



**UNIVERSIDADE ESTADUAL DA PARAÍBA
CAMPUS I - CAMPINA GRANDE
PRÓ-REITORIA DE PÓS-GRADUAÇÃO E PESQUISA
PROGRAMA DE PÓS-GRADUAÇÃO EM QUÍMICA
CURSO DE MESTRADO EM QUÍMICA**

PAULO FERREIRA DE BRITO

**DESENVOLVIMENTO DE UM SISTEMA INTEGRADO DE CLASSIFICAÇÃO
COLORIMÉTRICA PARA IDENTIFICAÇÃO DE ESTÁGIOS DE MATURAÇÃO DE
TOMATES TIPO ROMA**

CAMPINA GRANDE

2024

PAULO FERREIRA DE BRITO

**DESENVOLVIMENTO DE UM SISTEMA INTEGRADO DE CLASSIFICAÇÃO
COLORIMÉTRICA PARA IDENTIFICAÇÃO DE ESTÁGIOS DE MATURAÇÃO DE
TOMATES TIPO ROMA**

Dissertação apresentada ao Programa de Pós-Graduação em Química da Universidade Estadual da Paraíba como requisito para obtenção do título de Mestre em Química.

Área de concentração: Química

Orientador: Prof. Dr. José Germano Vêras Neto
Co-orientador - Prof. Dr. Railson de Oliveira Ramos

CAMPINA GRANDE

2024

É expressamente proibido a comercialização deste documento, tanto na forma impressa como eletrônica. Sua reprodução total ou parcial é permitida exclusivamente para fins acadêmicos e científicos, desde que na reprodução figure a identificação do autor, título, instituição e ano do trabalho.

B862d Brito, Paulo Ferreira de.

Desenvolvimento de um sistema integrado de classificação colorimétrica para identificação de estágios de maturação de tomates tipo Roma [manuscrito] / Paulo Ferreira de Brito. - 2024.

87 p. : il. colorido.

Digitado. Dissertação (Mestrado em Química) - Universidade Estadual da Paraíba, Centro de Ciências e Tecnologia, 2024. "Orientação : Prof. Dr. José Germano Vêras Neto, Departamento de Química - CCT. " "Coorientação: Prof. Dr. Railson de Oliveira Ramos , UEPB - Universidade Estadual da Paraíba "

1. controle de qualidade em linha. 2. pós-colheita. 3. reconhecimento de padrões. 4. arduino. 5. sensor TCS. I.
Título

21. ed. CDD 540

PAULO FERREIRA DE BRITO

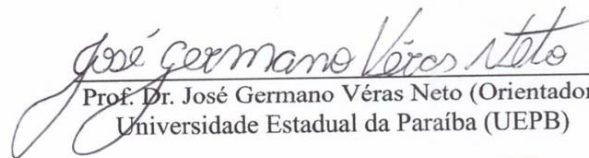
**DESENVOLVIMENTO DE UM SISTEMA INTEGRADO DE CLASSIFICAÇÃO
COLORIMÉTRICA PARA IDENTIFICAÇÃO DE ESTÁGIOS DE MATURAÇÃO DE
TOMATES TIPO ROMA**

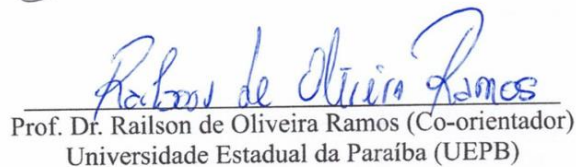
Dissertação apresentada ao Programa de Pós-Graduação em Química da Universidade Estadual da Paraíba como requisito para obtenção do título de Mestre em Química.

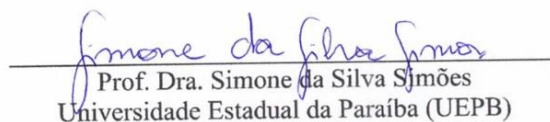
Área de concentração: Química

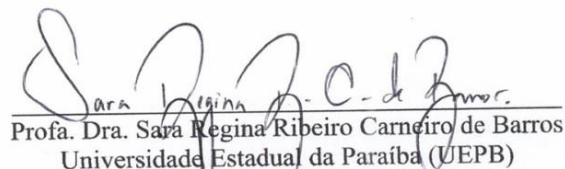
Aprovada em: 05/08/2024

BANCA EXAMINADORA


Prof. Dr. José Germano Vêras Neto (Orientador)
Universidade Estadual da Paraíba (UEPB)


Prof. Dr. Railson de Oliveira Ramos (Co-orientador)
Universidade Estadual da Paraíba (UEPB)


Prof. Dra. Simone da Silva Simões
Universidade Estadual da Paraíba (UEPB)


Profa. Dra. Sara Regina Ribeiro Carneiro de Barros
Universidade Estadual da Paraíba (UEPB)

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001. A conclusão deste trabalho representa a realização de um grande sonho, e não seria possível sem o apoio e incentivo de muitas pessoas e instituições. Por isso, dedico esta seção de agradecimentos àqueles que, de diversas formas, contribuíram para que este momento se tornasse realidade.

Primeiramente, gostaria de expressar meu profundo respeito e gratidão a Deus e aos Orixás. Agradeço a Exu, o mensageiro que abre os caminhos e guia meus passos; a Oyá, minha mãe senhora dos ventos e tempestades, que trouxe a força e a transformação necessárias para enfrentar os desafios; e a Oxalá, que acalmou meu Ori, trazendo paz e discernimento nos momentos mais difíceis. Que a sabedoria e a proteção de vocês continuem me guiando em todas as jornadas que estão por vir.

Expresso minha eterna gratidão às minhas mães, Nubia Ferreira Cunha e Maria do Carmo Ferreira Cunha, por todo o amor, cuidado e apoio incondicional. Vocês sempre acreditaram em mim, mesmo nos momentos mais difíceis, e foram minha base de força e motivação para seguir em frente. Este trabalho é, em grande parte, fruto dos valores que vocês me ensinaram.

