



BACHAREL EM CIÊNCIA DA COMPUTAÇÃO

**CLASSIFICAÇÃO DO NÍVEL DE MATURAÇÃO E CONTAGEM DE
TOMATES COM REDES NEURAS CONVOLUCIONAIS USANDO
DADOS DE COLORIMETRIA**

GUILHERME HONÓRIO CAETANO

Rio Verde, GO

2026



INSTITUTO FEDERAL GOIANO - CAMPUS RIO VERDE
BACHAREL EM CIÊNCIA DA COMPUTAÇÃO

**CLASSIFICAÇÃO DO NÍVEL DE MATURAÇÃO E CONTAGEM DE
TOMATES COM REDES NEURAIIS CONVOLUCIONAIS USANDO
DADOS DE COLORIMETRIA**

GUILHERME HONÓRIO CAETANO

Trabalho de Conclusão de Curso apresentado ao Instituto Federal Goiano - Campus Rio Verde, como requisito parcial para a obtenção do Grau de Bacharel em Ciência da Computação.

Orientadora: Prof. Heyde Francielle do Carmo França

Rio Verde, GO

Julho, 2026

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO

PARA DISPONIBILIZAR PRODUÇÕES TÉCNICO-CIENTÍFICAS

NO REPOSITÓRIO INSTITUCIONAL DO IF GOIANO

Com base no disposto na Lei Federal nº 9.610, de 19 de fevereiro de 1998, AUTORIZO o Instituto Federal de Educação, Ciência e Tecnologia Goiano a disponibilizar gratuitamente o documento em formato digital no Repositório Institucional do IF Goiano (RIIF Goiano), sem ressarcimento de direitos autorais, conforme permissão assinada abaixo, para fins de leitura, download e impressão, a título de divulgação da produção técnico-científica no IF Goiano.

IDENTIFICAÇÃO DA PRODUÇÃO TÉCNICO-CIENTÍFICA

- | | |
|--|---|
| <input type="checkbox"/> Tese (doutorado) | <input type="checkbox"/> Artigo científico |
| <input type="checkbox"/> Dissertação (mestrado) | <input type="checkbox"/> Capítulo de livro |
| <input type="checkbox"/> Monografia (especialização) | <input type="checkbox"/> Livro |
| <input checked="" type="checkbox"/> TCC (graduação) | <input type="checkbox"/> Trabalho apresentado em evento |

Produto técnico e educacional - Tipo:

Nome completo do autor:

Guilherme Honório Caetano

Matrícula:

2022102201940254

Título do trabalho:

Classificação do Nível de Maturação e Contagem de Tomates com Redes Neurais Convolucionais Usando Dados de Colorimetria

RESTRICÇÕES DE ACESSO AO DOCUMENTO

Documento confidencial: Não Sim, justifique:

Informe a data que poderá ser disponibilizado no RIIF Goiano: **08 / 07 / 2026**


O documento está sujeito a registro de patente? Sim Não

O documento pode vir a ser publicado como livro? Sim Não

DECLARAÇÃO DE DISTRIBUIÇÃO NÃO-EXCLUSIVA

O(a) referido(a) autor(a) declara:

- Que o documento é seu trabalho original, detém os direitos autorais da produção técnico-científica e não infringe os direitos de qualquer outra pessoa ou entidade;
- Que obteve autorização de quaisquer materiais incluídos no documento do qual não detém os direitos de autoria, para conceder ao Instituto Federal de Educação, Ciência e Tecnologia Goiano os direitos requeridos e que este material cujos direitos autorais são de terceiros, estão claramente identificados e reconhecidos no texto ou conteúdo do documento entregue;
- Que cumpriu quaisquer obrigações exigidas por contrato ou acordo, caso o documento entregue seja baseado em trabalho financiado ou apoiado por outra instituição que não o Instituto Federal de Educação, Ciência e Tecnologia Goiano.

Documento assinado digitalmente
 **GUILHERME HONORIO CAETANO**
Data: 07/07/2026 16:51:22-0300
Verifique em <https://validar.iti.gov.br>

Rio Verde - GO
Local

07 / 07 / 2026
Data

Assinatura do autor e/ou detentor dos direitos autorais
Documento assinado digitalmente

Ciente e de acordo:

 **HEYDE FRANCIELLE DO CARMO FRANCA**
Data: 07/07/2026 18:38:24-0300
Verifique em <https://validar.iti.gov.br>

Assin:



SERVIÇO PÚBLICO FEDERAL
MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA GOIANO

Ata nº 16/2026 - GEPTNM-RV/DE-RV/CMPRV/IFGOIANO

ATA DE DEFESA DE TRABALHO DE CURSO

Ao(s) 22 dia(s) do mês de junho de 2026, às 14 horas, reuniu-se a banca examinadora composta pelos docentes: Heyde Francielle do Carmo (orientadora), Fábيا Barbosa da Silva(membro), Adriano Ferraz da Costa(membro), para examinar o Trabalho de Curso intitulado “Classificação do Nível de Maturação e Contagem de Tomates com Redes Neurais Convolucionais Usando Dados de Colorimetria” do(a) estudante Guilherme Honório Caetano, Matrícula nº 2022102201940254, do Curso de Bacharelado em Ciência da Computação do IF Goiano – Campus Rio Verde. A palavra foi concedida ao(a) estudante para a apresentação oral do TC, houve arguição do(a) candidato pelos membros da banca examinadora. Após tal etapa, a banca examinadora decidiu pela APROVAÇÃO do estudante. Ao final da sessão pública de defesa foi lavrada a presente ata que segue assinada pelos membros da Banca Examinadora.

(Assinado Eletronicamente)

Heyde Francielle do Carmo

Orientador(a)

(Assinado Eletronicamente)

Fábيا Barbosa da Silva

Membro

(Assinado Eletronicamente)

Adriano Ferraz da Costa

Membro

Observação:

() O(a) estudante não compareceu à defesa do TC.

Documento assinado eletronicamente por:

- **Heyde Francielle do Carmo Franca**, **PROFESSOR ENS BASICO TECN TECNOLOGICO**, em 22/06/2026 15:39:27.
- **Fabia Barbosa da Silva**, **2020202341360019 - Discente**, em 30/06/2026 14:37:05.
- **Adriano Ferraz da Costa**, **PROF ENS BAS TEC TECNOLOGICO - VISITANTE**, em 02/07/2026 22:07:06.

Este documento foi emitido pelo SUAP em 22/06/2026. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifgoiano.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código Verificador: 833687

Código de Autenticação: e6bd022ab3



INSTITUTO FEDERAL GOIANO
Campus Rio Verde
Rodovia Sul Goiana, Km 01, Zona Rural, 01, Zona Rural, RIO VERDE / GO, CEP 75901-970
(64) 3624-1000

**Ficha de identificação da obra elaborada pelo autor, através do
Programa de Geração Automática do Sistema Integrado de Bibliotecas do IF Goiano - SIBi**

C128 Caetano, Guilherme Honório
Classificação do Nível de Maturação e Contagem de Tomates
com Redes Neurais Convolucionais Usando Dados de
Colorimetria / Guilherme Honório Caetano. Rio Verde 2026.

33f. il.

Orientadora: Profª. Dra. Heyde Francielle do Carmo França.
Tcc (Bacharel) - Instituto Federal Goiano, curso de 0219201 -
Bacharelado em Ciência da Computação - Integral - Rio Verde
(Campus Rio Verde).

