MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA GOIANO
CAMPUS MORRINHOS
PROGRAMA DE PÓS-GRADUAÇÃO EM OLERICULTURA

JOÃO CARLOS SOARES DE SOUZA

VISÃO COMPUTACIONAL E INTELIGÊNCIA ARTIFICIAL PARA MEDIÇÃO DO MESOCARPO DE TOMATES

MORRINHOS – GO
2026

MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA GOIANO
CAMPUS MORRINHOS
PROGRAMA DE PÓS-GRADUAÇÃO EM OLERICULTURA

JOÃO CARLOS SOARES DE SOUZA

VISÃO COMPUTACIONAL E INTELIGÊNCIA ARTIFICIAL PARA MEDIÇÃO DO MESOCARPO DE TOMATES

Dissertação apresentada ao Programa de Pós-Graduação em Olericultura do Instituto Federal de Educação, Ciência e Tecnologia Goiano – Campus Morrinhos, como parte das exigências para a obtenção do título de Mestre em Olericultura.

Orientador: Prof. Dr. Alexandre Carvalho Silva

MORRINHOS – GO
2026

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

Souza, João Carlos Soares de
S729t Visão Computacional Inteligência Artificial para Medição de Mesocarpo de Tomates / João Carlos Soares de Souza. Morrinhos 2026.

57f. il.

Orientador: Prof. Dr. Alexandre Carvalho Silva.
Tese (Mestre) - Instituto Federal Goiano, curso de 0433044 - [MO.POS] Mestrado Profissional em Olericultura - Morrinhos (Campus Morrinhos).
1. Visão computacional. 2. Inteligência artificial. 3. Automação agrícola. 4. Fenotipagem. 5. Internet das coisas (IOT). I. Título.

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

- ☐ Tese (doutorado)
- ☒ Dissertação (mestrado)
- ☐ Monografia (especialização)
- ☐ TCC (graduação)
- ☐ Artigo científico
- ☐ Capítulo de livro
- ☐ Livro
- ☐ Trabalho apresentado em evento
- ☐ Produto técnico e educacional - Tipo:

Nome completo do autor: João Carlos Soares de Souza

Matrícula: 2024104330440005

Título do trabalho: VISÃO COMPUTACIONAL E INTELIGÊNCIA ARTIFICIAL PARA MEDIÇÃO DO MESOCARPO DE TOMATES

RESTRIÇÕES DE ACESSO AO DOCUMENTO

Documento confidencial: ☒ Não ☐ Sim, justifique:

Informe a data que poderá ser disponibilizado no RIIF Goiano: 25 / 05 / 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 inclusos 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.

Morrinhos, Goiás (Local) — 25 / 05 / 2026 (Data)

gov.br Documento assinado digitalmente
JOAO CARLOS SOARES DE SOUZA
Data: 25/05/2026 09:05:05-0300
Verifique em https://validar.iti.gov.br

_____
Assinatura do autor e/ou detentor dos direitos autorais

Ciente e de acordo:

_____
Assinatura do(a) orientador(a)

gov.br Documento assinado digitalmente
ALEXANDRE CARVALHO SILVA
Data: 25/05/2026 09:53:06-0300
Verifique em https://validar.iti.gov.br

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

Ata nº 24/2026 - CCEG-MO/CEG-MO/DE-MO/CMPMHOS/IFGOIANO

PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO

ATA Nº 139

BANCA EXAMINADORA DE DEFESA DE DISSERTAÇÃO

Ao um dia do mês de abril do ano de dois mil e vinte e seis, às 14:00 hs (quatorze horas), reuniram-se os componentes da banca examinadora em sessão pública realizada por videoconferência (https://meet.google.com/vjv-vmjg-kdm) para procederem a avaliação da defesa de Dissertação, em nível de mestrado, intitulada " ***Visão computacional e inteligência artificial para medição de mesocarpo de tomates***" de autoria de **João Carlos soares de Souza** discente do Programa de Pós-Graduação em Olericultura do Instituto Federal Goiano - Campus Morrinhos. A sessão foi aberta pelo presidente da Banca Examinadora, Prof. Dr. Alexandre Carvalho Silva, que fez a apresentação formal dos membros da Banca. A palavra, a seguir, foi concedida ao autor para, em 30 min., proceder à apresentação de seu trabalho. Terminada a apresentação, cada membro da banca fez suas arguições, adotando-se o sistema de diálogo sequencial. Terminada a fase de arguição, procedeu-se a avaliação da defesa. Tendo-se em vista as normas que regulamentam o Programa de Pós-Graduação em Olericultura, e procedidas às correções recomendadas, a Dissertação foi APROVADA, considerando-se integralmente cumprido este requisito para fins de obtenção do título de **MESTRE EM OLERICULTURA,** na linha de pesquisa em Sistemas de produção em olerícolas, pelo Instituto Federal Goiano - Campus Morrinhos. A conclusão do curso dar-se-á quando da entrega na Secretaria do PPGOL da versão definitiva da Dissertação, com as devidas correções. Assim sendo, a defesa perderá a validade se não cumprida essa condição, em até **60 (sessenta) dias** da sua ocorrência. A Banca Examinadora recomendou a publicação de artigo científico oriundo dessa Dissertação em periódico após procedida as modificações sugeridas. Cumpridas as formalidades da pauta, a presidência da mesa encerrou esta sessão de defesa de Dissertação de Mestrado, e para constar, foi lavrada a presente Ata, que, após lida e achada conforme, será assinada eletronicamente pelos membros da Banca Examinadora.

Membros da Banca Examinadora

Nome	Instituição	Situação no Programa
Prof. Dr. Alexandre Carvalho Silva	Instituto Federal Goiano Campus - Morrinhos	Presidente
Profa. Dra. Clarice Aparecida Megguer	Instituto Federal Goiano Campus - Morrinhos	Membro interno
Prof. Dr. Elliezer de Almeida Melo	Instituto Federal Goiano Campus - Morrinhos	Membro externo

Documento assinado eletronicamente por:

- **Alexandre Carvalho Silva**, **PROFESSOR ENS BASICO TECN TECNOLOGICO** , em 14/04/2026 09:33:04.
- **Elliezer de Almeida Melo**, **PROFESSOR ENS BASICO TECN TECNOLOGICO** , em 14/04/2026 09:42:42.
- **Clarice Aparecida Megguer**, **PROFESSOR ENS BASICO TECN TECNOLOGICO** , em 14/04/2026 11:05:52.

Este documento foi emitido pelo SUAP em 14/04/2026. 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: 810388
Código de Autenticação: 91e28b996b

INSTITUTO FEDERAL GOIANO
Campus Morrinhos
Rodovia BR-153, Km 633, Zona Rural, SN, Zona Rural, MORRINHOS / GO, CEP 75650-000
(64) 3413-7900

AGRADECIMENTOS

Em primeiro lugar, agradeço a Deus por me dar força e resiliência nos momentos mais difíceis, nas incontáveis horas sem dormir, nas madrugadas em que o cansaço dominava o meu corpo, mas minha alma queria seguir em frente a todo custo.

Ao Instituto Federal Goiano (IF Goiano) – Campus Morrinhos, pela oportunidade de qualificação, pela infraestrutura oferecida e pelo fomento à pesquisa que foram fundamentais para a realização deste trabalho.

Ao meu orientador Professor Alexandre Carvalho Silva, pela paciência, pelas valorosas orientações e pela confiança depositada em meu potencial. Seu direcionamento assertivo e sua expertise foram o alicerce para que esta pesquisa alcançasse os resultados de excelência que almejávamos.

À coordenação do curso de Olericultura e aos professores, por manterem o alto padrão de qualidade do nosso programa.

Expresso aqui minha mais profunda e sincera gratidão às coordenadoras pedagógicas do Colégio Zênite, Ozanete Maria Silva e Cristiane de Cássia Silva. Muito obrigado pela imensa compreensão, pela empatia e por me liberarem das minhas atividades laborais para que eu pudesse estar presente nas aulas. Sem o apoio, a parceria e a sensibilidade de vocês no ambiente de trabalho, a conclusão deste mestrado simplesmente não teria sido possível.

Por fim, de maneira muito especial, à minha esposa Núbia Consuelo Carvalho. Obrigado pelo amor incondicional, pelo companheirismo diário e por suportar com tanta paciência e incentivo as minhas ausências durante todo o tempo dedicado a este projeto. Esta vitória não é apenas minha, ela é nossa.

BIOGRAFIA DO AUTOR

João Carlos Soares de Souza é tecnólogo em Análise e Desenvolvimento de Sistemas pela Universidade Norte do Paraná – UNOPAR (2016). Possui pós-graduação *Lato Sensu* em Engenharia Robótica pela Universidade Unyleya (2023) e MBA em Gestão Industrial e Manutenção de Ativos pela Faculdade Ítalo Bologna – SENAI (2019). Iniciou sua trajetória acadêmica em Sistemas de Informação pelo ILES/Ulbra.

Com uma sólida carreira de 30 anos na área de tecnologia e 15 anos dedicados à robótica educacional, atua desde 2016 como Analista de Suporte no Colégio Zênite em Itumbiara - GO. Paralelamente, exerce a função de professor de robótica no projeto START do Governo de Goiás. É entusiasta da eletrônica e do estudo de novas tecnologias, dedicando-se à construção de robôs e à prática de atividades físicas, como corrida e escalada.

Ingressou no Programa de Pós-Graduação em Olericultura (PPGOL) do Instituto Federal Goiano – Campus Morrinhos em 2024, onde desenvolve pesquisa na área de Visão Computacional e Inteligência Artificial aplicada à medição do mesocarpo de tomates, sob orientação do Prof. Dr. Alexandre Carvalho Silva.

RESUMO

Os avanços em visão computacional e inteligência artificial têm impulsionado a inovação na agricultura, especialmente na inspeção automatizada de produtos. No contexto do Agro 4.0, sistemas padronizados são cruciais para otimizar processos e garantir análises objetivas frente aos métodos convencionais. Este estudo investiga a aplicação de Visão Computacional e Inteligência Artificial na medição da espessura do mesocarpo de tomates (*Solanum lycopersicum* L.), um parâmetro essencial para a padronização industrial e comercial. Para tanto, desenvolveu-se um sistema integrado de hardware e software de baixo custo, baseado na captura e processamento digital de imagens. A validação estatística comparou métodos automatizados com as medições físicas de referência. Os resultados demonstraram que o modelo de Inteligência Artificial (IA) superou a técnica convencional de Visão Computacional (VC), atingindo uma acurácia de 90,76% (contra 86,88% da VC) e um Erro Médio Absoluto (MAE) de 0,608mm. O Sistema obteve um tempo de inferência otimizado aproximadamente de 6 segundos por amostra. Conclui-se que a ferramenta de automação apresenta viabilidade técnica e alta confiabilidade, oferecendo perspectivas promissoras para a classificação em tempo real, seleção de novas variedades e o aprimoramento de avaliação fenotípica de frutos na olericultura e na indústria.

Palavra-chave: Visão computacional. Inteligência artificial. Automação agrícola. Fenotipagem.

ABSTRACT

Advances in computer vision and artificial intelligence have driven innovation in agriculture, particularly in automated product inspection. In the context of Agro 4.0, standardized systems are crucial for optimizing processes and ensuring objective analyses compared to conventional methods. This study investigates the application of Computer Vision and Artificial Intelligence in measuring the mesocarp thickness of tomatoes (Solanum lycopersicum L.), an essential parameter for industrial and commercial standardization. To this end, a low-cost integrated hardware and software system was developed, based on digital image capture and processing. Statistical validation compared automated methods with physical reference measurements. The results demonstrated that the Artificial Intelligence (AI) model outperformed the conventional Computer Vision (CV) technique, achieving an accuracy of 90.76% (compared to 86.88% for CV) and a Mean Absolute Error (MAE) of 0.608 mm. The system achieved an optimized inference time of approximately 6 seconds per sample. It is concluded that the automation tool demonstrates technical feasibility and high reliability, offering promising prospects for real-time classification, selection of new varieties, and the improvement of phenotypic evaluation of fruits in vegetable farming and industry.

Keywords: Computer vision. Artificial intelligence. Agricultural automation. Phenotyping.

LISTA DE FIGURAS

Figura 1A - Guia de variedades de tomates comercializadas na CEAGESP 33
Figura 2A - Mapa de distribuição da produção de tomates frescos na União Europeia 34
Figura 3A - Participação prevista no mercado econômico de tomates até 2030 34
Figura 4A - Estatísticas de produção de tomate nas safras de 2025/2026 35
Figura 1B - Sistema de hardware experimental em configuração de câmara escura para aquisição de imagens 36
Figura 2B - Procedimento metodológico duplo-cego de validação 37
Figura 3B - Visão geral do sistema de medição automatizada da espessura do mesocarpo 39
Figura 4B - Esquema elétrico do projeto de captura e análise de imagem..... 40
Figura 1C - Posicionamento do fruto com dois septos em relação ao plano de corte à câmera 42
Figura 2C - Posicionamento do fruto com dois ou mais septos em relação ao plano de corte à câmera 43
Figura 1D - Interface gráfica principal do sistema de medição automatizada 44
Figura 2D - Interface de conexão e resposta do módulo ESP32-CAM durante a conexão WIFI para captura de imagens 45
Figura 3D - Fluxograma do pipeline para a medição automatizada do mesocarpo de tomates 46
Figura 4D - Fluxograma de arquitetura lógica e pipeline de processamento de rede neural convolucional 47
Figura 5D - Reconstrução tridimensional da morfologia do fruto evidenciando a densidade da malha (182.410) de pontos ativos 47
Figura 6D - Reconstrução tridimensional após a aplicação de filtro com parâmetro de corte de 4,60mm de espessura 48
Figura 1E - Boxplot comparativo das médias de medição entre os métodos Manual, Visão Computacional (VC) e Inteligência Artificial (IA) 49
Figura 2E - Diagrama de caixa (boxplot) da variabilidade interna das medições manuais por amostra 50
Figura 3E – Gráfico de Bland-Altman para análise de concordância entre as medições manuais e por IA 53
Figura 4E - Gráfico de Bland-Altman para análise de concordância entre as medições manuais e por VC 55
Figura 5E - Gráfico de Bland-Altman para análise de concordância entre os métodos automatizados Visão Computacional (VC) versus Inteligência Artificial (IA) 57

LISTAS DE QUADROS

Quadro 1B - Componentes eletrônicos utilizados na construção do hardware 38

LISTA DE TABELAS

Tabela 1E - Principais indicadores estatísticos de desempenho e erro entre os métodos de medição..... 51

ÍNDICE

1 INTRODUÇÃO 12

2 REVISÃO BIBLIOGRÁFICA 13

2.1 Visão computacional para medição do mesocarpo de tomates 13

2.2 Classificação botânica e propriedades nutricionais 13

2.3 Explorando as similaridades da produção de tomate no mundo 14

2.4 Cultivo de tomate no Brasil e perfil do maior produtor 15

2.5 Ferramentas de visão computacional para avaliação de imagens 15

2.6 Aplicações de inteligência artificial para medições precisas em tomates 16

3 OBJETIVOS GERAIS E ESPECÍFICOS 17

3.1 Objetivo geral 17

3.2 Objetivos específicos 17

4 MATERIAIS E MÉTODOS 18

4.1 Descrição do local e período da pesquisa 18

4.2 Recursos instrumentais e infraestrutura tecnológica 18

4.3 Material biológico e protocolos de amostragem 19

4.4 Blindagem experimental e rigor metrológico 19

4.5 Processamento digital, inteligência artificial e calibração 19

4.6 Análise estatística e conformidade ética 20

5 CONSIDERAÇÕES E PONTOS RELEVANTES 21

5.1 Avaliação da qualidade do tomate: desafios e perspectivas 21

5.2 O desafio contra a imprecisão 21

6 CONCLUSÃO 24

REFERÊNCIAS 25

APÊNDICE 32

APÊNDICE A - CONTEXTO PRODUTIVO, VARIABILIDADE MORFOLÓGICA E MAPA DE DISTRIBUIÇÃO DO TOMATE PELO BRASIL E O MUNDO 33

APÊNDICE B - SISTEMA DE HARDWARE EXPERIMENTAL 36

APÊNDICE C - PROCEDIMENTOS METODOLÓGICOS DE AQUISIÇÃO E POSIÇÃO DAS AMOSTRAS 42

APÊNDICE D - FLUXO OPERACIONAL DO SISTEMA E INTERFACE DE CAPTURA E SUAS SUB-JANELAS 44

APÊNDICE E - ANÁLISE GRÁFICA DE RESÍDUOS E DISPERSÃO ESTATÍSTICA 49

1 INTRODUÇÃO

Os avanços recentes em tecnologias de visão computacional e algoritmos inteligentes têm transformado a agricultura de precisão. Esses sistemas possibilitam não apenas a automação dos processos de inspeção, pois favorecem a geração de imagens com alta fidelidade e reprodutibilidade (Wang et al., 2025).

A produção agrícola de alta precisão aliada à análise de imagens reflete com exatidão características reais de produtos agrícolas por meio de integração de atributos visuais, como cores, texturas e formas. A utilização de redes neurais convolucionais integradas a transformadores de imagens hiperespectrais permite prever com precisão atributos internos e externos de tomates. Essas tecnologias confirmam o potencial da visão computacional para medições automatizadas com parâmetros de qualidade. (Qi et al., 2024).

Estratégias de aprendizado de máquina voltadas à avaliação da qualidade de frutos sob restrições metodológicas e computacionais típicas de países em desenvolvimento, impulsionam avanços da visão computacional. Nesse contexto, pesquisadores comparam o treinamento de uma rede neural convolucional (CNN) desenvolvida do zero ao ajuste fino do modelo pré-treinado MobileNetV2 utilizando o aprendizado por transferência (Knott et al., 2023).

A integração de sensores inteligentes, Internet das Coisas (*IoT*) e análise de *Big Data* na agricultura de precisão torna viável o monitoramento de variáveis como umidade do solo, pH e estresse das plantas (Soussi et al., 2023).

