens. Os métodos apresentados no artigo foram incorporados ao Capítulo 3 (Metodologia), por representarem a primeira etapa prática do estudo e servirem como prova de conceito para a viabilidade do uso do YOLO na detecção do fruto. Além disso, as análises de desempenho descritas no Artigo 1 ofereceram base para o refinamento da abordagem utilizada posteriormente na construção do *dataset* expandido e na escolha do modelo final.

O Artigo 2 – intitulado *Smart Postharvest Management of Strawberries: YOLOv8-Driven Detection of Defects, Diseases, and Maturity* – corresponde à etapa mais avançada e mais completa da pesquisa; reflete diretamente o estudo principal desta dissertação. Sua metodologia, que envolve a construção de um *dataset* de 5.663 imagens, aplicação de técnicas de aumento de dados, definição das oito classes de qualidade e o treinamento do modelo YOLOv8n, foi incorporada integralmente ao Capítulo 3 (Metodologia). Os resultados apresentados no artigo foram incorporados ao Capítulo 4 (Resultados e Discussão), o que inclui métricas de desempenho, análise por classes e interpretação dos achados. O artigo também contribui para as reflexões presentes nas Considerações Finais, especialmente no que se refere às limitações do modelo, às possibilidades de aplicação prática em ambiente operacional e às recomendações para pesquisas futuras.

Com base nessas integrações, a estrutura geral da dissertação está organizada da seguinte forma:

- Capítulo 1 – Introdução: apresenta o contexto da cadeia produtiva do morango,

o problema de pesquisa, a justificativa, os objetivos e a importância da automação da classificação pós-colheita.

- Capítulo 2 – Fundamentação Teórica: reúne conceitos sobre perecibilidade, tecnologias digitais na agricultura, redes neurais convolucionais, evolução dos modelos YOLO e estudos relacionados à detecção de qualidade de morangos.
- Capítulo 3 – Metodologia: descreve as etapas metodológicas adotadas na pesquisa; incorpora elementos experimentais produzidos no Artigo 1 e o procedimento completo de desenvolvimento presentes no Artigo 2. Além da aplicação do *Design Science Research* para a criação do Artefato.
- Capítulo 4 – Resultados: apresenta o desempenho do modelo YOLOv8n, as análises por classe, o impacto da ampliação do *dataset* e as discussões que derivam da comparação com os resultados publicados no artigo.
- Capítulo 5 – Considerações Finais: discute as contribuições da pesquisa, suas limitações, implicações práticas para a CEAGESP e caminhos de continuidade.
- Apêndices: incluem documentos complementares, como registros de campo, telas do protótipo móvel, quadros de comparação de trabalhos correlatos, os dois artigos científicos produzidos, e o formulário de validação do primeiro protótipo, o que evidencia a produção acadêmica gerada durante o desenvolvimento da dissertação.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta conceitos essenciais para compreender o contexto da produção de morango e sua importância econômica assim como a aplicação da visão computacional na classificação de morangos, sustentando as etapas apresentadas no Capítulo 3.

2.1 Contexto da produção de morangos, importância econômica, perecibilidade e perdas pós-colheita

O morango é uma das frutas de maior relevância econômica no cenário agrícola mundial e apresenta posição estratégica em função do aumento constante da demanda, tanto para consumo *in natura*, quanto para processamento industrial. De acordo com a FAO (2025), sua produção global tem crescido de maneira consistente, impulsionada por fatores, como expansão de mercados, valorização de alimentos frescos e avanços tecnológicos na agricultura. No Brasil, a cadeia produtiva de morangos possui forte concentração nas regiões Sul e Sudeste, especialmente em Minas Gerais, Paraná, Rio Grande do Sul e São Paulo. Nesses territórios, além das condições climáticas favoráveis, a estrutura produtiva é marcada pela predominância de pequenas propriedades familiares, pela atuação de cooperativas e por um sistema de comercialização que depende fortemente das centrais de abastecimento (ALZEIST & RESENDE, 2019).

A CEAGESP se destaca nesse cenário como o principal entreposto de distribuição de frutas e hortaliças da América Latina e concentra expressivo fluxo de entrada e saída de morangos diariamente. A operação intensa e rápida, somada à sensibilidade fisiológica do fruto, impõe desafios significativos para manter a sua qualidade durante a comercialização. O alto volume de morangos movimentado diariamente exige inspeções visuais rápidas. Como essas inspeções são feitas manualmente, aumenta-se a necessidade de sistemas padronizados que reduzam a subjetividade dos responsáveis pela inspeção.

A perecibilidade é um dos fatores que mais condicionam a eficiência da cadeia de suprimentos do morango. Trata-se de um fruto não climatérico, caracterizado por uma alta taxa de respiração e por um teor elevado de água, fatores que reduzem sua vida útil de forma substancial. Estudos evidenciam que variações mínimas no manuseio, na temperatura ou na umidade relativa aceleram reações fisiológicas que comprometem a firmeza, a cor e os sólidos solúveis, aspectos diretamente

relacionados ao valor comercial (AHMED *et al.*, 2024). Além disso, a deterioração pode ser intensificada pela ocorrência de danos mecânicos durante as etapas de colheita, transporte e triagem, que se tornam portas de entrada para doenças.

As perdas pós-colheita de frutas e hortaliças no Brasil variam entre 30 e 40%, conforme relatado pelo CEDES (2018) e pela Embrapa (2023). O morango está entre os produtos mais vulneráveis a esse tipo de perda, especialmente devido à sua suscetibilidade ao mofo cinzento, causado pelo fungo *Botrytis cinerea*, uma das doenças mais severas documentadas na literatura (PETRASCH *et al.*, 2019). A antracnose, o oídio e outras doenças pós-colheita também representam riscos significativos, sobretudo quando associadas a rotas logísticas longas, condições inadequadas de armazenamento ou falhas na cadeia do frio (ALJAWASIM; SAMTANI e RAHMAN, 2023).

No ambiente operacional, essas vulnerabilidades são intensificadas pelo fluxo contínuo de cargas, pelas variações ambientais e pela limitação de tempo para avaliação manual de lotes. A classificação tradicional, baseada na inspeção visual e no conhecimento tácito, tende a apresentar inconsistências, resulta em variação de critérios e reduz a eficácia do processo. Assim, a implementação de tecnologias que permitam maior precisão, maior agilidade e maior padronização na avaliação visual torna-se fundamental para a mitigação de perdas e para o aumento da eficiência logística.

2.2 Transformação digital na agricultura e contribuições da visão computacional

O avanço das tecnologias digitais tem transformado profundamente o setor agrícola, amplia a capacidade de monitoramento, controle e tomada de decisão ao longo das cadeias produtivas. Sensores IoT, análise de Big Data e modelos de Inteligência Artificial têm sido integrados a sistemas capazes de gerar diagnósticos em tempo real, de prever pragas e de otimizar processos de colheita e pós-colheita (ADEWUSI *et al.*, 2024; ESPINEL *et al.*, 2024).

Nesse contexto, a visão computacional se destaca como uma ferramenta promissora, pois permite a interpretação automatizada de imagens, substitui ou complementa etapas que antes dependiam exclusivamente da percepção humana. A literatura recente aponta que técnicas de visão computacional podem superar avaliadores humanos em tarefas que envolvem alta repetitividade, avaliação de padrões sutis ou identificação de sinais precoces de doenças (UKWUOMA *et al.*,

2022). Essas técnicas têm sido muito utilizadas para reconhecer padrões visuais em plantas, quantificar produção, classificar estágios de maturação e detectar defeitos. Ela traz ganhos diretos para a padronização do controle de qualidade, especialmente em ambientes de alta rotatividade de produtos.

A integração da visão computacional em dispositivos móveis amplia o uso dessas tecnologias, permite aplicar modelos avançados diretamente em ambientes como linhas de triagem e entrepostos. O uso de sistemas mobile pode ser dentro deste contexto mais vantajoso por oferecer mobilidade, apoiar decisões rápidas e ter custo menor que soluções industriais de inspeção automatizada.

2.3 Redes Neurais Convolucionais

As Redes Neurais Convolucionais (CNNs) constituem um dos pilares mais sólidos na evolução da visão computacional moderna. Introduzidas para superar limitações de métodos baseados em extração manual de características, as CNNs são capazes de aprender estruturas hierárquicas de padrões visuais por meio de camadas convolucionais que detectam desde bordas simples até padrões complexos associados a objetos completos (LECUN; BENGIO e HINTON, 2015). Sua arquitetura combina convoluções, operações de *pooling* e camadas densas, o que resulta modelos altamente expressivos e eficazes para tarefas de classificação, segmentação e detecção.

O avanço das CNNs ao longo da última década consolidou seu papel em setores, como medicina, inspeção industrial, segurança alimentar e agricultura. Revisões recentes mostram que essas redes podem identificar doenças de plantas, classificar frutos e realizar inspeções visuais em tempo real com precisão equivalente ou superior à de especialistas (KRICHEN, 2023; DING *et al.*, 2025). No caso de morangos, CNNs têm sido aplicadas para identificar sintomas iniciais de *Botrytis cinerea*, diferenciar graus de maturação e detectar danos físicos, fatos que permitem ações mais rápidas e assertivas em pós-colheita (KIM *et al.*, 2021; HU *et al.*, 2023).

A evolução de arquiteturas baseadas em mecanismos de atenção, fusão multiescala e aprimoramento de extração de características aumentou a sensibilidade dos modelos a detalhes finos, característica essencial para distinguir defeitos visuais que têm consequências comerciais significativas, como machucados, manchas ou pequenas deformações. Essa capacidade torna as CNNs especialmente adequadas para dar suporte à classificação comercial em ambientes como a CEAGESP.

2.4 Evolução dos detectores de objetos e consolidação do YOLOv8

O campo da detecção de objetos passou por avanços significativos que possibilitaram melhorias substanciais em velocidade e precisão. Os primeiros modelos amplamente adotados, como R-CNN, Fast R-CNN e Faster R-CNN, estabeleceram as bases teóricas para a detecção baseada em regiões propostas, mas apresentavam limitações de velocidade que inviabilizavam aplicações em tempo real (GIRSHICK *et al.*, 2014; REN *et al.*, 2016). A posterior introdução do SSD representou marco importante ao eliminar a etapa de propostas e ao acelerar a detecção, embora ainda enfrentasse desafios no reconhecimento de objetos pequenos (LIU *et al.*, 2016).

A revolução mais expressiva ocorreu com o lançamento da arquitetura YOLO (*You Only Look Once*), que reformulou completamente a tarefa de detecção ao tratá-la como um problema de regressão direta que integrou localização e classificação em um único fluxo computacional (REDMON *et al.*, 2016). Essa abordagem consolidou o YOLO como referência para aplicações em tempo real devido ao seu desempenho superior em cenários dinâmicos e com restrições de *hardware*.

A evolução contínua das versões seguintes apresentou melhorias em treinamento, arquitetura e generalização, o que resultou no YOLOv8, lançado pela *Ultralytics* em 2023. Essa versão apresenta refinamentos estruturais que garantem equilíbrio eficaz entre velocidade e precisão, além de maior flexibilidade para implementação em dispositivos móveis. Estudos recentes confirmam a aplicabilidade do YOLOv8 na agricultura, especialmente na triagem automática de frutos, detecção de maturação, identificação de defeitos e diagnóstico de doenças. Elas ainda mostram robustez em condições de iluminação variável, presença de oclusões e capturas em diferentes ângulos (TAO *et al.*, 2024; XIAO *et al.*, 2023; XIAO *et al.*, 2020; HE *et al.*, 2024). Essas características tornam o YOLOv8 particularmente promissor para uso em centrais de abastecimento, onde o tempo de resposta deve ser rápido e a variabilidade visual é elevada. No contexto desta pesquisa, sua capacidade de operar em dispositivos móveis, aliada à infraestrutura computacional otimizada, representa um avanço importante para a criação de ferramentas práticas de apoio à classificação e triagem.

2.5 Visão computacional aplicada ao morango: maturação, qualidade e doenças

A literatura recente mostra expansão significativa do uso de visão computacional para análise de morangos, com foco na classificação de maturação, identificação de

doenças e avaliação de qualidade comercial. O estudo de Zhou *et al.* (2021) mostra que sistemas baseados em imagens aéreas e terrestres podem identificar níveis de maturação com desempenho elevado, mostra que eles apontam o potencial das CNNs para monitoramento em larga escala. Em ambientes mais operacionais, estudos, como os de Tao *et al.* (2023) e Xiao *et al.* (2024), confirmam que detectores modernos são capazes de diferenciar frutos maduros, verdes e danificados mesmo sob condições complexas de iluminação e sem necessidade de ambientes controlados.

Além da maturação, a detecção de doenças tem sido alvo de diversas investigações. Kim *et al.* (2021) aplicaram modelos de *deep learning* para identificar sintomas de *Botrytis cinerea* e outras doenças, enquanto Hu *et al.* (2023) incorporaram mecanismos de atenção com *class-attention*, o que aumentou a sensibilidade para lesões pequenas e de difícil identificação (HU *et al.*, 2023). He *et al.* (2024) destacam o YOLOv8 como alternativa eficaz em cenários onde o diagnóstico rápido é essencial, especialmente em ambientes produtivos. Estudos mais recentes, como Li *et al.* (2025), propõem uma versão otimizada do YOLOv8 com fusão de convolução e atenção, o que melhora a detecção de pequenas manchas em campo. Outras pesquisas enfatizam a necessidade de detecção de defeitos físicos não patológicos, como machucados e manchas, que impactam diretamente a qualidade comercial e a aceitabilidade do produto (LU *et al.*, 2021).

Apesar de bons resultados, a literatura ainda apresenta limitações importantes; a maioria dos estudos é conduzida em ambientes controlados, com fundo padronizado, iluminação estável e câmeras fixas, o que contrasta com as condições reais de entrepostos. Em geral, há pouca diversidade de dados em termos de safras, lotes, condições meteorológicas e dispositivos de captura. Além disso, poucos estudos integram maturação, defeitos e doenças em um único modelo de classificação, e a validação em campo, especialmente em locais de grande fluxo como a CEAGESP, permanece limitada.

Diante do panorama apresentado, observa-se que há uma lacuna expressiva no desenvolvimento de sistemas aplicados à classificação pós-colheita de morangos em ambientes operacionais reais. O presente estudo busca preencher parte dessa lacuna ao propor o desenvolvimento de um modelo baseado em YOLOv8 adaptado às características visuais específicas observadas em morangos comercializados na CEAGESP. A integração desse modelo a um aplicativo móvel representa avanço relevante, uma vez que permite a implementação de inferência em tempo real, sem a

necessidade de infraestrutura computacional complexa ou equipamentos especializados.

Ao adotar abordagem orientada ao ambiente real de triagem, esta pesquisa amplia a aplicabilidade dos sistemas de visão computacional em contextos de alta variabilidade visual; oferece alternativa tecnológica para padronizar processos, reduzir perdas e apoiar classificadores humanos. Além disso, ao validar o sistema em operação no entreposto, a pesquisa contribui para uma discussão mais ampla sobre a viabilidade de sistemas móveis de *deep learning* em cadeias de suprimentos de produtos perecíveis.

3 METODOLOGIA

A metodologia desta pesquisa foi organizada em quatro etapas complementares que estruturam o desenvolvimento da dissertação. A primeira etapa consistiu na investigação teórica, conduzida por meio de um levantamento sistemático da literatura sobre visão computacional, modelos da arquitetura YOLO e métodos de classificação pós-colheita. A segunda etapa corresponde à experimentação preliminar apresentada no *Artigo 1 – Utilização de IA e Rede Neural para Identificação de Morangos*. Para isto, foi realizada uma prova de conceito que utiliza o modelo YOLOv8m para avaliar a viabilidade inicial da identificação automática de morangos. A terceira etapa abrange o desenvolvimento final da solução, detalhado no *Artigo 2 – Smart Postharvest Management of Strawberries: YOLOv8-Driven Detection of Defects, Diseases, and Maturity*, que envolveu a construção de um *dataset* ampliado, a definição das oito classes de qualidade visual e o treinamento do modelo YOLOv8n. Por fim, a quarta etapa corresponde à aplicação do *Design Science Research* (DSR), no qual o modelo treinado foi integrado a um protótipo de aplicação móvel para identificação em tempo real, o que indica viabilidade prática em contextos operacionais. Essas quatro etapas se articulam de forma lógica e progressiva; constituem o procedimento metodológico que sustenta esta dissertação.

3.1 Levantamento bibliográfico

O desenvolvimento inicial da pesquisa envolveu a realização de um levantamento bibliográfico sistemático, com o objetivo de compreender o estado da arte sobre classificação pós-colheita de morangos, visão computacional aplicada à agricultura, as arquiteturas baseadas em *Deep Learning* e as metodologias utilizadas para treinamento de modelos YOLO. O levantamento foi realizado utilizando as bases científicas: *ScienceDirect*, *Scopus*, *Web of Science*, *IEEE Xplore*, *SpringerLink*, *MDPI* e *Google Scholar*. Essas plataformas foram escolhidas devido à sua ampla abrangência nas áreas de computação aplicada, ciências agrárias e engenharia de sistemas.

As buscas foram realizadas a partir da combinação de descritores relacionados ao tema central da dissertação e, por isto, inclui: *Strawberry postharvest*, *computer vision in agriculture*, *deep learning fruit quality*, *YOLO strawberry detection*, *fruit defects detection*, *CNN fruit quality*, *mobile inference deep*

learning, *postharvest losses*, *dataset strawberry deep learning* e *fruit grading neurais networks*. O processo de seleção contemplou a leitura de títulos, resumos e, posteriormente, dos textos completos. Selecionaram-se artigos alinhados ao objetivo de compreender metodologias de construção, de anotação e de avaliação de modelos voltados à classificação de frutas perecíveis, levantamento que contribuiu para a elaboração dos artigos.

Esse levantamento permitiu identificar lacunas específicas, como a ausência de estudos validados em ambientes operacionais similares à CEAGESP e a restrição da maior parte das pesquisas a laboratórios ou a estufas controladas. Também permitiu compreender padrões metodológicos, tais como a importância da criação cuidadosa do *dataset*, a anotação manual de imagens, o uso de *data augmentation*, a seleção do modelo YOLO mais adequado e a necessidade de avaliações técnicas e operacionais. Essas constatações fundamentaram as etapas subsequentes da dissertação.

3.2 Análise metodológica do Artigo 1 e sua relevância para esta pesquisa

O primeiro artigo, intitulado *Utilização de IA para a Identificação de Morangos*, apresentou um procedimento experimental voltado ao treinamento da rede YOLOv8m para a identificação de morangos. Inicialmente, foi utilizado um conjunto de dados que contém 1.257 imagens de morangos, obtidas no *Open Images Dataset V7*, todas com anotações prévias, incluindo caixas delimitadoras e rótulos de classe. Antes do treinamento, essas imagens passaram por uma etapa de pré-processamento que envolveu a padronização das dimensões, normalização dos valores de pixel e verificação das anotações, o que assegura consistência e qualidade do *dataset*. Após essa etapa, o conjunto de dados foi dividido em 80% para treinamento e 20% para teste.

O treinamento foi conduzido no ambiente *Google Colab Pro* utilizando GPU e bibliotecas utilizadas em aprendizado profundo, como *PyTorch* e *Ultralytics*. O modelo foi inicializado com pesos pré-treinados, o que acelerou o processo de convergência e aumentou o desempenho da rede. Durante o treinamento, o desempenho do YOLOv8m foi monitorado por métricas essenciais, como precisão, revocação, *F1-score* e *mAP50*, que permitiram avaliar a capacidade da rede de identificar corretamente os morangos presentes nas imagens.

A metodologia apresentada no primeiro artigo (Apêndice D) é relevante para estudos que buscam desenvolver soluções aplicadas à classificação pós-colheita, pois mostra de maneira prática e detalhada todas as etapas necessárias para treinar um modelo de detecção de objetos voltado ao reconhecimento de morangos. Esse conjunto de procedimentos corrobora a importância de um fluxo metodológico estruturado; inclui curadoria do *dataset*, pré-processamento, uso de arquiteturas (como o YOLOv8) e validação com métricas padronizadas. Assim, o artigo reforça a viabilidade técnica da utilização do YOLOv8 em aplicações que exigem detecção rápida e precisa de frutas em diferentes contextos operacionais, o que se alinha às demandas enfrentadas em entrepostos de distribuição, como a CEAGESP.

3.3 Análise metodológica do Artigo 2 e sua contribuição ao estudo

O segundo artigo, intitulado *Smart Postharvest Management of Strawberries: YOLOv8-Driven Detection of Defects, Diseases, and Maturity*, apresentou uma abordagem voltada ao ambiente de pós-colheita e utiliza o modelo YOLOv8n para detecção de qualidade em frutas. A metodologia enfatiza a eficiência do modelo em cenários operacionais; destaca aspectos, como baixa latência, leveza do modelo, inferência em tempo real e adequação a dispositivos com menor capacidade computacional. Apresenta ainda a viabilidade de integrar modelos leves a sistemas embarcados e aplicações móveis, ponto crucial para esta dissertação.


Do ponto de vista metodológico, contribuiu-se para orientar decisões relacionadas à escolha da versão do YOLOv8, à adaptação do modelo ao ambiente mobile e à avaliação dos tempos de inferência. O artigo destacou que modelos menores, como o YOLOv8n, podem apresentar um equilíbrio vantajoso entre velocidade e precisão, quando utilizados em *smartphones*, conclusão validada posteriormente na presente dissertação por meio de testes empíricos.

Além disso, o Artigo 2 (Apêndice D) estruturou sua metodologia em três etapas: definição das classes de morangos, desenvolvimento do modelo e ampliação do conjunto de dados com técnicas de *Data Augmentation*. Inicialmente, foram coletadas imagens de domínio público, classificadas em oito categorias que representam desde frutos íntegros e maduros, até condições de não conformidade, como maturação desigual, ausência de cálice e doenças fúngicas.

Na segunda etapa, o dataset de 2.196 imagens foi dividido em treinamento, validação e teste (80%, 10%, 10%) antes de qualquer aumento de dados. Diferentes variantes do YOLOv8 foram testadas e destacou-se a versão *nano* (YOLOv8n) por oferecer desempenho comparável ao *medium* com maior velocidade de inferência. O treinamento ocorreu em Google Colab Pro com GPU NVIDIA A100; utilizaram-se bibliotecas, como *PyTorch*, *TensorFlow*, *OpenCV*, *Ultralytics* e *Roboflow*.


A terceira etapa aplicou *data augmentation* ao conjunto de treinamento; incluiu rotações e desfoque gaussiano leve; ampliou o *dataset* para 5.663 imagens e reforçou a generalização do modelo. O desempenho do YOLO foi avaliado por *precision*, *recall*, *mAP50* e *mAP95*; mediu tanto a detecção, quanto a classificação das condições pós-colheita. O artigo evidencia um fluxo metodológico replicável para detecção de qualidade de frutas; reforça a importância da divisão adequada dos dados, o uso de *data augmentation* e a escolha da variante do YOLO. As Figura 1 e 2 ilustram a Plataforma Roboflow utilizada para anotações das imagens, aplicação de *data augmentation* e organização do conjunto de imagens para treinamento.

Figura 1: Plataforma Roboflow utilizada para organização, anotação e aplicação de *data augmentation*.



Fonte: Autora (2025).