I. Título.

Dedico este trabalho à minha família, que sempre esteve ao meu lado, oferecendo amor, apoio e incentivo em todos os momentos da minha trajetória acadêmica. Em especial, aos meus pais, aos meus avós, à minha irmã e à minha namorada, que compartilharam comigo cada desafio e cada conquista, acreditando no meu potencial mesmo quando o caminho parecia difícil. O carinho, a compreensão e a confiança de vocês foram fundamentais para que eu nunca desistisse e pudesse chegar até aqui. Esta conquista também é de vocês. Dedico, ainda, este trabalho a todos que, de alguma forma, contribuíram para a realização deste sonho.

AGRADECIMENTOS

Agradeço, primeiramente, a Deus, por me conceder saúde, força, sabedoria e perseverança para enfrentar os desafios ao longo desta jornada. Nos momentos de incerteza, foi por meio da fé que encontrei coragem para seguir em frente e concluir mais esta importante etapa da minha vida.

À minha família, em especial aos meus pais, aos meus avós e à minha irmã, deixo minha mais profunda gratidão pelo amor, pelos ensinamentos e por sempre acreditarem no meu potencial. Vocês foram meu alicerce em todos os momentos e estiveram ao meu lado em cada conquista e dificuldade. Nada disso teria sido possível sem o apoio e o incentivo que sempre recebi de vocês.

À minha namorada, agradeço por caminhar ao meu lado durante toda essa trajetória. Obrigado pelo amor, pelo companheirismo, pela paciência, pelo incentivo e pela compreensão nos momentos em que a dedicação aos estudos exigiu tempo, renúncias e esforço. Sua presença tornou essa caminhada mais leve, fortaleceu minha confiança e me deu forças para seguir em frente, mesmo diante das dificuldades.

À minha orientadora, meu sincero agradecimento pela confiança, pela paciência e por todos os ensinamentos compartilhados ao longo desta caminhada. Obrigado por cada orientação, por cada conversa e por sempre estar disposta a ajudar nos momentos em que surgiam dúvidas e desafios. Sua dedicação e comprometimento foram fundamentais para a realização deste trabalho e marcaram de forma muito positiva a minha formação. Sou grato pela oportunidade de aprender com você durante essa trajetória.

Aos professores do Instituto Federal Goiano, agradeço por todo o conhecimento compartilhado durante a graduação e pelo compromisso com a formação de seus alunos. Cada aula, orientação e experiência contribuíram para ampliar minha visão, fortalecer minha formação e me preparar para os desafios da vida profissional.

Ao Instituto Federal Goiano, agradeço por proporcionar um ambiente de aprendizado, pesquisa e crescimento. A oportunidade de estudar em uma instituição pública de excelência, aliada à infraestrutura e ao incentivo à produção científica, foi essencial para o desenvolvimento deste trabalho e para minha formação.

Aos meus amigos e colegas, obrigado pela amizade, pela convivência, pelas conversas, pela troca de experiências e pelos momentos compartilhados ao longo desses anos. Cada um, à sua maneira, tornou essa caminhada mais leve, enriquecedora e inesquecível.

Por fim, agradeço a todos que, de alguma forma, fizeram parte desta trajetória. Cada palavra de incentivo, gesto de confiança e demonstração de apoio contribuíram para que este sonho se tornasse realidade.

A todos, o meu mais sincero muito obrigado.

RESUMO

CAETANO, G. H.. **Classificação do Nível de Maturação e Contagem de Tomates com Redes Neurais Convolucionais Usando Dados de Colorimetria**. Julho, 2026. 19 f. Monografia – (Curso de Bacharel em Ciência da Computação), Instituto Federal Goiano - Campus Rio Verde. Rio Verde, GO.

A classificação do estágio de maturação dos tomates é uma tarefa relevante para aplicações em agricultura de precisão, tradicionalmente realizada de forma manual e subjetiva. Este trabalho apresenta uma abordagem que integra medições colorimétricas no espaço de cor CIELAB e modelos da família YOLO para a detecção, contagem e classificação automática de tomates nas classes *green*, *intermediary* e *red*. Foi construído um conjunto de dados contendo 1.040 imagens e 8.748 frutos anotados, cujas classes foram definidas a partir de medições realizadas em 150 amostras e agrupadas por meio do algoritmo K-means. Foram avaliados os modelos YOLOv10, YOLO11, YOLO12 e YOLO26, nas variantes *Small* e *Medium*, todos com precisão superior a 95%, *recall* acima de 94% e mAP@0.5 de até 97,5%. O modelo YOLO26m apresentou o melhor desempenho geral. Os modelos treinados foram integrados a uma aplicação web desenvolvida em Streamlit para processamento de imagens e vídeos. Os resultados demonstram o potencial da integração entre colorimetria e aprendizado profundo para o monitoramento automatizado da maturação dos tomates.

Palavras-chave: Tomates. Classificação de imagens. Visão Computacional. Redes Neurais. YOLO. Espaço de Cor CIELAB. Colorimetria. Streamlit. Agricultura de precisão.

ABSTRACT

CAETANO, G. H.. **Tomato Maturity Level Classification and Counting Using Convolutional Neural Networks with Colorimetry Data**. Julho, 2026. 19 f. Trabalho de Conclusão de Curso – Bacharel em Ciência da Computação, Instituto Federal Goiano - Campus Rio Verde. Rio Verde, GO,

Tomato maturity classification is an important task in precision agriculture and is traditionally performed manually and subjectively. This work presents an approach that combines colorimetric measurements in the CIELAB color space with YOLO models for automatic tomato detection, counting, and classification into *green*, *intermediary*, and *red* classes. A dataset containing 1,040 images and 8,748 annotated fruits was built, with maturity classes defined from measurements obtained from 150 samples and grouped using the K-means algorithm. YOLOv10, YOLO11, YOLO12, and YOLO26 models, in both *Small* and *Medium* variants, were evaluated, achieving precision values above 95%, recall above 94%, and mAP@0.5 up to 97.5%. YOLO26m achieved the best overall performance. The trained models were integrated into a web application developed using Streamlit for image and video processing. The results highlight the potential of combining colorimetry and deep learning techniques for automated tomato maturity monitoring.

Keywords: Tomatoes. Image Classification. Computer Vision. Neural Networks. YOLO. CIELAB Color Space. Colorimetry. Streamlit. Precision Agriculture.

LISTA DE FIGURAS

Figura 1 – Exemplo de imagem utilizada na complementação do conjunto de dados e sua respectiva segmentação inicial realizada no Roboflow com a classe <i>tomato</i>	4
Figura 2 – Exemplos das técnicas de <i>data augmentation</i> aplicadas às imagens do conjunto de treinamento.	5
Figura 3 – Exemplo de imagem anotada com as classes de maturação dos frutos (<i>green</i> , <i>intermediary</i> e <i>red</i>) após a classificação automática e validação manual.	7
Figura 4 – Distribuição das instâncias por classe de maturação no conjunto de dados.	7
Figura 5 – Comportamento das métricas de desempenho e das funções de perda do modelo YOLO26m durante o treinamento.	12
Figura 6 – Matriz de confusão do modelo YOLO26m para as classes de maturação dos tomates.	12
Figura 7 – Interface da aplicação web durante o processamento de uma imagem, destacando as detecções e o relatório das classes de maturação.	13
Figura 8 – <i>Frame</i> de vídeo processado com detecção, rastreamento e contagem dos frutos.	14