Esse conjunto de evidências descreve condições concretas para a adoção de tecnologias emergentes na agricultura, sobretudo na avaliação automatizada da qualidade dos frutos como o tomate. Propõe-se nesta pesquisa um conjunto de técnicas baseada em visão computacional e modelos de aprendizado de máquina para medir a espessura do mesocarpo de tomates (*Solanum lycopersicum* L.), ainda pouco difundida na literatura para ser precisa, reprodutível e de baixo custo na classificação automatizada dos frutos.

A metodologia será validada por meio da comparação de métodos manuais tradicionais, visando a aplicação prática em ambientes agrícolas e laboratoriais. Tal abordagem permite aferir a confiabilidade do sistema proposto para o suporte à tomada de decisão na olericultura moderna. A implementação de sistemas automatizados torna-se, portanto, uma estratégia essencial diante da relevância econômica, da constante expansão da cultura e dos desafios no cenário nacional (Landau et al., 2024).

2 REVISÃO BIBLIOGRÁFICA

2.1 Visão computacional para medição do mesocarpo de tomates

A visão computacional desempenha um papel fundamental na classificação morfológica do tomate, permitindo avaliar com precisão a forma e a estrutura interna dos frutos. Esse conjunto de técnicas automatizadas possibilita a realização de inferências indiretas sobre a espessura do mesocarpo, o que contribui significativamente para a padronização da qualidade e para a valorização comercial da produção (Chen et al., 2023). Processos de monitoramento contínuo da espessura baseados em sistemas de visão computacional utilizam validações em comparação com medições manuais e integram modelos de aprendizado de máquina para avaliar parâmetros internos das amostras analisadas (Liu et al., 2023; Hageraats, 2025).

Tais abordagens reforçam a relevância do uso de algoritmos avançados como aliados na agricultura de precisão e na avaliação automatizada da qualidade. A integração dessas ferramentas otimiza o monitoramento fenotípico e garante diagnósticos mais objetivos sobre a estrutura interna dos frutos, sendo elementos fundamentais para a eficiência tecnológica na cadeia da olericultura (Liu et al., 2023).

2.2 Classificação botânica e propriedades nutricionais

O tomateiro é uma planta de origem andina que apresenta grande variabilidade de gêneros e ampla adaptabilidade em diferentes regiões climáticas (Landau et al., 2022). O tomate (*Solanum lycopersicum* L.), pertencente à família *Solanaceae*, destaca-se mundialmente por sua relevância econômica e nutricional (Fozia et al., 2024). Embora a origem seja atribuída à América do Sul, com consumo registrado pelos astecas na Mesoamérica por volta de 700 d.C., o fruto ganhou protagonismo na culinária mediterrânea apenas no início do século XIX (FAO, 2022). A disseminação inicial até a América Central é atribuída aos povos maias, que introduziram a cultura aos astecas (Embrapa, 2022).

O fruto é valorizado por seu elevado teor de vitaminas, minerais e compostos bioativos com ação antioxidante, como a vitamina C, o licopeno e a luteína, concentra macro e microelementos essenciais, como potássio, cálcio, magnésio e fósforo, o que o torna uma matéria-prima promissora para alimentos funcionais voltados à promoção da

saúde cardiovascular (Zharkova et al., 2024). A variabilidade morfológica é expressiva, com frutos em colorações amarela, rosa, laranja ou verde, apresentando epiderme lisa, polpa suculenta e sementes distribuídas no mesocarpo, conforme ilustrado pelas variedades apresentadas na Figura 1A do Apêndice A (Ceagesp, 2021).

Atributos como forma e cor influenciam diretamente a aceitação do consumidor e indicam o estágio de maturação (Vazquez et al., 2024). Parâmetros físico-químicos e sensoriais são essenciais para a classificação final da qualidade, sendo a análise de componentes principais (PCA) uma ferramenta eficaz para identificar diferenças significativas entre os frutos (Zhang et al., 2023). Dentre os índices qualitativos, destacam-se o teor de sólidos solúveis, a presença de açúcares (frutose e glicose) e ácidos orgânicos como cítrico e málico, que equilibram o sabor. A firmeza, o frescor e o aroma são determinados pela dureza, teor de umidade e compostos voláteis, fatores que impactam a exposição do produto no mercado e atendem às exigências crescentes dos consumidores dos frutos com “atributos superiores” (Cammarelle et al., 2023).

2.3 Explorando as similaridades da produção de tomate no mundo

A introdução do tomate na Europa ocorreu no século XV durante a "Troca Colombiana", juntamente com o cacau e a batata (Mantino et al., 2024). Atualmente, a produção mundial concentra-se em países do sul europeu, com a Itália e a Espanha liderando tanto o consumo in natura quanto o processamento industrial (Eurostat, 2024). Esses países respondem por uma parcela substancial do volume cultivado na União Europeia, conforme demonstra o mapeamento de concentração produtiva detalhado na Figura 2A do Apêndice A (Mantino et al., 2024).

A sustentabilidade da produção enfrenta desafios devido às mudanças climáticas e à introdução de novos patógenos, que aumentam a incidência de doenças em culturas sensíveis (Singh et al., 2023). Paralelamente, o processo de urbanização elevou a demanda por produtos processados, exigindo das indústrias padrões rigorosos de uniformidade e rendimento do mesocarpo para minimizar desperdícios. Estima-se que o mercado global atinja US$ 262,2 bilhões até 2030, impulsionado pela expansão em mercados emergentes, conforme as projeções econômicas reunidas na Figura 3A Apêndice A (Mordor Intelligence, 2025).

2.4 Cultivo de tomate no Brasil e perfil do maior produtor

O cultivo no Brasil consolidou-se no século XIX através da imigração italiana, expandindo-se inicialmente a partir de São Paulo. Em 2023, o setor industrial registrou aumento na área de cultivo, motivado pela alta rentabilidade e pela necessidade de monitoramento assertivo para atender aos padrões de exportação (Almeida et al., 2023). O país produz anualmente entre 4,1 e 4,3 milhões de toneladas, embora projeções para 2026 indiquem um recuo no tomate de mesa devido a custos de mão de obra e restrições de crédito. O desempenho dos principais polos agrícolas nacionais encontra-se ilustrado na Figura 4A do Apêndice A (Revista Hortifruti Brasil, 2025).

Goiás consolidou-se como o maior produtor nacional, respondendo por 31,4% da produção, com destaque para o processamento industrial (Almeida et al., 2023). Esse sucesso decorre de solos adequados e da modernização tecnológica das propriedades (Seapa, 2025). A cadeia produtiva estadual envolve mais de 10 mil produtores e impacta cerca de 200 mil pessoas, utilizando sistemas sustentáveis como a rotação de culturas e defensivos biológicos (Martha et al., 2023; Gottems, 2025). Dados nacionais reforçam a força do setor, que movimenta anualmente cerca de R$ 9,1 bilhões, com rendimento médio de 72.760 kg/ha, tendo em Cristalina, Morrinhos e Silvânia seus principais polos de excelência (IBGE, 2025; Seapa, 2025).

2.5 Ferramentas de visão computacional para avaliação de imagens

A classificação físico-química de mesocarpos é uma tarefa complexa que exige tecnologias avançadas, como espectroscopia, ultrassom e imagens hiperespectrais (Medina et al., 2025). O uso de inteligência artificial e *Deep Learning* permite identificar frutos por tamanho e cor, otimizando a colheita (Cintas et al., 2025). Tais tecnologias são fundamentais para o diagnóstico preciso de fitossanidade em campo e para o mapeamento de áreas de cultivo (Shoaib et al., 2023). A visão computacional atua como um pilar estratégico que abrange desde a estimativa de safra até a padronização rigorosa de textura e cor (Fracarolli et al., 2021). A integração prática entre algoritmos preditivos e captura padronizada de imagens transforma dados visuais em indicadores quantitativos de rendimento, viabilizando o monitoramento automatizado e de baixo custo (Hageraats, 2025)."

2.6 Aplicações de inteligência artificial para medições precisas em tomates

As Redes Neurais Convolucionais (CNN) são projetadas para extrair automaticamente características relevantes de dados em formato de imagem (Raj et al., 2025). Na tomaticultura, essas arquiteturas são empregadas na detecção de defeitos e na avaliação de atributos de qualidade que, muitas vezes, superam a consistência de avaliadores humanos (Faria et al., 2024). Modelos de *Deep Learning* apresentam elevados índices de desempenho em condições reais de campo (Akintola et al., 2025). Em sistemas embarcados, a automação de medidas físicas como volume e área superficial apresenta forte correlação com métodos tradicionais, atingindo coeficiente de determinação (R^2) próximo a 0,95, o que indica uma acurácia de 95% na estimativa automatizada (Costa et al., 2023).

A integração tecnológica apoia a triagem em tempo próxima do real, garantindo a padronização de lotes industriais (Moya et al., 2025). O acesso a plataformas com interfaces amigáveis tem reduzido as barreiras para a adoção dessas ferramentas por técnicos e produtores (Vision Platform, 2024). Estudos indicam que a combinação de imagens de alta resolução e dados físico-químicos permite caracterizar objetivamente a forma e a composição do fruto, favorecendo a seleção de fenótipos (Almeida et al., 2024).

A maioria das aplicações atuais foca em imagens externas, sendo escassos os estudos sobre a quantificação direta do mesocarpo, parâmetro vital para o rendimento industrial (Ali et al., 2024). Protocolos reprodutíveis baseados em aquisição padronizada e validação com dados de referência (*Ground Truth*) são essenciais para consolidar a agricultura digital (Hageraats, 2025). O presente projeto insere-se nesta lacuna, direcionando a visão computacional para a estimativa da estrutura interna, visando aprimorar o desempenho tecnológico na cadeia produtiva do tomate (Soussi et al., 2024).

A validação dessa proposta tecnológica requer a transição dos modelos teóricos para um ambiente de experimentação prático e estruturado. A concepção de um equipamento dedicado, capaz de isolar variáveis luminosas e padronizar a captura das amostras, atua como o alicerce para a execução confiável dos algoritmos preditivos. O detalhamento dessa arquitetura de hardware, integrado às rotinas de processamento de imagem e aos protocolos de calibração necessários para atestar a acurácia do sistema frente ao método manual, fundamenta o rigor da etapa metodológica descrita a seguir.

3 OBJETIVOS GERAIS E ESPECÍFICOS

3.1 Objetivo geral

Desenvolver e validar uma metodologia automatizada, baseada em visão computacional e inteligência artificial, para medir a espessura do mesocarpo de tomates (*Solanum lycopersicum* L.), visando otimizar a classificação de qualidade dos frutos e adequar os processos produtivos e comerciais aos padrões da olericultura.

3.2 Objetivos específicos

Projetar e implementar um algoritmo focado na identificação precisa dos limites de área superficial do tomate para a extração de medidas. Desenvolver uma interface gráfica que permita a realização de testes consecutivos, visualização de dados analíticos e processamento de lotes de amostras com geração de *QR Code* para rastreamento. Automatizar o envio de relatórios via *e-mail* e a geração de cópias de segurança do sistema. Avaliar o desempenho da aplicação em diferentes variedades de tomates e nas regiões de média circunferência dos frutos, sob configurações experimentais, a fim de assegurar a robustez da metodologia em ambiente controlado. Comparar os resultados da abordagem automatizada com os métodos tradicionais de medição da espessura do mesocarpo, validando a precisão e a consistência da tecnologia proposta.

4 MATERIAIS E MÉTODOS

4.1 Descrição do local e período da pesquisa

A pesquisa foi conduzida nas dependências do Instituto Federal Goiano – Campus Morrinhos, em Goiás, abrangendo o intervalo entre 2024 e 2026. As atividades concentraram-se na integração entre o campo experimental para obtenção das amostras e a infraestrutura laboratorial destinada ao desenvolvimento computacional. Durante este período, executaram-se as etapas cronológicas de coleta de dados biológicos, calibração dos sensores ópticos, treinamento das arquiteturas de inteligência artificial e a subsequente validação estatística do sistema proposto sob condições controladas.

4.2 Recursos instrumentais e infraestrutura tecnológica

Para a estruturação do sistema de medição, utilizou-se uma estação de trabalho equipada (computador) com processador de desempenho intermediário e 8 *GB* de memória *RAM*, responsável pelo processamento dos algoritmos e gerenciamento do banco de dados. A unidade de aquisição de imagens baseou-se no módulo *ESP32-CAM*, operando de forma integrada a uma estrutura física opaca projetada para atuar como câmara escura. Este ambiente foi dotado de iluminação artificial padronizada via sistema *Ring Light LED* de 6.500 K, garantindo a neutralidade cromática e a mitigação de ruídos luminosos externos. O detalhamento técnico da montagem, as especificações dos componentes eletrônicos e o esquema elétrico do sistema estão documentados no Apêndice B deste documento.

O ecossistema de desenvolvimento foi estruturado em linguagem *Python* (versão 3.11) sob ambiente *Jupyter Notebook*. A arquitetura computacional integrou bibliotecas especializadas como *OpenCV* para visão computacional, *NumPy* e *Pandas* para manipulação matricial, e *Matplotlib* para visualização de dados. A comunicação entre o hardware de captura e a interface de processamento ocorreu via protocolo *HTTP* em rede local sem fio (*WiFi*). Uma interface gráfica funcional, implementada através da biblioteca *Tkinter*, viabilizou a operação do sistema, permitindo o controle de fluxo desde a captura inicial até a exportação automatizada dos indicadores de qualidade.

4.3 Material biológico e protocolos de amostragem

A unidade experimental consistiu em 100 frutos de tomate (*Solanum lycopersicum* L.) produzidos em áreas experimentais do Instituo Federal Goiano – Campus Morrinhos/GO. A seleção priorizou a diversidade fenotípica, contemplando diferentes estágios de maturação (verde, intermediário e maduro), além de variações morfométrica de tamanho e formato. Cada unidade foi submetida a um corte longitudinal cuidadoso para a exposição do mesocarpo, sendo posicionada em uma base móvel automática para captura. Os procedimentos de higienização, técnica de seccionamento e a organização das amostras para análise visual encontram-se detalhados no Apêndice C.

4.4 Blindagem experimental e rigor metrológico

A metodologia de validação seguiu um protocolo em duplo-cego, em conformidade com as diretrizes da norma ABNT NBR ISO/IEC 17025:2017, visando eliminar vieses de aferição. O processo foi dividido em duas frentes independentes: a extração automatizada via visão computacional e a medição manual de referência com paquímetro digital de precisão. O operador do sistema digital não deteve acesso aos dados manuais, assim como os avaliadores independentes realizaram as aferições sem o conhecimento prévio dos resultados gerados pelos algoritmos. A consolidação dos dados ocorreu apenas após a conclusão de ambas as etapas, garantindo a integridade dos dados de referência (*Ground Truth*) dispostas no Apêndice B deste documento.

4.5 Processamento digital, inteligência artificial e calibração

O *pipeline* de processamento iniciou-se com a conversão das imagens para tons de cinza e a aplicação de filtros para detecção de bordas, visando o realce do mesocarpo. Para superar as limitações da visão clássica, implementou-se uma Rede Neural Convolucional (CNN) baseada em *Deep Learning*, treinada com um conjunto de 250 imagens. Este banco de dados foi expandido via técnicas de *data augmentation*, utilizando imagens reais e sintéticas para elevar a capacidade de generalização do modelo. A calibração física, necessária para converter a unidade de pixel para milímetros, utilizou um padrão de referência (quadrado) bidimensional de 1 cm^2. A espessura média do mesocarpo foi calculada através da distância euclidiana entre a epiderme e a cavidade

locular, cujos resultados de processamento e densidade da malha de pontos ativos estão evidenciados pelas Figuras 5D e 6D constantes no Apêndice D.

4.6 Análise estatística e conformidade ética

A análise dos dados foi processada no ambiente computacional *R* (*RStudio*). A comparação entre as médias obtidas pela metodologia de visão computacional e pelo método convencional de referência (paquímetro digital) utilizou o teste t para amostras pareadas. A hipótese nula testada assumiu a inexistência de diferença entre os métodos, estabelecendo um nível de significância de 15% para a rejeição de discrepâncias entre as aferições manuais e automatizadas.

Para validação, aplicou-se o método de *Bland-Altman* para quantificar a concordância real entre a inferência do algoritmo e o *Ground Truth*. Esta análise gráfica e analítica possibilitou a determinação dos limites de concordância e a identificação de eventuais vieses sistemáticos (*bias*), fundamentais para validar se a tecnologia proposta apresenta tendenciosidades ao longo de diferentes espessuras de mesocarpo. A amplitude da associação entre as variáveis foi verificada pelo coeficiente de correlação de *Pearson*, enquanto o coeficiente de determinação (R^2) descreveu a proporção da variância dos dados explicada pelo modelo de regressão linear.

A viabilidade de transição do sistema para a escala industrial fundamenta-se na minimização dos erros de estimativa. Para quantificar a acurácia do pipeline de processamento, calculou-se o Erro Médio Absoluto (MAE), que expressa o desvio médio das predições na mesma unidade física da variável original (milímetros). O Erro Percentual Médio (MAPE) permitiu analisar a precisão relativa do sistema, independentemente das variações de calibre ou do estágio de maturação do tomate analisado. O comportamento da distribuição amostral e a presença de potenciais valores atípicos (*outliers*) decorrentes de variações morfológicas severas foram mapeados via diagramas de caixa (*boxplots*), conforme detalhado no Apêndice E.

Tais procedimentos utilizados, treinamento de IA, desenvolvimento de software, análise dos resultados e a proposição metodológica sejam de autoria própria, mantendo a fidedignidade científica exigida. A condução do estudo respeitou integralmente as diretrizes da Portaria CNPq nº 2.664/2026, estando a declaração de responsabilidade e transparência metodológica devidamente documentada no Apêndice B.