Figura 2: Plataforma *Roboflow* organização e curadoria do conjunto de dados.



Fonte: Autora (2025)

3.4 Design Science Research (DSR) aplicado ao desenvolvimento do artefato

A etapa referente ao desenvolvimento do aplicativo móvel baseou-se na abordagem metodológica *Design Science Research* (DSR), cuja essência é a construção e a avaliação de artefatos capazes de resolver problemas práticos e gerar conhecimento científico (HEVNER *et al.*, 2004; PEFFERS *et al.*, 2007). Tal abordagem é adequada ao presente estudo por contemplar o desenvolvimento dos artefatos: (1) um modelo de detecção baseado em YOLOv8, aplicado à classificação de morangos; (2) um aplicativo móvel integrado a este modelo, destinado a apoiar a classificação da qualidade de morangos em ambientes de comercialização, como a CEAGESP. Segundo Peffers *et al.* (2007), o processo da DSR é estruturado em seis etapas interdependentes e são elas: identificação do problema, definição dos objetivos, desenho e desenvolvimento, demonstração, avaliação e comunicação.

3.4.1 Identificação do Problema e Motivação

O morango apresenta alta perecibilidade; demanda uma avaliação rápida e precisa. No contexto da CEAGESP, falhas na classificação podem resultar perdas significativas, redução da qualidade percebida e desperdício ao longo da cadeia. A avaliação manual é limitada por sua subjetividade, variabilidade entre avaliadores. Assim, justifica-se o desenvolvimento de ferramentas baseadas em Inteligência Artificial que tornem o processo mais rápido, padronizado e acessível.

Para complementar a identificação do problema, foram realizadas também visitas técnicas a produtores de morango em Atibaia e Monte Alegre do Sul, conforme descrito no Apêndice B.

3.4.2 Definição dos Objetivos

Os objetivos do artefato foram definidos para atender às lacunas identificadas na literatura e às necessidades operacionais observadas na CEAGESP, em alinhamento ao objetivo geral e aos objetivos específicos apresentados na Introdução. O DSR orienta que os objetivos sejam direcionados à resolução prática do problema identificado: a subjetividade e a baixa padronização da triagem pós-colheita de morangos. Assim, estabelecem-se os seguintes objetivos do artefato:

- a) Construção e treinamento de um modelo YOLOv8 capaz de identificar e classificar morangos quanto à qualidade, maturação, defeitos e doenças. Atende diretamente ao Objetivo Específico 1.
- b) Desenvolver um aplicativo móvel que execute o modelo em tempo real, utilizando a câmera do dispositivo. Atende ao Objetivo Específico 2.
- c) Validar o modelo e o aplicativo em condições reais de comercialização, considerando variabilidade de iluminação, lotes e dispositivos. Relaciona-se ao Objetivo Específico 3.
- d) Contribuir para a redução de perdas e para a melhoria da eficiência logística da cadeia de suprimentos do morango. Complementa o Objetivo Geral ao evidenciar o impacto prático esperado do artefato.

3.4.3 Desenho e Desenvolvimento do Artefato

O processo de construção do artefato foi estruturado em duas etapas iniciais, e ele baseou-se nas contribuições dos estudos realizados.

Na primeira contribuição, referente ao Artigo 1 – Modelo YOLOv8 para a identificação de morangos, foi realizada a elaboração e a anotação de um *Dataset* com imagens de diferentes bases (*Google*, *Kaggle*, CEAGESP e acervo próprio). As etapas de pré-processamento incluíram o redimensionamento das imagens para 640×640 *pixels*, auto-orientação e normalização. Para ampliar a capacidade de generalização do modelo, foram aplicadas técnicas de aumento de dados, como *flips* horizontais, rotações em diferentes ângulos e aplicação de borramento. O modelo YOLOv8 foi então treinado em diferentes configurações (100, 200 épocas

e *early stopping* em torno de 70 épocas), e sua performance foi avaliada com métricas quantitativas: *precision*, *recall*, *mAP@0.5* e *mAP@0.5:0.95*, para que fosse possível aprender como treinar o modelo e desenvolvê-lo.

Já a segunda contribuição fundou-se no Artigo 2 – *Smart Postharvest Management of Strawberries: YOLOv8-Driven Detection of Defects, Diseases, and Maturity* – que demonstrou a viabilidade da utilização do YOLOv8n em aplicações práticas de classificação de qualidade no pós-colheita. Para isso, foi compilado um *DataSet* expandido de 5.663 imagens que abrangem oito classes distintas (boa qualidade, imaturo, maturação desigual, ausência de cálice, deformação grave, além de doenças como antracnose, mofo cinzento e oídio). O modelo foi treinado em diferentes regimes (100, 200 e *early stopping* em torno de 70 épocas); alcançou desempenho satisfatório, com destaque para classes com características bem definidas, como antracnose e mofo cinzento (*mAP@0.5* > 0.96). A arquitetura resultante contemplou três elementos principais: (1) módulo de inferência em tempo real, com tempo médio de apenas 1 ms por imagem; (2) sistema de análise e distinção das classes de qualidade, capaz de identificar defeitos, doenças e estágio de maturação; (3) módulo de monitoramento e exportação de resultados, o que possibilita consolidar informações relevantes para a tomada de decisão no controle pós-colheita. Assim, o YOLOv8n, conforme os estudos, apresentou eficácia para aplicações em sistemas automatizados de classificação de morangos e reforçou sua aplicabilidade na redução de perdas e na gestão inteligente da cadeia produtiva.

3.4.3.1 Desenvolvimento da Solução (Aplicativo Android e Versão Web)

O desenvolvimento da aplicação foi conduzido com o objetivo de permitir o uso prático do modelo de detecção e classificação de morangos em diferentes plataformas, resultando na implementação de duas versões funcionais: uma versão *Android* (APK) e uma versão *Web*. Ambas foram desenvolvidas utilizando o framework Expo, baseado em *React Native*, devido à sua capacidade de compilar o mesmo código para múltiplos dispositivos.

Após a definição do ambiente de desenvolvimento, foram importadas as bibliotecas necessárias para captura e seleção de imagens, gerenciamento de estados, navegação e comunicação com serviços externos. A estrutura do

aplicativo foi então construída, incluindo telas, componentes gráficos e o fluxo de operação para envio de imagens ao modelo.

Para a realização da inferência, foi utilizada exclusivamente a API de inferência, responsável por executar o modelo treinado em nuvem. Dessa forma, tanto a versão Android quanto a versão Web realizam o mesmo processo:

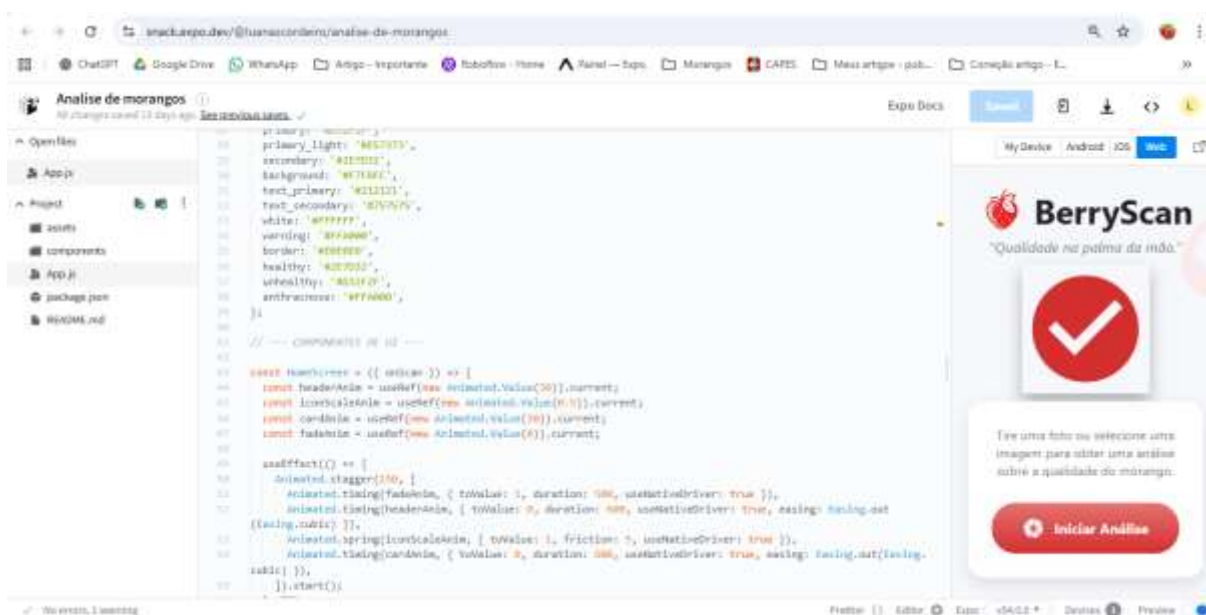
1. Captura ou seleção de uma imagem pelo usuário;
2. envio da imagem ao *endpoint* da API;
3. recebimento das anotações (*bounding boxes*);
4. da classe prevista pelo modelo;
5. do score de confiança da detecção.

A resposta retornada pela API também inclui uma imagem anotada, destacando visualmente o defeito ou condição identificada no morango, o que facilitava a interpretação por parte do usuário.

A versão APK para *Android* foi gerada utilizando o sistema de *build* do Expo, possibilitando sua instalação em dispositivos móveis utilizados pelos classificadores da CEAGESP. A versão Web, por sua vez, foi disponibilizada diretamente via navegador, permitindo testes imediatos em computadores e tablets sem necessidade de instalação.

Embora dependessem de conexão à internet por utilizarem inferência via API, ambas as plataformas demonstraram desempenho satisfatório durante os testes iniciais. A disponibilidade das duas versões permite validar posteriormente a solução em diferentes cenários operacionais, incluindo áreas internas e externas dos galpões da CEAGESP, com diferentes condições de iluminação e diversidade de fundos. A seguir a figura 3 mostra o ambiente Expo com a parte de código na linguagem *JavaScript* e a Interface do aplicativo no canto direito da tela.

Figura 3: Ambiente Expo Interface do aplicativo *BerryScan*.



Fonte: Autora (2025).

Concluídas essas etapas, desenvolveu-se o primeiro protótipo para os testes iniciais (ver Apêndice C), e o aplicativo foi devidamente registrado, conforme apresentado no Anexo 1 que se refere a documentação do registro.

3.4.4 Demonstração

A demonstração foi conduzida em dois níveis:

1. Laboratorial: aplicação do modelo YOLOv8 em *DataSet* de teste, para verificar acurácia e robustez, conforme os artigos 1 e 2 (Apêndice D)
2. Aplicada: execução do aplicativo em ambiente simulado de triagem de morangos que considerou condições reais da CEAGESP (variação de iluminação, diferentes lotes de frutas).

3.4.5 Avaliação

A avaliação do artefato envolveu critérios quantitativos e qualitativos:

Modelo YOLOv8: análise de métricas padrões (*precision*, *recall*, *mAP*) e de matrizes de confusão, além da identificação de erros críticos (como, por exemplo, a confusão entre “boa qualidade” e “imaturo”), conforme apresentado nos artigos 1 e 2 disponíveis em apêndices.

Aplicativo móvel: avaliação exploratória de usabilidade com potenciais usuários, na consideração de Tempo de resposta (*inference time*), facilidade de uso

(*interface*), percepção de aplicabilidade (viabilidade em feiras/centros de distribuição). Foram realizados testes e formulários para os quais se utilizou escala *Likert*, conforme Apêndice E.

3.4.6 Comunicação

Os resultados obtidos foram comunicados em duas frentes:

1. Produção científica: dois artigos (um submetido e apresentado no SIMPEP em 2024; outro publicado na *AgriEngineering*, em 2025), integrados à presente dissertação.
2. Disseminação prática: disponibilização dos protótipos e relatórios técnicos à CEAGESP, com a intenção da aplicação real na cadeia de triagem e de classificação de morangos.

3.5 Fluxo Metodológico do processo de *Design Science Research*

O fluxograma apresenta as seis etapas do processo de *Design Science Research*: (1) Identificação do Problema, com ênfase nas perdas pós-colheita de morangos na CEAGESP; (2) Definição dos Objetivos que envolvem a construção de um modelo YOLOv8 e o desenvolvimento de um aplicativo móvel; (3) Desenho e Desenvolvimento dos artefatos; (4) Demonstração em cenários laboratoriais e aplicados; (5) Avaliação, por meio de métricas de desempenho e análise de usabilidade; (6) Comunicação que engloba a divulgação científica e a aplicação prática dos resultados.

Figura 4: Fluxo metodológico da pesquisa baseado em *Design Science Research* (DSR).



Fonte: Autora (2025).

4 RESULTADOS

Este capítulo apresenta e discute os resultados obtidos nos experimentos conduzidos com os modelos YOLOv8m e YOLOv8n, aplicados às tarefas de detecção e classificação da qualidade de morangos. A progressão metodológica adotada, inicialmente centrada na detecção básica dos frutos e posteriormente expandida para a classificação detalhada de defeitos, doenças e estágios de maturação, fornece a base necessária para os objetivos desta dissertação, que se propõe a construir um aplicativo para a avaliação automatizada da qualidade de morangos na cadeia pós-colheita. Para facilitar a visualização e a compreensão dos resultados, figuras e quadros são integrados ao longo do capítulo.

4.1 Integração dos Estudos

A estudo realizado foi organizado em duas etapas experimentais interligadas: a primeira é dedicada à detecção de morangos em imagens por meio do modelo YOLOv8m; a segunda, mais abrangente, é dedicada à classificação da qualidade e utiliza o modelo YOLOv8n. Embora independentes em termos de escopo, as duas etapas são complementares e delineiam uma trajetória de amadurecimento metodológico e técnico. A Figura 5 ilustra esse encadeamento por meio de um fluxograma e representa o *processo* geral da pesquisa. Ela ainda evidencia a sequência lógica entre aquisição, pré-processamento de imagens, anotação manual, treinamento dos modelos, inferência e aplicação.

Figura 5: *Processo geral da pesquisa.*



Fonte: Autora (2025)

De maneira complementar, o Quadro 1 apresenta uma síntese comparativa entre os dois estudos. Destaca elementos, como tamanho do *dataset*, número de classes, métricas de desempenho e aplicabilidade prática. Essa síntese reforça a ideia de que o primeiro estudo cumpre o papel de etapa fundacional, enquanto o segundo consolida um sistema completo de classificação multiclasse já orientado a aplicações logísticas.

Quadro 1: Comparação dos Artigos

Elemento	Artigo 1 (YOLOv8m)	Artigo 2 (YOLOv8n)
<i>Objetivo</i>	Identificar morangos	Classificar 8 classes de qualidade
<i>Dataset</i>	1257 imagens	5663 imagens
<i>Nº classes</i>	1	8
<i>Melhor mAP50</i>	0.47	0.79
<i>Melhor definição</i>	70 épocas	200 épocas (ou 70 com otimização)
<i>Aplicabilidade</i>	Triagem inicial	Pós-colheita e decisão logística

Fonte: Autora (2025)

4.2 Resultados do Modelo YOLOv8m: Detecção de Morangos

A primeira etapa do trabalho concentrou-se na detecção dos frutos em imagens, requisito fundamental para qualquer sistema de classificação subsequente. O treinamento com YOLOv8m utilizou 1.257 imagens rotuladas com uma única classe, o que proporcionou uma base experimental para avaliar a capacidade do modelo em reconhecer instâncias de morangos, independentemente de variações de cor, formato, iluminação ou disposição espacial.

Ao longo do treinamento, observou-se melhoria contínua das métricas até cerca de 70 épocas, ponto a partir do qual as curvas de desempenho tendem à estabilização. A Tabela 2 apresenta a evolução das principais métricas; revela que o *mAP50* oscilou entre 0,44 e 0,47 nas iterações mais estáveis e que a *Box Precision* se manteve próxima de 0,50. Apesar de serem valores moderados, o comportamento do modelo é consistente com o tamanho reduzido e a simplicidade do *dataset*. A análise visual das inferências demonstrou que o modelo conseguiu detectar adequadamente todos os morangos nas imagens de teste, ainda que com variação na confiança das detecções.

Esses resultados confirmam a viabilidade da abordagem e evidenciam que o YOLOv8m, mesmo treinado em uma base relativamente limitada, é capaz de fornecer

uma etapa inicial de detecção confiável. Essa etapa é crucial para a segunda fase da pesquisa, uma vez que qualquer processo automatizado de classificação depende de detecções precisas e estáveis.

Quadro 2: Resumo do treinamento: evolução das Métricas YOLOv8m

<i>Treino</i>	<i>Epoch</i>	<i>BoxP</i>	<i>R</i>	<i>mAP50</i>	<i>mAP50-90</i>
1º	10	0.309	0.413	0.295	0.175
2º	70	0.525	0.479	0.447	0.301
3º	70	0.525	0.479	0.447	0.301
4º	200	0.451	0.512	0.462	0.316
5º	70	0.453	0.563	0.442	0.289
6º	70	0.478	0.58	0.449	0.29
7º	70	0.493	0.569	0.472	0.294
8º	70	0.5	0.537	0.465	0.294
9º	70	0.413	0.522	0.387	0.255
10º	70	0.472	0.522	0.422	0.279

Fonte: Autora (2025)

Figura 6: Exemplo de imagem utilizada no teste.



Fonte: Autora (2025)

4.3 Resultados do Modelo YOLOv8n: Classificação da Qualidade


O segundo estudo aprofunda significativamente o escopo analítico ao incorporar oito categorias distintas relacionadas à qualidade do morango; para isto, cobre tanto condições desejáveis, quanto defeitos e doenças. A ampliação do *dataset* para 5.663 imagens permitiu treinar um modelo mais robusto, capaz de captar nuances visuais presentes em frutos com diferentes características. O YOLOv8n apresentou bom desempenho em relação ao modelo anterior. Atingiu *mAP50* de 0.79, precisão de 0.744 e *recall* de 0.777 após 200 épocas de treinamento, valores que refletem equilíbrio entre capacidade de generalização e sensibilidade às particularidades das classes.

4.3.1 Desempenho por classe

A análise individual das classes revelou diferenças importantes entre os grupos. A Figura 7 apresenta as curvas de *F1-score* para cada classe, o que permite observar como o desempenho evoluiu ao longo das épocas. Doenças com característica visual evidente, como antracnose, oídio (powdery mildew) e mofo-cinza (*gray mold*), foram detectadas, fato que indica que padrões texturais e cromáticos característicos são prontamente captados pela rede.

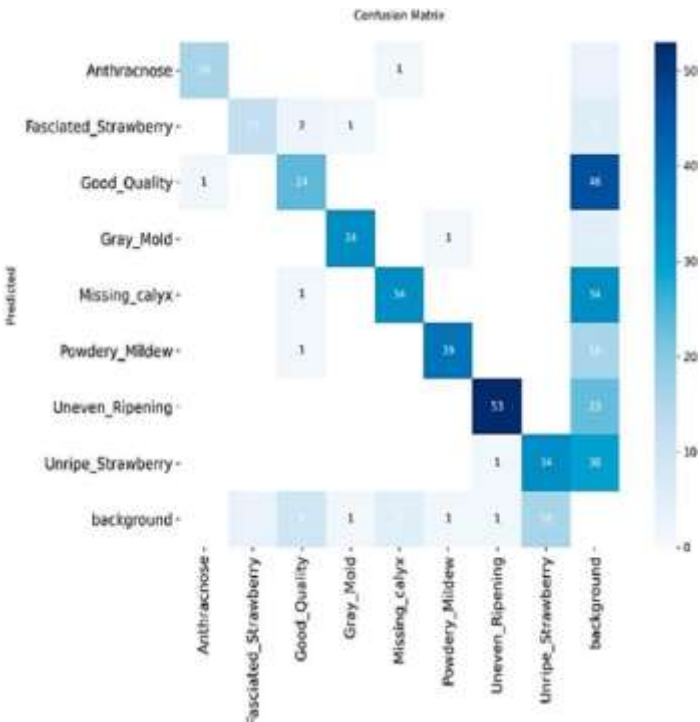
Em contrapartida, classes como *Good Quality*, *Unripe* e *Uneven Ripening* apresentaram desempenho inferior devido às sutis diferenças visuais entre elas. Essa proximidade gera sobreposição nas respostas da rede, situação que se torna evidente nas matrizes de confusão apresentadas na Figura 7.

Figura 7: Curvas de F1- score por Classe.



Fonte: Autora (2025).

Figura 8: Matriz de Confusão.



Fonte: Autora (2025).

A persistência de confusão entre classes relacionadas ao grau de maturação ressalta uma dificuldade para esse tipo de tarefa: a transição entre verde, parcialmente maduro e totalmente maduro é contínua e frequentemente dependente de nuances de cor e textura que exigem *datasets* equilibrados e detalhados. Para sistematizar esses desafios, o Quadro 3 apresenta uma descrição dos principais obstáculos observados para cada classe, bem como sugestões de aprimoramento.

Quadro 3: Principais Desafios por Classe

Classe	Desafio Visual	Tipo de Confusão	Solução sugerida
Good Quality	Semelhança com "Uneven"	Confusão com maturação desigual	Refinar rótulo + dados balanceados
Unripe	Coloração varia	Confusão com defeitos leves	Aumentar dataset – morangos imaturos.
Fasciated	Forma irregular	Confusão com defeitos mecânicos	Treinar textura e contorno
Missing Calyx	Área pequena	Confusão com o fundo	Fotos com maior foco no cálice
Gray Mold	Boa performance	–	Aumentar dataset

<i>Anthracnose</i>	Boa performance	–	Aumentar <i>dataset</i>
<i>Powdery Mildew</i>	Boa performance	–	Aumentar <i>dataset</i>
<i>Uneven Ripening</i>	Transição difusa	Confusão com "Good Quality"	Separar níveis de maturação

Fonte: Autora (2025).

4.4 Comparação entre as Variantes do YOLOv8

Para avaliar a adequação das diferentes variantes do YOLOv8 ao contexto desta pesquisa, no artigo 2 foi realizada uma comparação entre os modelos *nano*, *small* e *medium*. O quadro 4 apresenta essa comparação considerando precisão e tempo de inferência.

Quadro 4: Comparação dos Modelos YOLOv8

Modelo	mAP50	Tempo de inferência
YOLOv8n	0.827	9.3 ms
YOLOv8s	0.827	19.3 ms
YOLOv8m	0.828	44.4 ms


Fonte: Autora (2025)

Os resultados demonstram que o YOLOv8n oferece o melhor equilíbrio entre acurácia e velocidade; é capaz de operar em tempo real com apenas 9,3 ms por imagem e desempenho comparável ou superior às versões mais pesadas. Essa característica o torna especialmente adequado para aplicações práticas em linhas de triagem, centros de distribuição ou ambientes de pós-colheita que demandam rapidez e eficiência.

4.5 Aplicação dos Resultados na Cadeia de Suprimentos do Morango

A última etapa da análise integra os resultados técnicos à realidade operacional da cadeia de suprimentos. A Figura 9 apresenta um mapa conceitual que relaciona as etapas da cadeia, da colheita ao varejo, às potencialidades de aplicação do modelo proposto. A utilização do modelo ao longo dessas etapas permite monitoramento contínuo, identificação precoce de problemas fitossanitários, segregação eficiente de lotes e priorização logística baseada na maturidade. Ainda contribui para a redução de perdas e para o aumento da qualidade percebida pelo consumidor final.