LISTA DE TABELAS

Tabela 1 – Valores dos centróides no espaço de cor CIELAB para as classes de maturação <i>green</i> , <i>intermediary</i> e <i>red</i>	6
Tabela 2 – Parâmetros utilizados no treinamento dos modelos YOLO.	8
Tabela 3 – Desempenho dos modelos YOLOv10, YOLO11, YOLO12 e YOLO26 nas variantes <i>Small</i> e <i>Medium</i>	10
Tabela 4 – Custo computacional e tempo de treinamento dos modelos YOLOv10, YOLO11, YOLO12 e YOLO26 nas variantes <i>Small</i> e <i>Medium</i>	11
Tabela 5 – Comparação entre os resultados obtidos neste trabalho e os trabalhos relacionados.	14

LISTA DE ABREVIATURAS E SIGLAS

AP	Average Precision
CIE	Commission Internationale de l'Éclairage
CIELAB	Commission Internationale de l'Éclairage L*a*b*
CNN	Convolutional Neural Network
COCO	Common Objects in Context
FAO	Food and Agriculture Organization
FAOSTAT	Food and Agriculture Organization Corporate Statistical Database
FANN	Feedforward Artificial Neural Network
FLOPs	Floating Point Operations
GFLOPs	Giga Floating Point Operations
GIMP	GNU Image Manipulation Program
GNB	Gaussian Naïve Bayes
GPU	Graphics Processing Unit
HLS	Hue, Lightness and Saturation
HSV	Hue, Saturation and Value
IoU	Intersection over Union
JSON	JavaScript Object Notation
LDA	Linear Discriminant Analysis
mAP	Mean Average Precision
RAM	Random Access Memory
RGB	Red, Green and Blue
SVM	Support Vector Machine
TP	True Positive
FP	False Positive
FN	False Negative
USDA	United States Department of Agriculture
YOLO	You Only Look Once

SUMÁRIO

1	–	INTRODUÇÃO	1
2	–	TRABALHOS RELACIONADOS	2
2.1		Classificação da maturação de tomates com YOLO	2
2.2		Classificação baseada em características colorimétricas	2
2.3		Diferenças da proposta	3
3	–	MATERIAIS E MÉTODOS	4
3.1		Construção do conjunto de dados	4
3.2		Definição e agrupamento das classes de maturação	5
3.3		Rotulagem automática dos frutos	6
3.4		Treinamento dos modelos YOLO	8
3.5		Métricas de avaliação	8
3.6		Desenvolvimento da aplicação web	9
4	–	RESULTADOS E DISCUSSÕES	10
4.1		Desempenho dos modelos YOLO	10
4.2		Avaliação da aplicação web	13
4.3		Comparação com trabalhos relacionados	14
5	–	CONCLUSÃO	16
5.1		Trabalhos futuros	16
		REFERÊNCIAS	18

1 INTRODUÇÃO

O tomate é uma cultura agrícola de grande importância, com alta produção e consumo (PÉK; HELYES; LUGASI, 2010). Além disso, é um produto hortícola amplamente reconhecido por sua coloração vermelha intensa e alto valor nutricional, sendo uma fonte rica de antioxidantes (HORVÁTH-MEZŐFI et al., 2024). De acordo com dados da Organização das Nações Unidas para Agricultura e Alimentação (FAO), disponíveis na base estatística FAOSTAT, a produção mundial anual de tomates atingiu aproximadamente 188,5 milhões de toneladas. No Brasil, a produção foi de aproximadamente 4,4 milhões de toneladas, representando uma parcela significativa da produção global (FAO, 2024).

A classificação manual dos tomates para colheita e comercialização é um processo demorado e dependente da percepção humana, tornando-se suscetível a erros e inconsistências (LI et al., 2023). A avaliação visual da cor é influenciada por fatores como brilho e condições de iluminação (CAMELO; GÓMEZ, 2004). Nesse contexto, colorímetros são amplamente utilizados para medir a cor dos frutos no espaço de cor CIELAB por meio dos parâmetros L^* , a^* e b^* (ÖZTEKIN; VURSAVUŞ; KESILMIŞ, 2021). Entretanto, esses dispositivos exigem contato direto com a amostra, possuem área de medição reduzida e apresentam custo elevado, fatores que dificultam sua aplicação em larga escala (GOÑI; SALVADORI, 2017).

Diante dessas limitações, este trabalho propõe uma abordagem que integra a precisão das medições colorimétricas com a abrangência proporcionada pela visão computacional. Enquanto os colorímetros fornecem medidas confiáveis do espaço de cor, os sistemas de visão computacional ampliam a cobertura da análise sem necessidade de contato direto com o fruto (GOÑI; SALVADORI, 2017). Nesse contexto, técnicas baseadas em aprendizado profundo, como as redes neurais convolucionais (CNNs), apresentam grande potencial para automatizar a classificação da maturação (LI et al., 2023). A combinação dessas abordagens pode aumentar a confiabilidade na avaliação da qualidade dos frutos, reduzindo as limitações inerentes a cada método quando utilizado isoladamente (ÖZTEKIN; VURSAVUŞ; KESILMIŞ, 2021).

Este trabalho tem como objetivo desenvolver e avaliar um sistema baseado em modelos da família YOLO (*You Only Look Once*), treinados a partir de anotações definidas com auxílio de medições colorimétricas no espaço de cor CIELAB, para realizar a detecção, classificação e contagem automática de tomates em diferentes estágios de maturação. Ademais, são comparadas diferentes versões da família YOLO e desenvolvida uma aplicação interativa em Python utilizando a biblioteca Streamlit, permitindo o processamento de imagens e vídeos e ampliando as possibilidades de aplicação da solução em cenários relacionados à agricultura de precisão.

2 TRABALHOS RELACIONADOS

2.1 Classificação da maturação de tomates com YOLO

Diversos estudos têm investigado o uso de modelos YOLO para classificação automática da maturação de tomates. Araujo (2025) comparou as versões YOLOv8, YOLOv9, YOLOv10 e YOLO11 em um conjunto de dados contendo 159 imagens e 1.063 instâncias de tomates cereja distribuídas em três estágios de maturação (*green*, *intermediary* e *red*). As classes foram definidas a partir da análise manual do componente de matiz do espaço HSV utilizando o software GIMP. A autora também observou ganhos no desempenho ao utilizar anotações por segmentação em relação às caixas delimitadoras, sendo a YOLO11 o modelo de melhor desempenho, com precisão de 85%, revocação (*recall*) de 83% e mAP@0.5 de 85%.

De forma semelhante, Yang e Ju (2024) avaliaram os modelos YOLOv5, YOLOv8 e YOLOv9, além de uma variante da YOLOv8 com *backbone* ResNet50, para classificação de tomates cereja em dois estágios de maturação (*ripe* e *unripe*). Os experimentos foram conduzidos em um conjunto contendo 742 imagens após aumento de dados. A melhor configuração foi obtida pela YOLOv8l-ResNet50, que alcançou precisão de 70,7%, *recall* de 77,5% e mAP de 75,7%, destacando o potencial de arquiteturas híbridas em cenários com oclusões e variações de iluminação.

Apesar dos resultados obtidos, ambos os trabalhos dependem de critérios visuais para definição das classes e utilizam conjuntos de dados relativamente reduzidos, fatores que podem limitar a escalabilidade do processo e introduzir subjetividade na rotulagem. Como perspectivas futuras, os autores destacam a ampliação dos conjuntos de dados, a avaliação em condições mais próximas de cenários reais e o emprego de estratégias capazes de melhorar a detecção em situações de oclusão e sobreposição de frutos.