5 CONSIDERAÇÕES E PONTOS RELEVANTES

5.1 Avaliação da qualidade do tomate: desafios e perspectivas

A qualidade do fruto é essencial para garantir, fidelizar e satisfazer consumidores, agregando valor ao produto e reforçando o planejamento do plantio (Cepea, 2024). O tomate (*Solanum lycopersicum* L.), embora amplamente consumido em escala global, impõe desafios logísticos e qualitativos que se iniciam no campo e culminam no varejo.

Determinar a qualidade desse fruto com precisão permanece um desafio técnico, um desses atributos, como paredes espessas, conferem maior firmeza e resistência ao transporte sendo uma das principais características desejáveis tanto para o consumo *in natura* quanto para o processamento agroindustrial (Milone, 2024). A espessura do mesocarpo, camada interna rica em nutrientes, consolida-se como parâmetro crucial para a classificação econômica e comercial. Essa medição, ainda é realizada predominantemente de forma manual, resultando em um processo laborioso e suscetível a erros humanos que podem gerar custos elevados na cadeia final da produção (Chen et al., 2023).

A superação desse cenário exige tecnologias que aumentem a precisão da triagem, substituindo métodos arcaicos para eliminar gargalos de padronização no mercado (Folha Agrícola, 2025). A integração entre sensores, visão computacional e inteligência artificial representa um avanço importante, permitindo que cada fruto seja avaliado de forma objetiva e replicável (Massruhá et al., 2023). Essas inovações impactam diretamente a competitividade do setor, atendendo a um mercado rigoroso quanto à procedência e à qualidade dos alimentos. O investimento em soluções tecnológicas para a avaliação de hortaliças abre espaço para uma agricultura mais estável e resiliente frente às adversidades climáticas e logísticas.

5.2 O desafio contra a imprecisão

A medição manual da espessura do mesocarpo apresenta limitações operacionais e econômicas significativas em sistemas produtivos de larga escala. O processo exige atenção contínua do operador, o que resulta em baixa produtividade e risco elevado de erro humano, diretamente influenciado por fadiga, distração e variabilidade na

experiência técnica dos avaliadores. A ausência de padronização nas aferições manuais compromete a consistência dos lotes e prejudica toda a cadeia de suprimentos, gerando disparidades na classificação dos frutos e dificultando o atendimento às exigências do mercado consumidor contemporâneo.

Estudos recentes evidenciam que inconsistências na triagem acarretam perdas pós-colheita superiores a 30%, impactando negativamente a rentabilidade da produção (Ojeleye et al., 2023). A necessidade recorrente de repetir medições para mitigar erros amplia os custos operacionais, agravados pela crescente escassez de mão de obra qualificada no setor agrícola. Regiões com menor densidade populacional enfrentam dificuldades adicionais para reter profissionais capacitados, tornando o processo estritamente manual inviável a médio e longo prazo (Li et al., 2023).

Soluções tecnológicas inseridas no contexto agronômico demonstram eficácia próxima a 95% nos processos de classificação, revelando potencial para transformar a comercialização de tomates no Brasil (Almeida et al., 2024). A conformidade com padrões globais de qualidade e a maior celeridade de processamento posicionam o país de forma estratégica em mercados emergentes. Para contornar os desafios de infraestrutura e conectividade no ambiente rural, a transição de arquiteturas dependentes de computação em nuvem para o processamento em borda (*Edge Computing*) desponta como alternativa tecnológica primária (Bolfe et al., 2023).

A inteligência artificial embarcada diretamente em dispositivos de hardware de baixo custo e alta eficiência energética permite que a extração de características e a tomada de decisão ocorram de forma autônoma, sem exigir conexão ininterrupta com a internet. Essa descentralização do processamento de dados contorna gargalos estruturais das zonas agrícolas e assegura respostas em tempo próximo do real nas linhas de triagem. A automação descentralizada reduz a latência operacional e os custos de implantação, abrindo caminho para uma transição digital acessível em lavouras e agroindústrias brasileiras.

A adoção de sistemas de visão computacional embarcados atende à demanda crescente da agroindústria por padronização morfológica contínua. No caso específico do tomate, a espessura do mesocarpo atua como indicador mecânico de resistência ao transporte e métrica direta do rendimento industrial para a produção de polpas, molhos e extratos (Milone, 2024). A delegação da avaliação física a sistemas automatizados reduz o viés associado à fadiga humana e viabiliza a triagem de milhares de frutos com

uniformidade milimétrica, independentemente do tempo de operação do maquinário (Chen et al., 2023).

A integração entre dispositivos de Internet das Coisas (IoT) e algoritmos preditivos consolida a agricultura de precisão de ponta a ponta, acompanhando o produto da lavoura às etapas de seleção e classificação (Massruhá et al., 2023). A capacidade de um microcontrolador capturar a imagem do fruto, processar os dados da rede neural e determinar a classificação de qualidade em frações de segundo otimiza a logística de pós-colheita. A digitalização dessas etapas substitui o empirismo visual das bancadas de triagem por métricas auditáveis, protegendo a cadeia de suprimentos das oscilações econômicas e assegurando margens de rentabilidade robustas para produtores e indústria (Cepea, 2024).

6 CONCLUSÃO

A visão computacional consolidou-se como uma tecnologia eficaz para superar os desafios associados à medição manual da espessura do mesocarpo de tomates. O monitoramento por métodos computacionais permitiu a realização de análises precisas, mitigando a subjetividade e garantindo a padronização na classificação dos frutos. A redução drástica da interferência de erros humanos elevou a confiabilidade dos dados obtidos, demonstrando viabilidade técnica para aplicação em escala produtiva.

O emprego de redes neurais convolucionais integradas à visão computacional viabilizou a construção de um modelo robusto para análises em tempo quase real. O método fundamentado em visão computacional clássica apresentou acurácia de 86,88%, enquanto o modelo de inteligência artificial alcançou desempenho superior, com 90,76% de precisão em relação às medições físicas de referência. Durante os ensaios laboratoriais, estimou-se um tempo médio de operação de aproximadamente 6 segundos por amostra, indicando ganhos de agilidade e reprodutibilidade no fluxo de triagem. O diferencial da metodologia reside na integração entre captura física, processamento digital e validação morfométrica, atendendo às exigências de padronização do mercado.

O estudo identificou desafios estruturais relacionados ao preparo dos frutos e às variações na qualidade e captura das imagens sob condições de iluminação oscilantes, fatores que influenciam o desempenho de *hardware* de baixo custo, em relação ao *software*, observaram-se limitações nos dados disponíveis para o treinamento da Inteligência Artificial. O refinamento das ferramentas e a validação por meio de testes estatísticos confirmaram elevada concordância metrológica, evidenciando a praticidade do modelo para uso laboratorial e para o desenvolvimento de futuras aplicações comerciais.

O aperfeiçoamento de componentes de hardware embarcado e de arquiteturas de *Deep Learning* constituem o foco de pesquisas futuras, visando ampliar a precisão das estimativas e integrar o sistema desde a captura inicial em campo até as etapas finais de comercialização. Esta pesquisa oferece contribuição relevante para a digitalização do meio rural ao validar uma metodologia rigorosa, reprodutível e de baixo custo operacional, com potencial de escala para diferentes perfis e realidades do agronegócio brasileiro.

REFERÊNCIAS BIBLIOGRÁFICAS

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **ABNT NBR ISO/IEC 22989**: Inteligência artificial - Conceitos de inteligência artificial e terminologia. Rio de Janeiro: ABNT, 2024.

AKINTOLA, K. G. *et al*. A review of deep convolutional neurais networks applications in detection of tomato diseases using leaf images. **International Journal of Advances in Engineering and Management**, [S. l.], v. 7, n. 9, p. 415-431, 2025. DOI: https://doi.org/10.35629/5252-0709415431.

ALI, A. *et al*. Quality and physiological evaluation of tomato subjected to different supplemental lighting systems. **Scientia Horticulturae**, [S. l.], v. 323, p. 112469, 1 jan. 2024. DOI: https://doi.org/10.1016/j.scienta.2023.112469.

ALI, L. K. J. *et al*. Effect of different levels of salt and drought stresses on gene expression of two tolerance-different tomato cultivars in vitro. **Iraqi Journal of Agricultural Sciences**, Baghdad, v. 55, n. 2, p. 795–802, 2024. DOI: https://doi.org/10.36103/gc35eh69.

ALIBABA CLOUD. **Qwen**: modelo de linguagem de inteligência artificial. [S. l.]: Alibaba Cloud, 2026. Disponível em: https://chat.qwen.ai/. Acesso em: 2 jan. 2024.

ALMEIDA, A. M. *et al*. Advanced phenotyping in tomato fruit classification through artificial intelligence. **Scientia Agricola**, Piracicaba, v. 81, e20240115, 2024. DOI: https://doi.org/10.1590/1678-992X-2024-0115.

ALVES, F. V. *et al*. Challenges, trends and opportunities in digital agriculture in Brazil. *In*: MASSRUHÁ, S. M. F. S. *et al*. (org.). **Digital agriculture**: research, development and innovation in production chains. Brasília, DF: Embrapa, 2023. cap. 16.

ARDUINO FORUM. **Começando com ESPE32-CAM**. [S. l.], 2023. Disponível em: https://forum.arduino.cc/t/comecando-com-esp32-cam/1117382. Acesso em: 8 dez. 2023.

BOLFE, E. L. *et al*. Challenges, trends and opportunities in digital agriculture in Brazil. *In*:

MASSRUHÁ, S. M. F. S. *et al*. (org.). **Digital agriculture**: research, development and innovation in production chains. Brasília, DF: Embrapa, 2023. cap. 16, p. 281-299. Disponível em: https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1156772/1/LV-Digital-agriculture-2023-cap16.pdf. Acesso em: 12 dez. 2025.

BRASIL. Ministério da Ciência, Tecnologia e Inovação. **Estratégia Brasileira de Inteligência Artificial (EBIA)**. Brasília, DF: MCTI, 2021. Disponível em: https://www.gov.br/mcti. Acesso em: 15 abr. 2026.

CAMMARELLE, A. *et al*. Preferences for processed tomato products' attributes: an explorative analysis of Italian consumers using a large sample. **Frontiers in Sustainable Food Systems**, [S. l.], v. 8, art. 1444902, 2024. DOI: https://doi.org/10.3389/fsufs.2024.1444902.

CARVALHO, J. C. L. *et al*. Computer vision-based device for estimating physical parameters of tomato fruits. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 30, n. 1, p. 112-119, 2026. Disponível em: https://www.agriambi.com.br/revista/v30n01/v30n01a07.pdf. Acesso em: 12 jan. 2025.

CEAGESP. **Tomate**. São Paulo: Companhia de Entrepostos e Armazéns Gerais de São Paulo, 2021. Hortipedia – Guia de variedades de tomate comercializadas na CEAGESP. Disponível em: https://ceagesp.gov.br/hortiescolha/hortipedia/tomate. Acesso em: 15 jun. 2024.

CEPEA. **Clima acelera produção, e oferta fica acima da média em 2024; para 2025, disponibilidade deve ser mais regular**. Piracicaba: Centro de Estudos Avançados em Economia Aplicada - ESALQ/USP, 2024. Disponível em: https://cepea.esalq.usp.br/br/releases/hf-brasil-cepea-clima-acelera-producao-e-oferta-fica-acima-da-media-em-2024-para-2025-disponibilidade-deve-ser-mais-regular.aspx. Acesso em: 6 jun. 2025.

CHEN, L. P. *et al*. Grading method for tomato multi-view shape using machine vision. **International Journal of Agricultural and Biological Engineering**, [S. l.], v. 16, n. 6, p. 184–196, 2023. DOI: https://doi.org/10.25165/j.ijabe.20231606.7768.

CINTAS, D. *et al*. Automated tomato sorting and counting using YOLOv11 for industrial and precision agriculture applications. **Applied Artificial Intelligence**, [S. l.], v. 39, n. 1, 2025. DOI: https://doi.org/10.1080/08839514.2025.2576891.

CIRKITDESIGNER. **Cirkitdesigner**: online circuit design tool. [S. l.], 2024. Disponível em: https://app.cirkitdesigner.com/. Acesso em: 13 maio 2024.

CODEGPT. **Projects**. [S. l.], 2024. Disponível em: https://chatgpt.com/. Acesso em: 16 maio 2024.

COSTA, A. *et al*. Computer vision-based device for estimating physical parameters of tomato fruits. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 30, n. 1, art. 7, p. 1-12, 2023. Disponível em: https://www.agriambi.com.br/revista/v30n01/v30n01a07.pdf. Acesso em: 3 out. 2025.

DICAS DE INFORMÁTICA BÁSICA. **Como funciona um drive de CD-ROM**. [S. l.], 2023. Disponível em: https://www.cursosdeinformaticabasica.com.br/como-funciona-um-drive-de-cd-rom/. Acesso em: 18 nov. 2023.

EASYEDA. **EasyEDA**: online PCB design & circuit simulator. [S. l.], 2024. Disponível em: https://easyeda.com/. Acesso em: 2 mar. 2024.

EMBRAPA. **Agro 4.0**: o papel da pesquisa e perspectivas para a agricultura digital no Brasil. Brasília, DF: Embrapa, 2023. Disponível em: https://ainfo.cnptia.embrapa.br/digital/bitstream/doc/1154917/1/PL-Agro4.0-023.pdf. Acesso em: 29 maio 2025.

EMBRAPA HORTALIÇAS. **Cultivares**. [S. l.], 2024. Disponível em: https://www.embrapa.br/agencia-de-informacao-tecnologica/cultivos/tomate/pre-producao/caracteristicas/cultivares. Acesso em: 1 dez. 2024.

ESPINOZA, G. *et al*. Liquidity and asset turnover: A simple linear regression model for agricultural firms. *In*: LACCEI INTERNATIONAL MULTI-CONFERENCE FOR

ENGINEERING, EDUCATION AND TECHNOLOGY, 22., 2024, Buenos Aires. **Proceedings** [...]. Buenos Aires: LACCEI, 2024. Disponível em: https://proceedings.laccei.org/index.php/laccei/article/view/2761.

EUROSTAT. **How much fruit and vegetables does the EU harvest?** Luxembourg: Eurostat, 2025. Disponível em: https://ec.europa.eu/eurostat/web/products-eurostat-news/w/ddn-20250825-1. Acesso em: 12 set. 2025.

FAO. **História do tomate**: a jornada entre a curiosidade venenosa e o ingrediente popular. [S. l.], 2024. Disponível em: https://www.fao.org/brasil/noticias/detail-events/es/c/1508041/#:~:text=O%20tomate%20se%20originou%20na,como%20ele%20chegou%20%C3%A0%20Europa. Acesso em: 7 maio 2024.

FARIA, S. E. S. *et al*. Advanced phenotyping in tomato fruit classification through deep learning architectures. **Scientia Agricola**, Piracicaba, v. 81, n. 2, p. 270-281, 2024. DOI: https://doi.org/10.1590/1678-992X-2024-0115.

FOLHA AGRÍCOLA. **Novo tomate salada permite pencas mais próximas e mais produtividade por metro quadrado**. [S. l.], 3 jan. 2025. Disponível em: https://folhaagricola.com.br/2024/12/18/novo-tomate-salada-permite-pencas-mais-proximas-e-mais-produtividade-por-metro-quadrado/. Acesso em: 6 jun. 2025.

FONSECA, C. S. *et al*. Computational vision for tomato classification using a decision tree algorithm. **Engenharia Agrícola**, [S. l.], v. 45, n. 1, p. 102-113, 2025. DOI: https://doi.org/10.1590/1809-4430-Eng.Agric.v45e20240124/2025.

FOZIA *et al*. Morphological, phenotypic and nutritional characterization of exotic and local tomato germplasm under tunnel. **Food Bioscience**, [S. l.], v. 59, p. 104241, 1 jun. 2024. DOI: https://doi.org/10.1016/j.fbio.2024.104241.

FRACAROLLI, J. A. *et al*. Visão computacional aplicada a alimentos e produtos agrícolas. **Revista Ciência Agronômica**, Fortaleza, v. 51, e20207749, 2021. DOI: https://doi.org/10.5935/1806-6690.20200087. Disponível em: https://www.scielo.br/j/rca/a/wZzwb7DZjLd85nHTLB5DDbv/?format=html. Acesso em: 29 maio 2025.

FURQUIM, M. *et al*. Panorama geral da tomaticultura no Estado em Goiás: uma análise descritiva a partir de levantamento bibliográfico. **Research, Society and Development**, [S. l.], v. 9, n. 7, p. e955974310, 16 jun. 2020. DOI: http://dx.doi.org/10.33448/rsd-v9i7.4310.

GOOGLE. **Gemini**: modelo de linguagem. Mountain View: Google, 2026. Disponível em: https://gemini.google.com/. Acesso em: 12 abr. 2026.

GOOGLE. **Nano Banana Pro**: modelo de geração de imagens. Mountain View: Google, 2026. Disponível em: https://gemini.google.com/. Acesso em: 12 abr. 2026.

GOTTEMS, Leonardo. **Controle biológico impulsiona sustentabilidade no tomate**. [S. l.]: Agrolink, 22 abr. 2025. Disponível em: https://www.agrolink.com.br/noticias/controle-biologico-impulsiona-sustentabilidade-no-tomate_501341.html. Acesso em: 27 maio 2025.

HAGERAATS, S. **Computer vision for continuous monitoring of head thickness in tomato**. [S. l.], Relatório WPR-1356, 2025. DOI: https://doi.org/10.18174/675098.

IBGE. **Produção de Tomate**. [S. l.], 2024. Disponível em: https://www.ibge.gov.br/explica/producao-agropecuaria/tomate/br. Acesso em: 15 out. 2024.

KNOTT, M. *et al*. Facilitated machine learning for image-based fruit quality assessment in developing countries. **Journal of Food Engineering**, [S. l.], v. 344, n. 111473, p. 1-12, 2023. DOI: https://doi.org/10.1016/j.jfoodeng.2022.111401.