Figura 9: Mapa Conceitual da Cadeia de Suprimentos.



Fonte: Autora (2025)

Esses achados confirmam que os modelos desenvolvidos nesta pesquisa não apenas apresentam desempenho técnico satisfatório. Eles também dialogam diretamente com as demandas reais da cadeia de pós-colheita do morango e reforçam sua aplicabilidade prática e relevância científica.

5 DISCUSSÃO

Este capítulo discute os resultados obtidos nos dois estudos desenvolvidos nesta pesquisa; articula-os com a literatura científica, com os desafios da cadeia de suprimentos do morango e com os objetivos centrais desta dissertação. A discussão está organizada de forma a evidenciar as contribuições das pesquisas (Artigos 1 e 2), para a construção de um sistema tecnológico capaz de reduzir perdas, melhorar a tomada de decisão logística e fortalecer a qualidade pós-colheita do morango.

5.1 Integração entre Detecção e Classificação na Avaliação Automatizada de Morangos

A detecção inicial dos frutos, obtida pelo modelo YOLOv8m no desenvolvimento do Artigo 1 (Apêndice D), constitui a base estrutural do sistema de classificação da qualidade apresentado nesta dissertação. Mesmo com um conjunto de dados reduzido, o modelo apresentou taxas de detecção estáveis; mostra que arquiteturas intermediárias são capazes de identificar com precisão o objeto de interesse, requisito essencial para etapas posteriores, como a classificação multiclasse. Resultados semelhantes foram verificados no Artigo 2 (Apêndice D), que evidenciou a viabilidade do uso do YOLOv8n na detecção de maturação, de defeitos e de doenças em morangos pós-colheita (Cordeiro; Nääs; Okano, 2025). Em consonância, Ogundele *et al.* (2025) desenvolveram uma versão otimizada do YOLOv8s para classificação de maturação e rastreamento em tempo real e alcançaram $mAP@0,5$ de 92,5%.

Outras contribuições recentes incluem o DS-YOLO, modelo leve proposto por Teng *et al.* (2025) para aumentar a eficiência computacional e adaptações voltadas à análise de saúde vegetal, como o uso de atenção contextual em Wu *et al.* (2025). Zhao *et al.* (2025) também destacam que mecanismos de atenção global podem ampliar a sensibilidade à maturação. Assim, embora o desempenho do YOLOv8m tenha sido moderado, sua estabilidade é estratégica para os objetivos desta dissertação, pois uma detecção precisa evita falhas estruturais e minimiza erros para etapas subsequentes de classificação.

5.2 Desempenho do YOLOv8n e Complexidade da Classificação de Qualidade

A segunda etapa da análise, conduzida com o YOLOv8n (Artigo 2), mostrou um avanço significativo no desempenho do sistema; refletiu tanto a maior complexidade

do modelo, quanto a ampliação do *dataset* e a diversificação dos padrões de entrada. O *mAP50* de 0,79, aliado à precisão e ao *recall* próximos de 0,75–0,77 (Cordeiro; Nääs; Okano (2025), demonstra que o modelo consegue identificar com precisão os frutos, o que constitui uma base sólida para as etapas subsequentes de classificação multiclasse. Resultados semelhantes foram observados por Gamani, Arhin e Asamoah (2024), que relataram desempenho robusto do YOLOv8 na segmentação de morangos em campo aberto.

A análise por classe evidenciou a complexidade intrínseca da classificação de qualidade. Categorias, como *Good Quality*, *Unripe* e *Uneven Ripening* apresentaram fronteiras visuais difusas, fortemente influenciadas por fatores, como iluminação, textura superficial e heterogeneidade de coloração. Esse comportamento é consistente com o observado por Yue, Xu e Wu (2025), que sugerem que modelos baseados apenas em imagens RGB podem não capturar completamente nuances sutis de maturação.

Apesar dessas limitações, o YOLOv8n demonstrou capacidade classificatória adequada para uso prático. A elevada precisão em classes patológicas com a inclusão de *anthracnose*, *powdery mildew* e *gray mold*, indica que doenças com padrões texturais distintos podem ser detectadas com confiabilidade. Tal desempenho é crítico para a cadeia de suprimentos, pois permite a identificação precoce de lotes contaminados e evita que doenças comprometam outros frutos. Pranata, Darma e Sandhiyasa (2023) também evidenciaram que o YOLOv8 apresenta alta acurácia na detecção de doenças de morango, reforça a relevância desta abordagem para aplicações industriais.

Em síntese, os estudos confirmam que a etapa de detecção inicial é estratégica e sustentadora do sistema de classificação de qualidade proposto, que ele garante que etapas posteriores não sejam comprometidas por falhas estruturais e que oferece uma base confiável para decisões na gestão pós-colheita.

5.3 Limitações Observadas e Implicações para a Expansão da Metodologia

Durante os experimentos, observou-se que algumas classes de maturação dos morangos se confundem facilmente, especialmente *Unripe*, *Good Quality* e *Uneven Ripening*. Isso mostra que é preciso melhorar a base de dados e a forma como as imagens são anotadas. O problema não está só no modelo; está ainda na própria maturação, que é gradual e difícil de classificar, até mesmo para humanos.

Uma forma de melhorar a precisão é usar informações além das imagens RGB. Por exemplo, espectros não visíveis, como infravermelho próximo (NIR) ou infravermelho de onda curta (SWIR), e imagens multiespectrais podem ajudar o modelo a perceber diferenças sutis entre os frutos. Li *et al.*, (2024) mostraram que a espectroscopia *hiperespectral* consegue prever características de qualidade de morangos em diferentes estágios de maturação. Mancini *et al.* (2020) também demonstraram que a técnica NIR permite medir firmeza e sólidos solúveis sem destruir o fruto.

Além disso, coletar imagens em condições reais de iluminação e usar técnicas avançadas de *data augmentation* ajuda a aumentar a robustez do modelo; torna-o mais capaz de lidar com frutos difíceis de classificar. Estudos mostram ainda que a combinação de imagens com sensores e *machine learning* permite detectar problemas fisiológicos antes de aparecerem visualmente, aumenta a confiabilidade da classificação (CASTRO *et al.*, 2024).

5.4 Adequação dos Modelos YOLOv8 para Aplicações Reais na Cadeia Logística

A comparação entre as variantes YOLOv8n, YOLOv8s e YOLOv8m, apresentada nos resultados do Artigo 2 (Apendice D), reforçou que o YOLOv8n oferece o melhor equilíbrio entre acurácia, velocidade e leveza, características cruciais para sistemas de triagem automatizada. Conforme apresentado no estudo, o YOLOv8n atingiu um *mAP50* de 0,79 e tempo de inferência de apenas 1 ms por imagem, o que mostra que é completamente viável para aplicações em tempo real (CORDEIRO; NÄÄS; OKANO, 2025).

Esse desempenho de inferência é extremamente relevante para cadeias de suprimento de produtos perecíveis, como morangos, produto para o qual decisões precisam ser tomadas rapidamente para evitar perda de qualidade. A capacidade de classificar frutos em tempo real permite dividir lotes por maturação, isolar frutos contaminados e priorizar rotas de envio, ações que podem reduzir perdas pós-colheita e melhorar a eficiência logística. Sistemas semelhantes de classificação de morangos que utilizam YOLOv8 já foram implementados em campo, exploram modelos leves, capazes de realizar contagem e classificação em tempo real (OGUNDELE *et al.*, 2025).

5.5 Contribuições do Modelo para a Cadeia de Suprimentos do Morango

Os resultados obtidos nesta pesquisa indicam que o modelo desenvolvido tem potencial direto para impactar positivamente várias etapas da cadeia de suprimentos. A capacidade de identificar doenças permite decisões rápidas de separação e tratamento; ela evita que frutos contaminados comprometam lotes inteiros. A classificação por maturidade viabiliza estratégias avançadas de logística, como expedição escalonada, alocação diferenciada para mercados e uso mais eficiente de câmaras de resfriamento.

Além disso, a triagem automatizada reduz a dependência de inspeção manual, que é subjetiva, demorada e suscetível a erros. A automação não apenas aumenta a precisão, mas também contribui para reduzir custos operacionais e melhorar a rastreabilidade; alinha-se às tendências globais de digitalização e de agricultura de precisão.

A Figura 9, apresentada no capítulo anterior, resume essas possibilidades ao inserir o modelo no fluxo da cadeia de suprimentos. A aplicação simultânea em diferentes pontos, da colheita ao varejo, demonstra a versatilidade do sistema e reforça o caráter inovador desta dissertação.

A análise integrada dos resultados evidencia que os modelos YOLOv8m e YOLOv8n, apesar de suas limitações, oferecem desempenho robusto e aplicabilidade real na avaliação automatizada da qualidade de morangos. A detecção confiável, associada à classificação de múltiplas categorias de qualidade e doença, forma um sistema completo e funcional que pode ser incorporado à cadeia de suprimentos com impacto imediato na redução de perdas e na melhoria da eficiência operacional.

A discussão demonstra que os objetivos desta dissertação foram atendidos de forma consistente e que os achados contribuem tanto para o avanço científico, quanto para a solução prática de problemas logísticos na pós-colheita de morangos. As oportunidades de aprimoramento identificadas abrem espaço para a continuidade da pesquisa e para a ampliação das aplicações tecnológicas no setor agrícola. A seguir, faz-se a comparação entre os dois artigos que estruturam essa Dissertação.

Quadro 5: Comparação entre os artigos desenvolvidos na pesquisa

Aspecto	Artigo 1 (SIMPEP 2024)	Artigo 2 (AgriEngineering 2025)
Objetivo	Prova de conceito: avaliar YOLOv8m na identificação de morangos	Aplicação prática: YOLOv8n para defeitos, doenças e maturação
Dataset	Open Images Dataset V7 (subset)	5.663 imagens (Google, Kaggle, CEAGESP, fotos próprias)
Classes	Classe única (morangos)	8 classes (Good Quality, Unripe, Defects, Diseases)
Pré-processamento	Resize e ajustes básicos	Resize 640x640, auto-orientação
Aumento de dados	Flip e rotações simples	Flip, rotação, blur, variação de iluminação
Treinamentos	50, 70, 100, 200 épocas	100, 200 e ~70 (early stopping)
Métricas avaliadas	BoxP, Recall, mAP@0.5	Precision, Recall, mAP@0.5, mAP@0.5:0.95, Confusion Matrix
Principais resultados	Melhor equilíbrio em 70 épocas (evitou <i>overfitting</i>)	mAP 75-83%; classes minoritárias com menor recall; inferência ~1ms
Contribuições	Validou viabilidade técnica do YOLOv8m; base para evolução	Validou aplicabilidade prática em tempo real; viabilidade em app móvel

Fonte: Autora (2025).

O quadro acima sintetiza as principais diferenças e os principais avanços entre os dois artigos que compõem esta dissertação. O Artigo 1 (SIMPEP 2024) apresenta a prova de conceito inicial, com aplicação do modelo YOLOv8 em *dataset* reduzido e foco apenas na identificação de morangos. Já o Artigo 2 (AgriEngineering 2025) expande a proposta; utiliza um *dataset* mais elaborado com múltiplas classes; avalia métricas detalhadas e valida a aplicabilidade prática em tempo real, com vistas à integração em aplicativos móveis.

6 CONSIDERAÇÕES FINAIS

A presente dissertação teve como propósito apresentar a aplicação de técnicas de visão computacional para a classificação pós-colheita de morangos, com foco no apoio à tomada de decisão em ambientes operacionais, como a CEAGESP. A pesquisa foi estruturada em quatro etapas complementares, envolvendo levantamento bibliográfico, experimentos computacionais e o desenvolvimento de um protótipo móvel, o que possibilitou a avaliação prática da solução proposta.

Um dos diferenciais deste estudo está na possibilidade de validação em contextos reais, aproximando o desenvolvimento tecnológico das rotinas de operação do CEAGESP. Foram conduzidos testes de usabilidade do protótipo com consumidores finais, comerciantes e equipe técnica, aplicou-se também um questionário estruturado com escala *Likert*, permitindo analisar percepções relacionadas à facilidade de uso, clareza da interface, velocidade de resposta e potencial de adoção no processo de triagem de morangos. Os resultados indicaram boa aceitação inicial do aplicativo e destacaram seu potencial como ferramenta complementar ao método manual de classificação. Além disso, o software desenvolvido no âmbito desta pesquisa foi devidamente registrado, conforme documentação apresentada no Anexo 1.

Durante essa etapa, os participantes apontaram pontos de atenção, reforçando questões já observadas na análise técnica. O aplicativo ainda apresenta alguns erros de classificação, sobretudo em classes com características visuais muito sutis, como diferentes níveis de maturação, ou em categorias minoritárias no *dataset*, como *Anthracoze* e *Powdery Mildew*. Tais erros derivam, principalmente, da variação intra-classe, das condições de iluminação, de oclusões e do desbalanceamento das classes, fatores que influenciam a capacidade discriminativa do modelo. Essas observações evidenciam a necessidade de ampliar o conjunto de dados, incorporar maior diversidade visual e a importância do cuidado com as anotações, de modo a aprimorar o desempenho nas classes mais desafiadoras.

As contribuições desta pesquisa atingem três dimensões. No âmbito científico, o estudo avança na aplicação do YOLOv8 para frutas altamente perecíveis como o morango, especialmente ao considerar cenários reais de comercialização, e não apenas ambientes controlados. No âmbito tecnológico, demonstra-se a viabilidade de um protótipo móvel de baixo custo, capaz de realizar inferências rápidas e auxiliar

trabalhadores da cadeia de suprimentos. No âmbito social e ambiental, a solução favorece práticas mais eficientes e sustentáveis, alinhando-se aos Objetivos de Desenvolvimento Sustentável (ODS), em particular o ODS 9 (Indústria, inovação e infraestrutura) e o ODS 12 (Consumo e produção responsáveis), ao contribuir para a redução de perdas e o uso mais racional dos recursos na cadeia logística.

Apesar dos avanços alcançados, o estudo apresenta limitações que constituem oportunidades para pesquisas futuras. A expansão da base de dados, em volume e diversidade de condições reais fundamental para reduzir erros de classificação. Testes ampliados em escala operacional na CEAGESP, envolvendo diferentes turnos, lotes, ambientes e perfis de classificadores, contribuirão para validar de forma mais robusta a eficácia da solução. Investigações futuras também podem incorporar imagens multiespectrais, sensores IoT e integração com sistemas de rastreabilidade, ampliando o monitoramento em tempo real dos atributos de qualidade. Além disso, aperfeiçoamentos na interface e na experiência do usuário poderão facilitar a adoção do aplicativo no ambiente produtivo. O contato com produtores de morango em Atibaia e Monte Alegre do Sul reforçou a relevância prática da proposta, evidenciando que soluções de baixo custo e fácil usabilidade são essenciais para a adoção no setor. Essa aproximação com a realidade dos agricultores indicou que a pesquisa não apenas contribui no âmbito acadêmico, mas também possui potencial de transferência tecnológica para diferentes contextos e etapas da cadeia de suprimentos.

Diante dos resultados apresentados e discutidos ao longo desta dissertação, conclui-se que o objetivo geral proposto foi atingido, ao evidenciar a viabilidade da aplicação de técnicas de visão computacional baseadas em redes neurais profundas para a classificação pós-colheita de morangos, com potencial de apoio à tomada de decisão em ambientes reais de comercialização, como a CEAGESP. De forma complementar, os objetivos específicos também foram alcançados, uma vez que foi realizado o levantamento e a análise do estado da arte, desenvolvido e treinado um modelo YOLOv8, avaliado seu desempenho em condições práticas e implementado um protótipo móvel funcional para a classificação da qualidade dos frutos. Os experimentos computacionais, aliados à validação preliminar com usuários, demonstraram que a solução proposta atende às demandas do contexto estudado, confirmando seu potencial de aplicação prática e sua contribuição para a melhoria da eficiência, da padronização e da sustentabilidade do processo de triagem pós-colheita de morangos.

REFERÊNCIAS

ADEWUSI, A. O. et al. AI in precision agriculture: A review of technologies for sustainable farming practices. *World Journal of Advanced Research and Reviews*, v. 21, p. 2276–2285, 2024. DOI: <https://doi.org/10.30574/wjarr.2024.21.1.0314>.

AHMED, M. M. et al. Biochemical dynamics and quality attributes of strawberry fruits across maturity stages with respect to different preservation methods. *Futuristic Biotechnology*, v. 4, p. 28–35, 2024. DOI: <https://doi.org/10.54393/fbt.v4i01.98>.

AL RABBANI ALIF, M.; HUSSAIN, M. YOLOv1 to YOLOv10: a comprehensive review of YOLO variants and their application in the agricultural domain. *arXiv preprint*, arXiv:2406.10139, 2024. Disponível em: <https://arxiv.org/abs/2406.10139>. Acesso em: 23 nov. 2025.

ALJAWASIM, B. D.; SAMTANI, J. B.; RAHMAN, M. New insights in the detection and management of anthracnose diseases in strawberries. *Plants*, v. 12, p. 3704, 2023. DOI: <https://doi.org/10.3390/plants12213704>.

ALZEIST, A. R.; RESENDE, J. T. V. Strawberry breeding in Brazil: Current momentum and perspectives. *Horticultura Brasileira*, v. 37, p. 7–16, 2019. DOI: <https://doi.org/10.1590/S0102-053620190101>.

BADGUJAR, C. M.; POULOSE, A.; GAN, H. Agricultural object detection with You Look Only Once (YOLO) algorithm: a bibliometric and systematic literature review. *Computers and Electronics in Agriculture*, v. 223, art. 109090, 2024. DOI: <https://doi.org/10.1016/j.compag.2024.109090>.

CASTRO-VALDECANTOS, P.; EGEA, G.; BORRERO, C. et al. Detecção de comprometimento fisiológico induzido pela murcha de Fusarium em plantas de morango usando imagens hiperespectrais e aprendizado de máquina. *Precision Agric*, 25, 2958–2976, 2024. DOI: <https://doi.org/10.1007/s11119-024-10173-6>.

CEDES – Centro de Estudos e Debates Estratégicos. *Perdas e desperdícios de alimentos no Brasil*. Brasília: Câmara dos Deputados, 2018. Disponível em:

<https://www2.camara.leg.br>. Acesso em: 20 mar. 2025.

CONCEIÇÃO, G. S.; SOUSA, G. C.; SILVA-MATOS, R. R. S.; MOTA, P. R. A. Strawberry Production in Brazil: a Bibliometric Analysis and Systematic Review. *Revista de Gestão Social e Ambiental*, v. 19, n. 1, 2025. Disponível em: <https://rgsa.openaccesspublications.org/rgsa/article/view/11495>. Acesso em: 23 nov. 2025.

CORDEIRO, L. d. S.; NÄÄS, I. d. A.; OKANO, M. T. Smart postharvest management of strawberries: YOLOv8-driven detection of defects, diseases, and maturity. *AgriEngineering*, v. 7, n. 8, p. 246, 2025. Disponível em: <https://www.mdpi.com/2624-7402/7/8/246>. Acesso em: 23 nov. 2025.

DING, H. et al. Application of convolutional neural networks and recurrent neural networks in food safety. *Foods*, v. 14, p. 247, 2025. DOI: <https://doi.org/10.3390/foods14020247>.

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. *Perdas pós-colheita de frutas e hortaliças no Brasil*. Brasília, 2023. Disponível em: <https://www.embrapa.br>. Acesso em: 5 mar. 2025.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA – EMBRAPA. *Relatório de Avaliação de Impacto na Cadeia Produtiva do Morango*. Brasília, DF, 2023. Disponível em: https://bs.sede.embrapa.br/2023/relatorios/meioambiente_morango.pdf. Acesso em: 23 nov. 2025.

ESPINEL, R. et al. Artificial intelligence in agricultural mapping: A review. *Agriculture*, v. 14, p. 1071, 2024. DOI: <https://doi.org/10.3390/agriculture14071071>.

FAO – Food and Agriculture Organization of the United Nations. *Global Agricultural Statistics: Strawberry*. Rome, 2025. Disponível em: <https://www.fao.org>. Acesso em: 20 abr. 2025.

GAMANI, A.-R.; ARHIN, I.; ASAMOAHA, A. K. Performance evaluation of YOLOv8 model configurations, for instance segmentation of strawberry fruit development stages in an open field environment. *ArXiv*, 2024. Disponível em: <https://arxiv.org/abs/2408.05661>. Acesso em: 23 nov. 2025.

GIRSHICK, R. et al. Rich feature hierarchies for accurate object detection and semantic segmentation. *arXiv preprint*, arXiv:1311.2524, 2014. Disponível em: <https://arxiv.org/abs/1311.2524>. Acesso em: 28 set. 2025.

HE, Y. et al. Automatic disease detection from strawberry leaf based on improved YOLOv8. *Plants*, v. 13, p. 2556, 2024. DOI: <https://doi.org/10.3390/plants13182556>.

HEVNER, A. R. et al. Design Science in Information Systems Research. *MIS Quarterly*, v. 28, n. 1, p. 75–105, mar. 2004. Disponível em: <https://www.uni-kassel.de/fb07/index.php?eID=dumpFile&t=f&f=4899&token=fda52302d42e5e5c05d7f89c2d578f80fedf7b28>. Acesso em: 28 set. 2025.

HOWARD, A. et al. Searching for MobileNetV3. In: *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2019. DOI: <https://doi.org/10.48550/arXiv.1905.02244>.

HU, X. et al. Class-attention-based lesion proposal convolutional neural network for strawberry diseases identification. *Frontiers in Plant Science*, v. 14, p. 1091600, 2023. DOI: <https://doi.org/10.3389/fpls.2023.1091600>.

HU, X.; WANG, R.; DU, J.; HU, Y.; JIAO, L.; XU, T. Class-attention-based lesion proposal convolutional neural network for strawberry diseases identification. *Frontiers in Plant Science*, v. 14, 2023. Disponível em: <https://www.frontiersin.org/articles/10.3389/fpls.2023.1091600/full>. Acesso em: 23 nov. 2025.

K., Detection of strawberry diseases using a convolutional neural network. *Plants*, v. 10, n. 1, p. 31, 2020. DOI: <https://doi.org/10.3390/plants10010031>.

KIM, B.; HAN, Y.; PARK, J.; LEE, J. Improved vision-based detection of strawberry diseases using a deep neural network. *Frontiers in Plant Science*, v. 11, 2021. DOI: <https://doi.org/10.3389/fpls.2020.559172>. Disponível em: <https://www.frontiersin.org/journals/plant-science/articles/10.3389/fpls.2020.559172>. Acesso em: 22 nov. 2025.

KRICHEN, M. Convolutional neural networks: A survey. *Computers*, v. 12, p. 151, 2023. DOI: <https://doi.org/10.3390/computers12080151>.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, p. 436–444, 2015. DOI: <https://doi.org/10.1038/nature14539>.

LI, F.; YU, J.; ZHANG, P.; XIE, M. Prediction of strawberry quality during maturity based on hyperspectral technology. *Agronomy*, v. 14, n. 7, p. 1450, 2024. DOI: <https://doi.org/10.3390/agronomy14071450>. Disponível em: <https://www.mdpi.com/2073-4395/14/7/1450>. Acesso em: 23 nov. 2025.