2.2 Classificação baseada em características colorimétricas

Abordagens baseadas em características colorimétricas também têm sido adotadas para classificação automática da maturação de frutos. Karki et al. (2024) avaliaram os algoritmos Gaussian Naïve Bayes (GNB), *Support Vector Machine* (SVM) e Redes Neurais Artificiais (*Feedforward Artificial Neural Network* – FANN), utilizando atributos extraídos dos espaços de cor RGB, HLS, CIELAB e YCbCr. Os experimentos foram conduzidos em um conjunto contendo 400 morangos distribuídos em quatro estágios de maturação (*unripe*, *semi-ripe*, *ripe* e *overripe*), sendo obtida acurácia de 96,7% com a FANN utilizando o espaço de cor CIELAB.

De maneira análoga, Nuraini et al. (2023) combinaram atributos dos espaços CIELAB e HSV com o algoritmo *Linear Discriminant Analysis* (LDA) para classificar

tomates em seis estágios de maturação (*Mature Green, Breaker, Turning, Pink, Light Red* e *Red Ripe*). Utilizando um conjunto de dados contendo 720 imagens, os autores obtiveram acurácia de 88,2%.

Embora apresentem resultados promissores, essas abordagens dependem de etapas de segmentação e extração manual de características, além de serem geralmente desenvolvidas em condições controladas de aquisição das imagens. Como perspectivas futuras, os autores destacam o uso de técnicas de *Deep Learning* para automatizar a extração de características e aumentar a robustez dos modelos diante de maior variabilidade visual e condições mais próximas de cenários reais de cultivo.

2.3 Diferenças da proposta

Com base nas limitações observadas na literatura, este trabalho propõe uma abordagem que integra medições colorimétricas no espaço de cor CIELAB e modelos da família YOLO para detecção, classificação e contagem de tomates em diferentes estágios de maturação. Diferentemente dos estudos analisados, a definição das classes é orientada por medições obtidas por meio de um colorímetro digital, reduzindo a subjetividade associada às avaliações visuais. Adicionalmente, diferentes versões da YOLO são avaliadas utilizando anotações por segmentação dos frutos em três classes de maturação (*green, intermediary* e *red*), e os modelos treinados são integrados a uma aplicação baseada em Streamlit para processamento de imagens e vídeos.

3 MATERIAIS E MÉTODOS

3.1 Construção do conjunto de dados

O conjunto de dados foi construído a partir da base disponibilizada por Araujo (2025), composta por 159 imagens contendo 1.063 frutos rotulados em três classes de maturação (*green*, *intermediary* e *red*). Para ampliar a diversidade visual da base, foram adicionadas 352 novas imagens capturadas com um smartphone Samsung Galaxy S24 em diferentes condições de iluminação e ambientes de cultivo.

Após a aquisição, as imagens foram analisadas individualmente, sendo removidas amostras repetidas ou com baixa qualidade. Ao final da etapa de filtragem, o conjunto passou a contar com 400 imagens. As anotações foram realizadas na plataforma Roboflow utilizando polígonos de segmentação, inicialmente com uma única classe genérica denominada *tomato*. As anotações provenientes da base original também foram revisadas e corrigidas quando necessário, visando manter a padronização do conjunto de dados. A Figura 1 exibe um exemplo de imagem presente no conjunto de dados e sua respectiva segmentação inicial.



(a) Imagem original.

(b) Segmentação inicial.

Figura 1 – Exemplo de imagem utilizada na complementação do conjunto de dados e sua respectiva segmentação inicial realizada no Roboflow com a classe *tomato*.

Fonte: Autoria própria.

As imagens foram redimensionadas para 640×640 pixels e divididas em 80%, 10% e 10% para os conjuntos de treinamento, validação e teste, respectivamente. Em seguida, técnicas de aumento de dados (*data augmentation*) foram aplicadas exclusivamente ao conjunto de treinamento, incluindo rotações, recortes com zoom e variações de brilho e saturação, com o objetivo de ampliar a variabilidade visual das amostras e favorecer a

capacidade de generalização dos modelos. Após essa etapa, o conjunto de dados totalizou 1.040 imagens e 8.748 frutos anotados. Exemplos das transformações aplicadas são mostrados na Figura 2.

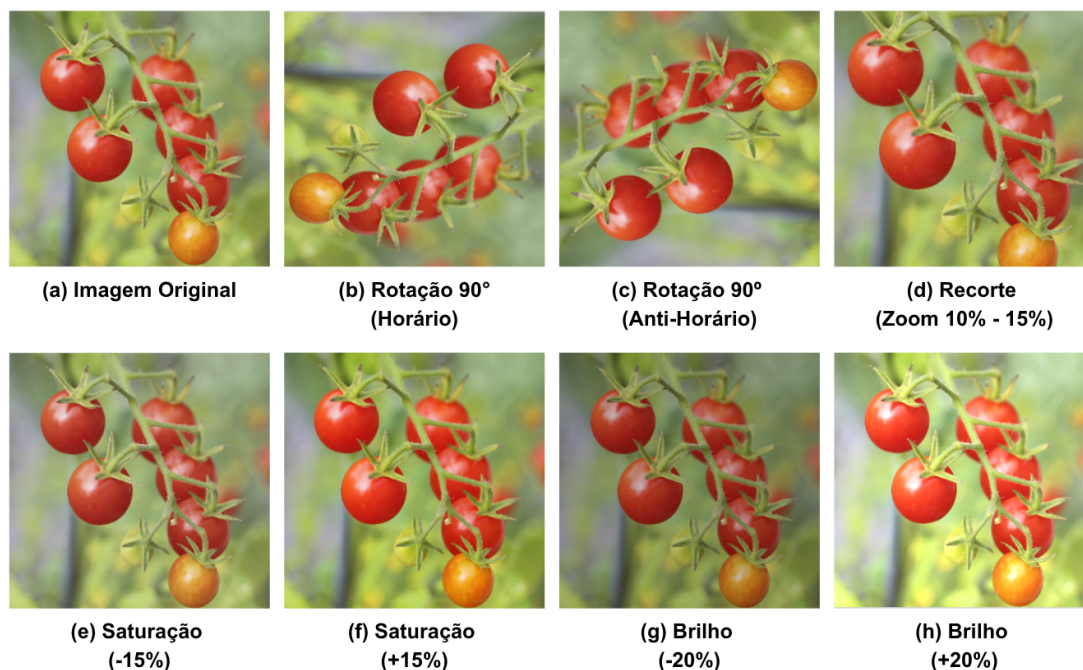


Figura 2 – Exemplos das técnicas de *data augmentation* aplicadas às imagens do conjunto de treinamento.

Fonte: Autoria própria.

3.2 Definição e agrupamento das classes de maturação

A definição das classes de maturação foi baseada nos seis estágios propostos pelo USDA (*green, breaker, turning, pink, light red e red*) (USDA, 1991). Para caracterizar cada estágio, foram realizadas medições em 150 tomates no espaço de cor CIELAB utilizando um colorímetro digital Konica Minolta CR-400, previamente calibrado conforme as recomendações do fabricante, sendo selecionados 25 frutos por estágio.

Os valores dos componentes L^* , a^* e b^* obtidos para as 150 amostras foram padronizados e submetidos ao algoritmo de agrupamento não supervisionado *K-means* com $k = 3$, visando agrupar os seis estágios originais em três classes de maturação.