KWEON, A. *et al*. Visual based Tomato Size Measurement System for an Autonomous Picking Robot. **arXiv**, 2023. DOI: https://doi.org/10.48550/arXiv.2304.06177. Disponível em: https://arxiv.org/abs/2304.06177. Acesso em: 17 out. 2025.

LANDAU, E. C.; SILVA, G. A. da. **Evolução da produção de tomate (Solanum lycopersicum, Solanaceae)**. [S. l.], 2024. Disponível em: https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1122701/1/Cap40-EvolucaoProducaoTomate.pdf. Acesso em: 6 ago. 2024.

LI, Z. *et al*. Artificial intelligence development and rural labor: impact on employment quality and mechanisms. **International Review of Economics & Finance**, [S. l.], 2025. DOI: https://doi.org/10.1016/j.iref.2025.104292.

LIU, Y. *et al*. Development of multimodal fusion technology for tomato maturity assessment. **Sensors**, [S. l.], v. 24, n. 8, p. 2467, 2024. DOI: https://doi.org/10.3390/s24082467.

MANTINO, F. *et al*. **The governance of transitions in agri-food systems**. Roma: CREA, 2024. Disponível em: https://www.econstor.eu/bitstream/10419/325674/1/1899579818.pdf. Acesso em: 23 jun. 2025.

MARTHA, G. B. *et al*. Charting new sustainable agricultural innovation pathways for the Brazilian soybean production chain. **Scientia Agricola**, Piracicaba, v. 80, e20230042, 2023. DOI: https://doi.org/10.1590/1678-992X-2023-0067.

MASSRUHÁ, S. M. F. S. *et al*. Agro 4.0: o papel da pesquisa e perspectivas para a transformação digital na agricultura. *In*: **AGRO 4.0 – FUNDAMENTOS, REALIDADES E PERSPECTIVAS PARA O BRASIL**. Brasília, DF: CNA; USP, 2023. Disponível em: https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1154917/1/PL-Agro4.0-2023.pdf. Acesso em: 2 out. 2025.

MEDINA, G. *et al*. Strategies for analysing hyperspectral imaging data for food quality and safety issues – A critical review of the last 5 years. **Microchemical Journal**, [S. l.], v. 214, p. 113994, 2025. DOI: https://doi.org/10.1016/j.microc.2025.113994.

MICROSOFT. **Microsoft Copilot**. Redmond: Microsoft, 2026. Disponível em: https://copilot.microsoft.com/. Acesso em: 12 abr. 2026.

MICROSOFT. **Copilot Chat – CQ67N8jR5QfZdU6xFsjWV**. [S. l.], 2025. Disponível em: https://copilot.microsoft.com/chats/CQ67N8jR5QfZdU6xFsjWV. Acesso em: 6 jun. 2025.

MILONE, Ricardo. **Produção de tomate industrial deve crescer 10% em 2024, mas clima traz desafios**. [S. l.]: Revista Cultivar, 18 out. 2024. Disponível em: https://revistacultivar.com.br/noticias/producao-de-tomate-industrial-deve-crescer-10-em-2024-mas-clima-traz-desafios. Acesso em: 6 jun. 2025.

MORDOR INTELLIGENCE. **Tomato Market Size, Share & Growth Forecast Report, 2025-2030**. [S. l.], 2025. Disponível em: https://www.mordorintelligence.com/industry-reports/tomato-market. Acesso em: 27 nov. 2025.

MOYA, V. *et al*. Tomato classification with YOLOv8: Enhancing automated sorting and quality assessment. **Smart Agricultural Technology**, [S. l.], v. 12, art. 101221, 2025. DOI: https://doi.org/10.1016/j.atech.2025.101221.

OJELEYE, A. *et al*. Evaluation of postharvest losses of tomato (Lycopersicon esculentum) fruits along the value chain during the pandemic lockdown in Osogbo, Osun State, Nigeria. **Nigerian Journal of Horticultural Science**, [S. l.], v. 27, n. 1, p. 53-60, 2023. Disponível em: https://hortson.org.ng/images/Journals/2023volume/Ojeleye_et_al_2023.pdf. Acesso em: 20 out. 2025.

OLIVEIRA, C. *et al*. Are forest transitions associated with the international trade of agricultural and forest commodities? **Ambiente & Sociedade**, São Paulo, v. 26, e023008, 2023. Disponível em: https://mpmt.mp.br/site/storage/webdisco/arquivos/Est%C3%A3o%20as%20Transi%C3%A7%C3%B5es%20florestais.pdf. Acesso em: 5 dez. 2025.

OPENAI. **ChatGPT**: assistente de inteligência artificial generativa. San Francisco: OpenAI, 2026. Disponível em: https://chat.openai.com. Acesso em: 25 fev. 2026.

PERPLEXITY AI. **Perplexity**: assistente de inteligência artificial generativa. San Francisco: Perplexity AI, 2026. Disponível em: https://www.perplexity.ai. Acesso em: 8 nov. 2023.

POSIT. **RStudio Desktop**: integrated development environment for R and Python. [S. l.]: Posit, 2025. Disponível em: https://posit.co/download/rstudio-desktop/. Acesso em: 29 maio 2025.

PROJECT JUPYTER. **Jupyter Notebook**: web-based interactive computing platform. [S. l.]: Project Jupyter, 2025. Disponível em: https://jupyter.org/. Acesso em: 29 maio 2025.

PYTHON SOFTWARE FOUNDATION. **Python**: a programming language that lets you work quickly and integrate systems more effectively. [S. l.]: Python Software Foundation, 2025. Disponível em: https://www.python.org/. Acesso em: 2 set. 2023.

QI, H. *et al*. Hyperspectral imaging using a convolutional neural network with transformer for the soluble solid content and pH prediction of cherry tomatoes. **Foods**, Basel, v. 13, n. 2, p. 251, 2024. DOI: https://doi.org/10.3390/foods13020251.

R CORE TEAM. **R**: a language and environment for statistical computing. Vienna, Austria: R Foundation for Statistical Computing, 2026. Disponível em: https://www.R-project.org/. Acesso em: 12 abr. 2026.

RAJ, R. *et al*. An Extensive Study of Convolutional Neural Networks: Applications in Computer Vision for Improved Robotics Perceptions. **Sensors**, [S. l.], v. 25, n. 4, 1033, 2025. DOI: https://doi.org/10.3390/s25041033.

REVISTA HORTIFRUTI BRASIL. **Panorama do tomate em 2023**. Piracicaba: Cepea/Esalq/USP, 2023. Disponível em: https://www.hfbrasil.org.br. Acesso em: 20 mar. 2025.

RUIZ, R. **ESP32 with Load Cell and HX711 Amplifier (Digital Scale)**. [S. l.]: Random Nerd Tutorials, 2022. Disponível em: https://randomnerdtutorials.com/esp32-load-cell-hx711/. Acesso em: 29 maio 2025.

SEAPA. Secretaria de Estado de Agricultura, Pecuária e Abastecimento. **Agro em Dados**: destaque do mês – fevereiro de 2025: Tomate. Goiânia, 2025. Disponível em: https://goias.gov.br/agricultura/destaque-do-mes-agro-em-dados-fevereiro-2025-tomate. Acesso em: 5 abr. 2025.

SHOAIB, M. *et al*. An advanced deep learning models-based plant disease detection: A review of recent research. **Frontiers in Plant Science**, [S. l.], v. 14, 21 mar. 2023. DOI: https://doi.org/10.3389/fpls.2023.1158933.

SINGH, B. K. *et al*. Climate change reshaping plant–fungal interactions. **Nature Reviews Microbiology**, [S. l.], 2024. DOI: https://doi.org/10.3390/insects13080738. Disponível em: https://www.nature.com/articles/s41579-023-00900-7. Acesso em: 11 set. 2025.

SOUSSI, A. *et al*. Smart Sensors and Smart Data for Precision Agriculture: A Review. **Sensors**, [S. l.], v. 24, n. 8, 2647, 2024. DOI: https://doi.org/10.3390/s24082647.
USINAINFO. **Programando ESP32CAM com ESP32CAM MB**. [S. l.], 2023. Disponível em: https://www.usinainfo.com.br/blog/programando-esp32-cam-wifi-com-esp32-cam-mb/. Acesso em: 10 nov. 2023.

VAZQUEZ, D. V. *et al*. Machine Learning-Based Tomato Fruit Shape Classification System. **Plants**, [S. l.], v. 13, n. 17, p. 2357, 2024. DOI: https://doi.org/10.3390/plants13172357.

VISION PLATFORM. **Visão computacional e IA na produção agrícola**. [S. l.], 2024. Disponível em: https://visionplatform.ai/pt/visao-computacional-computer-vision-e-ia-na-producao-agricola-2024/. Acesso em: 23 maio 2025.

WANG, J. *et al*. Integration of Remote Sensing and Machine Learning for Precision Agriculture: A Comprehensive Perspective on Applications. **Agronomy**, [S. l.], v. 14, n. 9, p. 1975, 2024. DOI: https://doi.org/10.3390/agronomy14091975.

WANG, T. *et al*. Research on non-destructive detection model of tomato fruit quality based on electrical properties and machine learning algorithms. **Frontiers in Plant Science**, [S. l.], v. 16, art. 1690652, 2025. DOI: https://doi.org/10.3389/fpls.2025.1690652.

WANG, W. *et al*. A review of computer vision technologies in precision agriculture: From crop disease detection to farm management. **Theoretical and Natural Science**, [S. l.], v. 101, p. 34-39, 2025. DOI: https://doi.org/10.54254/2753-8818/2025.CH22224.

WILLMOTT, C. J. *et al*. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. **Climate Research**, [S. l.], v. 30, n. 1, p. 79–82, 2005. DOI: https://doi.org/10.3354/cr030079. Acesso em: 16 maio 2025.

ZHANG, J. *et al*. A comprehensive evaluation of tomato fruit quality and identification of volatile compounds. **Plants**, [S. l.], v. 12, n. 16, p. 2947, 2023. DOI: https://doi.org/10.3390/plants12162947.

ZHANG, Y. *et al*. Quantitative extraction and evaluation of tomato fruit phenotypes based on image recognition. **Frontiers in Plant Science**, [S. l.], v. 13, 2022. DOI: https://doi.org/10.3389/fpls.2022.859290.

ZHARKOVA, I. *et al*. Assessment of vitamin- and mineral-content stability of tomato fruits as a potential raw material to produce functional food. **Functional Foods in Health and Disease**, [S. l.], v. 14, n. 1, p. 14–32, 2024. DOI: https://doi.org/10.31989/ffhd.v14i1.1259.

APÊNDICE

APÊNDICE A - CONTEXTO PRODUTIVO, VARIABILIDADE MORFOLÓGICA E MAPA DE DISTRIBUIÇÃO DO TOMATE PELO BRASIL E O MUNDO

Este apêndice reúne dados e ilustrações que fundamentam a relevância econômica do tomate e o comportamento da produção em diferentes mercados. As informações apresentadas abrangem a distribuição geográfica na União Europeia, projeções de mercado até 2030 e estatísticas das safras recentes, complementando a fundamentação teórica da dissertação. O panorama visual auxilia na compreensão da dinâmica em que o sistema de medição automatizada será inserido, relacionando o desenvolvimento tecnológico às demandas comerciais nacionais e internacionais.

O tomate apresenta ampla variabilidade morfológica, com frutos de diferentes colorações, formatos e dimensões, o que determina a segmentação entre consumo *in natura* e processamento industrial. A Figura 1A detalha essa diversidade de grupos varietais e as opções disponíveis na cadeia de abastecimento brasileira (CEAGESP, 2021).

Figura 1A - Guia de variedades de tomates comercializadas na CEAGESP

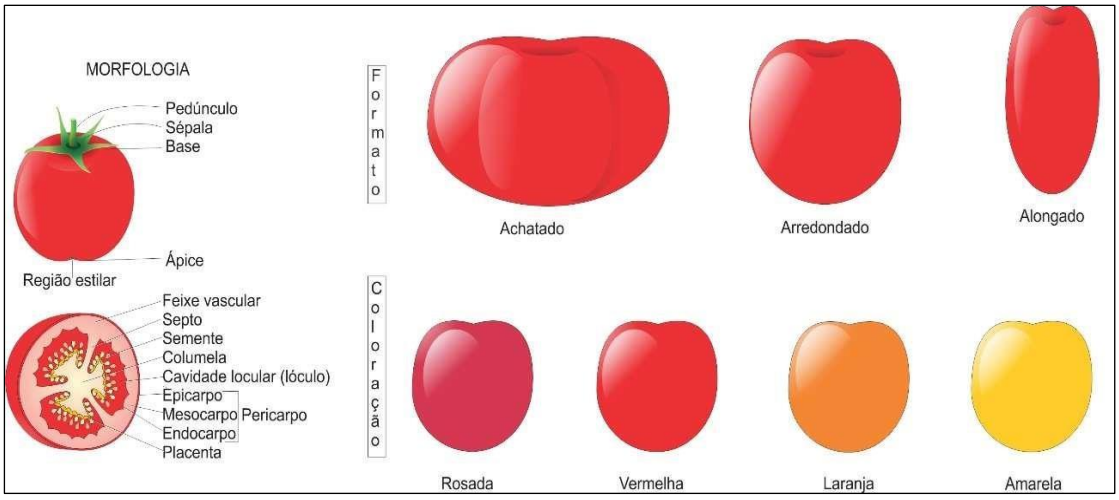

Fonte: Ceagesp (2021).

A introdução do tomate na Europa ocorreu no século XV por meio da "Troca Colombiana". Atualmente, a produção de tomates frescos concentra-se em países do sul do continente, com destaque para Itália e Espanha. Estas regiões atuam como polos fornecedores para o mercado de frescos e para a agroindústria regional (Mantino et al.,

2024). A distribuição da produção na União Europeia e os principais centros produtores estão mapeados na Figura 2A (Eurostat, 2025).

Figura 2A - Mapa de distribuição da produção de tomates frescos na União Europeia

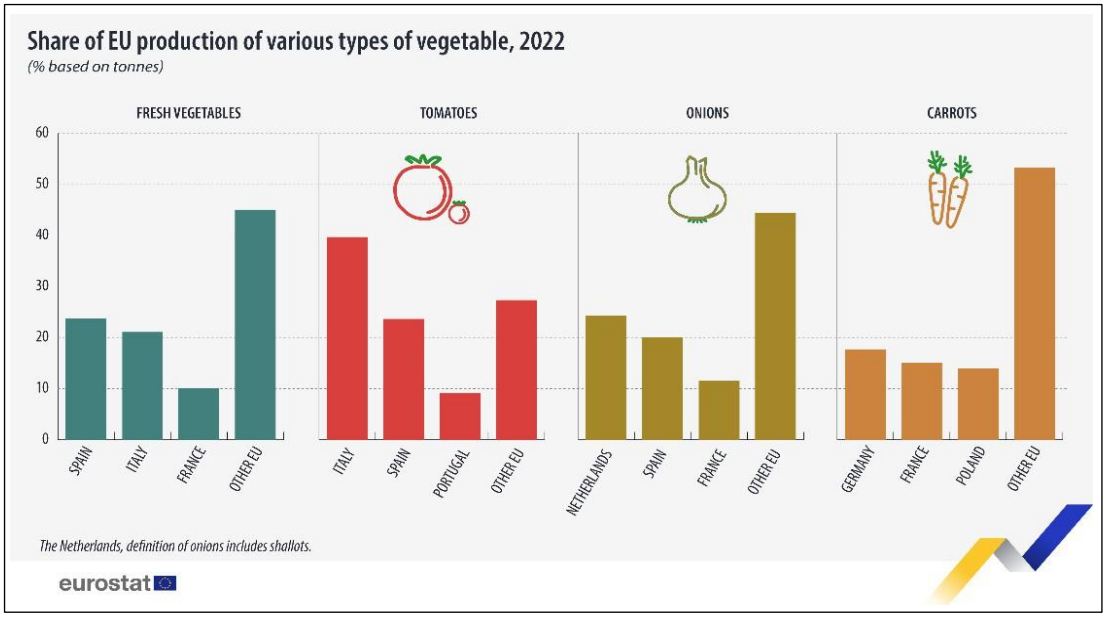

Fonte: Eurostat (2022).

A mudança nos hábitos alimentares e a urbanização acelerada impulsionam o consumo de tomates processados, como polpas e extratos. A indústria exige frutos com alta padronização de qualidade e rendimento, pressionando a cadeia produtiva pela otimização da seleção pós-colheita. Projeções indicam que o valor de mercado global da cultura pode atingir US$ 262,2 bilhões até 2030 (Mordor Intelligence, 2025). A Figura 3A apresenta a participação prevista nos diferentes segmentos econômicos.

Figura 3A - Participação prevista no mercado econômico de tomates até 2030

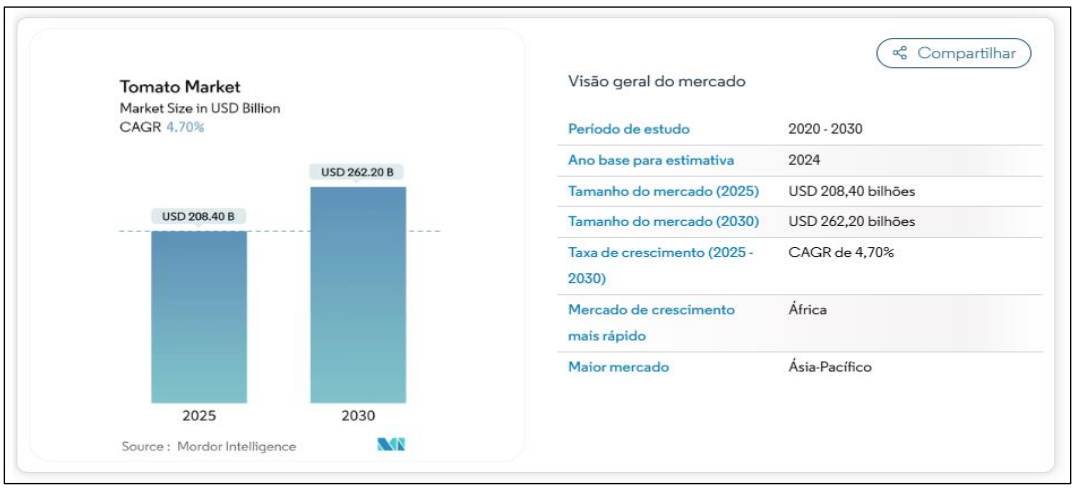

Fonte: Mordor Intelligence (2025).