LI, H.; LIU, J.; HAN, K.; CAI, X. CAFM-Enhanced YOLOv8: A two-stage optimization for precise strawberry disease detection in complex field conditions. *Applied Sciences*, v. 15, n. 18, p. 10025, 2025. DOI: <https://doi.org/10.3390/app151810025>. Disponível em: <https://www.mdpi.com/2076-3417/15/18/10025>. Acesso em: 23 nov. 2025.

LIU, J.; SUN, J.; WANG, Y.; LIU, X.; ZHANG, Y.; FU, H. Non-Destructive Detection of Fruit Quality: Technologies, Applications and Prospects. *Foods*, v. 14, n. 12, art. 2137, 2025. DOI: <https://doi.org/10.3390/foods14122137>.

LIU, W. et al. SSD: Single Shot MultiBox Detector. In: *European Conference on Computer Vision (ECCV)*, p. 21–37, 2016. Disponível em: <https://arxiv.org/abs/1512.02325>. Acesso em: 28 set. 2025.

LU, Y.; GONG, M.; LI, J.; MA, J. Strawberry defect identification using deep learning infrared–visible image fusion. *Agronomy*, v. 13, n. 9, p. 2217, 2023. DOI: <https://doi.org/10.3390/agronomy13092217>. Disponível em: <https://www.mdpi.com/2073-4395/13/9/2217>.

MANCINI, M.; MAZZONI, L.; GAGLIARDI, F. et al. Application of the non-destructive NIR technique for the evaluation of strawberry fruits quality parameters. *Foods*, v. 9, n. 4, p. 441, 2020. DOI: <https://doi.org/10.3390/foods9040441>.

OGUNDELE, O. M.; TAMRAKAR, N.; KOOK, J.-H.; KIM, S.-M.; CHOI, J.-I.; KARKI, S.; AKPENPUUN, T. D.; KIM, H. T. Real-time strawberry ripeness classification and counting: an optimized YOLOv8s framework with class-aware multi-object tracking. *Agriculture*, v. 15, n. 18, p. 1906, 2025. DOI: <https://doi.org/10.3390/agriculture15181906>.

PATHMANABAN, P.; GNANAVEL, B. K.; ANANDAN, S. S. et al. Advancing post-harvest fruit handling through AI-based thermal imaging: applications, challenges, and future trends. *Discover Food*, v. 3, art. n. 27, 2023. DOI: <https://doi.org/10.1007/s44187-023-00068-2>.

PEFFERS, K. T. et al. A Design Science Research Methodology for Information Systems Research. *Journal of Management Information Systems*, v. 24, n. 3, p. 45–77, 2007. Disponível em: <https://arxiv.org/abs/2006.02763>. Acesso em: 28 set. 2025.

PETRASCH, S. et al. Grey mould of strawberry, a devastating disease caused by the ubiquitous necrotrophic fungal pathogen *Botrytis cinerea*. *Molecular Plant Pathology*, v. 20, p. 877–892, 2019. DOI: <https://doi.org/10.1111/mpp.12794>.

PRANATA, I. M. D.; DARMA, I. W. A. S.; SANDHIYASA, I. M. S.; WIGUNA, I. K. A. G. Strawberry disease detection based on YOLOv8 and K Fold cross validation. *Jurnal Ilmiah Merpati (Menara Penelitian Akademika Teknologi Informasi)*, v. 11, n. 3, p. 199–210, dez. 2023. DOI: <https://doi.org/10.24843/JIM.2023.v11.i03.p06>.

PRIYADARSHI, R.; JAYAKUMAR, A.; DE SOUZA, C. K.; RHIM, J.-W.; KIM, J. T. Advances in strawberry postharvest preservation and packaging: a comprehensive review. *Comprehensive Reviews in Food Science and Food Safety*, v. 23, n. 4, p. e13417, 2024. DOI: <https://doi.org/10.1111/1541-4337.13417>.

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)*, 2016. DOI: <https://doi.org/10.1109/CVPR.2016.91>.

REN, S. et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *arXiv preprint*, arXiv:1506.01497, 2016. Disponível em: <https://arxiv.org/pdf/1506.01497>. Acesso em: 28 set. 2025.

TAN, M.; LE, Q. EfficientNetV2: Smaller Models and Faster Training. In: *International Conference on Machine Learning*, 2021. DOI: <https://doi.org/10.48550/arXiv.2104.00298>.

TAO, Z.; LI, K.; RAO, Y.; LI, W.; ZHU, J. Strawberry Maturity Recognition Based on Improved YOLOv5. *Agronomy*, v. 14, p. 460, 2024. DOI: <https://doi.org/10.3390/agronomy14030460>.

TENG, H.; SUN, F.; WU, H.; LV, D.; LV, Q.; FENG, F.; YANG, S.; LI, X. DS-YOLO: a lightweight strawberry fruit detection algorithm. *Agronomy*, v. 15, n. 9, p. 2226, 2025. DOI: <https://doi.org/10.3390/agronomy15092226>.

UKWUOMA, C. C.; ZHIGUANG, Q.; HEYAT, M. B. B.; ALI, L.; ALMASPOOR, Z.; MONDAY, H. N. Recent advances in fruit detection and classification using deep learning techniques. *Mathematical Problems in Engineering*, v. 2022, p. 1–29, 2022. DOI: <https://doi.org/10.1155/2022/9210947>.

WANG, W.; LI, C.; XI, Y.; GU, J.; ZHANG, X.; ZHOU, M.; PENG, Y. Research progress and development trend of visual detection methods for selective fruit harvesting robots. *Agronomy*, v. 15, n. 8, p. 1926, 2025. DOI: <https://doi.org/10.3390/agronomy15081926>.

WU, E.; MA, R.; DONG, D.; ZHAO, X. D-YOLO: A lightweight model for strawberry health detection. *Agriculture*, v. 15, n. 6, p. 570, 2025. DOI: <https://doi.org/10.3390/agriculture15060570>.

XIAO, B.; NGUYEN, M.; YAN, W. Q. Identificação da maturação de frutas usando o modelo YOLOv8. *Multimed Tools Appl*, v. 83, p. 28039–28056, 2024. DOI: <https://doi.org/10.1007/s11042-023-16570-9>.

XIAO, F.; WANG, H.; XU, Y.; ZHANG, R. Fruit detection and recognition based on deep learning for automatic harvesting: an overview and review. *Agronomy*, v. 13, n. 6, p. 1625, 2023. DOI: <https://doi.org/10.3390/agronomy13061625>.

XIAO, J. R.; CHUNG, P. C.; WU, H. Y.; PHAN, Q. H.; YEH, J. L.; HOU, M. T. YUE, Y.; XU, S.; WU, H. A strawberry ripeness detection method based on improved YOLOv8. *Applied Sciences*, v. 15, n. 11, p. 6324, 2025. DOI: <https://doi.org/10.3390/app15116324>.

YUE, Y.; XU, S.; WU, H. A strawberry ripeness detection method based on improved YOLOv8. *Applied Sciences*, v. 15, n. 11, p. 6324, 2025. DOI: <https://doi.org/10.3390/app15116324>.

ZHAO, S.; FANG, C.; HUA, T.; JIANG, Y. Detecting the maturity of red strawberries using improved YOLOv8s model. *Agriculture*, v. 15, n. 21, p. 2263, 2025. DOI: <https://doi.org/10.3390/agriculture15212263>.

ZHOU, X. et al. Strawberry maturity classification from UAV and near-ground imaging using deep learning. *Smart Agricultural Technology*, v. 1, p. 100001, 2021. DOI: <https://doi.org/10.1016/j.atech.2021.100001>.

APENDICE A

Quadro 1: Comparação de trabalhos correlatos sobre detecção e classificação de morangos

Autor/Ano	Objetivo	Método	Classes	Métricas Principais	Cenário
Tang et al. (2023)	Reconhecimento de maturação	Mask R-CNN	6 estágios de maturação	Acurácia > 95%	Ambiente controlado
Wang et al. (2022)	Detecção multi-estágio	DSE-YOLO	Maturação (verde→maduro)	mAP 86,6%	Campo
Afzaal et al. (2021)	Identificação de doenças	Mask R-CNN	7 doenças	mAP 82,4%	Folhas/frutos
Xiao et al. (2020)	Classificação de doenças	ResNet50	Doenças fúngicas	Acurácia até 100%	Dataset controlado
Bhujel et al. (2022)	Mofo cinzento	Segmentação DL	Severidade do mofo	IoU 89%	Campo/lab
Kutyrev (2023)	Condição nutricional	YOLOv7	Deficiência de cálcio	Precisão ~94%	Estufa
Zhang et al. (2023)	Doenças precoces	CNN + hiperespectral	Mofo cinzento, antracnose	Acurácia >97%	Lab
Chai et al. (2023)	Maturação + AR	YOLOv7 + AR	Estágios de maturação	mAP 0,89 / F1 0,92	AR (HoloLens 2)
He et al. (2023)	Colheita robótica	YOLOv5s-Straw	3 classes maturação	mAP 80,3% / 18ms	Campo aberto
Liu et al. (2024)	Estágio de crescimento	SGSNet (leve)	Crescimento (estágios)	Alta precisão / tempo real	Estufa

O quadro apresenta uma síntese de estudos recentes que aplicaram técnicas de visão computacional e aprendizado profundo à detecção e à classificação de morangos. São destacados os objetivos de cada pesquisa, os métodos utilizados, as classes analisadas, as métricas de desempenho e os cenários de validação. Essa sistematização evidencia avanços, tendências metodológicas e limitações da literatura, além de ressaltar a contribuição desta dissertação ao propor o uso do modelo YOLOv8, integrado a um aplicativo móvel no contexto do CEAGESP.

APENDICE B – Relato de Visitas Técnicas em Atibaia e Monte Alegre do Sul (SP).

Além das etapas de revisão bibliográfica e construção do artefato, foram realizadas pesquisas de campo com produtores de morango em Atibaia, São Paulo. O objetivo foi compreender práticas de cultivo, tecnologias empregadas e desafios enfrentados na produção de morangos de alta qualidade, bem como observar a dinâmica das operações agrícolas e aspectos relacionados à sustentabilidade. Em outubro de 2024, foram visitadas duas propriedades: o Orquidário e Produtor de Morangos Takebayashi e o Sítio Santo Antônio.

No Takebayashi, reconhecido pelo uso de técnicas modernas, observou-se o cultivo em estufas com substratos, que permitem maior controle de pragas, doenças e condições climáticas, além de reduzir o consumo de água e otimizar nutrientes. A propriedade destacou ainda o compromisso com a qualidade visual dos frutos, considerando que parte da produção é destinada ao sistema de colha e pague.

Já no Sítio Santo Antônio, voltado à produção orgânica, o enfoque esteve nas práticas agroecológicas e no cultivo sustentável, com utilização de adubos naturais, diversificação de culturas e emprego de coberturas vegetais para conservação da umidade e proteção do solo.

As visitas proporcionaram uma visão abrangente de diferentes abordagens produtivas, evidenciando tanto a busca por eficiência quanto a valorização da sustentabilidade. Essa experiência reforçou a importância da integração entre tecnologia, sustentabilidade e mercado na agricultura, oferecendo lições que se conectam diretamente à proposta desta dissertação. A seguir, registros fotográficos das visitas.

Figura 10: Fotos da visita aos produtores de Atibaia (SP)





Fonte: Autora (2025)

Posteriormente em Setembro de 2025, ocorreu uma visita à Monte Alegre do Sul afim de levantar mais informações e estabelecer novos contatos com fornecedores, produtores e comerciantes locais.


Figura 11: Fotos de Monte Alegre do Sul (SP)



Fonte: Autora (2025)

APÊNDICE C – IMAGENS PROTÓTIPO INICIAL DO APLICATIVO MOBILE

Figura 12: Telas do aplicativo móvel em desenvolvimento



Fonte: Autora (2025)

APÊNDICE D – ARTIGOS PUBLICADOS



UTILIZAÇÃO DE IA E REDE NEURAL IDENTIFICAÇÃO DE MORANGOS

LUANA DOS SANTOS CORDEIRO – luana.cordeiro4@aluno.unip.com.br
UNIVERSIDADE PAULISTA - UNIP

MADALENA DE OLIVEIRA BARBOSA DIVINO -
madalena.divino@aluno.unip.br
UNIVERSIDADE PAULISTA - UNIP

FERNANDA PEREIRA LEITE AGUIAR -
fernanda.aguiar11@aluno.unip.br
UNIVERSIDADE PAULISTA - UNIP

SUELY DOS SANTOS SOUSA - suely.sousa3@aluno.unip.br
UNIVERSIDADE PAULISTA - UNIP

PROF. DR. MARCELO TSUGUIO OKANO -
marcelo.okano1@docente.unip.br
UNIVERSIDADE PAULISTA - UNIP

ÁREA: 3. PESQUISA OPERACIONAL
SUBÁREA: 3.7 – INTELIGÊNCIA COMPUTACIONAL

RESUMO: ESTE ARTIGO INVESTIGA A APLICAÇÃO DE TÉCNICAS DE VISÃO COMPUTACIONAL NA IDENTIFICAÇÃO DE MORANGOS EM IMAGENS, COM FOCO NA UTILIZAÇÃO DO DEEP LEARNING (DL) OU APRENDIZADO PROFUNDO E DA REDE NEURAL CONVOLUCIONAL (CNN) YOU ONLY LOOK ONCE (YOLOV8). CONSIDERANDO A RELEVÂNCIA DO MORANGO NA CADEIA PRODUTIVA DE FRUTAS NO BRASIL E NO MUNDO, O DESENVOLVIMENTO DE TECNOLOGIAS INOVADORAS PARA IDENTIFICAÇÃO E DETECÇÃO É CRUCIAL PARA A AUTOMAÇÃO E MELHORIA DOS PROCESSOS DE SELEÇÃO. O ESTUDO APRESENTA UMA ANÁLISE DETALHADA DO PROCESSO DE TREINAMENTO DA REDE NEURAL CONVOLUCIONAL YOLOV8M, ESPECIFICAMENTE VOLTADA PARA A

IDENTIFICAÇÃO DE MORANGOS EM IMAGENS. DURANTE O TREINAMENTO, FOI OBSERVADO UM PROGRESSO SIGNIFICATIVO NO DESEMPENHO DO MODELO, CONFORME INDICADO PELAS MÉTRICAS DE PRECISÃO DA CAIXA (BOXP), REVOCAÇÃO (R) E MAP50. ESTE TRABALHO NÃO APENAS CONTRIBUI PARA O AVANÇO DO CAMPO DA VISÃO COMPUTACIONAL, MAS TAMBÉM OFERECE INSIGHTS VALIOSOS SOBRE O TREINAMENTO DE REDES NEURAS CONVOLUCIONAIS PARA A IDENTIFICAÇÃO DE MORANGOS, PROMOVENDO POTENCIALMENTE MAIOR EFICIÊNCIA E PRECISÃO NA SELEÇÃO DE FRUTAS.

PALAVRAS-CHAVES: REDES NEURAS CONVOLUCIONAIS; VISÃO COMPUTACIONAL; APRENDIZAGEM PROFUNDA; YOLOV8M.

1. INTRODUÇÃO

O morango é um produto de grande relevância na cadeia produtiva de frutas do Brasil, e o desenvolvimento de novas tecnologias e técnicas para sua identificação e detecção pode contribuir significativamente para a automatização e melhoria da seleção dos melhores exemplares. De acordo com dados da Organização das Nações Unidas para Agricultura e Alimentação (FAO), o Brasil produziu cerca de 183.923 toneladas de morangos em 2022 (FAO, 2024). O sistema produtivo de frutas é uma das cadeias mais importantes do país, posicionando o Brasil em 3º lugar no ranking mundial de produção, com um volume anual de 45 milhões de toneladas. Esse número é expressivo, considerando as enormes quantidades desperdiçadas ao longo de toda a cadeia produtiva (EMBRAPA, 2023).

Os morangos, membros da família das rosáceas, passam por um ciclo de crescimento que inclui floração, frutificação e amadurecimento. Eles amadurecem rapidamente, em aproximadamente quatro semanas desde a floração até o fruto maduro, e são altamente valorizados nos mercados da América, Europa e Ásia. Sua produção vem crescendo nas últimas décadas devido à alta demanda dos consumidores e à sua variedade de aplicações (ZHOU et al., 2021; BONOW et al., 2023). Essas frutas são amplamente apreciadas em todo o mundo, tanto pelo sabor quanto pelos benefícios nutricionais. No Brasil, os principais produtores de morango são os estados do Sudeste e Sul, mas novas técnicas de produção têm permitido o cultivo durante todo o ano e em outras regiões do país (PBMH & PIMO, 2019).

O desenvolvimento de novas tecnologias digitais trouxe grandes avanços na resolução de desafios complexos por meio do reconhecimento de padrões. A detecção automática de morangos pode ajudar a reduzir desperdícios ao longo de sua cadeia produtiva, uma vez que, devido ao rápido amadurecimento dos morangos, a identificação e classificação do estado de maturidade são referências valiosas para monitorar a produção. Este artigo, inicialmente, foca na identificação de morangos.

A Inteligência Artificial tem sido amplamente utilizada em diversas áreas, inclusive na agricultura. Nos últimos anos, técnicas de aprendizado de máquina e aprendizado profundo como detecção e classificação de objetos por meio de imagens e vídeos, têm sido aplicadas em pesquisas sobre morangos (ZHOU et al., 2021).

Nesse contexto, a Visão Computacional e o aprendizado profundo emergem como ferramentas tecnológicas robustas.

As Redes Neurais e o aprendizado profundo têm sido utilizados com sucesso em inúmeras aplicações, especialmente na detecção de frutas na agricultura, oferecendo soluções para problemas complexos (SA et al., 2016). Assim, a identificação de morangos com técnicas de aprendizado de máquina e aprendizado profundo apresenta viabilidade significativa, especialmente nos setores agrícola e industrial, tornando-se crucial para a otimização de processos na agricultura, aumentando a eficiência e reduzindo desperdícios. No Brasil, aproximadamente 26 milhões de toneladas de alimentos são desperdiçados anualmente, dos quais 5,3 milhões de toneladas são frutas e 5,6 milhões de toneladas são hortaliças (CEDES, 2018).

Este estudo apresenta o uso de técnicas de Visão Computacional para análise de imagens e identificação de morangos, utilizando a aplicação de *Deep Learning* (DL) ou aprendizado profundo e a Rede Neural Convolucional *You Only Look Once* (YOLOv8), reconhecida por sua eficiência na detecção de objetos. Além disso, avaliar o impacto dessas tecnologias em setores como a agricultura, destacando suas vantagens, possíveis limitações e sugestões para trabalhos futuros.

2. FUNDAMENTAÇÃO TEÓRICA


Neste capítulo apresenta-se as tecnologias e conceitos utilizados nesta pesquisa. Segundo Wang et al. (2024), a detecção de frutas por meio de tecnologias de processamento de imagens passou por três fases de evolução: processamento de imagens digitais convencionais, processamento de imagens com base em aprendizado de máquina e processamento de imagens com base em aprendizado profundo. No primeiro estágio, técnicas como análise de limiar, detecção de bordas, crescimento de região e matriz de co-ocorrência de nível de cinza são usadas para extrair características como cor, tamanho, forma e textura a fim de identificar frutas. Em comparação com os métodos tradicionais, os algoritmos de detecção baseados em aprendizado profundo indicam vantagens como melhor adaptabilidade, alta velocidade de detecção e elevada taxa de precisão. A integração da Visão Computacional com a tecnologia de Inteligência Artificial tem sido incorporada aos processos de produção agrícola, substituindo atividades intensivas em mão de obra e melhorando fatores de produtividade (WANG et al., 2022).

Backes e Júnior (2019) enfatizam que um sistema de Visão Computacional consiste em vários estágios: Aquisição: responsável pela obtenção de imagens, simulando a função ocular. Processamento de Imagem: visa melhorar as

características da imagem, podendo personalizá-la ou preparar para as etapas seguintes. Segmentação: divide a imagem em áreas de interesse. Extração de Características/Análise de Imagens: obtém um conjunto de características do objeto de interesse, permitindo sua identificação. Reconhecimento de Padrões: classifica ou agrupa imagens com base em suas características.

A Figura 1 ilustra o esquema do funcionamento de um sistema de visão computacional.

FIGURA 1 - Esquema de um sistema de visão computacional



Fonte: Adaptado de BACKES e JUNIOR (2019)

Com o avanço das aplicações da Inteligência Artificial, técnicas como o aprendizado profundo, estão sendo amplamente utilizadas em cenários agrícolas, um campo conhecido como agricultura inteligente. Essa abordagem incorpora uma variedade de tecnologias digitais, incluindo aprendizado profundo, *Big Data* e Internet das Coisas (IoT), aplicadas à agricultura (LIU et al., 2021). Conforme Ludermir (2021), o aprendizado de máquina tem como objetivo melhorar o desempenho dos programas por meio de modelos, sendo necessário muitos exemplos para gerar conhecimento computacional, representado por hipóteses derivadas dos dados. A inferência indutiva é o principal método para derivar novos conhecimentos e prever eventos futuros em aprendizado de máquina, onde a correta generalização depende da qualidade dos dados. Existem três tipos principais de aprendizado de máquina: supervisionado, não supervisionado e de reforço.


No tipo supervisionado, o algoritmo necessita de exemplos rotulados para criar um classificador que determine corretamente a classe dos novos exemplos. No caso do não supervisionado, os exemplos são agrupados com base em suas semelhanças. Já no reforço, o algoritmo recebe sinais de reforço para avaliar suas hipóteses. Uma aplicação eficaz do aprendizado de máquina requer um bom conjunto de exemplos, técnicas para melhorar a qualidade dos dados, seleção adequada de algoritmos, definição de parâmetros e monitoramento contínuo do sistema para garantir seu desempenho (LUDERMIR, 2021).

Avanços constantes no aprendizado de máquina têm impulsionado desenvolvimentos significativos nas tarefas agrícolas. Devido à sua capacidade de extrair características de alta dimensão de imagens de frutas, o aprendizado profundo é amplamente utilizado na detecção de frutas e na colheita automática. Em particular, as Redes Neurais Convolucionais (CNNs) demonstraram a capacidade de atingir níveis de precisão e velocidade comparáveis aos humanos em algumas áreas de detecção de frutas e colheita automática (XIAO, 2023).

O aprendizado profundo tem mostrado excelentes capacidades para aprender recursos de imagens e é amplamente utilizado na detecção de objetos em imagens, com o objetivo de melhorar o desempenho da visão artificial na detecção de frutas (YU et al., 2019). Segundo LeCun, Bengio e Hinton (2015), o aprendizado profundo permite que modelos computacionais compostos por múltiplas camadas de processamento aprendam representações de dados em diferentes níveis de abstração. Esses métodos representam uma melhoria significativa em relação ao estado da arte em reconhecimento de fala e visual, além de descobrir estruturas complexas em grandes conjuntos de dados utilizando um algoritmo de retropropagação para ajustar os parâmetros internos da máquina.