Após a convergência do algoritmo, os clusters foram ordenados pelos valores do eixo a^* , associado à transição entre verde e vermelho (CIE, 1976), e vinculados às classes *green, intermediary e red*. Os valores dos centróides obtidos estão listados na Tabela 1 e serviram como referência para a classificação automática dos frutos.

Tabela 1 – Valores dos centróides no espaço de cor CIELAB para as classes de maturação *green*, *intermediary* e *red*.

Classe	L^*	a^*	b^*
Green	54.91	-1.48	21.10
Intermediary	48.91	9.50	28.85
Red	39.92	20.74	21.28

Fonte: Autoria própria.

3.3 Rotulagem automática dos frutos

Após a determinação dos centróides no espaço de cor CIELAB, foi desenvolvido um script em Python (3.12.3) para reclassificar automaticamente as anotações originalmente associadas à classe genérica *tomato* em três classes de maturação (*green*, *intermediary* e *red*). Para isso, o conjunto de dados foi exportado da plataforma Roboflow no formato COCO (*Common Objects in Context*), contendo as coordenadas dos polígonos de segmentação e os identificadores dos frutos em arquivos JSON.

Os valores dos pixels das imagens, originalmente representados em *uint8*, foram convertidos para *float32*, normalizados para o intervalo $[0,1]$ e convertidos para o espaço de cor CIELAB, conforme recomendado pela documentação do OpenCV (OpenCV, 2024). Esse procedimento permitiu padronizar os valores extraídos das imagens com aqueles obtidos pelo colorímetro.

Os polígonos de segmentação foram utilizados para gerar máscaras dos frutos, às quais foi aplicada uma erosão morfológica para reduzir a influência de regiões externas. Os valores médios dos componentes L^* , a^* e b^* foram calculados e comparados aos centróides das classes por meio da distância euclidiana ponderada, dada por:

$$d = \sqrt{w_L(L - L_c)^2 + w_a(a - a_c)^2 + w_b(b - b_c)^2} \quad (1)$$

em que L , a e b representam os valores médios do fruto analisado, L_c , a_c e b_c os componentes do centróide da classe considerada, e w_L , w_a e w_b os pesos associados a cada componente. Foram adotados $w_L = 0,5$, $w_a = 3,0$ e $w_b = 2,0$, atribuindo maior importância ao eixo a^* devido à sua maior sensibilidade às variações de maturação. As classes resultantes foram então atualizadas diretamente nos arquivos JSON.

Concluída a classificação automática, o conjunto de dados foi carregado novamente na plataforma Roboflow, onde as anotações foram revisadas manualmente para corrigir inconsistências decorrentes de oclusões e interferências do ambiente. A Figura 3 apresenta uma amostra do conjunto de dados final.



Figura 3 – Exemplo de imagem anotada com as classes de maturação dos frutos (*green*, *intermediary* e *red*) após a classificação automática e validação manual.

Fonte: Autoria própria.

Ao final da revisão manual, observou-se um desbalanceamento entre as classes de maturação, refletindo a distribuição natural dos frutos nos diferentes estágios durante a coleta das imagens. A classe *green* representou 46,1% das instâncias, enquanto as classes *red* e *intermediary* corresponderam a 32,3% e 21,6%, respectivamente. Apesar dessa diferença, as três classes apresentaram quantidade suficiente de amostras para o treinamento dos modelos. A Figura 4 mostra a distribuição das classes.

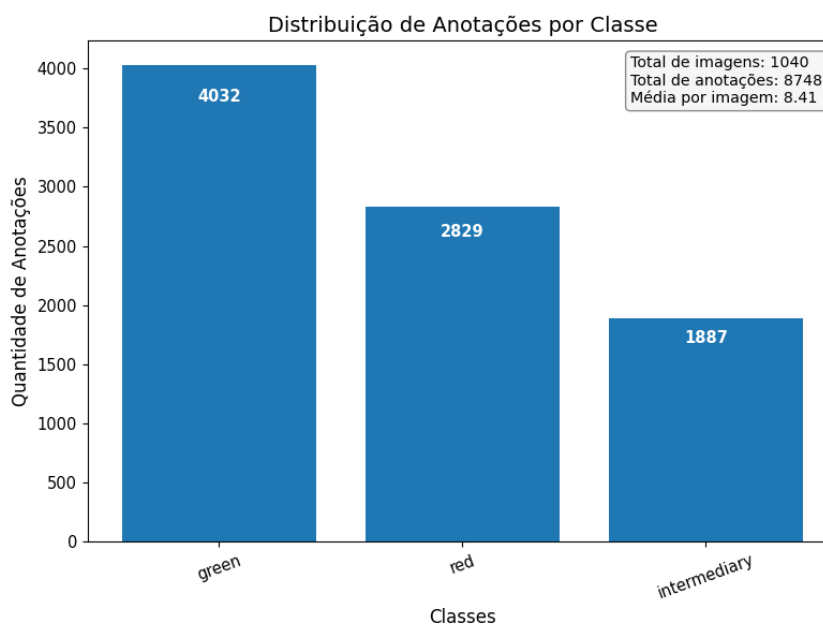


Figura 4 – Distribuição das instâncias por classe de maturação no conjunto de dados.

Fonte: Autoria própria.

3.4 Treinamento dos modelos YOLO

As imagens e anotações foram exportadas da plataforma Roboflow no formato YOLO26 para o treinamento dos modelos YOLOv10, YOLO11, YOLO12 e YOLO26, nas variantes *Small* (s) e *Medium* (m). O treinamento foi realizado em ambiente Python (3.12.3), utilizando como base o código disponibilizado no repositório oficial da Ultralytics¹, em um computador com Ubuntu 24.04.3 LTS, processador AMD Ryzen 9 7900X3D, 32 GB de memória RAM DDR5 (5600 MHz) e GPU NVIDIA GeForce RTX 4080 SUPER de 16 GB. Os principais parâmetros adotados estão apresentados na Tabela 2.

Tabela 2 – Parâmetros utilizados no treinamento dos modelos YOLO.

Parâmetro	Valor
epochs	500
batch	16
imgsz	640
patience	500
plots	True

Fonte: Autoria própria.

3.5 Métricas de avaliação

O desempenho dos modelos foi avaliado por meio das métricas precisão (*precision*), revocação (*recall*), F1-Score e *mean Average Precision* (mAP), considerando os indicadores mAP@0.5 e mAP@0.5:0.95. A precisão representa a proporção de detecções corretas, enquanto a revocação mede a capacidade do modelo em identificar corretamente os objetos presentes nas imagens (PADILLA; NETTO; SILVA, 2020), sendo definidas pelas Equações 2 e 3.

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

em que TP , FP e FN representam, respectivamente, os números de verdadeiros positivos, falsos positivos e falsos negativos.

O F1-Score, definido pela Equação 4, foi utilizado para avaliar o equilíbrio entre precisão e revocação (SUJON et al., 2025).

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (4)$$

Além dessas métricas, foram utilizados os indicadores mAP@0.5 e mAP@0.5:0.95, amplamente empregados em tarefas de detecção de objetos (PADILLA; NETTO; SILVA,

¹ <<https://github.com/ultralytics/ultralytics>>

2020). O cálculo dessas métricas baseia-se na *Average Precision* (AP), correspondente à área sob a curva precisão \times revocação para cada classe, dada pela Equação 5.

$$AP = \sum_n (R_n - R_{n-1})P_n \quad (5)$$

A *mean Average Precision* (mAP) é obtida pela média dos valores de AP entre as classes avaliadas, conforme a Equação 6.