Agradeço de coração à minha melhor amiga, Valdiênia Mendes Aguiar, por estar ao meu lado em todos os momentos, sejam eles de alegria ou dificuldade. Sua amizade é um dos maiores presentes que a vida me deu, e sua presença constante foi um pilar fundamental durante esta jornada. Obrigado por nunca me abandonar e por sempre me apoiar com palavras e gestos que me encorajaram a continuar.

Ao meu orientador, José Germano Veras Neto, dedico minha sincera gratidão pela paciência, dedicação e pelos valiosos ensinamentos ao longo deste processo. Sua orientação foi crucial para o meu desenvolvimento acadêmico e para a concretização desta pesquisa. Agradeço por acreditar no meu potencial e por me guiar com sabedoria até a conclusão desta etapa tão importante.

Também expresso meu profundo agradecimento ao meu coorientador, Railson de Oliveira Ramos, por todo o suporte técnico e científico prestado ao longo da pesquisa. Sua expertise foi essencial para superar os desafios encontrados e para o aprimoramento dos resultados obtidos. Agradeço pela disponibilidade e por compartilhar comigo seus conhecimentos com tanta generosidade.

Ao Programa de Pós-Graduação em Química (PPGQ) da Universidade Estadual da Paraíba (UEPB), agradeço pela formação sólida e pela oportunidade de crescer como pesquisador e profissional. As experiências e conhecimentos adquiridos durante o curso foram fundamentais para o desenvolvimento deste trabalho.

Por fim, mas não menos importante, agradeço ao Laboratório de Química Analítica e Quimiometria (LQAQ) por fornecer o espaço e os insumos necessários para a execução desta pesquisa. A infraestrutura, os equipamentos e o ambiente de trabalho do LQAQ foram essenciais para o progresso e a qualidade do estudo realizado.

A todos, meu muito obrigado. Sem o apoio, a paciência e a confiança de vocês, este trabalho não teria sido possível.

RESUMO

A indústria alimentícia enfrenta uma demanda crescente por métodos precisos e confiáveis para avaliar a qualidade dos tomates, com ênfase no parâmetro cor, crucial para determinar o estágio de maturação e a aceitação pelo consumidor. A análise visual tradicional, apesar de amplamente utilizada, apresenta deficiências significativas, tal como a subjetividade, resultando em variabilidade entre avaliadores. Em contraste, a visão computacional, com uso de sensores ópticos, oferece uma abordagem objetiva e consistente, permitindo a classificação precisa dos estágios de maturação com base em dados quantitativos. O presente estudo desenvolveu um método automático de classificação colorimétrica para tomates tipo Roma em diferentes estágios de maturação, utilizando o sensor óptico TCS3472 integrado com Arduino. A pesquisa buscou atender à necessidade da indústria alimentícia por métodos precisos e não destrutivos, capazes de distinguir entre tomates verdes, semi-maduros e maduros. Foram utilizados modelos de classificação univariada e multivariada, incluindo a análise de componentes principais (PCA), análise discriminante por componentes principais (PCA-DA) e a análise discriminante por mínimos quadrados parciais (PLS-DA). O desempenho dos modelos foi avaliado em termos de precisão, sensibilidade, especificidade e taxa de correção classificatória (TCC), comparando-se os espaços de cor RGB e CIE *Lab** e medidas de refletância. Os resultados indicaram que o modelo RGB, especialmente quando utilizado em SIMCA e PLS-DA, apresentou uma alta TCC, superior a 97%, com 98% de sensibilidade para tomates maduros, 94% para semi-maduros e 100% para verdes. A abordagem baseada na diferença entre os canais azul (B) e vermelho (R) mostrou-se particularmente eficaz, superando os modelos baseados em sinais individuais de R e G. Por outro lado, o modelo CIE *Lab** apresentou melhor desempenho na identificação de tomates verdes, mas mostrou dificuldades na classificação de tomates maduros e semi-maduros. A pesquisa conclui que o método baseado em RGB é mais adequado para aplicações que exigem alta precisão e confiabilidade na classificação dos estágios de maturação dos tomates, enquanto o método baseado em refletância CIE *Lab** pode ser útil em contextos onde a identificação de tomates verdes seja crítica. A aplicação prática do método proposto pode otimizar a seleção e o processamento de tomates na indústria, contribuindo para a redução de perdas pós-colheita e aumentando a eficiência dos processos de produção.

Palavras-chave: controle de qualidade em linha; pós-colheita; reconhecimento de padrões; arduino; sensor TCS3472.

ABSTRACT

The food industry is facing a growing demand for precise and reliable methods to assess the quality of tomatoes, with an emphasis on the color parameter, which is crucial for determining the ripeness stage and consumer acceptance. Traditional visual analysis, although widely used, presents significant deficiencies, such as subjectivity, resulting in variability among evaluators. In contrast, computer vision using optical sensors offers an objective and consistent approach, allowing for precise classification of ripening stages based on quantitative data. This study developed an automatic colorimetric classification method for Roma tomatoes at different ripening stages, utilizing the TCS3472 optical sensor integrated with Arduino. The research aimed to meet the food industry's need for precise, non-destructive methods capable of distinguishing between green, semi-ripe, and ripe tomatoes. Univariate and multivariate classification models were used, including principal component analysis (PCA), principal component discriminant analysis (PCA-DA), and partial least squares discriminant analysis (PLS-DA). The models' performance was evaluated in terms of accuracy, sensitivity, specificity, and correct classification rate (CCR), comparing the RGB and CIE Lab* color spaces along with reflectance. The results indicated that the RGB model, especially when used in SIMCA and PLS-DA, achieved a high CCR, above 97%, with 98% sensitivity for ripe tomatoes, 94% for semi-ripe, and 100% for green. The approach based on the difference between the blue (B) and red (R) channels proved particularly effective, surpassing models based on individual R and G signals. On the other hand, the CIE Lab* model performed better in identifying green tomatoes but showed difficulties in classifying ripe and semi-ripe tomatoes. The research concludes that the RGB-based method is more suitable for applications requiring high precision and reliability in classifying tomato ripening stages, while the CIE Lab* reflectance-based method may be useful in contexts where identifying green tomatoes is critical. The practical application of the proposed method can optimize tomato selection and processing in the industry, contributing to reducing post-harvest losses and increasing production process efficiency.