Indira et al. (2023) descrevem as redes neurais como um tipo de Rede Neural Artificial (RNA) usada na análise de imagem, onde as imagens são exibidas em computadores como uma matriz de números de *pixels*. É crucial que o processamento de imagens em rede mantenha as relações entre os *pixels* (valores). Uma rede neural matemática é utilizada na camada de rede para preservar essa relação espacial entre os *pixels*, conforme pode ser observada na Figura 02:

FIGURA 2 - Arquitetura CNN para identificação de frutas



Fonte: Adaptado de INDIRA et al. (2023)

A Figura 2 descreve as etapas de um sistema CNN para identificação de frutas:

- Input (Entrada):** início do processo com a entrada da imagem da fruta na rede neural, representada por valores numéricos de intensidade de cor nos canais RGB.
- CNN Block (Bloco Convolutivo):** composto por camadas convolucionais onde são aplicados filtros para detectar padrões específicos na imagem, como bordas e texturas.

Cada filtro produz um mapa de características (*Feature Map*) que destaca a presença desses padrões. *FNN Block* (Bloco de Redes Neurais Totalmente Conectadas): após várias camadas convolucionais e possivelmente de *Pooling*, os *Feature Maps* são achatados em um vetor e passados para camadas totalmente conectadas que realizam a classificação final das frutas. *Output* (Saída): a saída da CNN é uma distribuição de probabilidade sobre as classes de frutas, indicando a probabilidade de a imagem pertencer a cada categoria.

Neste estudo, foi utilizado o modelo YOLO (*You Only Look Once*), um modelo popular de detecção de objetos criado por Joseph Redmon e Ali Farhadi na Universidade de Washington em 2015. A versão YOLOv8, lançada em janeiro de 2023, apresenta desempenho superior em precisão e velocidade na detecção de objetos. Desenvolvido pela *Ultralytics*, o YOLOv8 é especializado em detecção de objetos, identificando e marcando caixas delimitadoras ao redor dos objetos em imagens ou vídeos. Ele classifica os objetos detectados em categorias com base em suas características, conseguindo detectar múltiplos objetos em uma única imagem ou quadro de vídeo com alta precisão e rapidez (ULTRALYTICS, 2024).

Conforme Ultralytics (2024), existem diferentes modelos do YOLOv8, variando em tamanho, velocidade e precisão: YOLOv8n: Menor e mais leve, ideal para dispositivos com menor poder de processamento ou para aplicações em tempo real onde a latência é crucial. YOLOv8s: Maior, com mais parâmetros, oferecendo melhor precisão na detecção de objetos. YOLOv8m: Tamanho intermediário entre n e s, buscando balancear velocidade e precisão. YOLOv8l: Maior que o s, focado em alta precisão para tarefas complexas.

YOLOv8x: O maior e mais completo modelo, ideal para máxima precisão em aplicações exigentes.

2.1 Trabalhos Correlatos

A produção de frutas frescas enfrenta desafios significativos devido à sua perecibilidade e fragilidade, demandando atenção meticulosa durante o processo de cultivo e colheita, o que resulta em custos elevados. Reconhecendo essa demanda, diversos estudos têm explorado o potencial da Inteligência Artificial, especificamente a visão computacional, para otimizar a produção de frutas (WANG et al., 2022).

A fragilidade e perecibilidade das frutas aumentam a necessidade de cuidados intensivos durante o processo de produção, contribuindo para o alto custo desses produtos. Muitos pesquisadores estão direcionando seus esforços para integrar a Inteligência Artificial na produção de frutas, com foco na utilização da Visão Artificial

para identificar frutas de forma mais eficiente (WANG et al., 2022).

Nesse contexto, Tang et al. (2023) propuseram um método inovador de reconhecimento da maturação de morangos, combinando Mask R-CNN e segmentação de região, o que resultou em uma precisão aprimorada na identificação de diferentes estágios de maturação, contribuindo para a gestão eficaz da colheita de morangos em ambientes complexos.

Em paralelo, Afzaal et al. (2021) desenvolveram um modelo de segmentação de instâncias para identificar doenças em morangos com base no Mask R-CNN, fornecendo uma abordagem autônoma para monitorar a saúde das plantas e tomar medidas preventivas contra sete tipos de doenças.

Além disso, Wang et al. (2022) abordaram o desafio da detecção de morangos em diferentes estágios de maturação no ambiente natural, apresentando o DSE-YOLO, que incorpora técnicas de melhoria de semântica detalhada para aumentar a precisão na detecção de frutas pequenas e distinguir entre diferentes tipos de frutas.

Wise et al. (2022) exploraram o potencial da análise automatizada de imagens, orientada por aprendizado de máquina, para prever o desenvolvimento e a qualidade dos morangos, oferecendo uma abordagem promissora para a automação da colheita por meio da integração de sistemas de tomada de decisão.

Adicionalmente, Xiao et al. (2020) apresentaram um algoritmo de CNN com o modelo Resnet50 para a detecção de várias doenças do morango, fornecendo uma técnica simples e eficaz para a detecção precoce de problemas de saúde das plantas.

Kutyrëv e Filippov (2023) propuseram um método para aumentar a precisão no diagnóstico de deficiência de cálcio em morangueiros, utilizando algoritmos de aprendizado de máquina, como Redes Neurais Convolucionais (CNN) YOLOv7, para detectar sinais de deficiência de cálcio nas folhas, oferecendo uma ferramenta valiosa para a gestão nutricional das plantas.

Bhujel et al. (2022) implementaram uma rede de aprendizado profundo para a segmentação e quantificação precisa da doença do mofo cinzento do morango, demonstrando a viabilidade de utilizar técnicas de visão computacional para monitorar a saúde das plantas de forma não destrutiva no ambiente natural.

Esses estudos contribuem significativamente para a pesquisa sobre a aplicação de métodos baseados em Redes Neurais Convolucionais na identificação de morangos, destacando a diversidade de abordagens e o potencial para otimizar e automatizar os processos de cultivo e colheita de frutas.

3. METODOLOGIA

Para alcançar os objetivos propostos, a pesquisa foi dividida em duas fases principais: a revisão bibliográfica e o treinamento da Rede Neural Convolucional YOLOv8m. A primeira fase consistiu em um estudo de literatura abrangente sobre diversos temas, incluindo morangos, Visão Computacional, aprendizado de máquina, aprendizado profundo, reconhecimento e detecção de objetos, Redes Neurais Convolucionais e a aplicação específica do YOLOv8 na detecção de imagens.

A revisão bibliográfica é uma ferramenta essencial para desenvolver uma compreensão profunda dos tópicos relevantes, permitindo contextualizar, identificar lacunas e construir uma base teórica sólida (MIGUEL, 2010). A citação das principais conclusões de outros autores permite destacar a contribuição da pesquisa realizada, evidenciando comportamentos e atitudes, sejam contraditórias ou corroborativas. Confirmar os resultados obtidos por outras comunidades de pesquisa é fundamental, assim como enumerar as discrepâncias encontradas (MARCONI, 2007).

Durante este estudo de literatura, buscou-se compreender as contribuições mais recentes sobre o tema. Brown e Davis (2022) enfatizam a importância da atualização contínua das revisões bibliográficas para manter a pesquisa atualizada. Johnson e Smith (2020) sugerem que a seleção criteriosa das fontes é crucial para garantir a confiabilidade e a relevância das informações, aspectos fundamentais para a construção de uma estrutura teórica consistente.

A segunda fase consistiu na parte experimental computacional, que envolveu a coleta de um conjunto abrangente de dados de imagens de morangos, englobando vários tipos e condições de morangos para garantir a robustez e precisão no desempenho do modelo. O conjunto de dados foi obtido no repositório do Open Images Dataset V7 and Extensions, mantido pelo Google. Cada imagem é disponibilizada com anotações detalhadas, incluindo caixas delimitadoras (*bounding boxes*) e rótulos de classe, compreendendo um total de 1257 imagens anotadas. O modelo pré-treinado foi inicializado com pesos do Open Images *Dataset V7 and Extensions* e ajustado especificamente para a tarefa de identificação de morangos. O conjunto de dados foi dividido em 80% para treinamento e 20% para teste, seguindo uma prática comum de validação de modelos.

O treinamento do modelo ocorreu no ambiente de desenvolvimento do *Google Colab Pro*, utilizando recursos como GPU e alta RAM para acelerar o treinamento do modelo. A linguagem de programação *Python* foi empregada juntamente com diversas bibliotecas, incluindo: *PyTorch*: Utilizado para construir e treinar modelos de Redes Neurais Convolucionais. *Ultralytics*: Ferramenta essencial para simplificar o

treinamento e a avaliação de modelos de detecção de objetos, como o YOLOv8. *Pandas*, *NumPy*: Bibliotecas fundamentais para manipulação e processamento de dados. *Awscli*, *Urllib3*: Utilizados para realizar operações de *download* e gerenciamento de dados. *Tqdm*: Utilizado para exibir barras de progresso durante operações de treinamento e avaliação. *Opencv-python*: Usado para operações de processamento de imagem, como leitura e manipulação de imagens.

Após o treinamento, foram registradas métricas como precisão da caixa (*BoxP*), revocação (*R*) e média de precisão média (*mAP50*) fornecidas pela Rede Neural Convolutacional YOLOv8m. A Precisão mede a acurácia das caixas delimitadoras previstas, a Revocação avalia a capacidade do modelo de detectar todas as instâncias de morangos, e o F1-score fornece uma média harmônica de Precisão e Revocação. A métrica mAP oferece uma avaliação abrangente considerando a curva precisão-revocação em vários limiares de interseção sobre união (IoU).

Para realizar essas operações no *Google Colab*, além das bibliotecas mencionadas, foram utilizadas as seguintes: *Cv2*: Utilizado para operações de processamento de imagem. *Matplotlib.pyplot*: Utilizado para visualização de gráficos e resultados. *Os*, *Image*: Utilizados para operações de sistema de arquivos e manipulação de imagens. *Cv2_imshow*: Utilizado para exibir imagens dentro do ambiente de desenvolvimento do *Google Colab*, este ambiente proporcionou os recursos necessários para treinar e avaliar o modelo YOLOv8m para a detecção de morangos.

4. RESULTADOS E DISCUSSÕES

A análise dos resultados apresentados na Tabela 1 proporciona uma base para discussões acerca da eficácia do modelo e suas limitações.

TABELA 1 - Resumo treinamento do modelo de morangos

Treino	Epoch	BoxP	R	mAP50-	
				mAP50	90
1º	10	0.309	0.413	0.295	0.175
2º	70	0.525	0.479	0.447	0.301
3º	70	0.525	0.479	0.447	0.301
4º	200	0.451	0.512	0.462	0.316
5º	70	0.453	0.563	0.442	0.289
6º	70	0.478	0.58	0.449	0.29

7º	70	0.493	0.569	0.472	0.294
8º	70	0.5	0.537	0.465	0.294
9º	70	0.413	0.522	0.387	0.255
10º	70	0.472	0.522	0.422	0.279

Fonte: Elaborado pelos autores.

Inicialmente, o treinamento foi realizado por apenas 10 épocas, resultando em métricas modestas de desempenho, incluindo BoxP de 0.309, R de 0.413, mAP50 de 0.295 e mAP50-90 de 0.175. Em seguida, um segundo treinamento foi conduzido com 70 épocas, resultando em melhorias significativas em todas as métricas, com um aumento notável em BoxP, R, mAP50 e mAP50-90.

Neste ponto, conforme observado na Figura 3, foi constatado que nem todos os morangos estavam sendo identificados pelo modelo.

FIGURA 3 - Exemplo de imagem utilizada no teste



Fonte: Elaborado pelos autores.

Após observar uma estagnação no desempenho nas últimas 100 épocas de um treinamento de 200 épocas, o modelo interrompeu automaticamente o treinamento em 169 épocas, destacando sua capacidade de autoavaliação. Essa observação indica que o modelo atingiu seu limite de aprendizado e não estava mais obtendo ganhos significativos em desempenho. Apesar do aumento no número de épocas, o modelo não apresentou melhora significativa na precisão, sugerindo que o número ideal de épocas pode ter sido atingido em 70. Esta capacidade de autoavaliação é crucial para evitar *overfitting* e otimizar o tempo de treinamento.

Segundo Ying (2019), o *overfitting* é um problema fundamental no aprendizado de máquina supervisionado que impede que os modelos generalizem perfeitamente, ajustando-se excessivamente aos dados observados e não sendo eficazes em novos dados, devido ao ruído, ao tamanho limitado do conjunto de treinamento e à complexidade do classificador. Após a observação da estagnação, foram realizados seis treinamentos adicionais de 70 épocas cada, utilizando os pesos iniciais do treino anterior como ponto de partida. Essa estratégia resultou em valores consistentes para as métricas mAP50 (entre 0.442 e 0.472) e mAP50-90 (entre 0.289 e 0.294), demonstrando a efetividade do treinamento contínuo na estabilização do desempenho do modelo.

A partir do sexto treino utilizando os pesos do resultado do treino anterior, conforme mostrado na Figura 4, observa-se que o modelo foi capaz de identificar todos os frutos na imagem teste.

FIGURA 4 - Identificação de todos os frutos pelo modelo



Fonte: Elaborado pelos autores.

Os resultados indicam que o treinamento contínuo e a utilização de pesos iniciais ajustados de treinamentos anteriores podem levar à estabilização e melhoria do desempenho do modelo YOLOv8m, especialmente na detecção de morangos. Essa abordagem permitiu alcançar métricas consistentes e uma identificação eficaz das frutas nas imagens de teste.

5. CONCLUSÃO

Este estudo forneceu uma análise detalhada do processo de treinamento da Rede Neural Convolucional YOLOv8m para a identificação de morangos em imagens. Ao longo do treinamento, observou-se um progresso significativo no desempenho do modelo, conforme evidenciado pelas métricas de precisão da caixa (BoxP), revocação (R) e mAP50.

A capacidade do modelo de autoavaliação e intervenção automática durante o treinamento, como demonstrado pela interrupção automática do treinamento quando detectou estagnação, é um destaque significativo deste estudo. Essa capacidade permite uma utilização eficiente dos recursos computacionais, evitando o *overfitting* e otimizando o tempo de treinamento. Além disso, os treinamentos contínuos com o uso dos pesos anteriores foram fundamentais para explorar o potencial máximo do modelo. Embora os resultados dos treinamentos subsequentes tenham mostrado variações mínimas, isso indica que o modelo atingiu um ponto de saturação em seu aprendizado. Essa compreensão é crucial para evitar esforços desnecessários e focar em áreas de melhoria mais significativas.

No entanto, é importante reconhecer as limitações do modelo. Questões como variações significativas nos dados de entrada e a qualidade dos dados de treinamento podem afetar o desempenho do modelo na detecção de morangos em diferentes condições. Embora o YOLOv8m tenha demonstrado ser uma ferramenta poderosa para a detecção de morangos, este estudo identificou algumas limitações. O modelo pode ter dificuldade em lidar com variações significativas nos dados, como mudanças na iluminação ou na aparência dos morangos. Além disso, o desempenho do modelo pode ser afetado por questões como a qualidade e quantidade dos dados de treinamento.

O processo de detecção de morangos usando a Rede Neural Convolucional YOLOv8m representa um avanço significativo na agricultura de precisão porque permite a detecção rápida e precisa de morangos em vários *backgrounds*. Isso facilita a identificação e o monitoramento das frutas ao longo de seu ciclo produtivo. Além de ser capaz de distinguir frutos, o YOLOv8 pode ser treinado para detectar anomalias como doenças e pragas, o que permite que as plantações sejam protegidas rapidamente. A gestão agrícola pode usar a análise da aplicação para fazer ajustes nas práticas de cultivo para aumentar a produção e a qualidade dos morangos, melhorar a eficiência operacional e apoiar uma agricultura mais ecológica e sustentável.

Para pesquisas futuras, recomenda-se explorar técnicas adicionais de aumento de dados e considerar arquiteturas de rede alternativas para melhorar ainda mais o desempenho do modelo em cenários desafiadores. Além disso, é fundamental continuar investigando estratégias para lidar com variações nos dados e aprimorar a robustez do modelo em ambientes diversos. Este estudo contribui para o avanço do campo da visão computacional, oferecendo insights valiosos sobre o treinamento de Redes Neurais Convolucionais para a identificação de morangos. Ao continuar a explorar e aprimorar as técnicas de modelagem e treinamento, é possível desenvolver sistemas mais eficientes e precisos para uma variedade de aplicações práticas, incluindo a automação de processos agrícolas e o aprimoramento da produção de morangos. Essas melhorias podem levar a um aumento na eficiência e na precisão das operações agrícolas, proporcionando benefícios econômicos e sustentáveis ao setor agrícola.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

REFERÊNCIAS

AFZAAL, U.; BHATTARAI, B.; PANDEYA, Y. R.; LEE, J. An instance segmentation model for strawberry diseases based on mask R-CNN. *Sensors*, v. 21, n. 19, p. 6565, 2021.

BACKES, A. R.; JUNIOR, J. J. d. M. S. *Introdução à visão computacional usando Matlab*. [S.l.]: Alta Books Editora, 2019.

BHUJEL, A.; KHAN, F.; BASAK, J. K.; JAIHUNI, M.; SIHALATH, T.; MOON, B. E.; KIM, H. T. Detection of gray mold disease and its severity on strawberry using deep learning networks. *Journal of Plant Diseases and Protection*, v. 129, n. 3, p. 579-592, 2022.

BONOW, S.; ANTUNES, L. E. C.; SCHWENGBER, J. E.; FLORES CANTILLANO, R. F.; UENO, B. BRS DC Fênix, Cultivar, Morango, Variedade. Embrapa Clima Temperado, 2023.

BROWN, A.; DAVIS, R. The Evolving Landscape of Literature Reviews in Contemporary Research. *Journal of Academic Writing*, v. 12, n. 1, p. 112-128, 2022.

CEDES – Centro de Estudos e Debates Estratégicos. Consultoria Legislativa da Câmara dos Deputados. Perdas e desperdício de alimentos – estratégias para redução. Série de cadernos de trabalhos e debates 3. Brasília, DF, p. 260, 2018.

INDIRA, D. N. V. S. L. S.; GODDU, Jyothi; INDRAJA, Baisani; CHALLA, Vijaya Madhavi Lakshmi; MANASA, Bezawada. A review on fruit recognition and feature evaluation using CNN. *Materials Today: Proceedings*, v. 80, parte 3, p. 3438-3443, 2023. ISSN 2214-7853. Disponível em: <https://doi.org/10.1016/j.matpr.2021.07.267>. Acesso em: 9 jul. 2024.

EMBRAPA - Frutas e hortaliças. Disponível em: <https://www.embrapa.br/grandes-contribuicoes-para-a-agricultura-brasileira/frutas-e-hortalicas>. Acesso em: 18 mai. 2023..

JOHNSON, K.; SMITH, L. Strategies for Effective Literature Review: A Comprehensive Analysis. *Research Synthesis Methods*, v. 11, n. 4, p. 513-527, 2020.

KUTYRĚV, A. I.; FILIPPOV, R. A. Application of a convolutional neural network for monitoring the condition of garden strawberries. *Euro-Northeast Agricultural Science*, v. 24, n. 4, p. 685-696, 2023.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep Learning. *Nature*, v. 521, p. 436-44, 2015. Disponível em: <https://doi.org/10.1038/nature14539>. Acesso em: 9 jul. 2024.

LUDERMIR, T. B. Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. *Estudos Avançados*, v. 35, n. 101, p. 85–94, 2021. Disponível em: <https://doi.org/10.1590/s0103-4014.2021.35101.007>. Acesso em: 9 jul. 2024.

MARCONI, M. de A.; LAKATOS, E. M. Fundamentos de metodologia científica. 5. ed. São Paulo: Atlas, 2007. p. 43.

MIGUEL, P. A. C. Metodologia de pesquisa em engenharia de produção e gestão de operações. São Paulo: Editora Elsevier, 2010.

PBMH & PIMO - Programa Brasileiro Para A Modernização Da Horticultura & Produção Integrada De Morango. Normas de Classificação de Morango. São Paulo: CEAGESP, 2009. (Documentos, 33).

LIU, Q.; YAN, Q.; TIAN, J.; YUAN, K. Principais tecnologias e aplicações na agricultura inteligente. *Journal of Physics: Conference Series*, v. 1757, n. 1, fev. 2021. Disponível em: <https://doi.org/10.1088/1742-6596/1757/1/012059>. Acesso em: 9 jul. 2024.

SA, I.; GE, Z.; DAYOUB, F.; UPCROFT, B.; PEREZ, T.; McCOOL, C. DeepFruits: A fruit detection system using deep neural networks. *Sensors*, vol. 16, no. 8, article 1222, 2016.

TANG, C.; CHEN, D.; WANG, X.; NI, X.; LIU, Y.; LIU, Y.; WANG, S. A fine recognition method of strawberry ripeness combining Mask R-CNN and region segmentation. *Frontiers in Plant Science*, v. 14, 1211830, 2023.

ULTRALYTICS. Yolov8. Ultralytics, 2024. Disponível em: <https://docs.ultralytics.com>. Acesso em: 11 Maio 2024.

FAO - Food and Agriculture Organization of the United Nations. Production (t). [dataset]. Our World in Data, 2024. Disponível em: <https://ourworldindata.org/agricultural-production#explore-data-on-agricultural-production>. Acesso em: 28 mai. 2024.

WANG, A.; QIAN, W.; LI, A.; XU, Y.; HU, J.; XIE, Y.; ZHANG, L. NVW-YOLOv8s: An improved YOLOv8s network for real-time detection and segmentation of tomato fruits at different ripeness stages. *Computers and Electronics in Agriculture*, v. 219, 108833, 2024. Disponível em: <https://doi.org/10.1016/j.compag.2024.108833>. Acesso em: 9 jul. 2024.

WANG, C.; LIU, S.; WANG, Y.; XIONG, J.; ZHANG, Z.; ZHAO, B.; HE, P. Application of convolutional neural network-based detection methods in fresh fruit production: a comprehensive review. *Frontiers in Plant Science*, v. 13, 868745, 2022.

WANG, Y.; YAN, G.; MENG, Q.; YAO, T.; HAN, J.; ZHANG, B. DSE-YOLO: Detail semantics enhancement YOLO for multi-stage strawberry detection. *Computers and Electronics in Agriculture*, v. 198, 107057, 2022.

WANG, T.; PENG, H.; CAO, Y.; XU, X.; WEI, B.; CUI, T. TIA-YOLOv5: an improved YOLOv5 network for real-time detection of crop and weed in the field. *Frontiers in Plant Science*, v. 13, 1091655, 2022.

WISE, K.; WEDDING, T.; SELBY-PHAM, J. Application of automated image colour analyses for the early-prediction of strawberry development and quality. *Scientia Horticulturae*, v. 304, 111316, 2022.

XIAO, F.; WANG, H.; XU, Y.; ZHANG, R. Fruit Detection and Recognition Based on Deep Learning for Automatic Harvesting: An Overview and Review. *Agronomy*, v. 13, n. 6, 1625, 2023. Disponível em: <https://doi.org/10.3390/agronomy13061625>. Acesso em: 9 jul. 2024.

XIAO, J. R.; CHUNG, P. C.; WU, H. Y.; PHAN, Q. H.; YEH, J. L. A.; HOU, M. T. K. Detection of strawberry diseases using a convolutional neural network. *Plants*, v. 10, n. 1, 31, 2020.

YING, X. An Overview of Overfitting and its Solutions. *Journal of Physics: Conference Series*, v. 1168, 2019. Disponível em: <https://doi.org/10.1088/1742-6596/1168/2/022022>. Acesso em: 9 jul. 2024.