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (6)$$

em que N representa o número de classes. Neste trabalho, o mAP@0.5 considera um limiar de *Intersection over Union* (IoU) igual a 0,5, enquanto o mAP@0.5:0.95 corresponde à média dos resultados obtidos para limiares de IoU entre 0,5 e 0,95, com incrementos de 0,05 (PADILLA; NETTO; SILVA, 2020).

3.6 Desenvolvimento da aplicação web

Com o objetivo de facilitar a utilização dos modelos treinados, foi desenvolvida uma aplicação web em Python (3.12.3), utilizando a biblioteca **Streamlit** (1.54.0). A plataforma permite o processamento de imagens e vídeos para detecção, classificação e contagem dos tomates em diferentes estágios de maturação. Para vídeos, foi utilizado o método `model.track()` da biblioteca **Ultralytics** (8.4.23), empregando a configuração padrão baseada no algoritmo BoT-SORT (ULTRALYTICS, 2026). Os modelos são carregados a partir dos arquivos `best.pt`, correspondentes aos melhores pesos obtidos ao final do treinamento de cada rede neural. O limite máximo para envio de arquivos de mídia foi configurado em 5 GB, permitindo o processamento de vídeos de maior duração.

4 RESULTADOS E DISCUSSÕES

4.1 Desempenho dos modelos YOLO

Os resultados obtidos ao final do treinamento dos modelos YOLO são apresentados na Tabela 3, considerando as métricas de precisão, revocação (*recall*), F1-Score, mAP@0.5 e mAP@0.5:0.95.

Tabela 3 – Desempenho dos modelos YOLOv10, YOLO11, YOLO12 e YOLO26 nas variantes *Small* e *Medium*.

Modelo	Precisão	Recall	F1-Score	mAP@0.5	mAP@0.5:0.95
YOLOv10s	0.967	0.944	0.955	0.971	0.935
YOLO11s	0.960	0.941	0.950	0.973	0.934
YOLO12s	0.953	0.949	0.951	0.972	0.935
YOLO26s	0.961	0.942	0.951	0.973	0.939
YOLOv10m	0.973	0.944	0.958	0.975	0.940
YOLO11m	0.954	0.950	0.952	0.974	0.936
YOLO12m	0.957	0.951	0.954	0.975	0.939
YOLO26m	0.957	0.952	0.954	0.975	0.945

Fonte: Autoria própria.

De modo geral, todos os modelos apresentaram desempenho elevado na detecção e classificação dos frutos, com precisão superior a 95%, revocação acima de 94%, F1-Score superior a 95%, mAP@0.5 acima de 97% e mAP@0.5:0.95 superior a 93%. As diferenças entre as versões foram pequenas, indicando que todas foram capazes de aprender os padrões visuais associados às três classes de maturação.

Entre os modelos da série *Small*, o YOLOv10s apresentou os maiores valores de precisão (96,7%) e F1-Score (95,5%), enquanto o YOLO12s alcançou a maior revocação (94,9%). O melhor desempenho em mAP@0.5:0.95 foi obtido pelo YOLO26s, com 93,9%. Na série *Medium*, o YOLOv10m apresentou a maior precisão (97,3%) e o maior F1-Score (95,8%), enquanto o YOLO26m obteve a maior revocação (95,2%) e o maior mAP@0.5:0.95 (94,5%).

A Tabela 4 reúne a quantidade de parâmetros, o número de operações em ponto flutuante (GFLOPs) e o tempo necessário para o treinamento de cada modelo.

Os modelos da série *Medium* apresentaram maior custo computacional em relação à série *Small*, com aumento expressivo no número de parâmetros, GFLOPs e tempo de treinamento. Entretanto, os ganhos observados nas métricas de desempenho foram relativamente pequenos. Como exemplo, o YOLO26s apresentou mAP@0.5:0.95 de 93,9%, enquanto o YOLO26m atingiu 94,5%, correspondendo a um ganho inferior a 1%, acompanhado por um aumento de 9,95 para 21,78 milhões de parâmetros.

Tabela 4 – Custo computacional e tempo de treinamento dos modelos YOLOv10, YOLO11, YOLO12 e YOLO26 nas variantes *Small* e *Medium*.

Modelo	Parâmetros (M)	FLOPs (G)	Tempo
YOLOv10s	8.06	24.8	0h 43min
YOLO11s	9.43	21.6	0h 35min
YOLO12s	9.25	21.5	0h 55min
YOLO26s	9.95	22.5	0h 46min
YOLOv10m	16.49	64.0	1h 14min
YOLO11m	20.05	68.2	1h 12min
YOLO12m	20.14	67.7	1h 41min
YOLO26m	21.78	74.7	1h 25min

Fonte: Autoria própria.

Em aplicações com restrições de processamento ou requisitos de inferência em tempo real, o custo computacional pode ser um fator determinante na escolha do modelo. Nesse contexto, o YOLO11s mostra-se uma alternativa interessante por combinar baixo custo computacional e desempenho competitivo, alcançando precisão de 96,0%, revocação de 94,1% e mAP@0.5 de 97,3%, além de demandar o menor tempo de treinamento entre os modelos avaliados. Entretanto, como a aplicação desenvolvida neste trabalho é destinada ao processamento de imagens e vídeos enviados pelo usuário, sem exigência de resposta em tempo real, a qualidade da detecção e da localização dos frutos foi priorizada. Dessa forma, o YOLO26m foi adotado como modelo de referência por apresentar os melhores resultados em revocação (95,2%) e mAP@0.5:0.95 (94,5%). Ainda assim, todas as versões avaliadas foram integradas à aplicação desenvolvida, permitindo que diferentes modelos sejam selecionados de acordo com os requisitos de desempenho e custo computacional de cada cenário de utilização.

Após a definição do YOLO26m como modelo de referência, foi realizada uma análise mais detalhada do comportamento do treinamento. A evolução das perdas e das principais métricas ao longo das 500 épocas é ilustrada na Figura 5. As perdas de treinamento e validação apresentaram comportamento decrescente, enquanto as métricas de precisão, *recall*, mAP@0.5 e mAP@0.5:0.95 cresceram rapidamente nas primeiras épocas e posteriormente se estabilizaram. A proximidade entre as curvas de treinamento e validação sugere ausência de sobreajuste (*overfitting*) significativo e boa capacidade de generalização.

Embora essas métricas permitam avaliar o desempenho global do modelo, elas não indicam quais classes apresentam maior dificuldade de separação. Por esse motivo, foi analisada a matriz de confusão do YOLO26m, exibida na Figura 6. Observa-se maior concentração dos valores na diagonal principal, indicando elevadas taxas de acerto para as três classes de maturação. Os principais erros ocorreram entre as classes *intermediary* e *red*, comportamento esperado devido à transição gradual entre esses estágios. O leve desbalanceamento do conjunto de dados e a menor representatividade dessas classes em relação à classe *green* também contribuíram para reduzir a diversidade de exemplos disponíveis

durante o treinamento. Ainda assim, os resultados confirmam a elevada capacidade do modelo em discriminar os diferentes níveis de maturação dos frutos.