Keywords: inline quality control; post-harvest; pattern recognition; Arduino; TCS3472 sensor.

LISTA DE ILUSTRAÇÕES

Figura 1. Esteira transportadora com cabine de análise colorimétrica	28
Figura 2. Variação dos sinais de intensidade de cor (B: Azul, R: Vermelho, G: Verde) captados por sensores ópticos TCS3472 em cinco tomates maduros, cinco tomates semi-maduros e cinco tomates verdes, conforme eram expostos nos sensores em relação ao tempo de exposição.....	36
Figura 3 Espectros de variação RGB (Vermelho, Verde, Azul) para tomates em diferentes estágios de maturação. (I) medidas brutas e (II) medidas após alinhamento dos dados.	37
Figura 4 Gráfico (A) Scores, (B) Influência de PCA para a escala de cores RGB.....	39
Figura 5 Espectros de refletância obtidos pelo colorímetro CS-420 (A) das amostras em diferentes estágios de maturação, (B) tomates maduros, (C) tomates semi-maduros, (D) tomates verdes	45
Figura 6 Gráfico (A) Scores, (B) Influência de PCA para reflectância.....	48

LISTA DE TABELAS

Tabela 1. Métricas gerais para os ensaios Físico-químicos dos 150 tomates.	34
Tabela 2. Métricas obtidas por meio da definição dos limiares para os sinais RGB	38
Tabela 3. Métricas obtidas por PCA-DA para os modelos de treinamento RGB	40
Tabela 4. Métricas obtidas por PLS-DA para os modelos de treinamento RGB	42
Tabela 5. Métricas obtidas por SIMCA para os modelos de treinamento RGB	43
Tabela 6. Métricas obtidas por meio da definição dos limiares para os dados CIE L* a* b*	46
Tabela 7. Métricas obtidas por PCA-DA para os modelos de treinamento Reflectância.	50
Tabela 8. Métricas obtidas por PLS-DA para os modelos de treinamento para reflectância	51
Tabela 9. Métricas obtidas por SIMCA para os modelos de treinamento para a refletância	52

SUMÁRIO

1	INTRODUÇÃO	11
2	OBJETIVOS	13
2.1	OBJETIVO GERAL.....	13
2.2	OBJETIVOS ESPECÍFICOS	13
3	FUNDAMENTAÇÃO TEÓRICA	14
3.1	PRESENÇA DO TOMATE NA ECONOMIA BRASILEIRA.....	14
3.1.1	Legislação e regulamentação para o comércio do tomate.....	15
3.1.2	Análises para a qualidade e maturação do tomate.....	15
3.2	ANÁLISES NÃO DESTRUTIVAS DO GRAU DE MATURAÇÃO DE TOMATES	17
3.3	EFICÁCIA DA COLORIMETRIA NA AVALIAÇÃO NÃO DESTRUTIVA	19
3.3.1	Métodos colorimétricos para avaliação de tomates.....	19
3.3.2	Utilização de sensores ópticos (TCS3472) na análise de variação de cor.....	20
3.4	QUIMIOMETRIA	22
3.4.1	Análise por Componentes Principais (PCA).....	22
3.4.2	Análise Discriminante por Componentes Principais (PCA-DA).....	24
3.4.3	Análise Discriminante por Regressão de Mínimos Quadrados Parciais (PLS-DA)...	25
3.4.4	Análise de Componentes Independentes por Modelagem Classificatoria (SIMCA) .	26
4	MATERIAL E MÉTODOS	28
4.1	AQUISIÇÃO E PREPARAÇÃO DAS AMOSTRAS	28
4.2	ANÁLISES POR SENSORES TCS3472	28
4.2.1	Algoritmo de controle dos sensores, aquisição e tratamento dos sinais.....	29
4.3	ANÁLISE PELO COLORIMETRO DIGITAL CS-420.....	30
4.4	ANÁLISES FÍSICO-QUÍMICAS DOS TOMATES	30
4.4.1	Determinação dos Sólidos Solúveis (°Brix)	31
4.4.2	Determinação do pH.....	31
4.4.3	Determinação da Acidez Titulável	31
4.5	TRATAMENTOS QUIMIOMÉTRICOS	32
4.5.1	Pré-processamento	32
4.5.2	Análise de Componentes Principais (PCA).....	32
4.5.3	Obtenção dos limiares	32
4.5.4	Separação dos conjuntos de teste e treinamento.	32
4.5.5	Análise de Reconhecimento de Padrões	33
4.5.6	Técnicas de Análise Multivariada	33
4.5.7	Comparação de Métodos.....	33
5	RESULTADOS E DISCUSSÃO	34