YU, Y.; ZHANG, K.; YANG, L.; ZHANG, D. Fruit detection for strawberry harvesting robot in non-structural environment based on Mask-RCNN. *Computers and Electronics in Agriculture*, v. 163, 104846, 2019. Disponível em: <https://doi.org/10.1016/j.compag.2019.06.001>. Acesso em: 9 jul. 2024.

ZHOU, X.; LEE, W. S.; AMPATZIDIS, Y.; CHEN, Y.; PERES, N.; FRAISSE, C. Strawberry Maturity Classification from UAV and Near-Ground Imaging Using Deep Learning. *Smart Agricultural Technology*, v. 1, 100001, 2021. Disponível em: <https://doi.org/10.1016/j.atech.2021.100001>. Acesso em: 9 jul. 2024.



Article

Smart Postharvest Management of Strawberries: YOLOv8-Driven Detection of Defects, Diseases, and Maturity

Luana dos Santos Cordeiro, Irenilza de Alencar Nääs and Marcelo Tsuguio Okano *

Graduate Program in Production Engineering, Paulista University, São Paulo 04026-002, SP, Brazil; luana.cordeiro4@aluno.unip.br (L.d.S.C.); irenilza.naas@docente.unip.br (I.d.A.N.)

* Correspondence: marcelo.okano1@docente.unip.br

Abstract

Strawberries are highly perishable fruits prone to postharvest losses due to defects, diseases, and uneven ripening. This study proposes a deep learning-based approach for automated quality assessment using the YOLOv8n object detection model. A custom dataset of 5663 annotated strawberry images was compiled, covering eight quality categories, including anthracnose, gray mold, powdery mildew, uneven ripening, and physical defects. Data augmentation techniques, such as rotation and Gaussian blur, were applied to enhance model generalization and robustness. The model was trained over 100 and 200 epochs, and its performance was evaluated using standard metrics: Precision, Recall, and mean Average Precision (mAP). The 200-epoch model achieved the best results, with a mAP50 of 0.79 and an inference time of 1 ms per image, demonstrating suitability for real-time applications. Classes with distinct visual features, such as anthracnose and gray mold, were accurately classified. In contrast, visually similar categories, such as 'Good Quality' and 'Unripe' strawberries, presented classification challenges.

Keywords: YOLO; fruit classification; computer vision; defects and diseases; Convolutional Neural Networks; fruit quality



Academic Editor: Lilong Chai

Received: 9 July 2025

Revised: 20 July 2025

Accepted: 25 July 2025

Published: 1 August 2025

Citation: Cordeiro, L.d.S.; Nääs, I.d.A.; Okano, M.T. Smart Postharvest Management of Strawberries: YOLOv8-Driven Detection of Defects, Diseases, and Maturity.

AgriEngineering 2025, 7, 246.

<https://doi.org/10.3390/agriengineering7080246>

Copyright: © 2025 by the authors.

Licensee MDPI, Basel, Switzerland.

This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

According to the Food and Agriculture Organization of the United Nations (FAO) [1], global strawberry production in 2023 was approximately 10,485,454.06 tons. In the same year, Brazil produced approximately 187,795.78 tons, ranking ninth in the world, with the states in the southeast and south regions being its most prominent producers. This production has been growing thanks to new cultivation techniques, which enable year-round production in various parts of the country [2]. Despite these advances, waste throughout the production chain remains significant; it is estimated that the supply chain wastes approximately 26 million tons of food annually, of which 5.3 million tons are fruits and 5.6 million tons are vegetables [3,4].

Strawberry is a fruit with high commercial and nutritional value and great relevance in the fruit production chain in Brazil and worldwide. The genus for all strawberries is *Fragaria* L., which belongs to the rose family (*Rosaceae*). The most common strawberry-grown commercial hybrid (*Fragaria* × *ananassa*), resulting from a cross between two other species, *Fragaria chiloensis* (from Chile) and *Fragaria virginiana* (from North America), is commonly found today in the food supply chains [5]. Strawberries undergo a rapid growth cycle, spanning approximately four weeks between flowering and ripening, which makes them especially susceptible to damage, disease, and postharvest losses [6,7]. Therefore, as

it is a highly perishable fruit with significant commercial value, it requires careful handling to ensure the product's final quality is delivered to the consumer.

Visual defects, mechanical damage, and common diseases such as anthracnose and gray mold compromise not only the appearance of the fruit but also its durability and safety for consumption. Identifying these factors quickly and accurately reduces losses, increases process efficiency, and ensures a high quality standard [8–10]. Diseases significantly affect the quality and productivity of strawberries, making it urgent to develop accurate and timely methods for their identification. However, detecting diseases in strawberries poses a challenge due to the complexity of the image background and the subtle variations between different disease classes [11,12]. Due to their perishability, it is crucial to develop efficient classification and selection methods to ensure the delivery of high-quality fruit to the final consumer.

The growing demand for high-quality food and the pursuit of more efficient agricultural processes have driven the adoption of technologies in the fruit production chain. Among these technologies, solutions based on computer vision and artificial intelligence stand out, enabling the automation of traditionally manual tasks, such as fruit classification and selection, to increase sustainability and optimize agricultural practices [13–15].

Artificial intelligence (AI) techniques, particularly those based on deep learning and machine learning, have been increasingly utilized in agriculture over the past few years. Computer vision, combined with convolutional neural network (CNN) algorithms, has proven efficient in detecting and classifying fruits, including strawberries, using images and videos [13,16–18]. In this context, the You Only Look Once (YOLO) model stands out, recognized for its efficiency and speed in object detection. In its most recent version, YOLO presents significant advances in accuracy, generalization capacity, and computational performance, making it a promising choice for real-time agricultural applications [17,19]. The present study aims to apply computer vision techniques and convolutional neural networks to classify the quality of strawberries using the YOLO model. The proposal involves classifying the quality of strawberries in images, focusing on identifying defects, diseases, and ripeness; promoting greater efficiency in identifying these problems; and directly contributing to reducing waste and improving the quality of the final product delivered to the consumer. Moreover, the study examines the advantages, limitations, and prospects of implementing these technologies in the agricultural and commercial sectors.

2. Background

A high-quality strawberry exhibits consistent size, shape, and a vibrant red color characteristic of complete ripeness and cultivar specificity, with even pigment distribution, signifying optimal anthocyanin development [20]. Surface attributes such as evenly spaced achenes and a fresh green calyx contribute to the visual appeal and marketability [21]. Firmness, a key texture parameter, is best measured instrumentally and reflects cellular integrity, directly influencing shelf life and mechanical resilience [22]. The postharvest fruit must be free of defects, such as bruising or microbial contamination, including *Botrytis cinerea*

[23]. The flavor depends on the balance of soluble solids (7–12°Brix) and titratable acidity (0.4–0.9%), with the Soluble Solids Content (SSC) to Titratable Acidity (TA) (SSC/TA) ratio serving as a reliable indicator of sweetness perception [20]. Aroma is shaped by volatile organic compounds (VOCs), particularly esters and furanones, which vary by cultivar and ripening stage and are typically assessed via gas chromatography-mass spectrometry [21]. Juiciness reflects cellular water retention, enhancing mouthfeel. Nutritionally, strawberries are rich in vitamin C, anthocyanins, ellagic acid, and folate, which contribute to their coloration and health benefits [24]. A commercially viable fruit must retain firmness,

flavor, and nutritional quality during storage and transport, factors influenced by cultivar, maturity at harvest, and preservation strategies [23].

In recent years, computer vision technologies have accelerated progress in image detection, and machine learning or deep learning (ML/DL) is gradually becoming a common approach in crop disease detection systems [16,19]. In the broader context of technologies applied to fruit detection, image processing in agriculture has undergone a considerable evolution. According to Wang et al. [25], the process has undergone three main phases: (I) conventional digital image processing, (II) image processing with machine learning, and (III) image processing with deep learning. Initially, threshold analysis and regional segmentation were used to extract basic features such as color and shape [26].

However, with the emergence of deep learning, algorithms based on convolutional neural networks (CNNs) began to offer better performance, providing greater accuracy, speed, and adaptability to image variations. This evolution is essential for accurately identifying defects, diseases, and ripening stages, which are necessary elements in agricultural production.

The architecture of a convolutional neural network (CNN) mainly consists of an input layer, convolutional layers, activation functions, pooling layers, fully connected layers, and an output layer [27]. Convolutional neural networks (CNNs) excel in image processing and visual feature extraction, being widely applicable and efficiently identifying attributes such as color, shape, and texture [28–30]. This feature enables their use in tasks such as visual inspection of food, detection of surface defects, and identification of adulteration, allowing for the detection of deteriorated areas in fruits through texture analysis or the automatic identification of defective products on packaging lines [31,32]. Deep convolutional neural networks (CNNs) have revolutionized computer vision by enhancing image classification, object detection, and video prediction while addressing key challenges and paving the way for future research directions [6].

Diseases and postharvest damages significantly impact strawberry quality and yield, and deep learning has become an essential approach for disease detection in crops [16]. CNNs are particularly good at identifying patterns in images, such as detecting defects or diseases in fruits, due to their ability to capture complex spatial relationships between pixels. Their application in strawberry image processing enables the identification of fruit presence and the classification of defects, such as spots, cracks, or fungal diseases. Furthermore, CNNs can identify different stages of ripeness, providing valuable information for optimizing harvests and postharvest fruit transportation [26].

Integrating artificial intelligence (AI) and deep learning further enhances the speed and effectiveness of fruit detection. Models such as YOLO perform real-time classification of multiple objects in a single image, ensuring robust and accurate detection, especially suitable for agricultural contexts. Recent studies confirm this efficiency by highlighting the successful use of these algorithms in fruit production estimates and classification, with minimal errors [33].

3. Materials and Methods

The study was developed in three stages. First, we identified the most impactful conditions affecting postharvest fruit, ensuring we also had high-quality fruit. Second, we applied YOLO (You Only Look Once) to detect the condition, and third, the augmentation technique was used to improve the model quality. The images were all collected from the Creative Commons online source. Figure 1 shows the study stages.




Figure 1. Flowchart of the stages in the study. Source: The authors.

3.1. Image Acquisition and the Classes of Strawberry Images Studied

Table 1 presents the eight distinct strawberry conditions used to train and evaluate the YOLO model for quality assessment at the final stage of the supply chain. Each class includes a representative image and a detailed description of the condition. These categories encompass healthy and defective strawberries, ranging from good-quality fruit, characterized by firmness, vibrant color, and postharvest nutritional integrity, to various defects and diseases. The conditions include unripe strawberries, uneven ripening, missing calyx, fasciation (abnormal growth), and fungal infections such as powdery mildew, gray mold, and anthracnose. The descriptions are supported by physiological and biochemical traits, including pigment development, texture, and disease-specific symptoms, which provide the context for robust image-based classification. This classification framework forms the basis for automated detection using deep learning.

Table 1. Classification of strawberry conditions used for YOLO model training and evaluation, including visual examples and descriptive criteria for assessing postharvest quality and defects.









Class Image	Condition	Description
	A good-quality strawberry.	Maintaining fruit firmness, color, flavor, and nutritional quality postharvest is essential for commercial viability [34].
	An unripe strawberry.	An unripe strawberry is firm, green, or white due to the presence of chlorophyll, a lack of anthocyanins, and is typically smaller. Biochemically, it is low in sugars but high in organic acids, leading to a tart, astringent taste. It features a “green” aroma profile [34].

Table 1. Cont.

Class Image	Condition	Description
	Uneven ripening.	The area around the calyx (cap) remains white or pale green, while the rest of the fruit reddens [34].
	Strawberry with a missing calyx.	The calyx is expected to be present and fresh-looking for strawberries sold fresh. It is considered a defect or damage if it is missing, significantly damaged, or improperly developed [20].
	Fasciated strawberry.	It is a condition of abnormal plant growth where the growing tip (<i>apical meristem</i>) becomes elongated or multiplied, leading to flattened, crested, or contorted plant parts [33].
	Strawberry with powdery mildew.	A strawberry with powdery mildew is affected by a common fungal disease typically caused by the fungus <i>Podosphaera aphanis</i> . This disease affects various parts of the strawberry plant, including the fruit [35].
	Strawberry with gray mold.	A strawberry with gray mold is characterized by a rapidly developing soft rot covered in a distinctive, fuzzy, gray fungal growth, primarily caused by the fungus <i>Botrytis cinerea</i> , which typically develops under cool, moist, and humid conditions [36].
	Strawberry affected by anthracnose.	A strawberry affected by anthracnose, a disease caused by <i>Colletotrichum</i> species (commonly <i>C. acutatum</i>), exhibits distinct, firm, sunken lesions on the fruit. These lesions are typically circular, light brown, or tan spots that progressively darken to brown or black [37].

Source: Adapted from [33–37].

3.2. Model Development and Training

In the second stage, the dataset was first divided into three distinct, non-overlapping subsets to ensure an unbiased evaluation:

- Training Set: 1756 images (80% of the total).
- Validation Set: 220 images (10% of the total).
- Test Set: 220 images (10% of the total).

This resulted in a total set of 2196 strawberry images.

This split was performed prior to any augmentation to avoid data leakage between training and evaluation subsets. Data augmentation techniques were then applied exclusively to the training set to increase its variability and improve the model's generalization ability. At the same time, the validation and test sets remained unchanged for an accurate performance assessment. Ultimately, this process yielded approximately 900 annotated instances per strawberry condition.

YOLO Use

Initially, the YOLOv8m (Medium) model was benchmarked due to its improved detection accuracy compared to earlier YOLO versions. However, subsequent optimization experiments revealed that the lightweight YOLOv8n (Nano) variant provided comparable accuracy while achieving significantly faster inference time, which is crucial for real-time agricultural applications with limited computational resources. Therefore, YOLOv8n was ultimately selected as the final model for deployment in this study, ensuring an optimal balance between detection performance and processing speed. Terven and Cordova-Esparza [38] reported that YOLOv8m outperformed earlier iterations, such as YOLOv5, as well as alternative frameworks like Faster R-CNN, particularly in metrics like mean Average Precision (mAP). This study further evaluated model performance across datasets with and without augmentation, thereby elucidating the influence of data augmentation on detection accuracy.

3.3. Data Augmentation

Data augmentation was applied as part of the third stage, which is a process that increases the size of a training dataset through techniques such as rotation, flipping, cropping, and contrast adjustment to enhance the model's generalization and performance [39]. Data augmentation techniques were applied to the training set to improve the generalization capacity of the YOLOv8m model and optimize its accuracy in fruit identification [40]. This strategy aimed to simulate natural variations in real-world image capture conditions, making the model more robust to changes in lighting, angles, and image sharpness. The augmentation methods, such as rotation and blurring, were selected based on prior studies indicating their positive impact on YOLOv8m accuracy. In contrast, cropping was excluded due to its tendency to eliminate critical features in small objects [41]. Based on these find-

ings, specific data augmentation techniques were applied to the training dataset to enhance model generalization and robustness. First, random image rotations between -30° and

$+30^\circ$ were applied to simulate natural variability in camera angles and fruit orientation during harvesting and inspection, which improves the model's robustness to positional changes. Additionally, a Gaussian blur filter with a 3×3 kernel was used to replicate common imaging artifacts, such as slight motion blur or focus inconsistencies, which often occur in real-world postharvest environments. These augmentations were selected based on prior studies indicating that geometric transformations and controlled blurring enhance the generalization of the YOLO model in agricultural datasets.

Following data augmentation, the dataset increased to a total of 5663 images, with the final data split structured as follows:

- Training Set: 5223 images (92% of the total).
- Validation Set: 220 images (4% of the total).
- Test Set 220 images (4% of the total).

Model training was conducted using the Google Colab Pro platform, which provides access to hardware-accelerated resources suitable for deep learning workflows [42]. The computational environment also employed the Ultralytics YOLOv8 framework, version 8.3.144, implemented in Python 3.11.12 and PyTorch 2.6.0 with CUDA 12.4 support. The training was performed on an NVIDIA A100-SXM4 GPU with 40 GB of memory, which offers 40.5 GB (40,507 MiB) of VRAM. The implemented YOLOv8 model consisted of 72 layers and approximately 3.01 million parameters, with no gradient storage and an estimated computational load of 8.1 GFLOPs following layer fusion [43], in conjunction with the Ultralytics YOLOv8 model [44], OpenCV [45], and Roboflow [46]. Google Colab Pro was selected due to its high-performance GPU resources, which enable accelerated model training and improved computational efficiency during the development of the YOLOv8 detection framework. The model was implemented using Python, using several specialized libraries to facilitate workflow stages. OpenCV was used for image pre-processing, while TensorFlow served as the primary framework for model construction and training. PyTorch was applied as an alternative deep learning framework [47].

Following the training phase, the performance of the YOLOv8 convolutional neural network (CNN) was assessed using key evaluation metrics. These included Box Precision (BoxP) Equation (1), which quantifies the accuracy of predicted bounding boxes relative to ground truth annotations; Recall (R) (Equation (2)), which measures the proportion of correctly identified positive instances; Mean Average Precision at 50% Intersection-over-Union (mAP50) (Equation (3)), evaluating detection accuracy at a 50% overlap threshold; and Mean Average Precision at 95% IoU (mAP95) (Equation (4)), which applies a more stringent 95% overlap threshold to assess model precision.

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP}) \quad (1)$$

Here, TP = true positives (correctly predicted bounding boxes) and FP = false positives (incorrectly predicted bounding boxes).

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN}) \quad (2)$$

Here, TP = true positives (correctly predicted bounding boxes) and FN = false negatives (missed ground truth objects).

$$\text{mAP50} = (1/N) \times \sum (\text{AP}_i) \quad (3)$$

for IoU threshold = 0.50, where AP_i = Average Precision for class i and N = Number of object classes. $\text{IoU} \geq 0.50$ is required for a prediction to be considered a true positive

$$\text{mAP95} = (1/N) \times \sum ((1/10) \times \sum (\text{AP}_{i,j})) \quad (4)$$

for $j = 0.50$ to 0.95 in steps of 0.05 , AP_i = Average Precision for class i at IoU threshold j (incremented by 0.05 from 0.50 to 0.95). This reflects a more stringent and comprehensive evaluation across multiple IoU thresholds.

4. Results

This section presents the performance of the YOLOv8n model in two distinct training runs, comparing the results for classifying strawberries under varying quality conditions. Initially, a set of 2196 strawberry images was gathered from public sources (Google and

Kaggle) and our selected images. The images were pre-processed through automatic orientation and resizing to 640×640 pixels and then annotated in Roboflow [46]. To increase the variability and robustness of the dataset, data augmentation techniques were applied, including horizontal mirroring, 90° rotations (both clockwise and counterclockwise), and the application of blur with an intensity of up to twice the original value. This process expanded the dataset to a total of 5663 images, with 80% allocated for training, 10% for validation, and 10% for testing.

Two training runs were conducted using the YOLOv8n model: one with 100 epochs and the other with 200 epochs. The objective was to evaluate the impact of the number of iterations on the classification and detection performance of the different strawberry classes. Regarding the evaluation of the model, Table 2 summarizes the general performance metrics obtained by the trained models. The results in Table 2 indicate that Training 2 (200 epochs) consistently outperformed Training 1 (100 epochs) in most performance metrics. Notably, Training 2 demonstrated an improvement in mAP@0.5, increasing from 0.772 to 0.79, which indicates higher accuracy in object detection with an IoU of 0.5. There were also improvements in Precision (from 0.683 to 0.744) and recall (from 0.769 to 0.777), as well as an increase in mAP0.5 to 0.95.

Table 2. Comparison of performance metrics between YOLOv8n models (100 and 200 epochs).

General Metrics	Training 1	General Metrics
Epochs	100	200
Duration	1468 horas	2273 horas
mAP50-95	0.53	0.534
mAP50	0.772	0.79
Precision	0.683	0.744
Recall	0.769	0.777
Tempo de Inferência	2.0 ms/imagem	1.0 ms/imagem

Source: The authors.

Also noted is the substantial reduction in inference time for Training 2, which was 1.0 ms per image compared to 2.0 ms per image for Training 1. Such a result means that the model with 200 epochs processes images twice as fast, which can be considered suitable for real-time classification systems. The analysis of the F1-Confidence and Loss Curves, as shown in Figure 2 for both training sessions, provides insight into the relationship between prediction confidence and the balance between Precision and Recall for each class.

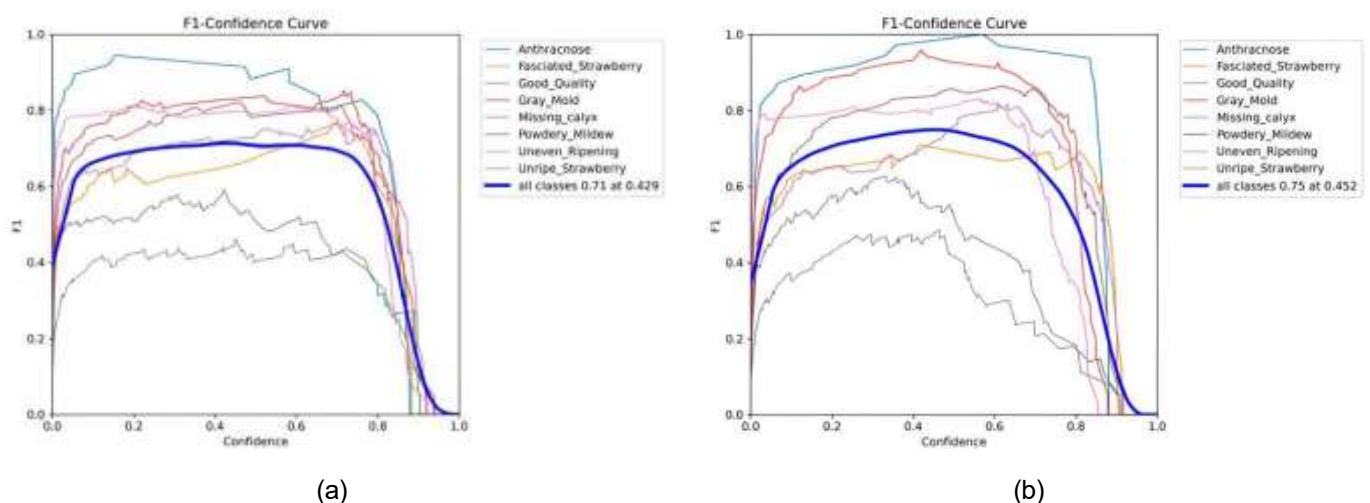


Figure 2. F1 curves as a function of confidence for models trained with 100 (a) and 200 (b) epochs. Source: The authors.

Figure 2 illustrates the F1-score as a function of confidence threshold for the YOLOv8n models trained with 100 epochs (Figure 2a) and 200 epochs (Figure 2b), respectively. These curves provide a detailed assessment of the trade-off between Precision and Recall across varying confidence levels for each strawberry quality class. A higher F1-score at a specific confidence value indicates a more optimal balance between false positives and false negatives. In the model trained for 200 epochs, higher peak F1-scores are achieved, particularly for classes with well-defined visual characteristics such as anthracnose, gray mold, and powdery mildew, which reach F1 values above 0.90. Conversely, lower F1-scores are observed for Good Quality and Unripe Strawberry, suggesting difficulties in distinguishing these categories due to visual overlap or intra-class variability. Notably, the model with 200 epochs shows not only improved F1-score magnitudes but also better separation and consistency across classes, highlighting the benefits of extended training in refining decision boundaries and enhancing classification confidence.