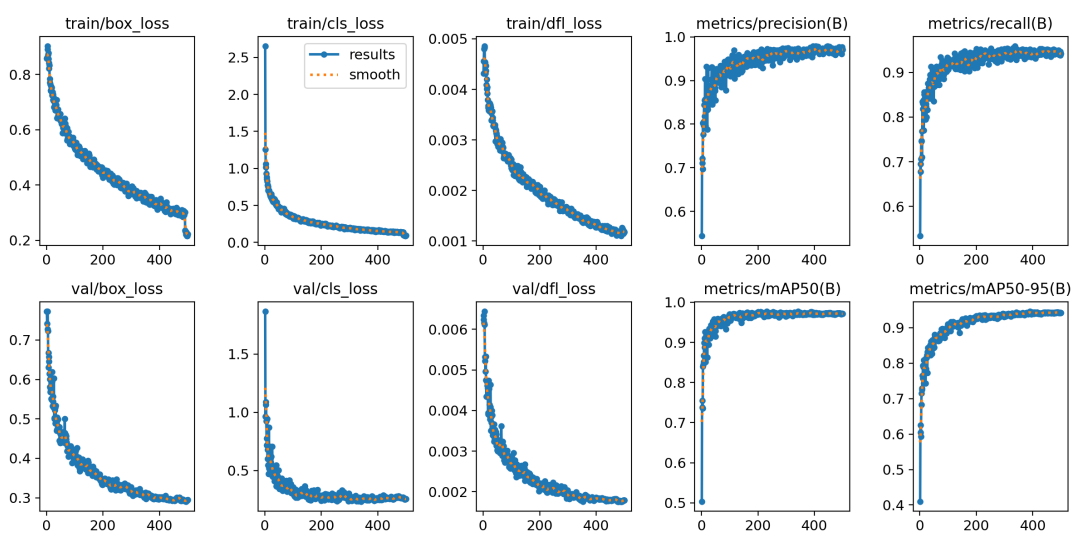


Figura 5 – Comportamento das métricas de desempenho e das funções de perda do modelo YOLO26m durante o treinamento.

Fonte: Autoria própria.



Figura 6 – Matriz de confusão do modelo YOLO26m para as classes de maturação dos tomates.

Fonte: Autoria própria.

4.2 Avaliação da aplicação web

Para complementar a análise dos modelos treinados, a aplicação web desenvolvida foi avaliada por meio do processamento de imagens e vídeos contendo tomates em diferentes estágios de maturação. A Figura 7 mostra um exemplo de inferência em imagem.

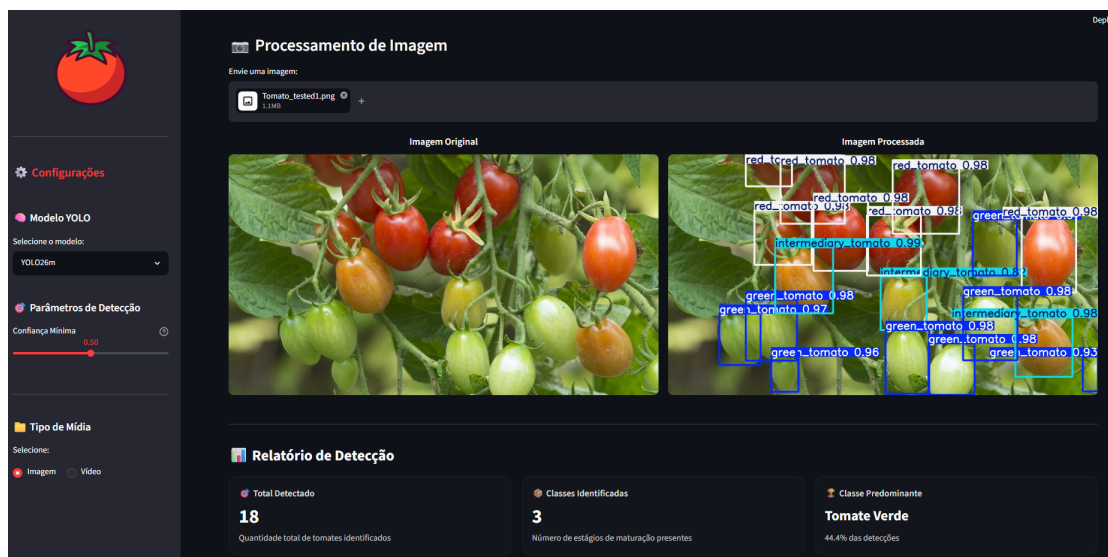


Figura 7 – Interface da aplicação web durante o processamento de uma imagem, destacando as detecções e o relatório das classes de maturação.

Fonte: Autoria própria.

O modelo foi capaz de detectar e classificar corretamente frutos pertencentes às classes *green*, *intermediary* e *red*, inclusive em situações com diferentes tamanhos, orientações e níveis moderados de sobreposição. Além das detecções, a aplicação fornece informações sobre a distribuição dos frutos entre as classes e a classe predominante na imagem analisada.

A aplicação também foi avaliada em vídeos, incorporando os recursos de rastreamento e contagem automática dos frutos. A Figura 8 ilustra um quadro (*frame*) extraído de um vídeo processado pelo sistema, permitindo observar as detecções e o rastreamento dos frutos durante a execução.

Durante os testes, o mecanismo de rastreamento apresentou comportamento estável, permitindo a contagem dos frutos por meio do cruzamento de uma linha de referência configurável, ajustada conforme a orientação e o posicionamento do vídeo.

Embora os resultados tenham sido promissores, algumas limitações foram identificadas. As principais dificuldades ocorreram em situações de oclusão severa, elevada sobreposição entre frutos e interferências causadas por folhas, ramos e hastes do tomateiro, que reduzem a quantidade de informação visual disponível. Por sua vez, a transição gradual entre os estágios *intermediary* e *red* pode dificultar a distinção entre frutos próximos ao limite entre essas classes, resultando em erros pontuais de classificação. Apesar dessas limitações, o sistema apresentou desempenho consistente em diferentes cenários de teste,

indicando potencial para aplicações em condições reais de monitoramento da maturação dos tomates.




Figura 8 – *Frame* de vídeo processado com detecção, rastreamento e contagem dos frutos.

Fonte: Autoria própria.

4.3 Comparação com trabalhos relacionados

Para estabelecer uma comparação com a literatura, foram considerados trabalhos que empregam redes neurais convolucionais da família YOLO para classificação da maturação de tomates e que reportam métricas compatíveis com as utilizadas neste estudo. Dessa forma, foram considerados os trabalhos de Araujo (2025) e Yang e Ju (2024), permitindo uma comparação mais direta entre os resultados. Os demais trabalhos relacionados, embora utilizem o espaço de cor CIELAB em suas abordagens, não foram considerados nesta comparação por empregarem métodos tradicionais de aprendizado de máquina e métricas de avaliação distintas, o que dificulta uma comparação direta com modelos de detecção baseados em redes neurais convolucionais. A Tabela 5 permite comparar os resultados obtidos neste trabalho com aqueles reportados na literatura.

Tabela 5 – Comparação entre os resultados obtidos neste trabalho e os trabalhos relacionados.

Trabalho	Classes	Precisão	Recall	mAP@0.5
Araujo (2025)	3	85,1%	82,8%	85,4%
Yang e Ju (2024)	2	70,7%	77,5%	75,7%
Presente trabalho	3	95,7%	95,2%	97,5%

Fonte: Autoria própria.

Embora as comparações devam ser interpretadas com cautela devido às diferenças entre conjuntos de dados e estratégias de rotulagem, os resultados obtidos demonstram o potencial da abordagem proposta. A combinação entre informações colorimétricas no espaço de cor CIELAB, anotações por segmentação e um conjunto de dados mais diversificado contribuiu para alcançar elevados valores nas métricas em geral.