No setor de hortifrutícolas, falhas na colheita, classificação e logística podem gerar perdas superiores a 30% do volume produzido. Ferramentas de medição baseadas em visão computacional surgem como estratégia para aumentar a padronização dos lotes e reduzir desperdícios. As estatísticas de produção das safras de 2025/2026, detalhadas na Figura 4A, revelam oscilações decorrentes de fatores climáticos e fitossanitários, reforçando a necessidade de tecnologias que elevem a eficiência da cadeia de suprimentos (Revista Hortifruti Brasil, 2023).

Figura 4A - Estatísticas de produção de tomate nas safras de 2025/2026

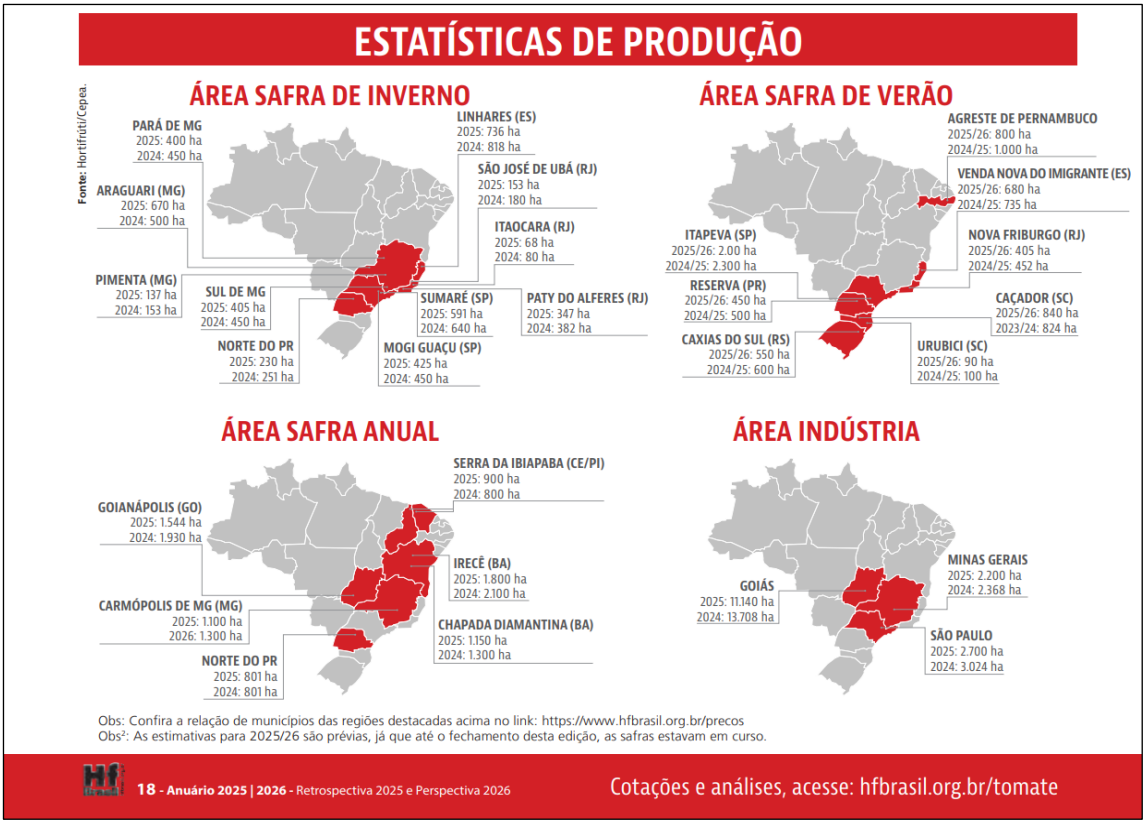

Fonte: Revista Hortifruti Brasil (2025, pag.18).

APÊNDICE B - SISTEMA DE HARDWARE EXPERIMENTAL

O apêndice B detalha o sistema de hardware desenvolvido para a aquisição automatizada de imagens de tomates e a medição da espessura do mesocarpo. São descritas a configuração da câmara escura para padronização de luzes, os componentes eletrônicos, a arquitetura de interligação e o arranjo experimental empregado na validação duplo-cego. No final deste apêndice, apresenta-se a declaração de integridade e de uso de Inteligência Artificial Generativa (IAG), em conformidade com a Portaria CNPq nº 2.664/2026.

Sistema de estrutura experimental

O hardware baseia-se em uma estrutura opaca que atua como câmara escura, o fruto é posicionado sobre uma gaveta móvel revestida com matriz quadriculada, permitindo o alinhamento da secção longitudinal em relação à lente. A iluminação provém de um conjunto de *LEDs* configurado para mitigar sombras e reflexos conforme detalha a Figura 1B, enquanto o módulo de processamento, acoplado à parte superior, gerencia a captura e o armazenamento das imagens digitais.

Figura 1B - Sistema de hardware experimental em configuração de câmara escura para aquisição de imagens de tomate

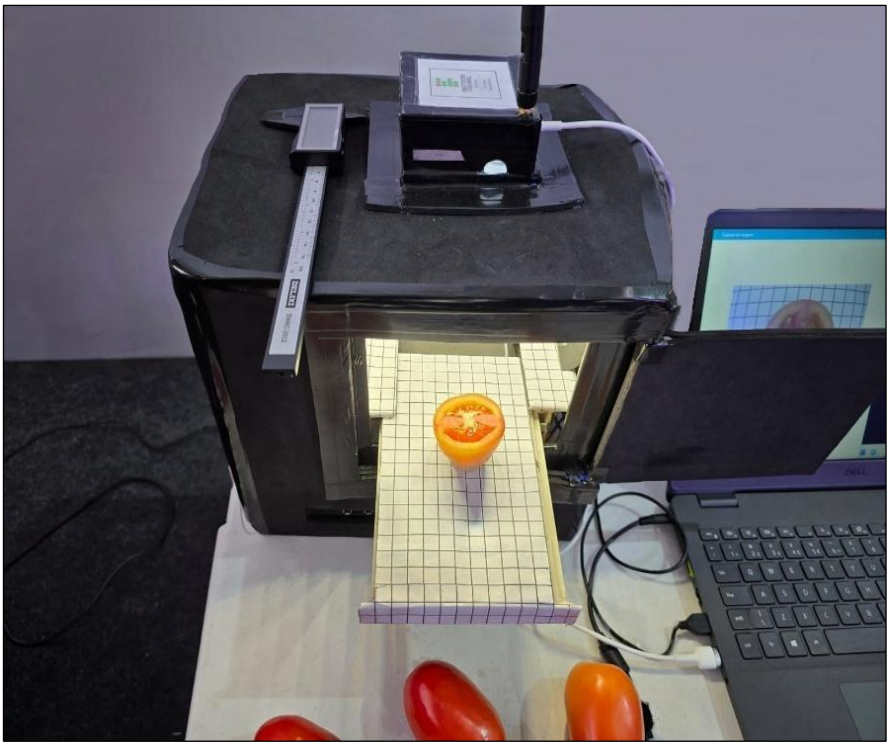

Fonte: Autor (2025).

Procedimento de validação duplo-cego

O protocolo experimental seguiu critérios de imparcialidade técnica para evitar vieses de confirmação. Inicialmente, o operador realizou a captura digital e a extração automatizada das medidas de cada amostra, mantendo os valores em sigilo durante o experimento. Tal conduta atende aos preceitos de imparcialidade estabelecidos pela norma ABNT NBR ISO/IEC 17025 (2017).

Em etapa independente, avaliadores efetuaram a aferição manual das mesmas dimensões utilizando paquímetros digitais calibrados. Os registros foram realizados em planilhas eletrônicas sem comunicação entre a equipe e o operador do sistema. A revelação dos dados gerados pelos algoritmos de visão computacional e inteligência artificial ocorreu apenas após a conclusão de todo o lote amostral, seguindo os métodos de validação e padronização de testes (Wang et al., 2025).

A consolidação final permitiu a comparação direta entre o método manual tradicional e a análise digital, fundamentando a análise estatística de concordância (Willmott et al., 2005). A Figura 2B ilustra a interação entre o operador e a equipe de avaliadores durante as aferições em bancada.

Figure 2B – Procedimento metodológico duplo-cego de validação

Fonte: Autor (2025).

Especificações técnicas e arquitetura

O sistema experimental integra módulos eletrônicos para captura, controle de iluminação e interface de treinamento. O Quadro 1B detalha os componentes utilizados e suas respectivas funções no arranjo experimental.

Quadro 1B - Componentes eletrônicos utilizados na construção do hardware

Nº	Componente	Especificação/Modelo	Função
1	Bateria Li-Ion	12V	Fonte principal de energia do sistema, alimentação externa da gaveta, servo motor e LEDs.
2	Chave liga/desliga	Simples	Controle de ativação/desativação, acionamento da gaveta e energia USB externa.
3	Resistores	470 Ω	Limitação de corrente para proteção dos LEDs.
4	Regulador de Tensão	Conversor *buck* LM2596S, DC para DC, 3.0-40V para 1.5-35V	Conversão de tensão para alimentação dos elementos lógicos e mecânicos.
5	Microcontrolador	ESP32-CAM (câmera 5MP, lente grande angular OV5640)	Captura e processamento de imagens do mesocarpo.
6	LEDs indicativos	Vermelho, Branco	Sinalização visual de *status* e de conexão à rede *Wi-Fi*.
7	PushButton - Botão	Vermelho e amarelo	Acionamento manual da gaveta do sistema.
8	Relé SPDT	5V, 2 unidades	Comutação de cargas e motores do sistema mecânico.
9	Motor DC	RF-300CA 5.9V 6600RPM	Movimentação da gaveta de acomodação do sistema.
10	Servo Motor	9g	Abertura automatizada da tampa/janela de isolamento.
11	Conector USB	5V, 2 unidades	Alimentação de periféricos externos.
12	Fonte de alimentação	Externa	Fonte de energia dedicada ao sistema de iluminação (*Ring Light*).
13	Iluminação Ring Light	Ring Light LED QX-200 (6.500 K) 5v externa	Iluminação padronizada e uniforme para a captura exata de imagens.

Fonte: Autor (2025).

A arquitetura do sistema de medição foi estruturada sob o conceito de modularidade, permitindo a independência entre as etapas de aquisição física e processamento lógico, dividindo-se em três camadas principais: a camada de captura (*Hardware*), responsável pelo controle ambiental e digitalização da imagem; a camada

de comunicação, que utiliza o protocolo *TCP/IP* para o tráfego de dados via rede sem fio; e a camada de inferência (*Software*), onde os modelos de visão computacional e inteligência artificial processam os *frames* recebidos. Essa separação garante que melhorias no hardware ou trocas de sensores não exijam a reestruturação dos algoritmos de detecção, conferindo escalabilidade ao projeto.

O fluxo de dados inicia-se no módulo *ESP32-CAM*, que gerencia os gatilhos de captura sincronizados com a abertura da janela de isolamento e o acionamento da iluminação *LED*. A Figura 1B detalha essa interconexão, demonstrando como a interface gráfica do operador atua como o nó central de comando, solicitando a captura e recebendo o *stream* de dados para a análise morfométrica em tempo real.

Figura 3B - Visão geral do sistema de medição automatizada da espessura do mesocarpo

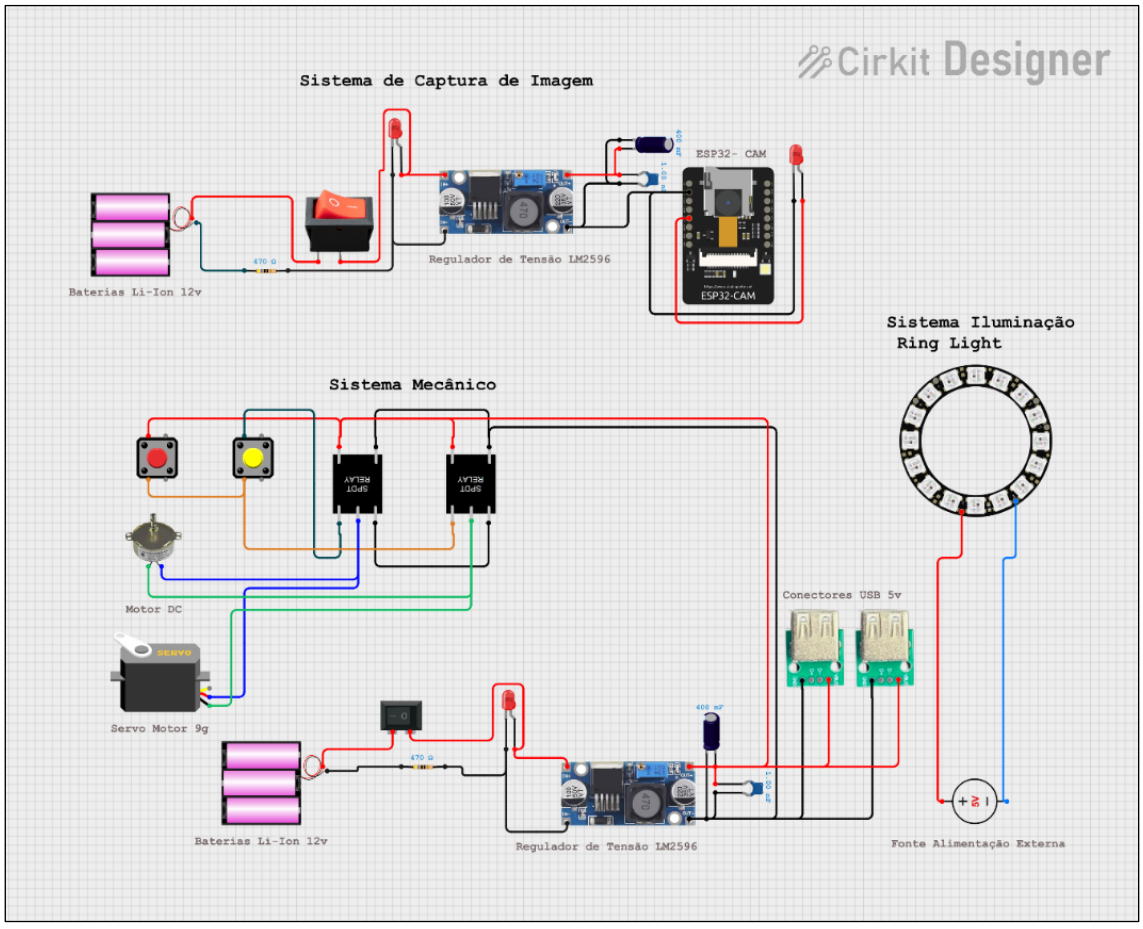

Fonte: Elaborado pelo autor utilizando o software CirkitDesigner (2024).

Estabilidade e proteção do circuito eletrônico

O projeto elétrico priorizou a estabilidade do sinal de vídeo, visto que o módulo *ESP32-CAM* é sensível a ruídos na alimentação e quedas de tensão (*brownouts*) durante a transmissão *Wi-Fi*. Para prevenir falhas de inicialização no sensor *OV5640*, o circuito integra um conversor *buck LM2596S*, que garante uma tensão estável de 5V e isola a lógica de processamento dos transientes gerados pelos atuadores mecânicos.

Adicionalmente, capacitores de desacoplamento e um barramento de aterramento *(GND)* robusto foram empregados para filtrar ruídos de alta frequência. O rigoroso isolamento elétrico entre a carga dos *LEDs* e a câmera previne interferências eletromagnéticas na matriz de *pixels*, assegurando a repetibilidade dos ensaios em regime contínuo, conforme detalha o diagrama da Figura 4B.

Figura 4B - Esquema elétrico do projeto de captura e análise de imagem

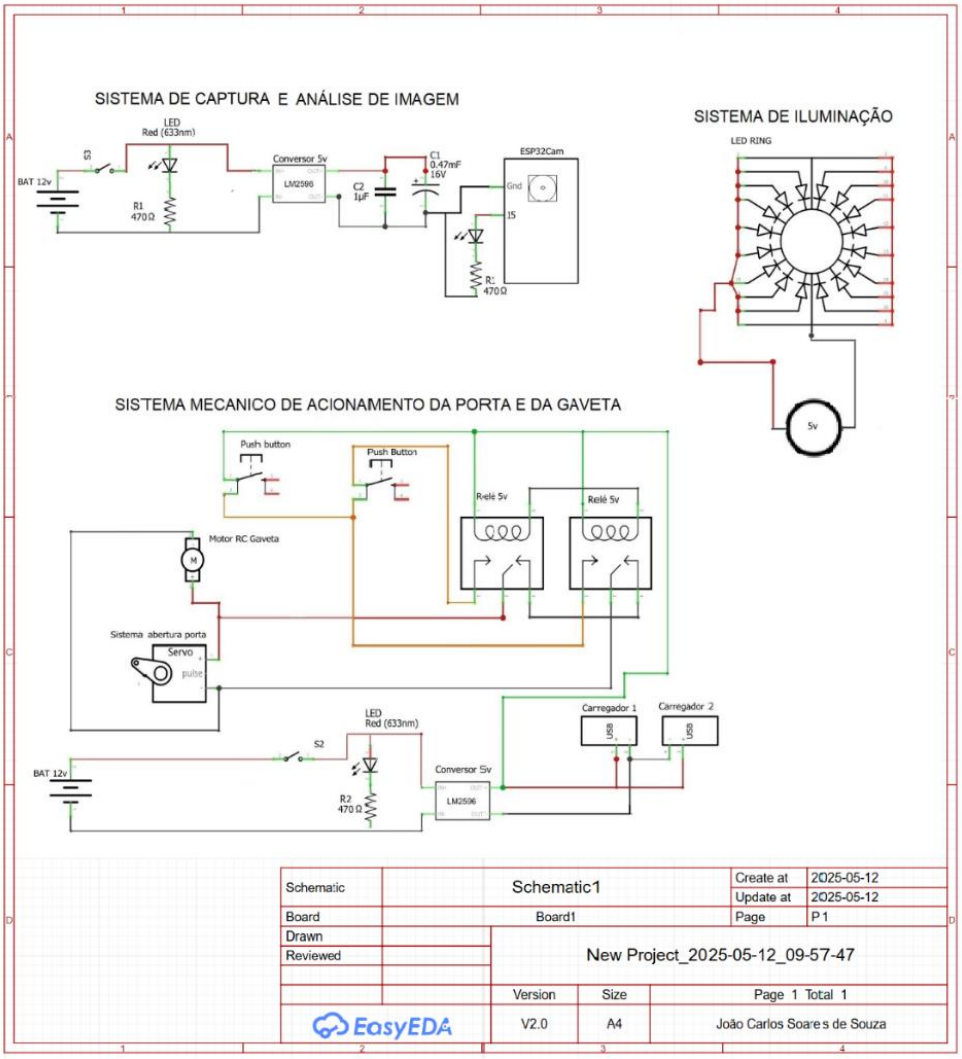

Fonte: Elaborado pelo autor utilizando o software EasyEDA (2024).