The model with 100 epochs achieved a maximum F1-score of 0.71 with a confidence of 0.429, while the model with 200 epochs achieved a higher value, reaching 0.75 with a confidence of 0.452. This improvement indicates that the second training enabled the model to define decision limits with greater confidence for different classes, particularly the most visually distinct ones, such as Gray_Mold, Anthracnose, and Powdery_Mildew, which have F1 curves of 0.90 or higher. On the other hand, it can be seen that the Good_Quality and Unripe_Strawberry classes presented the lowest F1 scores in both curves. Such an outcome reflects a greater difficulty in visually differentiating or a lower representation of these classes in the dataset, indicating that the performance curve for these classes shows low performance even at moderate confidence levels.

Figure 3 shows the evolution curves of losses and metrics (such as Precision, Recall, and mAP) during training with 100 and 200 epochs. The analysis of these curves (blue lines for the obtained values and orange dashed lines for the smoothed values) suggests progressive learning and no apparent signs of overfitting, especially for the 200-epoch model, which maintained a trend of continuous improvement, reflecting greater stability and generalization capacity.

The training dynamics of the YOLOv8n models across 100 (panel a) and 200 (panel b) epochs (Figure 3) illustrate the evolution of key performance metrics, Precision, Recall, mAP@0.5, and mAP@0.5:0.95, as well as the loss functions (box loss, classification loss, and distance-from-object loss, or DFL). The blue solid lines represent the raw metric values across training iterations, while the orange dashed lines indicate smoothed trends to emphasize the learning progression. In both training sessions, an apparent reduction in all loss components is observed during the early epochs, indicative of effective weight optimization and convergence. Particularly in the 200-epoch model, the loss curves exhibit sustained stability and lower variance in later epochs, suggesting improved generalization capacity without marked overfitting. Concurrently, the upward trends in mAP and recall, especially visible in the extended training, indicate incremental improvements in object detection accuracy. These patterns confirm that the longer training duration contributed to enhanced feature extraction and classification consistency, thereby validating the model's robustness and suitability for deployment in real-time postharvest quality assessment systems.

The training loss curves (box, cls, and dfl) show a decreasing and stable trend over the epochs in both models, indicating that the weight adjustment process was effective. However, it is possible to observe that the validation loss (val/box_loss, val/cls_loss, val/dfl_loss) shows a slight increase after half of the training, especially in the 200-epoch model. This outcome may be a subtle indication of the beginning of overfitting despite the evaluation metrics continuing to improve. Precision and recall increase significantly

until approximately the 50th epoch in both models, stabilizing at levels above 0.74 in the second training.




Figure 3. Loss curves (box, cls, dfi) and metrics (Precision, Recall, mAP0.5, mAP0.5:0.95) of the models trained with 100 (a) and 200 (b) epochs. Source: The authors.

The mAP0.5 in the 200-epoch model stabilizes at around 0.79, stops learning in the 159th epoch, and reaches a mAP0.5 of 0.95, which is approximately 0.16 higher than the previously presented values. The variations observed in the curves are expected in training with data from imbalanced classes, as in this study, and were smoothed out with the increase in the number of epochs. The graphs reinforce that the model with 200 epochs achieved better learning and stability in the classification parameters, albeit at the cost of a slight increase in validation losses, which is acceptable within a reasonable limit, given the dataset's complexity and size.

4.1. Analysis by Class

Table 3 details the per-class metrics for the model trained with 100 and 200 epochs. In the second training, the anthracnose class at mAP50 (0.995) achieved the best results, followed by Gray_Mold with mAP@0.5 (0.967) and Powdery_Mildew (0.882).

Table 3. Performance by class (Precision/Recall/mAP50/mAP50-95).

Class	Training 1 (YOLOv8n_inspection3)	Training 2 (YOLOv8n_inspection4)
Anthracnose	P: 0.890, R: 0.949, mAP50: 0.972, mAP50-95: 0.652	P: 0.969, R: 1.000, mAP50: 0.995, mAP50-95: 0.662
Fasciated_Strawberry	P: 0.639, R: 0.667, mAP50: 0.734, mAP50-95: 0.498	P: 0.684, R: 0.721, mAP50: 0.724, mAP50-95: 0.484
Good_Quality	P: 0.396, R: 0.486, mAP50: 0.443, mAP50-95: 0.321	P: 0.501, R: 0.459, mAP50: 0.398, mAP50-95: 0.279
Gray_Mold	P: 0.799, R: 0.861, mAP50: 0.891, mAP50-95: 0.585	P: 0.970, R: 0.906, mAP50: 0.967, mAP50-95: 0.590
Missing_calyx	P: 0.614, R: 0.875, mAP50: 0.829, mAP50-95: 0.582	P: 0.623, R: 0.850, mAP50: 0.842, mAP50-95: 0.585
Powdery_Mildew	P: 0.741, R: 0.902, mAP50: 0.822, mAP50-95: 0.604	P: 0.751, R: 0.951, mAP50: 0.882, mAP50-95: 0.651
Uneven_Ripening	P: 0.708, R: 0.909, mAP50: 0.598	P: 0.734, R: 0.891, mAP50: 0.845, mAP50-95: 0.579
Unripe_Strawberry	P: 0.675, R: 0.499, mAP50: 0.635, mAP50-95: 0.398	P: 0.722, R: 0.440, mAP50: 0.667, mAP50-95: 0.441

Source: The authors.


The classes with the most significant difficulty in classification were ‘Good Quality’ and ‘Unripe Strawberry’. The former presented low Precision and Recall, resulting in a mAP50 of only 0.398. This limitation may be related to the internal variability of the images considered ‘good’, which may share visual characteristics with other classes, such as Uneven_Ripening. Despite presenting a specific coloration, the Unripe_Strawberry class had a low Recall (0.440), suggesting that the model frequently fails to recognize all instances of this class in the test set.

These patterns are also presented in the F1-Confidence curves (Figure 1), where the Good_Quality (green) and Unripe_Strawberry (gray) classes maintain F1 values significantly lower than the others throughout the entire confidence interval. This result highlights both the reduced distinction between classes and the model’s difficulty in establishing well-defined decision limits for these categories. The recall and precision values indicate that the most frequent confusions are concentrated between Good_Quality and classes related to ripeness or deformities, such as Uneven_Ripening and Fasciated_Strawberry.


Figure 4 presents the confusion matrices of the models trained with 100 and 200 epochs, respectively. They provide a detailed view of the correct classifications and the main errors made by the model in each category.

In both matrices, we observed solid performance on the main diagonal for the classes anthracnose, gray mold, powdery mildew, and uneven ripening, confirming the metrics reported earlier. Higher counts in these quadrants indicate consistent, correct predictions. However, some confusion is evident, such as in the following cases:

- Good quality is frequently confused with uneven ripening, missing calyx, and, to a lesser extent, with the background itself. Even after 200 epochs, although there is a slight improvement (21 to 24 correct), errors persist for these classes, suggesting significant visual overlap.
- Unripe strawberry shows a confusing pattern with uneven ripening and missing calyx. The number of incorrect predictions for Unripe_Strawberry decreased from 36 to 30, representing progress, but it is still a critical area.
- Fasciated strawberry showed an increase in correct answers (from 10 to 12) and a slight reduction in cross-errors, demonstrating a benefit from the increase in epochs while maintaining some confusion with Good_Quality and anthracnose.



(a)



(b)

Figure 4. Confusion matrices of models trained with 100 (a) and 200 (b) epochs. Source: The authors.

A noteworthy positive aspect is that the model with 200 epochs exhibits a stronger diagonal and less dispersion outside it, indicating an improvement in the learning process and a reduction in ambiguities. These results reinforce the need for targeted interventions in classes with greater overlap, such as increasing the number of good quality and unripe strawberry samples, applying refined labeling to reduce subjectivity between uneven ripening and good quality, and introducing complementary attributes (for instance, texture, shine, and ripeness index via color).

Figure 5 shows images generated during training that are examples of fruit segmentation, detection, and classification of strawberries based on attributes such as quality (good quality), deformities (strawberry fascia, anthracnose, gray mold), immaturity, uneven ripening, and absence of calyx.




Figure 5. Images generated during training. Source: The authors.

Figure 4 presents representative output images generated by the YOLOv8n model during inference, illustrating its ability to detect and classify various strawberry conditions in real-time. The bounding boxes and class labels, superimposed on each fruit image, confirm the model's successful identification of distinct quality categories, including good quality, anthracnose, gray mold, fasciated strawberry, uneven ripening, and unripe strawberry. These detections reflect the model's capacity to extract and interpret salient visual features, such as color heterogeneity, lesion morphology, and calyx presence. The classification performance is more accurate in categories with distinct phenotypic markers, such as fungal infections. In contrast, greater ambiguity persists in visually similar classes, particularly between 'Good Quality' and 'Uneven Ripening'. The output demonstrates the feasibility of integrating YOLOv8n into automated sorting systems for postharvest quality control, supporting earlier metrics that indicate high model precision for visually distinctive defects.

4.2. Extended Model Evaluation and Optimization

To address initial concerns regarding convergence, we further optimized the training process by benchmarking different YOLOv8 variants (Nano, Small, and Medium) under the same dataset conditions. Through these experiments, YOLOv8n emerged as the optimal choice, achieving a superior balance between detection accuracy and inference speed for real-time applications. Additionally, we adopted an early stopping strategy, limiting training to approximately 70 epochs based on the stabilization of validation loss. This approach not only reduced the risk of overfitting observed in extended 200-epoch training but also improved mAP@0.5 for previously challenging classes, such as ‘Good Quality’ (from 0.398 to 0.746) and ‘Unripe Strawberry’ (from 0.667 to 0.783). These refinements indicate that careful model selection and training optimization can yield better performance with fewer epochs while maintaining high efficiency. Data augmentation techniques, including horizontal flipping, rotation, and Gaussian blur, were refined to address inter-class confusion. Table 4 summarizes the comparative performance across the three models.

Table 4. YOLOv8 model comparison with optimization parameters.

Model	Epochs	Precision	Recall	mAP@0.5	mAP@0.5:0.95	Inference Time (ms/img)
YOLOv8n	69	0.752	0.829	0.827	0.595	9.3
YOLOv8s	70	0.793	0.761	0.827	0.593	19.3
YOLOv8m	69	0.736	0.810	0.828	0.593	44.4

These results indicate that YOLOv8n achieves a comparable mAP@0.5 score to the larger models, while offering significantly faster inference time, a crucial factor for real-time agricultural applications. YOLOv8n outperformed its previous 200-epoch configuration in both accuracy and efficiency, achieving a higher mAP@0.5 and lower latency with less training time. Furthermore, improvements were observed in specific challenging classes. For example, the mAP@0.5 for the ‘Good Quality’ class increased from 0.398 (in the earlier version) to 0.746, and for ‘Unripe Strawberry’ from 0.667 to 0.783. These improvements are attributed to both dataset refinement and better tuning of training and augmentation parameters. This extended evaluation highlights that even without modifying the YOLOv8 architecture itself, careful selection of model variant, training duration, and augmentation strategy can substantially enhance detection performance. The findings highlight the practical potential of lightweight models, such as YOLOv8n, when optimized for deployment in constrained environments.

5. Discussion

YOLOv8n was ultimately selected as the optimal model due to its superior trade-off between detection accuracy and real-time inference speed. Furthermore, an early stopping strategy was applied, reducing training to approximately 70 epochs without compromising performance. This adjustment improved the mAP@0.5 for previously challenging classes and minimized the overfitting tendency observed in the 200-epoch training.

The findings from this study underscore the practical applicability of YOLOv8n in the postharvest classification of strawberries, demonstrating both operational speed and acceptable accuracy metrics for real-time deployment. The model’s enhanced performance in the second training iteration, particularly in terms of mAP50 (0.79), Precision (0.744), and Recall (0.777), aligns with earlier studies on object detection in agriculture using YOLO frameworks [17,40]. These results suggest that deeper training (200 epochs) enhances the model’s capacity to learn discriminative visual features, particularly for classes with clear phenotypic markers, such as anthracnose and gray mold.

The use of data augmentation was decisive for the model's robustness, enabling it to mitigate the effects of data scarcity in certain classes [48]. Previous models with fewer variation techniques tend to exhibit overfitting or low generalization, which was not observed in this case. This outcome is consistent with the findings of Xiao et al. [40], who found that applying geometric and photometric transformations, such as rotation, blur, and brightness adjustments, significantly improved the YOLOv8 model's performance in fruit classification tasks by enhancing the variability in training data and reducing model sensitivity to environmental noise. The application of data augmentation proved critical to improving model generalization. By simulating variations encountered in real-world image acquisition, such as lighting fluctuations and orientation inconsistencies, augmentation enhanced the robustness of feature learning [26]. This method aligns with the findings of Aboelenin et al. [49], who emphasized that balanced and diversified training datasets are essential for reducing overfitting in plant disease classification models.

Compared to conventional approaches based on convolutional neural networks or previous versions of YOLO, the results of YOLOv8n stand out both in accuracy and inference time, enabling practical applications. Among the limitations identified, the imbalance between classes stands out, with a smaller number of fasciated strawberry and good-quality samples, as previously observed [49].

Although no structural modifications were made to the core architecture of YOLOv8, several targeted optimizations were performed to enhance model performance. In addition to the YOLOv8n model initially used in the study, comparative experiments were conducted with the YOLOv8s and YOLOv8m variants. This model-level benchmarking enabled a comprehensive assessment of the trade-offs between accuracy and computational cost. Furthermore, training parameters such as the number of epochs were optimized, with 69–70 epochs yielding comparable or superior results to the original 200-epoch training. EarlyStopping techniques were also applied to avoid overfitting and improve training efficiency. The YOLOv8n model, in particular, demonstrated a precision of 0.752, a recall of 0.829, and mAP@0.5 of 0.827 in just 69 epochs, surpassing earlier configurations in both accuracy and inference speed. These results indicate that model selection, training duration, and convergence criteria were systematically adjusted to achieve optimal performance for real-time classification tasks, particularly in constrained computational environments. Therefore, while the backbone remained unchanged, the methodological refinements applied in this study reflect meaningful model optimization aligned with deployment-oriented research.

Per-class analysis revealed important insights into class-specific challenges. For example, the classes 'Good Quality' and 'Unripe Strawberry' had significantly lower performance metrics, a likely consequence of visual overlap and class imbalance. The relatively low mAP50-95 values for these categories (0.279 and 0.441, respectively) suggest a limitation in model granularity when handling subtler variations in color and shape, which are not as morphologically distinct as those in diseased classes, such as anthracnose or gray mold. Similar observations were made in previous studies by Hu et al. [11] and Zhou et al. [12], who reported model confusion in early fruit maturation stages due to low intra-class variance and high inter-class similarity.

It was observed that the classes uneven ripening, powdery mildew, gray mold, and missing calyx presented reasonable accuracy rates and correct predictions. This behavior indicates that the model was able to capture distinct visual patterns in these categories, even in different contexts [9]. On the other hand, some classes presented recurring confusion among themselves. The unripe strawberry class, for example, was frequently confused with good quality. Similarly, uneven ripening was also confused with good quality. These

confusions may be related to the visual similarity between the classes [11], particularly in cases of partial ripeness or strawberries that appear healthy but exhibit irregular patterns. It is also worth noting that the dataset was expanded in the most recent experiments, increasing the number of annotated validation images from 220 to 273 and the total number of class instances from approximately 900 to 1100. This increase improved class representation and diversity, particularly benefiting underperforming classes such as 'Good Quality' and 'Unripe Strawberry'. The expanded dataset contributed to better generalization and learning, as evidenced by improved mAP scores for these categories. These enhancements reflect the importance of dataset refinement as a complementary strategy to model selection in object detection tasks.

The evolution of the training and validation loss curves further supports the notion that 200 epochs yielded a more stable and better-generalizing model, albeit with slight signs of overfitting toward the later epochs. This trade-off is expected in small-to-moderate datasets [9], particularly when dealing with eight distinct visual classes characterized by imbalanced sample distributions.

Confusion matrices substantiate the quantitative metrics, showing frequent misclassifications between visually similar classes. The recurrent misidentification of good quality as uneven ripening or missing calyx suggests that the inclusion of auxiliary imaging modalities, such as hyperspectral or RGB-D sensors, could help resolve ambiguities [12]. Moreover, improved labeling precision and the integration of multisensorial descriptors (e.g., gloss, firmness proxies) may yield better intra-class consistency, as advocated by Ahmed et al. [20].

In addition to these improvements, the analysis of dataset structure and augmentation effects could be further enhanced using visual analytics tools. Although the augmentation strategies applied in this study improved performance, future work will benefit from embedding-space visualization methods such as t-SNE or PCA. These tools can help analyze feature distribution before and after augmentation, providing clearer insights into how augmented data affects class separability, particularly for categories with subtle visual distinctions. Moreover, heatmaps and class-wise visual dashboards may provide a better understanding of sample density, distribution imbalance, and potential dataset biases that impact model learning.

To address the observed misclassification between the 'Good Quality' and 'Unripe Strawberry' classes, additional training experiments were conducted using different YOLOv8 model variants (Nano, Small, and Medium) under consistent dataset and augmentation conditions. These new tests aimed to reduce confusion by evaluating whether model scaling could better capture subtle visual distinctions between these visually similar categories. The YOLOv8n model trained for 69 epochs achieved improved performance in both classes compared to the original YOLOv8n-200 model. Specifically, the 'Good Quality' class improved from a mAP@0.5 of 0.398 to 0.746, and the 'Unripe Strawberry' class increased from 0.667 to 0.783. These gains indicate enhanced class separability and reinforce that careful model selection, even without architectural changes, can contribute meaningfully to classification accuracy. While challenges persist, particularly under conditions of overlapping visual traits and dataset imbalance, these results validate the effectiveness of model version tuning in improving performance for the most challenging classes.

However, despite these improvements, certain limitations remain. The model still exhibits misclassification in instances where strawberries share highly similar visual traits, such as between early-stage ripening and fully ripe fruits. This finding suggests that even optimized deep learning models may require supplementary support from techniques such as color space transformations (for example, HSV), texture-based descriptors, or

multimodal inputs (for instance, hyperspectral data) to resolve ambiguities in fine-grained classification. Investigating these approaches will be a primary focus of future research.

A challenge encountered in this study was the persistent misclassification between the ‘Good Quality’ and ‘Unripe Strawberry’ categories. This confusion likely stems from the visual similarity in surface color and shape that these classes may share, particularly in cases of borderline ripeness or partial pigmentation. The F1-confidence curves (Figure 1) and confusion matrices (Figure 3) highlight this issue, with both classes exhibiting the lowest F1-scores and frequent cross-predictions. Such misclassification can be attributed to two primary factors: (i) overlapping visual features that reduce class separability and (ii) an imbalanced dataset where the good quality class was underrepresented, limiting the model’s ability to generalize subtle differences in texture and hue.

To mitigate this, future work should prioritize curating a more balanced dataset, primarily by increasing the representation of good-quality and unripe samples under varying lighting, maturation, and background conditions. The incorporation of additional image features, such as glossiness, surface texture, or color histograms extracted through HSV or LAB color space transformations, could enhance the model’s discriminative power [20,26]. Furthermore, implementing multispectral imaging or RGB-D sensors would allow the model to learn from biochemical or structural properties, such as firmness or chlorophyll content, which are not captured by RGB data alone [12]. On the architectural level, fine-tuning the classification head of the YOLOv8n model or integrating a two-stage hybrid system that first segments the fruit region and then applies a secondary classifier may further reduce ambiguity between closely related classes [11].

While the application of data augmentation techniques—such as rotation, Gaussian blur, and mirroring—clearly contributed to improving the model’s performance metrics, it is important to interpret this improvement in the context of the high-dimensional feature space in which the YOLOv8n model operates. In deep convolutional networks, such as YOLO, image transformations alter the distribution of learned features by introducing variations in spatial orientation, texture, and illumination, thereby increasing the diversity of activation patterns in the feature maps. From a representational learning perspective, these augmentations facilitate the generation of local perturbations around each class manifold, which can enhance the robustness of the decision boundary and reduce class overlap, particularly in low-sample regimes [40,50].

Although no explicit dimensionality reduction (e.g., t-SNE or UMAP) was performed in this study, the consistent performance gains observed in Precision, Recall, and class-wise mAP (particularly in visually distinct categories) suggest a positive shift in feature separability in the latent space. Future work should include visual embeddings of pre- and post-augmentation samples to formally assess cluster dispersion and inter-class margin shifts, as recommended by Lespinats et al. [50] and Colange et al. [51]. Moreover, measuring intrinsic dimensionality or analyzing learned embeddings via cosine similarity and intra-class variance could further reveal how augmentation affects the geometric structure of the dataset and its representation in YOLOv8’s intermediate layers.

The YOLOv8n model, when sufficiently trained and supported by augmentation strategies, performs robustly in strawberry defect classification. Nonetheless, the study highlights the need for improved class definition, enhanced image diversity, and potentially multimodal inputs to resolve persistent classification errors in visually similar fruit conditions. Additionally, the subjectivity involved in visual quality labeling can lead to inconsistencies, so attention should be given to the process. For future studies, it is essential to balance the dataset through the class-directed collection, include more images under natural lighting conditions, evaluate the system with multispectral or depth sensors (RGB-D) [12], and integrate it with devices for real-time testing.

6. Conclusions

This study presented the utility of the YOLOv8n model for automated postharvest strawberry quality classification, showing high accuracy in distinguishing between defects, diseases, and ripeness stages. The implementation of data augmentation strategies substantially bolstered model robustness by alleviating the adverse effects of class imbalance and inconsistencies in image quality. Quantitative performance assessment showed that increased training epochs were correlated with enhanced mean Average Precision (mAP), Precision, and Recall, supporting the model's suitability for real-time deployment in agricultural settings. Despite the strong performance in visually distinguishable categories, such as anthracnose and gray mold, limitations persisted in differentiating visually proximate classes, such as 'Good Quality' versus 'Unripe' strawberries. These results highlight a requirement for future research to focus on curating more equitably distributed datasets and integrating complementary imaging technologies. Overall, the presented approach constitutes a possible solution for optimizing postharvest handling and quality assurance throughout the strawberry supply chain.

We suggest exploring the integration of YOLOv8 with other emerging technologies to further enhance model performance and generalization capabilities in the future. This aspect involves incorporating Transformer-based architectures, such as DETR or Swin Transformer, which have demonstrated strong performance in object detection tasks involving complex spatial relationships. Additionally, the use of multimodal data fusion, combining RGB imagery with hyperspectral or depth information, may help address class ambiguity issues and improve detection robustness under variable lighting and occlusion conditions. These directions hold potential for advancing the technological contributions of this research beyond its current, single-modality, real-time scope.

As part of future work, we also intend to benchmark YOLOv8 against other state-of-the-art object detection architectures, such as Faster R-CNN, EfficientDet, and Transformer-based models, to further validate its relative performance in strawberry quality assessment tasks, particularly in scenarios where real-time inference is not a strict requirement, and to integrate color-aware and multimodal techniques to address remaining challenges in visually similar fruit categories.