5.1	ANÁLISES FÍSICO-QUÍMICAS	34
5.2	COLORIMETRIA.....	36
5.2.1	Sinais de intensidade RGB obtidos pelos sensores TCS3472.....	36
5.2.1.1	<i>Classificação univariada por análise de limiar para os sinais de intensidade RGB</i>	<i>37</i>
5.2.1.2	<i>Análise por Componentes Principais (PCA) - RGB.....</i>	<i>38</i>
5.2.1.3	<i>Reconhecimento de padrão supervisionado - RGB.....</i>	<i>40</i>
5.2.1.3.1	<i>PCA-DA para dados RGB</i>	<i>40</i>
5.2.1.3.2	<i>PLS-DA para dados RGB</i>	<i>41</i>
5.2.1.3.3	<i>SIMCA para dados RGB.....</i>	<i>42</i>
5.2.2	Sinais de obtidos pelo colorímetro digital CS-420.....	44
5.2.2.1	<i>Classificação por análise de limiar para dados CIE L* a* b*.....</i>	<i>45</i>
5.2.2.2	<i>Análise por Componentes Principais (PCA) – Refletância.....</i>	<i>47</i>
5.2.1.3	<i>Reconhecimento de padrão supervisionado – Refletância.....</i>	<i>49</i>
5.2.2.3.1	<i>PCA-DA para dados de refletância</i>	<i>49</i>
5.2.1.3.2	<i>PLS-DA para dados de refletância</i>	<i>51</i>
5.2.1.3.3	<i>SIMCA para dados de refletância</i>	<i>52</i>
5.2.3	Comparação Entre Modelos	53
5.2.3.1	<i>Limiares</i>	<i>53</i>
5.2.3.2	<i>PCA.....</i>	<i>53</i>
5.2.3.3	<i>PCA-DA</i>	<i>54</i>
5.2.3.4	<i>PLS-DA.....</i>	<i>55</i>
5.2.3.5	<i>SIMCA</i>	<i>55</i>
6	CONCLUSÃO	56
	REFERÊNCIAS	58
	APÊNDICE A – MEDIDAS DE pH PARA CADA AMOSTRA.....	67
	APÊNDICE B – MEDIDAS DE BRUX PARA CADA AMOSTRA	72
	APÊNDICE C – MEDIDAS DE ACIDEZ TOTAL PARA CADA AMOSTRA	77
	APÊNDICE D – SCRIPT PARA ALGORITMO DE VISÃO DE MÁQUINA.....	82

1 INTRODUÇÃO

O tomate (*Solanum lycopersicum*) é um fruto de importância econômica significativa na indústria alimentícia global. Em 2022, o Brasil produziu aproximadamente 3,8 milhões de toneladas de tomate, com Goiás liderando a produção nacional e a Paraíba ocupando a 12ª posição. A produção em Goiás é direcionada ao processamento industrial do tomate, incluindo polpa e extrato, enquanto o Nordeste, com destaque para a Paraíba, é mais voltado para o consumo *in natura*. Esses dados sublinham a importância econômica do tomate e a necessidade de práticas eficazes para garantir a qualidade e a durabilidade dos frutos, especialmente na classificação dos estágios de maturação (IBGE, 2022).

A classificação dos estágios de maturação impacta diversos parâmetros de qualidade de frutos, entre estes podem ser citados o teor de sólidos solúveis, a quantidade de açúcar, a acidez e o pH. A escolha correta do estágio de maturação não só melhora a aceitação dos produtos pelos consumidores como também ajuda a reduzir o desperdício para os consumidores finais, beneficiando tanto o mercado de consumo *in natura* quanto o de processamento (TOLASA *et al.*, 2021).

Estudos sobre os processos fisiológicos e bioquímicos da maturação do tomate são fundamentais para aprimorar métodos de cultivo e colheita. No entanto, os métodos utilizados são destrutivos ou, no mínimo, podem comprometer a integridade das amostras, o que é um fator a ser considerado na escolha do procedimento de avaliação a ser adotado (SOYTONG *et al.*, 2021). Para mitigar essas limitações, técnicas não destrutivas, como a análise colorimétrica, têm se mostrado eficazes para atender a demanda dos produtores e consumidores finais na classificação de frutos, incluindo tomates. Neste sentido, métodos uni e multivariados são usados para criar modelos preditivos que correlacionam cor com características químicas e sensoriais, ajudando na seleção de tomates que atendam aos padrões de mercado e reduzindo perdas pós-colheita (MARQUES *et al.*, 2022).

Dentre os métodos colorimétricos aqueles que utilizam sensores ópticos portáteis são amplamente utilizados para medir a variação de cor, oferecendo medições rápidas e precisas em diversos contextos, como na indústria alimentícia, farmacêutica e de cosméticos. Esses sensores se baseiam em princípios como espectroscopia de absorção, fluorescência e reflexão, e frequentemente permitem a conectividade sem fio para transferência de dados em tempo real (HU *et al.*, 2023). Entre os sensores ópticos, o TCS3472 se destaca por sua capacidade de detectar variações sutis na cor e fornecer dados precisos sobre a coloração de diferentes matrizes, incluindo tomates. Este sensor converte a intensidade do espectro de cores em sinais

de frequências distintas, facilitando a avaliação quantitativa da qualidade cromática e a otimização dos processos de produção (LYSENKO *et al.*, 2021).

Este trabalho, diante da necessidade de um controle mais eficiente da qualidade dos tomates, tem como objetivo o desenvolvimento de um método para classificar tomates do tipo Roma em um sistema de esteira, utilizando o sensor óptico TCS3472 para colorimetria e avaliação do grau de maturidade dos frutos por métodos uni e multivariados.

2 OBJETIVOS

2.1 OBJETIVO GERAL

Desenvolver um método automático de classificação colorimétrica para categorização de tomates do tipo Roma em diferentes estágios de maturação em esteira utilizando sensor óptico TCS3472 e Arduino a partir de modelos de classificação uni e multivariada.

2.2 OBJETIVOS ESPECÍFICOS

1. Adaptar um sistema de detecção de cor em esteira usando sensores TCS3472 e Arduino para a classificação do tomate quanto ao seu grau de maturação.
2. Desenvolver e validar limiares de classificação com base na análise dos picos de cor e calibrar o sistema para diferentes lotes de tomates.
3. Aplicar métodos de reconhecimento de padrões não supervisionado (PCA) e supervisionados (PCA-DA e PLS-DA) aos espectros de reflectância na região do visível e aos histogramas de frequência na região RGB para a classificação de maturação do tomate.
4. Comparar a eficácia dos modelos de classificação baseados nos espaços de cor RGB e CIE $L^* a^* b^*$, e validar seu desempenho em termos de precisão, sensibilidade e especificidade para os diferentes estágios de maturação dos tomates.
5. Comparar a eficácia dos métodos uni e multivariados na classificação do grau de maturação dos tomates, avaliando a precisão, sensibilidade e especificidade de cada abordagem.