Declaração de integridade científica e uso de IAG

Em conformidade com a Política de Integridade na Atividade Científica do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), instituída pela Portaria nº 2.664, de 6 de março de 2026, declara-se o uso de ferramentas de Inteligência Artificial Generativa (IAG) exclusivamente como instrumentos de suporte técnico e metodológico durante o desenvolvimento desta dissertação.

As plataformas *Qwen (Alibaba Cloud, 2026)* e *GPT (Open IA, 2026)* foram empregadas nas fases iniciais de desenvolvimento para apoio à codificação lógica, esclarecimento de dúvidas pontuais de programação e sugestão de alternativas de implementação. A ferramenta *Perplexity AI (Perplexity AI, 2026)* foi utilizada para depuração avançada de algoritmos, organização da pesquisa bibliográfica relacionada ao treinamento das redes neurais e revisão estrutural de trechos de código. Adicionalmente, o sistema *Gemini Edu (Google, 2026)* foi aplicado na etapa de revisão gramatical e estilística do texto acadêmico, com vistas à adequação às normas da língua portuguesa e às diretrizes de formatação institucional.

O uso destas tecnologias restringiu-se ao suporte operacional e ao refinamento da linguagem e do código-fonte. Não foi delegada a essas ferramentas a concepção da pesquisa, a definição dos objetivos, o delineamento experimental, a coleta de dados primários, a interpretação dos resultados ou a formulação das conclusões científicas. Toda a fundamentação teórica, o planejamento experimental, a execução das atividades no Instituto Federal Goiano – Campus Morrinhos, a análise estatística dos dados e a redação final do conteúdo foram realizados de forma autônoma pelo autor.

Em consonância com a Portaria CNPq nº 2.664/2026, a responsabilidade integral pela originalidade, veracidade e integridade desta obra recai exclusivamente sobre o pesquisador, que assume também a responsabilização por eventuais erros, omissões ou imprecisões decorrentes do uso de ferramentas de IAG.

APÊNDICE C - PROCEDIMENTOS METODOLÓGICOS DE AQUISIÇÃO E POSIÇÃO DAS AMOSTRAS

Este apêndice detalha os procedimentos metodológicos adotados para o preparo das amostras, o posicionamento dos frutos e a aquisição das imagens utilizadas na medição automatizada da espessura do mesocarpo. São descritas as orientações referentes ao corte longitudinal e ao alinhamento em relação ao sistema de captura, com ênfase nas particularidades morfológicas dos frutos, complementando as etapas detalhadas no capítulo de Materiais e Métodos.

Todas as imagens foram obtidas a partir de um corte longitudinal dos frutos, expondo sua estrutura anatômica interna para a análise digital. Para garantir a precisão na extração de dados visuais, cada tomate foi posicionado sobre a base de acomodação com, no mínimo, uma das paredes septais (estruturas que separam os lóculos onde ficam armazenadas as sementes) orientada diretamente para a lente da câmera. Essa configuração assegura que a região do mesocarpo permaneça plenamente visível na área de captura, permitindo a delimitação correta das fronteiras anatômicas entre epicarpo, mesocarpo e cavidades loculares. A Figura 1C ilustra o posicionamento adotado para frutos com dois septos, destacando o alinhamento da secção longitudinal em relação ao eixo óptico do sistema.

Figura 1C - Posicionamento do fruto com dois septos em relação ao plano de corte e à câmera

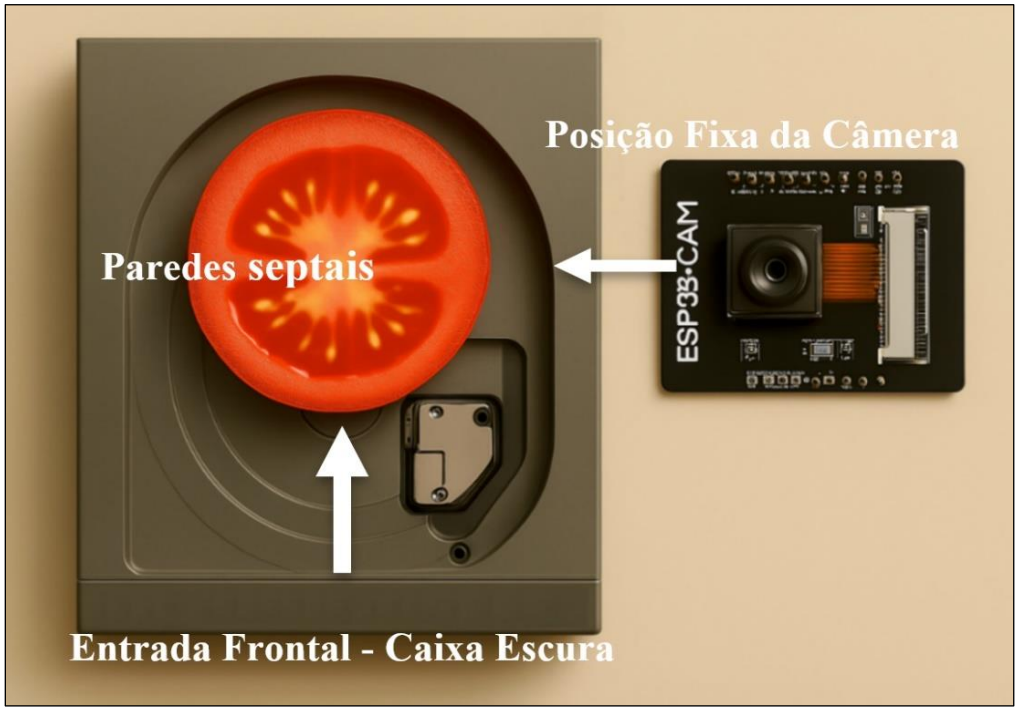

Fonte: Elaborado pelo autor com o auxílio da IA Microsoft Copilot Image (2025).

Para frutos com três ou mais septos, o procedimento de alinhamento foi adaptado para que a maior complexidade estrutural não gerasse oclusões na imagem. O posicionamento foi ajustado para manter pelo menos uma das paredes septais centralizada e voltada para a lente, garantindo que as múltiplas câmaras loculares fossem capturadas de forma equilibrada. Essa disposição evita o ocultamento parcial do mesocarpo e reduz assimetrias que poderiam comprometer o rastreamento feito pela inteligência artificial. A Figura 2C apresenta o esquema de posicionamento adotado para esses casos, confirmando a orientação do corte longitudinal e o enquadramento na base de acomodação.

Figura 2C - Posicionamento do fruto com dois ou mais septos em relação ao plano de corte à câmera

Fonte: Elaborado pelo autor com o auxílio da IA Microsoft Copilot Image (2025).

APÊNDICE D - FLUXO OPERACIONAL DO SISTEMA E INTERFACE DE CAPTURA E SUAS SUB-JANELAS

Neste apêndice é demonstrado como a gestão de dados do sistema ocorre de forma automatizada. Ao ser inicializado, o programa estruturado em *Python* cria sua pasta automaticamente na raiz no diretório padrão do sistema operacional (C:\SistemaVC), gerando subpastas essenciais para a operação: *ajuda*, *imagens*, *para_analise* e *relatorios*. A interface gráfica, desenvolvida com a biblioteca *Tkinter*, centraliza as operações por meio de um menu integrado, facilitando a navegação entre os módulos de captura, análise e exportação de resultados, conforme apresentado na Figura 1D.

Para garantir a integridade das informações, o sistema implementa uma rotina de salvamento incremental, evitando a sobreposição de dados brutos durante o processamento em lote. Os logs de execução e os arquivos de saída em formato (*.csv*) são armazenados automaticamente, permitindo a rastreabilidade de cada amostra. Essa estrutura foi projetada para garantir compatibilidade com sistemas de backup em nuvem, assegurando a preservação do banco de imagens utilizado no treinamento dos modelos de inteligência artificial.

Figura 1D – Interface gráfica principal do sistema de medição automatizada

Fonte: Autor (2025).

O processo de captura de imagens é viabilizado por um *firmware* embarcado no módulo *ESP32-CAM*, desenvolvido na plataforma *Arduino IDE*. O código disponibiliza dois *endpoints* principais: um para o envio de imagens codificadas em *Base64* e outro para a captura sob demanda via requisições *HTTP*. A comunicação via *Wi-Fi* integra a interface gráfica aos módulos de processamento e análise visual. A adoção da *Arduino IDE* justifica-se pela versatilidade e suporte à arquitetura do microcontrolador, permitindo a integração de bibliotecas em *C++* necessárias ao servidor web embarcado.

Além de servir como ambiente de compilação, a plataforma desempenhou papel fundamental na validação física do módulo por meio do monitor serial. O acompanhamento em tempo real das mensagens de diagnóstico e a confirmação do endereço *IP* atribuído ao *ESP32-CAM* foram cruciais para certificar o funcionamento da placa antes da integração definitiva. A Figura 2D ilustra a interface de comunicação e resposta do módulo durante as rotinas de captura.

Figura 2D - Interface de conexão e resposta do módulo ESP32-CAM durante a conexão WiFi para captura de imagens

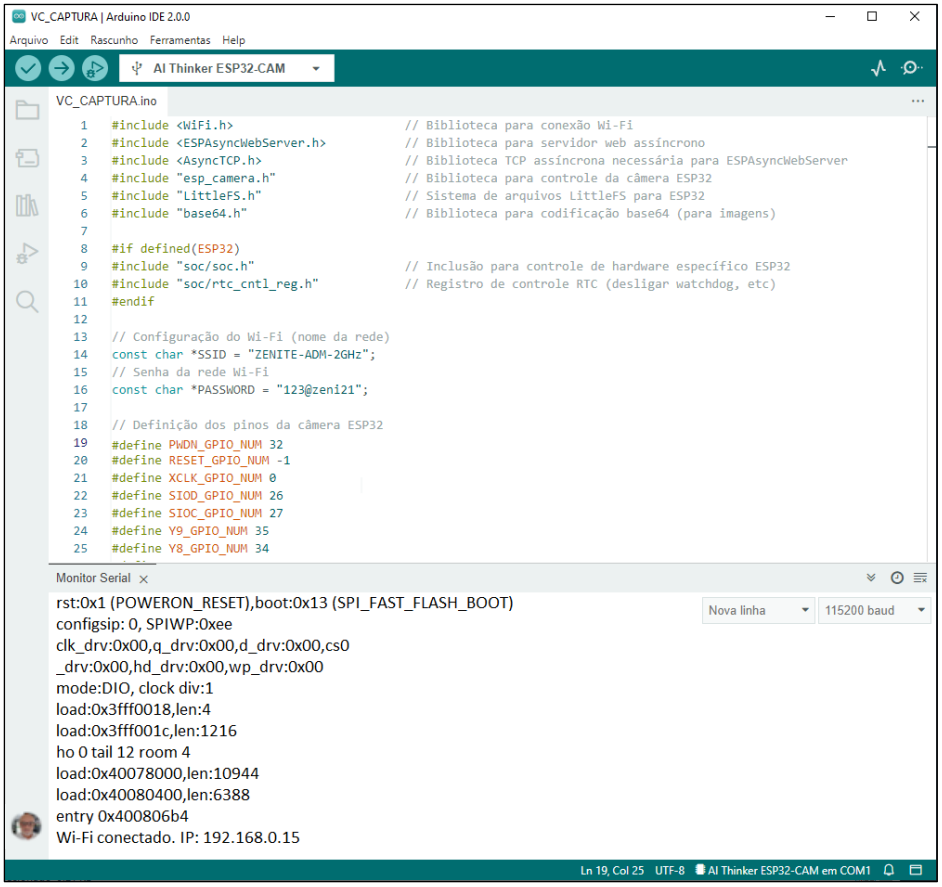

Fonte: Autor (2025).

O fluxo completo de funcionamento, desde a aquisição pelo módulo *ESP32-CAM* até a geração das medições calibradas, está sintetizado na Figura 3D. O fluxograma organiza as etapas de pré-processamento, segmentação, extração de características e inferência, garantindo a repetibilidade do *pipeline* de visão computacional.

Figura 3D - Fluxograma do pipeline para a medição automatizada do mesocarpo de tomates

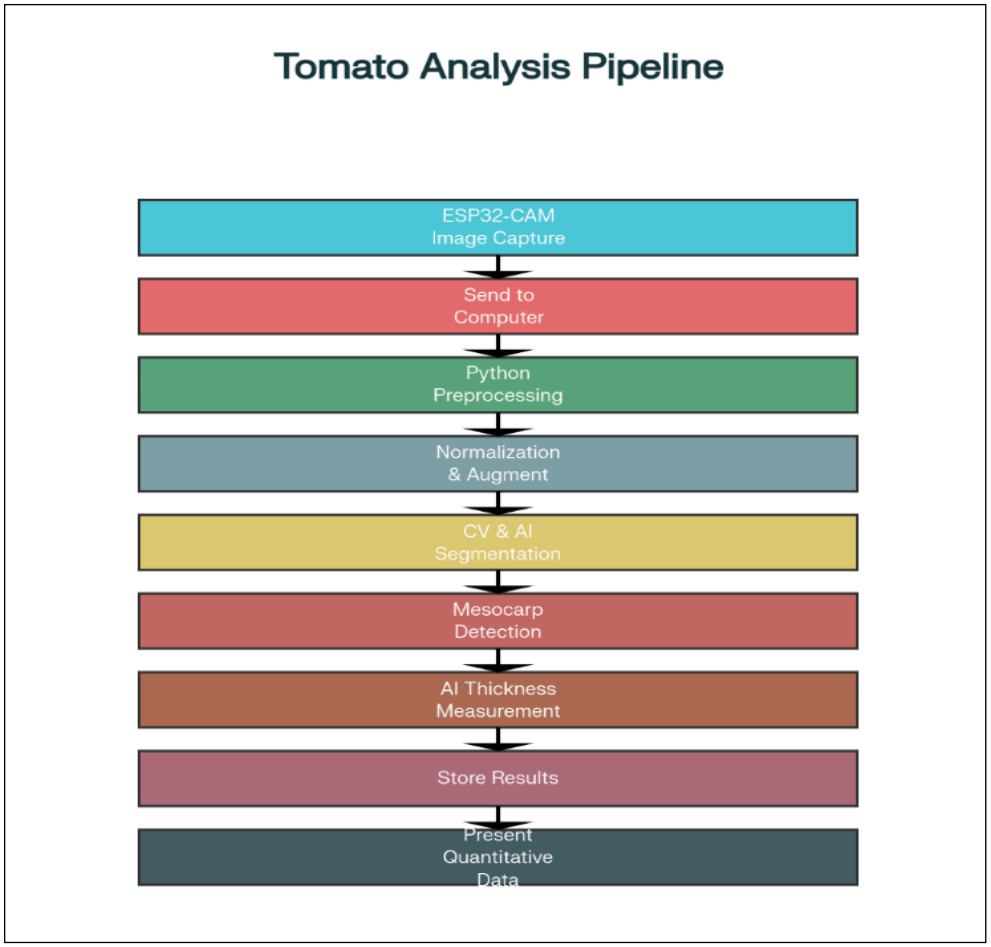

Fonte: Elaborado pelo autor com o auxílio da IA Google Gemini (2025).

A inteligência do sistema é direcionada para a arquitetura lógica da rede neural convolucional (*CNN*), responsável pela classificação e segmentação dos tecidos do fruto. O processamento segue um fluxo hierárquico onde camadas de convolução extraem mapas de características espaciais, seguidas por camadas de *pooling* para redução de dimensionalidade e camadas densas para a regressão dos valores dimensionais. Este processo, detalhado na Figura 4D, permite que o modelo identifique com precisão as bordas do mesocarpo mesmo sob variações morfológicas sutis (Faria et al., 2024).