5 CONCLUSÃO

Este trabalho apresentou o desenvolvimento e a avaliação de uma solução para detecção, contagem e classificação de tomates em diferentes estágios de maturação, integrando técnicas de visão computacional, colorimetria e modelos da família YOLO. A utilização de referências colorimétricas obtidas por meio de um colorímetro contribuiu para tornar o processo de rotulagem mais consistente e menos dependente de avaliações visuais subjetivas.

A avaliação de diferentes versões da família YOLO mostrou que todos os modelos apresentaram desempenho elevado, com precisão superior a 95%, *recall* acima de 94% e mAP@0.5 superior a 97%. Embora modelos mais complexos tenham proporcionado pequenos ganhos em algumas métricas, os resultados indicaram que o aumento da complexidade nem sempre resulta em melhorias proporcionais no desempenho. Entre os modelos avaliados, o YOLO26m apresentou os melhores resultados em mAP@0.5:0.95 e elevada estabilidade durante o treinamento, sendo adotado como modelo de referência.

A aplicação web desenvolvida permitiu integrar as etapas de detecção, classificação e contagem automática dos frutos em uma interface acessível, possibilitando o processamento de imagens e vídeos e ampliando as possibilidades de utilização da solução em diferentes cenários. Os testes realizados demonstraram comportamento robusto, embora limitações relacionadas a oclusões, sobreposição entre frutos e variações de iluminação ainda representem desafios para o sistema.

De maneira geral, os resultados obtidos demonstram que a abordagem proposta foi capaz de realizar, de forma automatizada e confiável, a detecção, a contagem e a classificação de tomates em diferentes estágios de maturação. Além disso, a combinação entre referências colorimétricas no espaço de cor CIELAB e modelos de detecção baseados em aprendizado profundo mostrou-se uma alternativa promissora para aplicações em agricultura de precisão, contribuindo para o monitoramento e a análise do processo de amadurecimento dos frutos.

5.1 Trabalhos futuros

Como perspectiva para trabalhos futuros, destaca-se a ampliação do conjunto de dados, incorporando maior variabilidade de cenários e condições de iluminação e, principalmente, novas amostras das classes *intermediary* e *red*. O aumento da representatividade dessas classes pode favorecer um melhor balanceamento do conjunto de dados e uma distinção mais precisa entre estágios de maturação com características cromáticas semelhantes. Da mesma forma, a inclusão de imagens com oclusões severas e elevada sobreposição entre frutos pode contribuir para que os modelos aprendam padrões frequentemente encontrados

em condições reais de cultivo.

Outra possibilidade consiste em avaliar diferentes variantes da família YOLO, incluindo modelos mais leves, arquiteturas mais complexas e o uso de *backbones* alternativos ou híbridos, conforme explorado por Yang e Ju (2024), com o objetivo de aumentar a robustez do sistema em cenários mais desafiadores.

Em relação à aplicação desenvolvida, futuras melhorias incluem o processamento em lote, o envio simultâneo de múltiplas imagens e vídeos e a adoção de soluções em nuvem para ampliar a escalabilidade do sistema. Além disso, a otimização do processamento de vídeos pode reduzir o tempo de inferência e até viabilizar aplicações em tempo real, ampliando o potencial de utilização do sistema em ambientes de produção.

Referências

- ARAUJO, A. B. M. Classificação automática de estágios de maturação do tomate usando redes neurais convolucionais yolo. Instituto Federal Goiano, 2025. Citado 3 vezes nas páginas 2, 4 e 14.
- CAMELO, A. F. L.; GÓMEZ, P. A. Comparison of color indexes for tomato ripening. *Horticultura Brasileira*, SciELO Brasil, v. 22, p. 534–537, 2004. Citado na página 1.
- CIE. *Colorimetry: Official Recommendations of the International Commission on Illumination*. Vienna: CIE, 1976. Citado na página 5.
- FAO. *FAOSTAT: Crops and Livestock Products*. 2024. Acesso em: 10 fev. 2026. Disponível em: <<https://www.fao.org/faostat/en/#data/QCL>>. Citado na página 1.
- GOÑI, S. M.; SALVADORI, V. O. Color measurement: comparison of colorimeter vs. computer vision system. *Journal of Food Measurement and Characterization*, Springer, v. 11, p. 538–547, 2017. Citado na página 1.
- HORVÁTH-MEZŐFI, Z. et al. Evaluation of color and pigment changes in tomato after 1-methylcyclopropene (1-mcp) treatment. *Sensors*, MDPI, v. 24, n. 8, p. 2426, 2024. Citado na página 1.
- KARKI, S. et al. Classification of strawberry ripeness stages using machine learning algorithms and colour spaces. *Horticulture, Environment, and Biotechnology*, Springer, v. 65, n. 2, p. 337–354, 2024. Citado na página 2.
- LI, P. et al. Tomato maturity detection and counting model based on mhsa-yolov8. *Sensors*, MDPI, v. 23, n. 15, p. 6701, 2023. Citado na página 1.
- NURAINI, R. et al. Tomato ripeness detection using linear discriminant analysis algorithm with cielab and hsv color spaces. *Building of Informatics, Technology and Science (BITS)*, v. 5, n. 2, p. 523531, Sep. 2023. Disponível em: <<https://ejurnal.seminar-id.com/index.php/bits/article/view/4192>>. Citado na página 2.
- OpenCV. *Color Conversions*. 2024. Disponível em: <https://docs.opencv.org/4.x/de/d25/imgproc_color_conversions.html>. Citado na página 6.
- ÖZTEKIN, Y. B.; VURSAVUŞ, K. K.; KESILMIŞ, Z. Firmness classification of tomato fruits by using colour parameters. *Anadolu Tarım Bilimleri Dergisi*, Ondokuz Mayıs University, v. 36, n. 3, p. 511–519, 2021. Citado na página 1.
- PADILLA, R.; NETTO, S. L.; SILVA, E. A. D. A survey on performance metrics for object-detection algorithms. In: IEEE. *2020 international conference on systems, signals and image processing (IWSSIP)*. [S.l.], 2020. p. 237–242. Citado 2 vezes nas páginas 8 e 9.
- PÉK, Z.; HELYES, L.; LUGASI, A. Color changes and antioxidant content of vine and postharvest-ripened tomato fruits. *HortScience*, American Society for Horticultural Science, v. 45, n. 3, p. 466–468, 2010. Citado na página 1.

SUJON, K. M. et al. Accuracy, precision, recall, f1-score, or mcc? empirical evidence from advanced statistics, ml, and xai for evaluating business predictive models. *Journal of Big Data*, Springer, v. 12, n. 1, p. 268, 2025. Citado na página 8.

ULTRALYTICS. *Multi-Object Tracking with Ultralytics YOLO*. 2026. Acesso em: 25 mar. 2026. Disponível em: <<https://docs.ultralytics.com/modes/track/>>. Citado na página 9.

USDA. *United States Standards for Grades of Fresh Tomatoes*. Washington, D.C., 1991. Disponível em: <https://www.ams.usda.gov/sites/default/files/media/Tomato_Standard%5B1%5D.pdf>. Citado na página 5.

YANG, D.; JU, C. Performance comparison of cherry tomato ripeness detection using multiple yolo models. *AgriEngineering*, MDPI, v. 7, n. 1, p. 8, 2024. Citado 3 vezes nas páginas 2, 14 e 17.