3 FUNDAMENTAÇÃO TEÓRICA

3.1 PRESENÇA DO TOMATE NA ECONOMIA BRASILEIRA

O tomate é um fruto com uma significativa importância no Brasil por compor a dieta alimentar de grande parte da população e, portanto, tendo esta cultura destacado impacto econômico. Como forma de avaliação do impacto da produção nacional, em 2020 o Brasil tornou-se o 9º maior produtor mundial de tomate produzindo 3.956.559 toneladas, com a Região Sudeste contribuindo com 1.851.962 toneladas. Goiás foi o maior produtor, com 1.059.871 toneladas, e a Paraíba apresentou uma produção variada em seus 223 municípios, com destaque para cidades como Caaporã e Campina Grande.

Para além da relevância do fruto em si para a dieta do brasileiro, o resíduo industrial do tomate também tem um papel relevante, sendo utilizado na alimentação de vacas leiteiras como uma solução econômica e nutritiva, podendo compor até 30% da dieta. Esta prática é vantajosa tanto do ponto de vista nutricional quanto econômico, contribuindo para a sustentabilidade na produção pecuária (CARDOSO e REIS, 2023). Esses dados destacam a relevância econômica do tomate no Brasil, tanto na dieta nacional quanto como uma commodity agrícola importante (BISSACOTTI, *et al.*, 2021; IBGE, 2023; CARDOSO e REIS, 2021; BARROS, 2024).

Dentre os tomates produzidos no Brasil o tipo Roma, também denominado de italiano, destaca-se por suas características como sabor suave e alto teor de açúcares naturais, tornando-o uma opção viável para consumo *in natura*, para as indústrias de bebidas alcoólicas e alimentícias. Além disso, a disponibilidade da variedade ao longo do ano e baixo custo favorecem sua utilização, promovendo a sustentabilidade e agregando valor ao mercado de bebidas alcoólicas (BARROS, 2024).

Entretanto, uma preocupação significativa de produtores de tomates e da indústria alimentícia é com o grau de maturidade dos frutos visto ser este o principal problema em perdas na colheita e pós-colheita. Além disso, a maturação do tomate é determinante para a qualidade sensorial e aceitação pelo consumidor. A colheita no momento correto afeta a textura, aroma e durabilidade do produto, sendo essencial para minimizar perdas e garantir a rentabilidade da produção. Assim sendo, adotar práticas e tecnologias adequadas para monitorar a maturação é fundamental para assegurar a qualidade dos tomates destinados à indústria ou ao consumo *in natura* (PEDROSO, 2020). Para isto, normas nacionais e transnacionais são importantes para garantir a qualidade do fruto ou dos produtos gerados para o mercado interno ou externo.

3.1.1 Legislação e regulamentação para o comércio do tomate

A legislação e regulamentação para o comércio do tomate no âmbito do MERCOSUL são baseadas no "Regulamento Técnico MERCOSUL de Identidade e Qualidade de Tomate", aprovado pela Resolução GMC nº 26/17. Este regulamento visa definir as características de identidade e qualidade do tomate *in natura*, assegurando uniformidade na identificação e classificação, contribuindo para a saúde dos consumidores e eliminando barreiras técnicas não tarifárias que possam afetar o comércio (MINISTÉRIO DA AGRICULTURA, 2018).

O regulamento aplica-se a todos os países que compõem o MERCOSUL, abrangendo tanto o comércio interno quanto as importações extrazona. Para assegurar clareza e eficácia das normas, o regulamento inclui definições essenciais, como "tomate", "identidade", "qualidade", "embalagem" e "lote", fundamentais para a compreensão e aplicação das diretrizes estabelecidas. Nesta norma, os tomates são classificados em calibres e categorias, com critérios específicos que determinam a aceitação ou rejeição de lotes, dependendo da presença de defeitos e das condições de conservação. A regulamentação também estabelece requisitos para a embalagem e acondicionamento dos tomates. Os frutos devem, também, cumprir limites máximos de resíduos de agrotóxicos e outros contaminantes, conforme regulamentos técnicos específicos, garantindo a segurança alimentar (MINISTÉRIO DA AGRICULTURA, 2018). Apesar da norma não apresentar como característica de aceitação ou rejeição o grau de maturidade do tomate de forma direta, é apresentada limitações na comercialização associados a qualidade e defeitos ou degradações no fruto que podem inviabilizar o lote para consumo.

3.1.2 Análises para a qualidade e maturação do tomate

A maturação dos tomates desempenha um papel crucial na qualidade nutricional destes frutos. À medida que amadurecem ocorrem mudanças significativas em sua composição, como o aumento dos sólidos solúveis, que está diretamente relacionado à redução da acidez, e ao incremento de açúcares, vitaminas e compostos antioxidantes. Tomates maduros, com coloração vermelha intensa, apresentam uma composição nutricional mais rica em comparação com os que estão em estágios iniciais, refletindo melhorias não só na textura e sabor, mas também na concentração de componentes benéficos à saúde, como o licopeno, um carotenoide antioxidante com propriedades anticâncer (FEDATO e VIEITES, 2023). Essas alterações na qualidade nutricional e nos componentes benéficos ressaltam a importância da maturação adequada para otimizar os benefícios dos tomates.

A importância da maturação é ainda mais evidenciada quando se considera a aceitação dos tomates pelos consumidores. Estudos sensoriais realizados por Domiciano *et al.* (2021) avaliaram a preferência dos consumidores entre tomates orgânicos e convencionais. Utilizando questionários e uma escala hedônica para avaliar atributos como aparência, gosto e textura, os pesquisadores asseguraram uma avaliação imparcial em um ambiente controlado.