Figura 4D - Fluxograma de arquitetura lógica e pipeline de processamento de rede neural convolucional

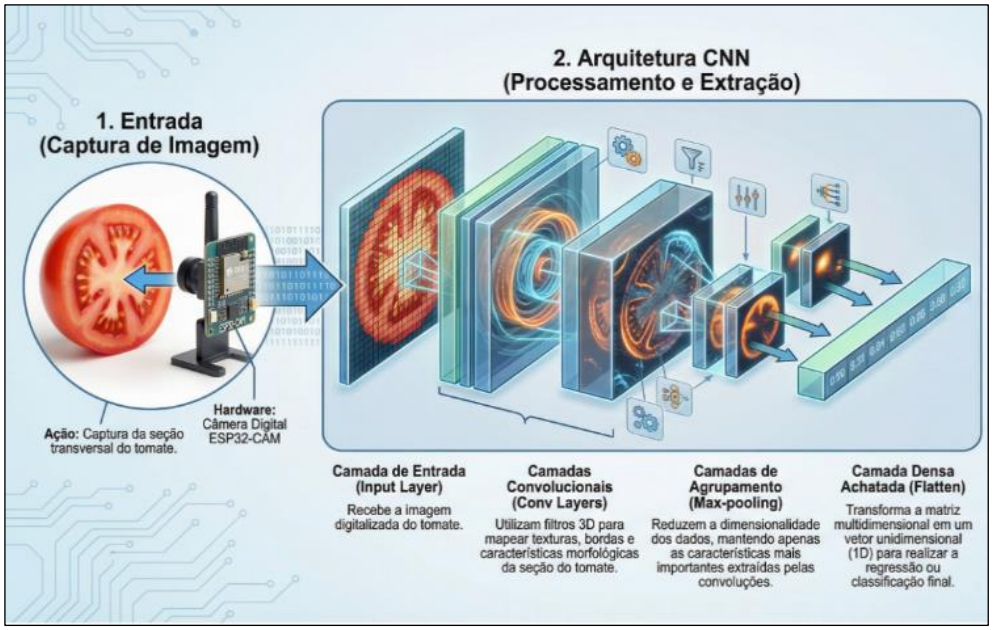

Fonte: Elaborado pelo autor com o auxílio da IA Nano Banana Pro (2026).

Para ampliar a compreensão da estrutura interna, o sistema gera uma reconstrução tridimensional a partir da nuvem de pontos capturada. A Figura 5D evidencia a morfologia do fruto através de uma malha densa composta por 182.410 pontos ativos. Esta representação permite visualizar a volumetria e a disposição dos septos internos em relação à parede externa do fruto antes da aplicação dos filtros de análise.

Figura 5D - Reconstrução tridimensional da morfologia do fruto evidenciando a densidade da malha (182.410) de pontos ativos

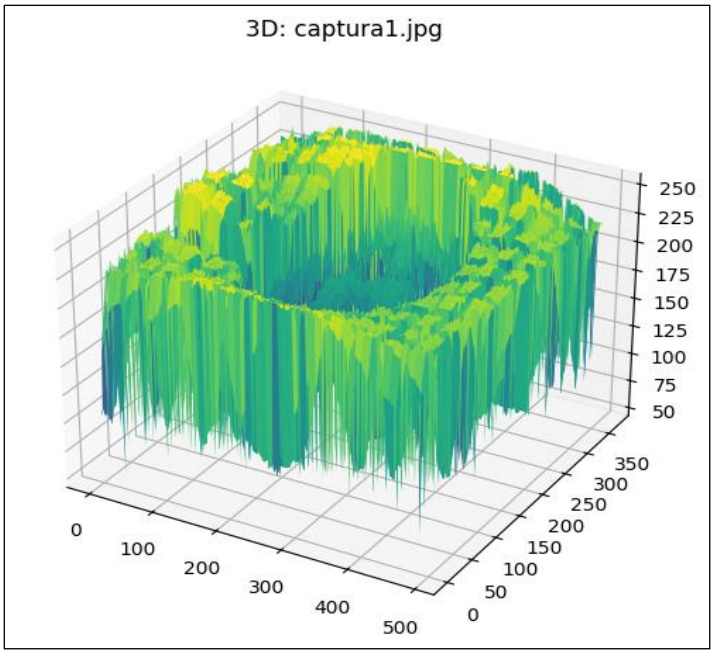

Fonte: Autor (2025).

Após a reconstrução inicial, o sistema aplica algoritmos de filtragem espacial para isolar as camadas de interesse e eliminar ruídos estruturais. A Figura 6D apresenta o resultado dessa filtragem, utilizando um parâmetro de corte de 4,60 mm para destacar a espessura do mesocarpo. Este procedimento de pós-processamento é essencial para garantir que a medição final reflita a espessura real do tecido, seguindo os protocolos de validação de modelos preditivos (Wang et al., 2025).

Figura 6D - Reconstrução tridimensional após a aplicação de filtro com parâmetro de corte de 4,60mm de espessura

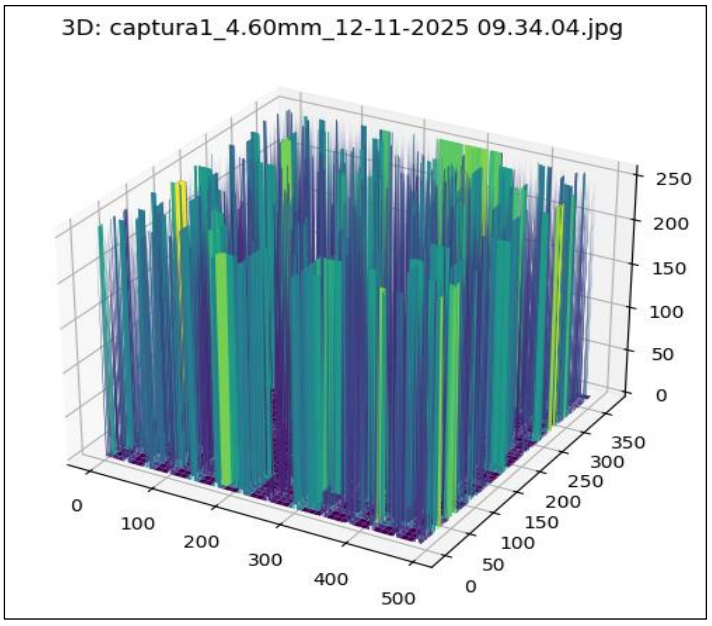

Fonte: Autor (2025).

APÊNDICE E - ANÁLISE GRÁFICA DE RESÍDUOS E DISPERSÃO ESTATÍSTICA

Este apêndice reúne o conjunto complementar de representações gráficas geradas durante o processamento estatístico dos dados no ambiente computacional R (operado via *RStudio*). O objetivo desta seção é fornecer o detalhamento visual e quantitativo que comprova o atendimento às premissas matemáticas dos testes paramétricos aplicados na pesquisa.

A Figura 1E apresenta o diagrama de caixa (*boxplot*) para a avaliação da variabilidade das medições. Os círculos brancos identificam os *outliers*, que representam eventuais valores atípicos em relação à distribuição principal dos dados. Por meio desta ferramenta visual, constata-se de maneira objetiva que os métodos automáticos se aproximam de forma confiável da realidade medida manualmente, ilustrando com clareza o comportamento da dispersão de dados.

Figura 1E - Boxplot comparativo das médias de medição entre os métodos Manual, Visão Computacional (VC) e Inteligência Artificial (IA)

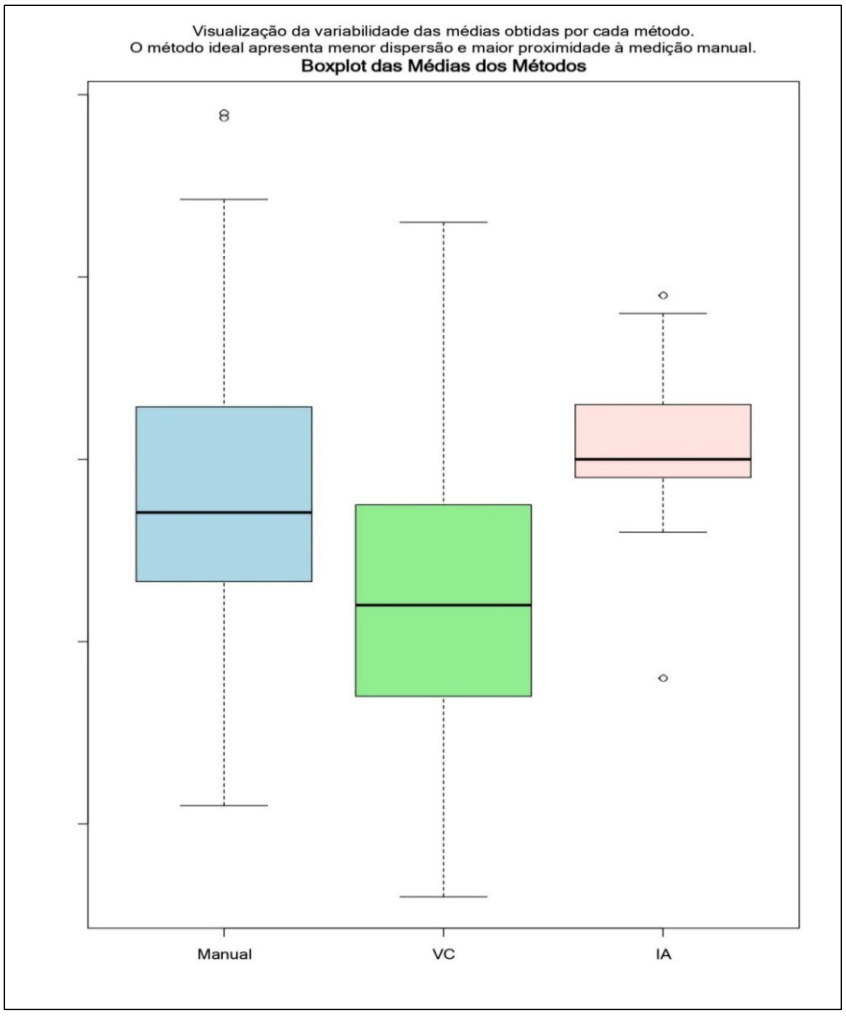

Fonte: Autor (2025).

A Figura 2E ilustra a ampla variabilidade interna do método manual por amostra. Os rótulos no eixo horizontal (real1 a real8) correspondem a 8 amostras físicas de tomates submetidas a múltiplas medições. Tais evidências visuais corroboram a robustez do método de Visão Computacional proposto, atestando a validade da concordância e a precisão do algoritmo quando comparado às medições de referência.

Figura 2E - Diagrama de caixa (boxplot) da variabilidade interna das medições manuais por amostra

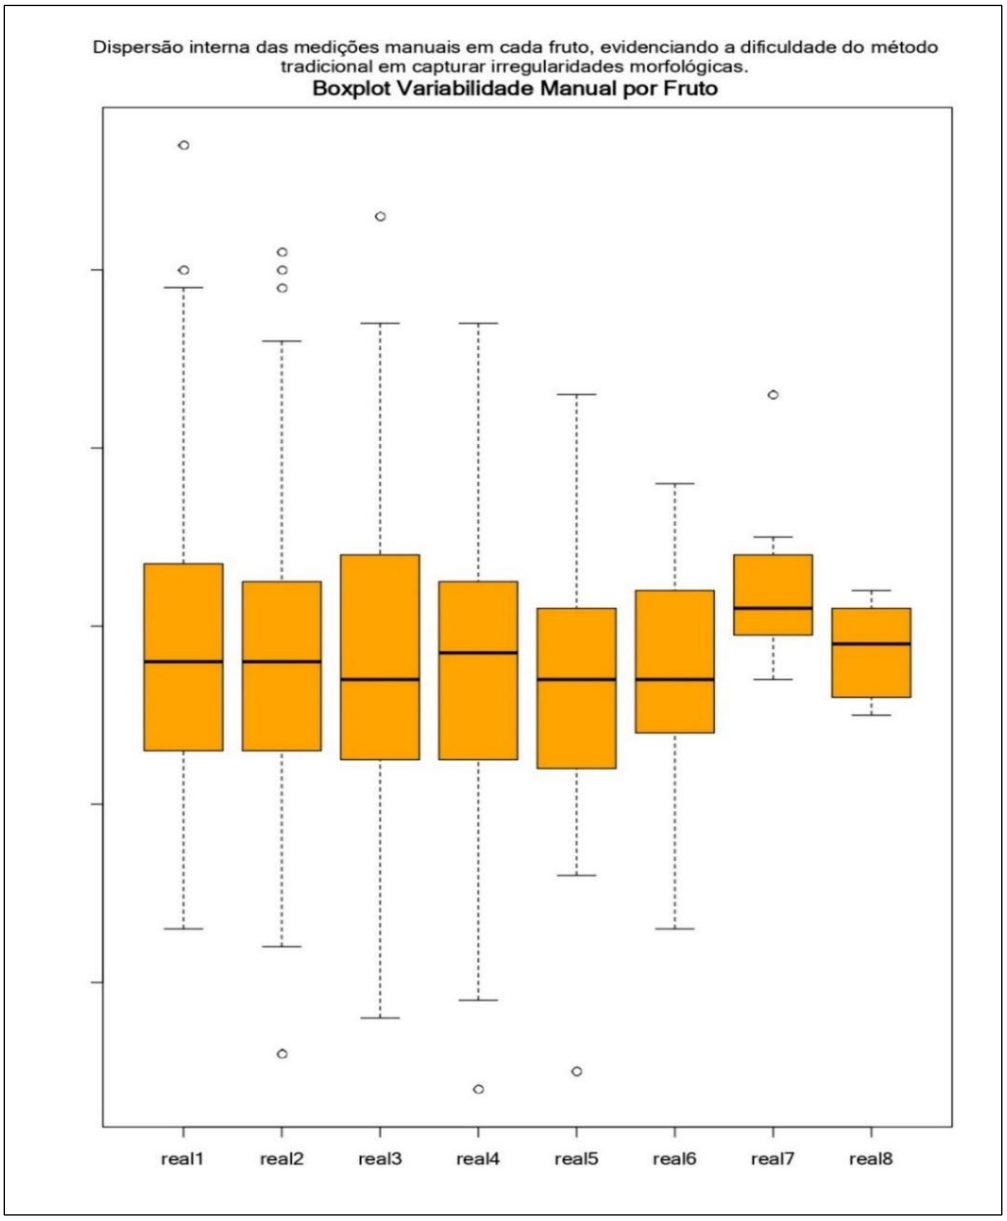

Fonte: Autor (2025).

Na avaliação do critério de erro máximo, a Tabela 1E apresenta a comparação direta dos métodos automatizados com o método manual. A verificação das métricas de erro e exatidão, como o MAPE e o MAE, atende aos princípios de Adequação e

Correção Funcional para avaliação da qualidade de produtos de software, estipulados pela norma ABNT NBR ISO/IEC 25023 (2024).

Tabela 1E - Principais indicadores estatísticos de desempenho e erro entre os métodos de medição

Comparação	**Correlação**	**p-valor teste-*t***	**MAE (mm)**	**R^2**	**MAPE (%)**	**Acurácia (%)**
Manual / VC	0.093	0.00000	0.923	0.009	13.12	86.88
Manual / IA	0.404	0.00005	0.608	0.163	9.24	90.76
VC / IA	0.138	0.00000	0.968	0.019	16.82	83.18

Fonte: Autor (2025).

A Inteligência Artificial (IA) apresentou Erro Percentual Médio Absoluto (MAPE) de 9,24% e acurácia de 90,76%. Esses resultados superam a margem de excelência de 85% definida para o projeto, indicando que a IA é altamente eficiente para substituir ou complementar o método manual em aplicações práticas. A Visão Computacional (VC) obteve um erro de 13,12% e acurácia de 86,88%, cumprindo também o critério de excelência, embora com um distanciamento ligeiramente maior em relação ao padrão manual quando comparado ao modelo de IA.

A comparação direta entre o método Manual e a Visão Computacional (VC) revelou uma *Correlação de Pearson* baixa (0,093) e um p-valor do teste-t pareado próximo a zero ($\sim 3{,}3 \times 10^{-7}$), rejeitando a hipótese nula de igualdade das médias. O Erro Médio Absoluto (MAE), indicador métrico recomendado para avaliação de desempenho preditivo (Willmott et al., 2005), apontou que a Visão Computacional difere do método Manual em 0,923 mm, com um R^2 de 0,009. Apesar dessas diferenças estatísticas de variância, a acurácia de 86,88% mantém o método dentro da faixa de aceitação do projeto.

Na comparação entre o método Manual e a Inteligência Artificial (IA), observou-se uma *Correlação de Pearson* superior (0,404), indicando que a IA acompanha o comportamento do método manual de forma mais aderente. O p-valor do teste-t pareado (0,00005) reafirma que os métodos geram resultados estatisticamente diferentes. Contudo, o MAE foi reduzido para 0,608 mm, com um R^2 de 0,163. O MAPE de 9,24% e a acurácia de 90,76% consolidam o desempenho superior desta abordagem preditiva.

O cruzamento entre os métodos automatizados (VC *versus* IA) demonstrou baixa correlação (0,138) e diferenças estatísticas significativas (p-valor = 0,00000). O MAE entre os sistemas foi de 0,968 mm, com MAPE de 16,82% e acurácia cruzada de 83,18%, indicando que, devido às lógicas de processamento distintas, as abordagens geram leituras com variações entre si, não atingindo o rigoroso critério de concordância interna de 85%.

As variações entre os métodos automáticos e o manual decorrem, em grande parte, da elevada representatividade espacial dos dados capturados (milhares de pixels analisados pelos algoritmos contra poucos pontos de aferição no paquímetro). O modelo de IA demonstrou acurácia superior, menor erro percentual e maior proximidade estatística do padrão físico, sendo equivalente e recomendado para protocolos de padronização. O método de VC mostrou-se viável operacionalmente, porém com menor acurácia geométrica.

A necessidade de adoção do método de *Bland-Altman* neste estudo justifica-se pela insuficiência dos coeficientes de correlação tradicionais (como o de *Pearson*) para atestar a intercambialidade entre instrumentos de medição. Enquanto a correlação avalia apenas a força e a direção da relação linear entre duas variáveis, a técnica de *Bland-Altman* quantifica especificamente a concordância metrológica, revelando a magnitude do erro sistemático (viés) e a amplitude da variabilidade aleatória por meio dos limites de tolerância.

Na fenotipagem automatizada do tomate, a validação de novos sistemas preditivos baseados em processamento de imagens e inteligência artificial contra o padrão físico (paquímetro manual) exige que as diferenças entre as aferições não ultrapassem margens agronomicamente aceitáveis. O viés médio, representado pela linha central contínua nos diagramas, indica se o método automático tende a superestimar ou subestimar sistematicamente a espessura do mesocarpo em relação à realidade. O intervalo de confiança de 95% (calculado convencionalmente como o viés ± 1,96 vezes o desvio padrão das diferenças) delimita a zona de segurança onde a imensa maioria das variações operacionais deve estar contida.