Author Contributions: Conceptualization, M.T.O. and L.d.S.C.; methodology, M.T.O. and L.d.S.C.; software, M.T.O. and L.d.S.C.; validation, M.T.O. and L.d.S.C.; formal analysis, M.T.O. and L.d.S.C.; investigation, M.T.O. and L.d.S.C.; resources, M.T.O. and L.d.S.C.; data curation, M.T.O.; writing—original draft preparation, L.d.S.C.; writing—review and editing, I.d.A.N. and M.T.O.; visualization, I.d.A.N.; supervision, M.T.O.; project administration, M.T.O. All authors have read and agreed to the published version of the manuscript.

Funding: This research received no external funding.

Data Availability Statement: Data will be available upon request.

Acknowledgments: The authors thank the Coordination for the Advancement of Higher Education—CAPES for the scholarship and the cooperation between Universidade Paulista and CEAGESP, which made the images available.

Conflicts of Interest: The authors declare no conflicts of interest.

References

1. FAO. *Global Agricultural Statistics: Strawberry*; Food and Agriculture Organization of the United Nations: Rome, Italy, 2025. Available online: <https://www.fao.org> (accessed on 20 April 2025).
2. Zeist, A.R.; Resende, J.T.V. Strawberry breeding in Brazil: Current momentum and perspectives. *Hortic. Bras.* 2019, *37*, 7–16. [CrossRef]
3. CEDES. Perdas e Desperdícios de Alimentos no Brasil. Centro de Estudos e Debates Estratégicos da Câmara dos Deputados. 2018. Available online: <https://www2.camara.leg.br/a-camara/estruturaadm/altosestudios/pdf/perdas-e-desperdicio-de-alimentos-no-brasil-estrategias-para-reducao> (accessed on 20 March 2025).
4. Embrapa. Perdas Pós-Colheita de Frutas e Hortalças no Brasil. Empresa Brasileira de Pesquisa Agropecuária. 2023. Available online: <https://www.embrapa.br> (accessed on 5 March 2025).
5. NCBI-National Center for Biotechnology Information. *Fragaria × ananassa* (Taxonomy ID: 3747). In NCBI Taxonomy Database. Available online: <https://www.ncbi.nlm.nih.gov/Taxonomy/Browser/wwwtax.cgi?mode=info&id=3747> (accessed on 18 May 2025).
6. Zhao, X.; Wang, L.; Zhang, Y.; Han, X.; Deveci, M.; Parmar, M. A review of convolutional neural networks in computer vision. *Artif. Intell. Rev.* 2024, *57*, 99. [CrossRef]
7. Albertini, M.R.; Ferrari, L.F.; Bonow, S.; Antunes, L.E.C. Produção de Mudanças de Morangueiro Cultivar BRS DC25 (Fênix) em Leito de Areia. 2023. Available online: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1156880/1/Cpact-Circular-240.pdf> (accessed on 20 March 2025).
8. Xu, L.; Wang, J.; Yang, G. An improved deep learning model for the classification of strawberry diseases. *Sensors* 2021, *21*, 4845. [CrossRef]
9. Yang, G.-F.; Yang, Y.; He, Z.-K.; Zhang, X.-Y.; He, Y. A rapid, low-cost deep learning system to classify strawberry disease based on cloud service. *J. Integr. Agric.* 2022, *21*, 460–473. [CrossRef]
10. Souza, B.; Zhang, H.; Oliveira, J. Automatic strawberry quality evaluation using deep learning and computer vision. *Fermentation* 2022, *9*, 249. [CrossRef]
11. Hu, X.; Wang, R.; Du, J.; Hu, Y.; Jiao, L.; Xu, T. Class-attention-based lesion proposal convolutional neural network for strawberry diseases identification. *Front. Plant Sci.* 2023, *14*, 1091600. [CrossRef]
12. Zhou, X.; Lee, W.S.; Ampatzidis, Y.; Chen, Y.; Peres, N.; Clyde Fraisse, C. Strawberry Maturity Classification from UAV and Near-Ground Imaging Using Deep Learning. *Smart Agric. Technol.* 2021, *1*, 100001. [CrossRef]
13. Koirala, A.; Walsh, K.B.; Wang, Z.; McCarthy, C. Fruit detection and quality evaluation using deep learning techniques: A review. *Agriculture* 2023, *13*, 241. [CrossRef]
14. Adewusi, A.O.; Asuzu, O.F.; Olorunsogo, T.; Iwuanyanwu, C.; Adaga, E.; Daraojimba, D.O. AI in precision agriculture: A review of technologies for sustainable farming practices. *World J. Adv. Res. Rev.* 2024, *21*, 2276–2285. [CrossRef]
15. Espinel, R.; Herrera-Franco, G.; Rivadeneira García, J.L.; Escandón-Panchana, P. Artificial Intelligence in Agricultural Mapping: A Review. *Agriculture* 2024, *14*, 1071. [CrossRef]
16. Zhao, S.; Liu, J.; Wu, S. Multiple disease detection method for greenhouse-cultivated strawberry based on multiscale feature fusion Faster R-CNN. *Comput. Electron. Agric.* 2022, *199*, 107176. [CrossRef]
17. Lin, Z.; Wang, Y.; Chen, H.; Huang, X. YOLOv5-based strawberry maturity and defect detection using computer vision. *Comput. Electron. Agric.* 2023, *210*, 107599.
18. Shahbazi, M.; Rahmoonfar, M. Real-time fruit detection using YOLOv4 and YOLOv5 models. *IEEE Access* 2021, *9*, 115526–115535.
19. Krichen, M. Convolutional Neural Networks: A Survey. *Computers* 2023, *12*, 151. [CrossRef]
20. Ahmed, M.M.; Asim, M.; Kaleri, A.A.; Manzoor, D.; Rajput, A.A.; Laghari, R.; Khaki, S.A.; Musawwir, A.; Ullah, Z.; Ahmad, W. Biochemical Dynamics and Quality Attributes of Strawberry Fruits across Maturity Stages with Respect to Different Preservation Methods: Biochemical Dynamics and Quality Attributes. *Futur. Biotechnol.* 2024, *4*, 28–35. [CrossRef]
21. Azam, M.; Ejaz, S.; Rehman, R.N.U.; Khan, M.; Qadri, R. *Postharvest Quality Management of Strawberries*; IntechOpen: London, UK, 2019; Chapter 4, pp. 59–79. Available online: <https://www.intechopen.com/chapters/66681> (accessed on 19 March 2025).
22. He, Y.; Peng, Y.; Wei, C.; Zheng, Y.; Yang, C.; Zou, T. Automatic Disease Detection from Strawberry Leaf Based on Improved YOLOv8. *Plants* 2024, *13*, 2556. [CrossRef]
23. Manda-Hakki, K.; Hassanpour, H. Changes in postharvest quality and physiological attributes of strawberry fruits influenced by L-Phenylalanine. *Food Sci. Nutr.* 2024, *12*, 10262–10274. [CrossRef]
24. Barbieri, G.; Colonna, E.; Roupael, Y.; De Pascale, S. Effect of the farming system and postharvest frozen storage on quality attributes of two strawberry cultivars. *Fruits* 2015, *70*, 361–368. [CrossRef]
25. Wang, X.; Li, Y.; Zhang, M. Intelligent systems in postharvest agriculture: Quality assessment and waste reduction. *Trends Food Sci. Technol.* 2022, *122*, 96–108. [CrossRef]
26. Wang, C.; Li, J.; Guo, Y.; Zhang, M.; Liu, Y. Strawberry detection and ripeness classification using YOLOv8+ model and image processing method. *Agriculture* 2024, *14*, 751. [CrossRef]
27. Alzubaidi, L.; Zhang, J.; Humaidi, A.; Al-Dujaili, A.; Duan, Y.; Al-Shamma, O.; Santamaría, J.; Fadhel, M.A.; Al-Amidie, M.; Farhan, L. Review of Deep Learning: Concepts, CNN Architectures, Challenges, Applications, Future

- Directions. *J. Big Data* 2021, *8*, 53. [CrossRef]
28. Seeliger, K.; Fritsche, M.; Güçlü, U.; Schoenmakers, S.; Schoffelen, J.; Bosch, S.; Gerven, M. Convolutional neural network-based encoding and decoding of visual object recognition in space and time. *NeuroImage* 2017, *180*, 253–266. [CrossRef]
 29. Jiang, B.; Zhang, Y.; Zhang, L.; De Bock, G.; Vliegthart, R.; Xie, X. Human-recognizable CT image features of subsolid lung nodules associated with diagnosis and classification by convolutional neural networks. *Eur. Radiol.* 2021, *31*, 7303–7315. [CrossRef]
 30. Purwono, P.; Maarif, A.; Rahmian, W.; Fathurrahman, H.; Frisky, A.; Haq, Q. Understanding of Convolutional Neural Network (CNN): A Review. *Int. J. Robot. Control Syst.* 2023, *2*, 4. [CrossRef]
 31. Ding, H.; Hou, H.; Wang, L.; Cui, X.; Yu, W.; Wilson, D.I. Application of Convolutional Neural Networks and Recurrent Neural Networks in Food Safety. *Foods* 2025, *14*, 247. [CrossRef]
 32. Khan, R.; Kumar, S.; Dhingra, N.; Bhati, N. The Use of Different Image Recognition Techniques in Food Safety: A Study. *J. Food Qual.* 2021, *2021*, 7223164. [CrossRef]
 33. Hernández-Martínez, N.; Blanchard, C.; Wells, D.; Salazar-Gutiérrez, M. Current state and future perspectives of commercial strawberry production: A review. *Sci. Hortic.* 2023, *312*, 111893. [CrossRef]
 34. Huang, Z.; Omwange, K.; Saito, Y.; Kuramoto, M.; Kondo, N. Monitoring strawberry (*Fragaria × ananassa*) quality changes during storage using UV-excited fluorescence imaging. *J. Food Eng.* 2023, *353*, 111553. [CrossRef]
 35. Wu, E.; Ma, R.; Dong, D.; Zhao, X. D-YOLO: A Lightweight Model for Strawberry Health Detection. *Agriculture* 2025, *15*, 570. [CrossRef]
 36. Petrasch, S.; Knapp, S.; Van Kan, J.; Blanco-Ulate, B. Grey mould of strawberry, a devastating disease caused by the ubiquitous necrotrophic fungal pathogen *Botrytis cinerea*. *Mol. Plant Pathol.* 2019, *20*, 877–892. [CrossRef]
 37. Aljawasim, B.D.; Samtani, J.B.; Rahman, M. New insights in the detection and management of anthracnose diseases in strawberries. *Plants* 2023, *12*, 3704. [CrossRef]
 38. Terven, J.; Córdova-Esparza, D.M.; Romero-González, J.A. A comprehensive review of YOLO architectures in computer vision: From YOLOv1 to YOLOv8 and YOLO-NAS. *Mach. Learn. Knowl. Extr.* 2023, *5*, 1680–1716. [CrossRef]
 39. Frizzi, S.; Bouchouicha, M.; Ginoux, J.M.; Moreau, E.; Sayadi, M. Convolutional neural network for smoke and fire semantic segmentation. *IET Image Process.* 2021, *15*, 634–647. [CrossRef]
 40. Xiao, B.; Nguyen, M.; Yan, W. Fruit ripeness identification using YOLOv8 model. *Multimed. Tools Appl.* 2023, *83*, 28039–28056. [CrossRef]
 41. Yilmaz, B.; Kutbay, U. YOLOv8 based drone detection: Performance analysis and optimization. *Computers* 2024, *13*, 234. [CrossRef]
 42. Google. (n.d.). Google Colab Pro. Available online: <https://colab.google.com> (accessed on 12 November 2024).
 43. Paszke, A.; Gross, S.; Massa, F.; Lerer, A.; Bradbury, J.; Chanan, G.; Killeen, T.; Lin, Z.; Gimelshein, N.; Antiga, L.; et al. PyTorch: An imperative style, high-performance deep learning library. In Proceedings of the Advances in Neural Information Processing Systems, Vancouver, BC, Canada, 8–14 December 2019; pp. 8024–8035. [CrossRef]
 44. Ultralytics. Ultralytics YOLOv8m Docs. Available online: <https://docs.ultralytics.com/> (accessed on 12 November 2024).
 45. Open Source Computer Vision Library. OpenCV. Available online: <https://opencv.org/> (accessed on 12 November 2024).
 46. Roboflow. Available online: <https://roboflow.com/> (accessed on 12 January 2024).
 47. Antunes, S.N.; Okano, M.T.; Nääs, I.A.; Lopes, W.A.C.; Aguiar, F.P.L.; Vendrametto, O.; Fernandes, J.C.L.; Fernandes, M.E. Model Development for Identifying Aromatic Herbs Using Object Detection Algorithm. *AgriEngineering* 2024, *6*, 1924–1936. [CrossRef]
 48. Lopes, W.A.C.; Fernandes, J.C.L.; Antunes, S.N.; Fernandes, M.E.; Nääs, I.D.A.; Vendrametto, O.; Okano, M.T. Augmented Reality Applied to Identify Aromatic Herbs Using Mobile Devices. *AgriEngineering* 2024, *6*, 2824–2844. [CrossRef]
 49. Aboelenin, S.; Elbasheer, F.A.; Eltoukhy, M.M.; Elhady, W.M.; Hosny, K.M. A hybrid Framework for plant leaf disease detection and classification using convolutional neural networks and vision transformer. *Complex Intell. Syst.* 2025, *11*, 2. [CrossRef]
 50. Lespinats, S.; Colange, B.; Dutykh, D. *Nonlinear Dimensionality Reduction Techniques: A Data Structure Preservation Approach*; Springer International Publishing: Berlin/Heidelberg, Germany, 2022. [CrossRef]
 51. Colange, B.; Vuillon, L.; Lespinats, S.; Dutykh, D. MING: An interpretative support method for visual exploration of multidimensional data. *Inf. Vis.* 2022, *21*, 246–269. [CrossRef]

Disclaimer/Publisher's Note: The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content

APÊNDICE E – Questionário de Avaliação do Aplicativo de Classificação da Qualidade de Morangos

Instruções ao Respondente

Este questionário tem como objetivo avaliar a experiência de uso do aplicativo desenvolvido para análise e classificação da qualidade de morangos. Não existem respostas certas ou erradas buscamos apenas sua percepção.

Por favor, assinale a opção que melhor representa sua opinião.

Escala utilizada:

- 1 – Discordo totalmente
- 2 – Discordo parcialmente
- 3 – Neutro
- 4 – Concordo parcialmente
- 5 – Concordo totalmente

Seção 1 – Perfil do Respondente

1. Qual é o seu papel na cadeia de suprimentos?
 - ☐ Produtor
 - ☐ Atacadista / CEAGESP
 - ☐ Feirante
 - ☐ Comerciante / Varejo
 - ☐ Consumidor final
 - ☐ Outro: _____
2. Já teve contato com aplicativos de análise ou classificação de produtos?
 - ☐ Sim
 - ☐ Não

Seção 2 – Usabilidade

3. ☐ 1 ☐ 2 ☐ 3 ☐ 4 ☐ 5 – O aplicativo é fácil de usar.
4. ☐ 1 ☐ 2 ☐ 3 ☐ 4 ☐ 5 – A navegação entre as telas é simples e intuitiva.
5. ☐ 1 ☐ 2 ☐ 3 ☐ 4 ☐ 5 – Consegui realizar a análise do morango sem dificuldade.
6. ☐ 1 ☐ 2 ☐ 3 ☐ 4 ☐ 5 – As instruções apresentadas são claras e suficientes.

Seção 3 – Clareza e Interpretação dos Resultados

7. ☐ 1 ☐ 2 ☐ 3 ☐ 4 ☐ 5 – Os resultados apresentados pelo aplicativo são fáceis de entender.
8. ☐ 1 ☐ 2 ☐ 3 ☐ 4 ☐ 5 – A identificação das classes (ex.: doenças, boa qualidade, imaturo) está clara para mim.

9. ☐ 1 ☐ 2 ☐ 3 ☐ 4 ☐ 5 – A explicação visual (caixa delimitadora e texto) facilita a interpretação.
-

Seção 4 – Desempenho

10. ☐ 1 ☐ 2 ☐ 3 ☐ 4 ☐ 5 – O tempo de análise (processamento) foi satisfatório.
11. ☐ 1 ☐ 2 ☐ 3 ☐ 4 ☐ 5 – O aplicativo funcionou sem travamentos ou erros.
12. ☐ 1 ☐ 2 ☐ 3 ☐ 4 ☐ 5 – As imagens foram processadas rapidamente no meu dispositivo.
-

Seção 5 – Confiabilidade do Sistema

13. ☐ 1 ☐ 2 ☐ 3 ☐ 4 ☐ 5 – As classificações apresentadas pelo aplicativo parecem corretas.
14. ☐ 1 ☐ 2 ☐ 3 ☐ 4 ☐ 5 – Confio na análise realizada pelo aplicativo para apoiar a tomada de decisão.
15. ☐ 1 ☐ 2 ☐ 3 ☐ 4 ☐ 5 – O aplicativo transmite segurança ao mostrar o resultado da detecção.
-

Seção 6 – Utilidade Percebida

16. ☐ 1 ☐ 2 ☐ 3 ☐ 4 ☐ 5 – O aplicativo pode me ajudar a avaliar melhor a qualidade do morango.
17. ☐ 1 ☐ 2 ☐ 3 ☐ 4 ☐ 5 – A ferramenta tem potencial para melhorar meu processo de compra, venda ou consumo.
18. ☐ 1 ☐ 2 ☐ 3 ☐ 4 ☐ 5 – O uso do aplicativo agrega valor ao meu trabalho ou rotina.
-

Seção 7 – Intenção de Uso Futuro

19. ☐ 1 ☐ 2 ☐ 3 ☐ 4 ☐ 5 – Eu usaria este aplicativo novamente no meu dia a dia.
20. ☐ 1 ☐ 2 ☐ 3 ☐ 4 ☐ 5 – Recomendaria o aplicativo para outras pessoas.
21. ☐ 1 ☐ 2 ☐ 3 ☐ 4 ☐ 5 – Vejo utilidade em utilizar esse aplicativo no futuro.
-

Seção 8 – Comentários Abertos

22. O que você mais gostou no aplicativo?

23. O que poderia ser melhorado?

24. Observações gerais:

ANEXO 1 – Documentação do Registro de Software



1

Pedido de Registro de Programa de Computador - RPC

Número do Processo: 512025006148-0

Dados do Titular

Titular 1 de 2

Nome ou Razão Social: MARCELO TSUGUIDO OKANO

Tipo de Pessoa: Pessoa Física

CPF/CNPJ: 10094147809

Nacionalidade: Brasileira

Qualificação Física: Pesquisador

Endereço: Rua Engenheiro Massinet Sorcinelli, 54

Cidade: Santo André

Estado: SP

CEP: 09760290

País: Brasil

Telefone: (11)41256096

Fax:

Email: okano@vop.com.br

**PETICIONAMENTO
ELETRÔNICO**

Esta solicitação foi enviada pelo sistema Peticionamento Eletrônico em
26/11/2025 às 19:48, Petição 870250108470

Titular 2 de 2

Nome ou Razão Social: LUANA DOS SANTOS CORDEIRO

Tipo de Pessoa: Pessoa Física

CPF/CNPJ: 38353708809

Nacionalidade: Brasileira

Qualificação Física: Mestrando

Endereço: Rua Casa Branca, 266 - Parque América

Cidade: Rio Grande da Serra

Estado: SP

CEP: 09450-000

País: BRASIL

Telefone: (11) 988 891984

Fax:

Email: lsc.luana@hotmail.com

2

Dados do Programa

Data de Publicação: 01/11/2025

Data de Criação: 01/11/2025

- § 2º do art. 2º da Lei 9.609/98: "Fica assegurada a tutela dos direitos relativos a programa de computador pelo prazo de cinquenta anos contados a partir de 1º de janeiro do ano subsequente ao da sua publicação ou, na ausência desta, da sua criação"

Título: BerryScan

Algoritmo hash: SHA-512 - Secure Hash Algorithm

Resumo digital hash: a10fac8757ff0110af59e379b0c503b0aa8fb2147f33ceae43f1e91708
15f27bc456422e83c1d6b196e6705b480f8a4905afc12aaa4e97dc8fc
b6d9a6a74c98

§1º e Incisos VI e VII do §2º do Art. 2º da Instrução Normativa: O titular é o responsável único pela transformação, em resumo digital hash, dos trechos do programa de computador e demais dados considerados suficientes para identificação e caracterização, que serão motivo do registro. O titular terá a inteira responsabilidade pela guarda da informação sigilosa definida no inciso III, § 1º, art. 3º da Lei 9.609 de 19 de fevereiro de 1998.

Linguagem: JAVA SCRIPT

HTML

CSS

PETICIONAMENTO ELETRÔNICO

Esta solicitação foi enviada pelo sistema Petição Eletrônica em
26/11/2025 às 19:48, Petição 870250108470

Petição 870250108470, de 26/11/2025, pág. 2/5

Campo de Aplicação: IN02 -TECNOLOGIA (POLÍTICA TECNOLÓGICA, COOPERAÇÃO
TÉCNICA, PESQUISA TECNOLÓGICA, INOVAÇÃO
TECNOLÓGICA, TECNOLOGIA APROPRIADA, QUÍMICA
TECNOLÓGICA)
IN03- ENGENHARIA (DESENHO TÉCNICO, ENGENHARIA
METALÚRGICA, ENGENHARIA QUÍMICA, MECÂNICA,
AUTOMOTIVA, AERONÁUTICA, NAVAL, DE PRODUÇÃO, DE
TESTE):

Campo de Aplicação: IN02 -TECNOLOGIA (POLÍTICA TECNOLÓGICA, COOPERAÇÃO TÉCNICA, PESQUISA TECNOLÓGICA, INOVAÇÃO TECNOLÓGICA, TECNOLOGIA APROPRIADA, QUÍMICA TECNOLÓGICA)
IN03-ENGENHARIA (DESENHO TÉCNICO, ENGENHARIA METALÚRGICA, ENGENHARIA QUÍMICA, MECÂNICA, AUTOMOTIVA, AERONÁUTICA, NAVAL, DE PRODUÇÃO, DE TESTE);

Tipo de Programa: AP01 - APLICATIVOS

Dados do Autor

Autor 1 de 2

Nome: LUANA DOS SANTOS CORDEIRO

CPF: 38353708809

Nacionalidade: Brasileira

Qualificação Física: Mestrando

Endereço: Rua Casa Branca, 266 - Parque América

Cidade: Rio Grande da Serra

Estado: SP

CEP: 09450-000

País: BRASIL

Telefone: (11) 988 891984

Fax:

Email: lsc.luana@hotmail.com

Autor 2 de 2

Nome: MARCELO TSUGUIO OKANO

CPF: 10094147809

Nacionalidade: Brasileira

Qualificação Física: Pesquisador

Endereço: Rua Engenheiro Massinet Sorcinelli, 54

Cidade: Sao Bernardo do Campo

Estado: SP

CEP: 09760-290

País: BRASIL

Telefone: (11) 991 096575

Fax:

Email: okano@vop.com.br

3

**PETICIONAMENTO
ELETRÔNICO**

Esta solicitação foi enviada pelo sistema Peticionamento Eletrônico em 26/11/2025 às 19:48, Petição 870250108470

Petição 870250108470, de 26/11/2025, pág. 3/5

Declaração de Veracidade - DV

Nome: declaracaoVeracidade_assinado.pdf