Entender a aceitação sensorial dos tomates é fundamental para alinhar a produção com as preferências dos consumidores. Deste modo, a consideração dos parâmetros como sólidos solúveis, acidez, açúcares, vitaminas e compostos antioxidantes é crucial para desenvolver variedades atrativas, competitivas e promover hábitos alimentares saudáveis e sustentáveis (CONSTANTINO *et al.*, 2022; PÉREZ-MARÍN *et al.*, 2021).

Estudos de Pérez-Marin *et al.* (2021) mostraram os parâmetros físico-químicos do tomate cereja e sua relação com a qualidade sensorial e comercial dos frutos. Além de morfologia e sensorialidade, as análises incluíram a determinação da concentração de compostos bioativos (licopeno, carotenoides) vinculados à cor, sabor e saúde humana. Assim, os autores concluíram que: a firmeza é crucial para a durabilidade e transporte; açúcares e acidez são determinantes para o sabor do fruto e são influenciados por maturação e condições de cultivo; a textura é afetada pelo cultivo e armazenamento e impacta diretamente no frescor.

O estudo de Felföldi *et al.* (2022) utilizou uma metodologia para investigar a qualidade de genótipos de tomate combinando análises uni e multivariadas com testes estatísticos apropriados para avaliar características físicas, químicas e organolépticas dos tomates. Métodos como a Análise de Componentes Principais (PCA, do inglês *Principal Component Analysis*), e a Análise de Correspondência (CA, do inglês *Correspondence Analysis*), foram eficazes para explorar múltiplas variáveis simultaneamente, destacando as mais relevantes para a qualidade do fruto.

Nascimento *et al.* (2023) propuseram um método integrativo para analisar massa, diâmetros, número de sementes, pH, acidez total titulável e sólidos solúveis totais dos tomates em São Luís, Maranhão. Essa abordagem permitiu garantir padrões consistentes de qualidade e atender às exigências do mercado, destacando a importância de conhecer a origem dos produtos e promover práticas que valorizem a produção regional. A integração de análises físicas e químicas contribuiu para assegurar a qualidade dos tomates e atender às demandas do mercado.

Rajapaksha *et al.* (2021) abordaram os estágios de maturação do tomate destacando a importância da maturidade na determinação da vida útil pós-colheita e na qualidade final do

produto. O documento menciona que o nível de maturidade dos frutos pode ser identificado usando índices de maturidade e pode ser detectado por meio de características fisiológicas e morfológicas, como idade cronológica, tamanho, forma, firmeza, peso, cor, pH, sólidos solúveis totais e teor de fibras. Além disso, os autores ressaltaram que a definição de maturidade também depende do propósito de utilização, citando o exemplo de como o tomate é considerado maduro para consumo *in natura* no mercado estadunidense quando está "maduro verde", enquanto em Israel o tomate deve estar pelo menos rosado para ser considerado maduro para a colheita.

Rahman *et al.* (2022) determinaram os estágios de maturação do tomate (imaturo, parcialmente maduro e maduro) com base na relevância prática e na importância desses estágios para a produção agrícola e a indústria alimentícia. Para os autores, cada estágio de maturação apresenta características distintas que influenciam diretamente na qualidade, no sabor e na utilização dos tomates para diferentes finalidades. O tomate imaturo, por exemplo, foi considerado mais adequado para processamento industrial pela falta de suculência e coloração, enquanto o tomate maduro possui suculência e coloração aceitável para consumo *in natura*. O estágio de parcialmente maduro representa uma transição entre esses dois extremos e pode ser utilizado de diferentes formas, dependendo da finalidade. Portanto, a escolha desses estágios de maturação se baseia na relevância prática para a indústria alimentícia e na necessidade de compreender e classificar os tomates de acordo com suas características específicas em cada estágio de maturação.

Apesar dos trabalhos apresentados anteriormente terem avaliado a qualidade dos tomates, eles utilizaram métodos invasivos e destrutivos, o que inviabiliza o uso dos procedimentos para avaliação dos frutos na indústria alimentícia ou para consumo *in natura*. Neste sentido, métodos instrumentais não invasivos podem ser alternativas necessárias para avaliar a qualidade dos tomates e permitir a seleção de frutos dentro de critérios objetivos para a produção de alimentos e/ou bebidas.

3.2 ANÁLISES NÃO DESTRUTIVAS DO GRAU DE MATURAÇÃO DE TOMATES

A espectroscopia de Infravermelho Próximo (NIRS, do inglês: *Near-Infrared Spectroscopy*), tem mostrado potencial significativo para o monitoramento da maturação dos tomates. De acordo com Aguiar *et al.* (2022), a NIRS é eficaz na determinação dos sólidos solúveis totais (SST), embora tenha limitações na avaliação da acidez titulável (AT) devido ao comprimento de onda utilizado. Esses resultados destacam a eficácia da NIRS como ferramenta

promissora para determinados parâmetros de qualidade de tomates, ao mesmo tempo em que evidenciam a necessidade de ajustes ou métodos alternativos.

Huang *et al.* (2021) propuseram a utilização da técnica de espectroscopia Vis/NIR para a detecção não destrutiva do conteúdo de SST e para a classificação da maturidade dos tomates. A técnica, aplicada por meio de um sistema de medição de espectros de transmitância total permitiu coletar espectros de transmitância dos tomates em diferentes estágios de maturidade. Os dados espectrais coletados foram pré-processados utilizando técnicas como suavização Savitzky-Golay, correção de espalhamento multiplicativo (MSC, do inglês *Multiplicative Scatter Correction*), variância normal padrão (SNV, do inglês *Standard Normal Variate*) e derivada de primeira ordem, para melhorar a qualidade dos espectros e reduzir ruídos. Modelos foram desenvolvidos para prever o conteúdo de SST e classificar a maturidade dos tomates com base nos espectros coletados. Esta pesquisa demonstrou que a intensidade espectral de transmitância aumentava com o estágio de maturidade, permitindo a distinção eficaz entre os diferentes níveis de maturidade dos tomates.