A aplicação dessa modelagem analítica fornece uma base robusta para a comprovação da eficácia tecnológica. Se os limites de concordância calculados forem estreitos o suficiente para não comprometer a tomada de decisão na seleção e padronização pós-colheita dos frutos, o sistema preditivo avaliado alinhando-se aos protocolos de validação não destrutiva (Wang et al., 2025). A transcrição visual desse

comportamento residual, essencial para atestar a confiabilidade dos algoritmos frente à variabilidade morfológica, é detalhada sequencialmente nas análises a seguir.

A Figura 3E apresenta a análise pelo método de *Bland-Altman*, o padrão estatístico exigido para avaliar a concordância entre dois instrumentos de medição. O eixo vertical ilustra a diferença das aferições, enquanto o eixo horizontal representa a média. As linhas tracejadas indicam o viés médio e os limites de concordância de 95%. Essa margem de 95% representa a tolerância estatística das divergências da amostragem, não devendo ser confundida com a acurácia global (85%) exigida para a validação sistêmica do algoritmo. A distribuição pontual evidencia que a absoluta maioria das medições geradas pela IA encontra-se estritamente dentro dos limites de tolerância estatística aceitáveis em relação ao manual.

Figura 3E - Gráfico de Bland-Altman para análise de concordância entre as medições manuais e por inteligência artificial (IA)

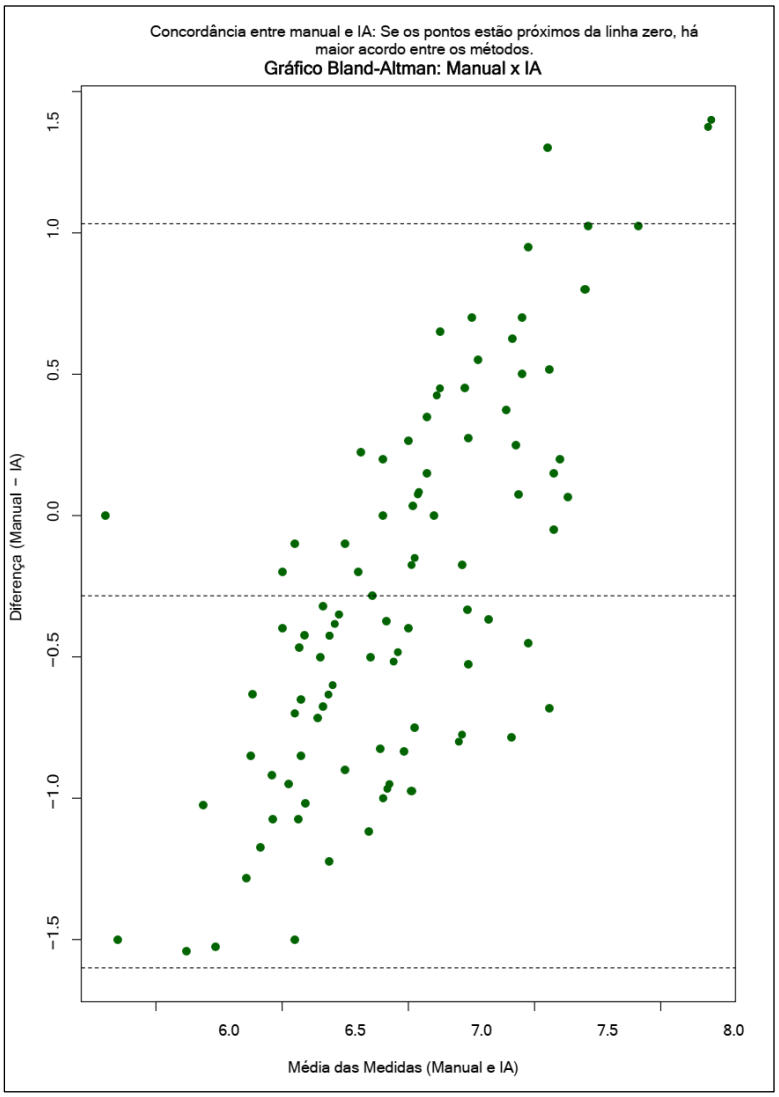

Fonte: Autor (2025)

A Figura 4E apresenta o gráfico de *Bland-Altman* para o método de Visão Computacional (VC), servindo como evidência do elevado alinhamento metrológico em relação ao padrão físico de referência, conforme preconizado pelos modelos de detecção não destrutivos (Wang et al., 2025). A distribuição dos resíduos mantém-se equilibrada ao longo do eixo das médias, com a vasta maioria das aferições rigorosamente contidas dentro dos limites de concordância de 95% (linhas tracejadas superior e inferior). A proximidade geométrica dos pontos em relação à linha central, que representa o viés médio, confirma que o algoritmo de Visão Computacional é capaz de replicar as medições manuais com precisão, validando a eficácia da solução para a automação da fenotipagem dos frutos.

A análise detalhada da dispersão revela que a técnica de processamento de imagem clássica não introduz erros sistemáticos significativos, mantendo a integridade dos dados mesmo diante da complexidade morfológica do mesocarpo. De acordo com a implementação de tecnologias de visão computacional na agricultura de precisão permite a transição de métodos de avaliação subjetivos para sistemas quantitativos de alta repetibilidade, eliminando as variações inerentes ao erro humano (Wang et al., 2025). A estabilidade demonstrada nos limites de concordância reforça a viabilidade do uso de sensores para a estimativa de dimensões de frutos, garantindo que o sistema seja tecnicamente viável para a substituição do método tradicional com o paquímetro.

Adicionalmente, a convergência estatística observada é essencial para a viabilidade de protocolos de avaliação da qualidade em larga escala. Conforme ressaltado por (Zhang et al., 2023), a avaliação abrangente da qualidade do tomate exige métodos que sejam simultaneamente precisos e rápidos, permitindo uma caracterização estrutural fiel. A extração de fenótipos baseada em reconhecimento de imagem, oferece uma alternativa robusta para a mensuração dessas características estruturais, o que é corroborado pela baixa amplitude dos resíduos no gráfico de concordância (Zhang et al., 2022). Essa precisão metrológica permite que o sistema seja integrado em fluxos de trabalho automatizados, onde a escala de análise é um fator determinante. o avanço na classificação de frutos através de ferramentas tecnológicas permite superar as limitações dos métodos convencionais, garantindo que a coleta de dados seja não apenas mais veloz, mas estatisticamente superior em termos de consistência (Almeida et al., 2024).

Os resultados da Figura 4E consolidam a maturidade técnica do algoritmo de VC, assegurando que as medições geradas refletem com exatidão a morfologia real das amostras analisadas

Figura 4E - Gráfico de Bland-Altman para análise de concordância entre as medições manuais e por Visão Computacional (VC)

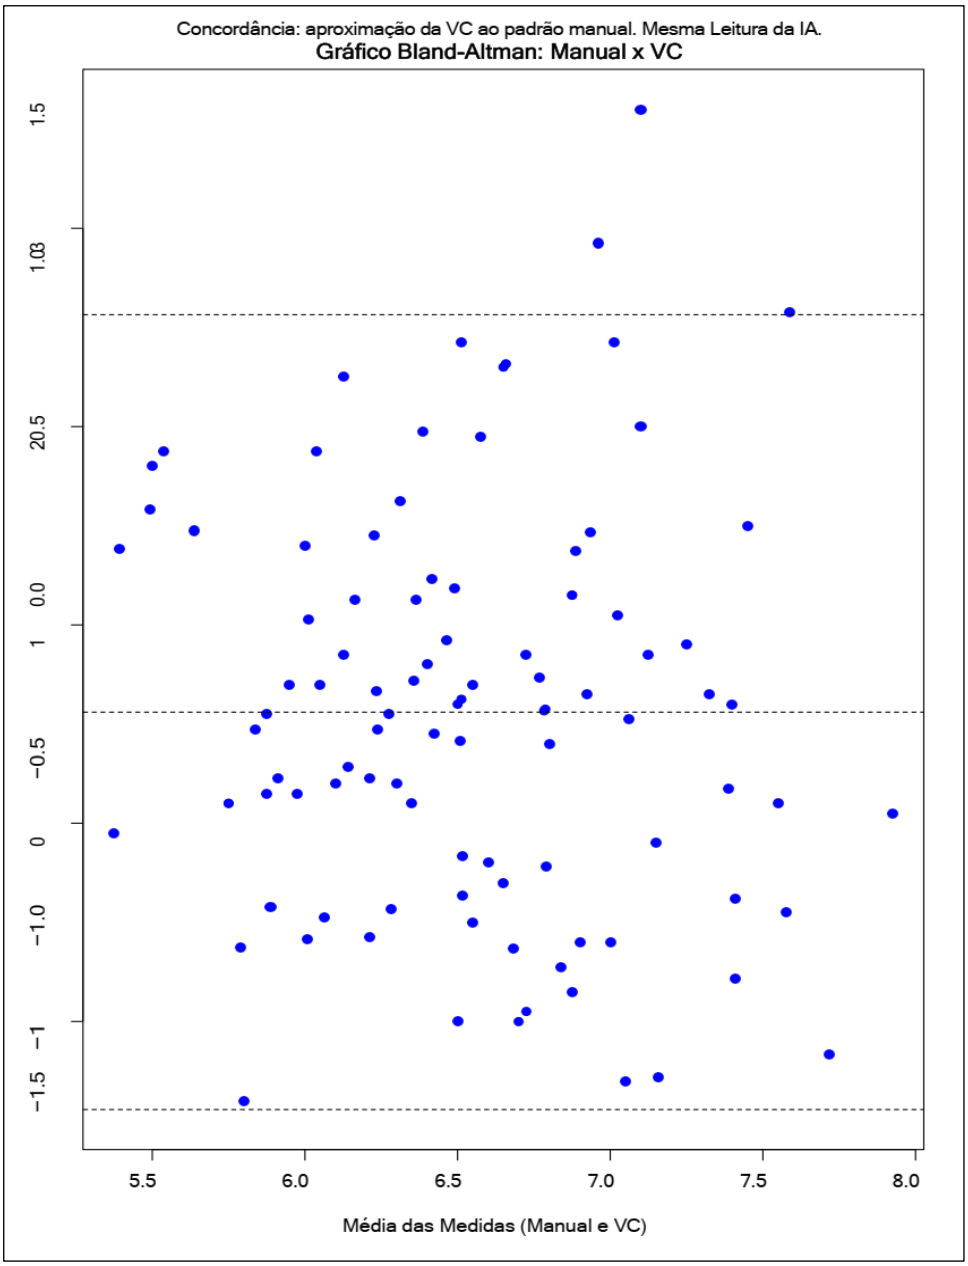

Fonte: Autor (2025).

Diferente das análises anteriores que utilizaram a medição física como referência, a Figura 5E compara as leituras geradas exclusivamente pelos sistemas eletrônicos desenvolvidos. A distribuição dos dados representados pelos pontos revela uma dispersão compacta em torno da linha central (viés médio), com a maioria absoluta das aferições contida dentro dos limites de concordância de 95%. Essa constatação confirma que, apesar de utilizarem lógicas de processamento distintas (técnicas de processamento de imagem clássicas e modelos de *Machine Learning)*, ambos os

algoritmos produzem resultados estatisticamente equivalentes. Tal evidência atesta a estabilidade e a intercambialidade das soluções tecnológicas propostas para a mensuração automática da espessura do mesocarpo.

A alta correlação entre os métodos automatizados reforça que a arquitetura de aquisição de dados é robusta o suficiente para suportar diferentes formas de processamento sem perda de integridade metrológica. a fenotipagem avançada na classificação de frutos de tomate, quando mediada por ferramentas tecnológicas, permite superar as limitações dos métodos convencionais de avaliação, garantindo uma análise de larga escala com precisão superior (Almeida et al., 2024). O fato de a Inteligência Artificial (IA) convergir para os mesmos valores da Visão Computacional (VC) demonstra que o treinamento do modelo foi capaz de extrair as características morfológicas reais do fruto, alinhando-se aos conceitos de terminologia e integridade sistêmica estabelecidos pela norma ABNT NBR ISO/IEC 22989 (2024).

A intercambialidade demonstrada na Figura 5E é crucial para a implementação de sistemas de monitoramento em tempo real na cadeia produtiva. A avaliação abrangente da qualidade do tomate exige métodos que consigam processar variáveis estruturais de forma rápida e precisa para garantir a identificação de compostos e características de valor comercial (Zhang et al. 2023). A extração quantitativa de fenótipos, fundamentada no reconhecimento de imagem encontra nesta equivalência estatística uma validação de que tanto algoritmos clássicos quanto modelos baseados em aprendizado profundo são aptos para a caracterização estrutural fiel (Zhang et al., 2022).

Esta redundância de precisão entre os sistemas eletrônicos consolida a viabilidade de modelos de detecção para métodos não destrutivos e para a qualidade do fruto, seguindo os parâmetros de pesquisa (Wang et al., 2025). A baixa amplitude dos limites de concordância no gráfico ratifica que a escolha entre uma tecnologia ou outra pode ser pautada pela disponibilidade de hardware ou custo computacional, visto que a entrega final do dado fenotípico permanece constante. Os resultados aqui apresentados validam o uso dessas tecnologias como ferramentas de suporte à decisão e automação da fenotipagem agronômica, garantindo confiabilidade estatística em todas as etapas de mensuração.

A convergência dos métodos automatizados estabelece um novo patamar de rigor para a fenotipagem digital, minimizando as discrepâncias comuns em medições manuais. A avaliação sistemática da qualidade e do comportamento fisiológico dos frutos exige metodologias que suportem diferentes condições de análise sem comprometer a

acurácia dos indicadores. Essa equivalência demonstrada na Figura 5E assegura que, independentemente da abordagem algorítmica utilizada, os dados extraídos sobre a espessura do mesocarpo mantêm a integridade necessária para estudos de desenvolvimento e monitoramento fisiológico, consolidando a robustez tecnológica das soluções propostas nesta pesquisa (Ali et al., 2024).

Figura 5E - Gráfico de Bland-Altman para análise de concordância entre os métodos automatizados: Visão Computacional (VC) versus Inteligência Artificial (IA).

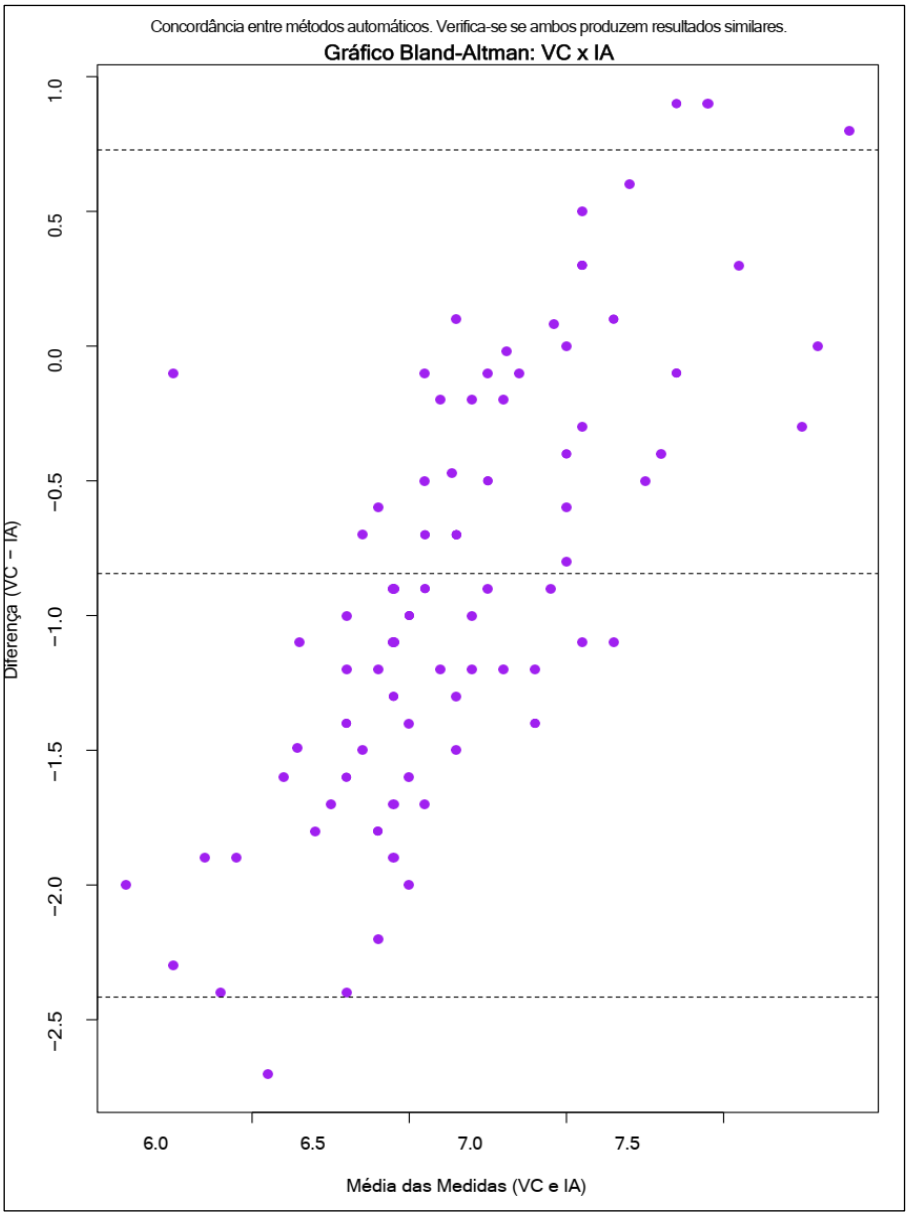

Fonte: Autor (2025).