Andrade *et al.* (2022) mostraram como NIRS, combinada com técnicas quimiométricas, foi uma ferramenta eficaz para a autenticação de produtos agrícolas, especificamente tomates e pimentões, em termos de práticas agrônomicas e origem geográfica. Os resultados do estudo mostraram que o modelo de classificação para tomates apresentou uma precisão de predição entre 88,8% e 95,2%, com sensibilidade entre 77,7% e 83,3%, área sob a curva (AUC, do inglês *Area under the curve*) de 0,95 e coeficiente de correlação de Pearson (PCC, do inglês *Pearson correlation coefficient*) de 82,9%. Estes resultados indicaram que a espectroscopia NIR combinada com análise discriminante por regressão por mínimos quadrados parciais (PLS-DA, do inglês *Partial Least Square Discriminant Analysis*) é eficaz na discriminação da origem geográfica e das práticas agrônomicas das amostras.

Uma abordagem diferente foi proposta por Abdelhamid *et al.* (2019). Os autores utilizaram a análise da clorofila por fluorescência para avaliar o grau de maturação dos tomates da variedade "Black baron" em cinco estágios: verde maduro, verde escuro, amarelo escuro, laranja escuro e vermelho escuro. O método desenvolvido permitiu classificar a maturidade dos tomates de forma objetiva e não destrutiva, demonstrando a eficácia da fluorescência da clorofila na avaliação da qualidade e maturidade dos frutos. Para além das técnicas analíticas citadas anteriormente, métodos colorimétricos permitem uma análise rápida, fácil, não destrutiva nem invasiva das amostras com custo significativamente mais baixo do que técnicas supracitadas.

3.3 EFICÁCIA DA COLORIMETRIA NA AVALIAÇÃO NÃO DESTRUTIVA

A colorimetria quantifica e descreve cores utilizando modelos de parâmetros colorimétricos, como os modelos L*(luminosidade de 0 preto a 100 branco) a* (valores positivos para vermelho e negativos para verde) b* (valores positivos para amarelo e negativos para azul) e L* C* (indica a intensidade ou saturação da cor, com valores maiores representando cores mais vibrantes.) H* (define a cor específica em um círculo cromático, expresso em graus (0° a 360°), onde cada grau corresponde a uma cor diferente) desenvolvidos pela Comissão Internacional de Iluminação (CIE, do inglês *Commission Internationale de l'Eclairage*). Estes modelos representam cores em um espaço tridimensional esférico, enquanto outros modelos, como RGB (*Red, Green, Blue*) e CMYK (*Cyan, Magenta, Yellow, Black*), têm aplicações específicas na análise de cores. Estes modelos podem ser aplicados na indústria de tintas como também na de alimentação, ajudando a compreender propriedades ópticas e interações das cores, sendo ferramentas adequadas para caracterizar materiais, dentre outros procedimentos (HIRAM *et al.*, 2023).

No contexto da conservação pós-colheita de tomates, a colorimetria desempenha um papel crucial na avaliação da qualidade dos frutos permitindo monitorar a coloração ao longo do armazenamento, assegurando avaliação segura da aparência dos tomates. A aplicação da colorimetria ajuda a quantificar a eficácia, por exemplo, de revestimentos de frutos para manutenção da coloração e, conseqüentemente, na qualidade visual (CARVALHO *et al.*, 2022).

3.3.1 Métodos colorimétricos para avaliação de tomates

Ileri *et al.* (2019) utilizaram o espaço de cor CIE L* a* b* para detectar defeitos em tomates, convertendo imagens do espaço de cor RGB. Os valores de intensidade de L*, a* e b* foram extraídos de cada ponto de pixel e desempenham um papel crucial na identificação e determinação do estado de maturação de pixels saudáveis ou defeituosos, permitindo a detecção de defeitos com base nas variações de cor nos tomates.

A pesquisa desenvolvida por Goisser e colaboradores (2021) aplicou a colorimetria para avaliar a qualidade do tomate, oferecendo uma análise objetiva e quantitativa da cor. Os autores mediram parâmetros como luminosidade, sinais dos canais vermelho e amarelo na avaliação não destrutiva dos frutos, preservando sua integridade para consumo ou venda.

Konagaya *et al.* (2019) investigaram a eficácia da colorimetria para a avaliação não destrutiva da qualidade dos tomates durante o armazenamento. Tomates cultivados

hidroponicamente em estufa, colhidos no estágio vermelho e submetidos a um período de armazenamento de 9 dias a 25°C após a colheita foram utilizados para a pesquisa. A metodologia empregada envolveu a aquisição das cores e fluorescência UV, sendo um colorímetro convencional utilizado como padrão de referência. A análise dos resultados abordou alterações nos valores de L*, a*, b* e C* no espaço de cor assim como nas mudanças nos índices RGB das imagens e fluorescência. As medidas colorimétricas revelaram mudanças nas proporções RGB com aumento do vermelho e diminuição do verde, indicando degradação.

A diversidade de sensores ópticos para avaliação da cor é grande, com abordagens significativamente distintas. Dentre os sensores mais utilizados na análise de cor em frutos destaca-se o sensor óptico de cor verdadeira (TCS, do inglês *True Color Sensor*). Esses sensores são dispositivos que medem a intensidade da luz em diferentes comprimentos de onda (geralmente nas bandas do vermelho, verde e azul) para determinar a cor precisa de um objeto ou superfície (SHCHELKANOVA *et al.*, 2020).

3.3.2 Utilização de sensores ópticos (TCS3472) na análise de variação de cor

De acordo com o manual *TCS3472 COLOR LIGHT-TO-DIGITAL CONVERTER With IR FILTER*, integrado ao sensor TCS3472 fornece um retorno digital de valores de detecção de luz vermelha, verde, azul (RGB). Um filtro de bloqueio de IR, integrado no chip e localizado nos fotodiodos de detecção de cores, minimiza o componente espectral de IR da luz recebida e permite que as medições de cores sejam feitas com precisão. A alta sensibilidade, ampla faixa dinâmica e filtro de bloqueio de IR tornam o TCS3472 uma solução de sensor de cores ideal para medidas de reflectância de cor. O TCS3472 contém um conjunto de fotodiodos organizados em uma matriz 3×4, quatro conversores analógico-digital (ADC, do inglês *Analog digital converter*) que integram a corrente dos fotodiodos, registradores de dados, uma máquina de estado e uma interface I2C. O conjunto de fotodiodos 3×4 é composto por fotodiodos idênticos, sendo três com filtros de passagem para vermelho, três com filtro verde, três com filtro azul, e três sem filtro (para medidas de intensidade de luz). Os quatro ADCs integradores convertem simultaneamente as correntes amplificadas do fotodiodo para um valor digital de 16 bits. Após a conclusão de um ciclo de conversão, os resultados são transferidos para os registradores de dados, que possuem buffer duplo para garantir a integridade dos dados. Toda a temporização interna, bem como o estado de espera de baixo consumo de energia, é controlado pela máquina de estado.

Diversos trabalhos foram publicados utilizando o sensor TCS, dentre estes alguns são citados abaixo. Nishidate *et al.* (2013) realizaram as análises de cor utilizando um sensor óptico para medir a intensidade de luz refletida pelas folhas de plantas. As leituras do sensor TCS210 foram convertidas em valores RGB que representam as cores percebidas. No entanto, devido à falta de um filtro infravermelho no sensor, foram aplicadas equações de correção aos valores RGB medidos para compensar as imprecisões. Esses valores corrigidos foram então utilizados para calcular os espectros de transmissão e, a partir deles, determinar as características espectrais de transmitância final. Com base nos dados espectrais obtidos, o Índice de Clorofila foi calculado, permitindo a determinação dos teores de pigmentos e nitrogênio nas plantas medidas. Além disso, as análises de cor foram visualizadas por meio de uma interface gráfica do usuário (GUI, do inglês *graphical user interface*) que apresenta os valores RGB corrigidos, os espectros de transmitância em diferentes comprimentos de onda e dados sobre as características espectrais de transmitância de forma gráfica.

Subrata *et al.* (2022) utilizaram o sensor óptico para analisar a cor dos tomates em movimento em uma esteira transportadora, com o objetivo de desenvolver um sistema de detecção de qualidade de tomates cereja com base em sua cor. A velocidade ideal da esteira transportadora durante o processo de detecção foi determinada como 30 cm/s, com uma distância de 7 cm entre os tomates. Os resultados mostraram que o sistema de detecção de qualidade dos tomates com base em sua cor, utilizando o sensor óptico TCS230, foi capaz de classificar com precisão os tomates em diferentes níveis de qualidade com base em sua cor. A taxa de sucesso na detecção de qualidade para tomates vermelhos foi de 89%, alaranjados 98% e verdes foi de 100%. No entanto, o estudo também concluiu que a precisão da detecção de qualidade ainda precisa ser aprimorada para tomates vermelhos e alaranjados.

Embora os resultados obtidos por sensores de cor, como o TCS3472, possam ser analisados de forma univariada, utilizando uma única medida de sinal para obter informações sobre as cores detectadas, uma abordagem mais sofisticada pode ser empregada para melhorar a precisão e exatidão dos resultados. A quimiometria, que se baseia em ferramentas matemáticas e estatísticas avançadas, permite a análise multivariada dos dados de sensores (JIMÉNEZ-CARVELO *et al.*, 2020).

Através de técnicas como PCA, análise de regressão múltipla, por exemplo, é possível extrair informações mais detalhadas e confiáveis dos dados brutos. Essas abordagens permitem a consideração de múltiplas variáveis simultaneamente, melhorando a capacidade de identificar padrões sutis e relações complexas entre as variáveis de cor e as características desejadas. Dessa

forma, a quimiometria não só refina a interpretação dos dados obtidos pelo sensor, mas também contribui para a implementação de sistemas mais precisos e eficazes em aplicações práticas (WONGRAVEE et al., 2020)

3.4 QUIMIOMETRIA

A quimiometria é uma área interdisciplinar que se concentra na aplicação de métodos matemáticos, estatísticos e computacionais para analisar, interpretar e extrair informações de dados químicos complexos. Ela desempenha um papel essencial em várias áreas da química e é fundamental para a pesquisa, desenvolvimento de produtos e controle de qualidade em diversos setores industriais (BRERETON *et al.*, 2018). A principal premissa da quimiometria é lidar com a natureza multivariada dos dados químicos, que frequentemente envolvem múltiplas variáveis inter-relacionadas, tornando as análises tradicionais insuficientes. A quimiometria permite a análise conjunta dessas variáveis, identificando padrões, tendências e informações ocultas nos dados (SALONEN *et al.*, 2019).

A quimiometria é amplamente aplicada em análises espectroscópicas, como NIR, cromatografia e espectrometria de massa, entre outras. Além disso, ela desempenha um papel crucial na indústria farmacêutica, alimentícia, petroquímica e em muitos outros setores, assegurando a qualidade dos produtos, otimizando processos e facilitando a tomada de decisões informadas (GOISSER *et al.*, 2021).

Dentro da quimiometria, são utilizadas diversas técnicas, incluindo PCA, a Análise Discriminante por Componentes Principais - Análise Discriminante (PCA-DA, do inglês *Principal Component Analysis Discriminant Analysis*), PLS-DA e a Análise de Componentes Independentes por Modelagem de Classificação por Componentes Mínimos (SIMCA, do inglês *Soft Independent Modeling of Class Analogy*). Cada uma dessas técnicas possui aplicações específicas, como a redução da dimensionalidade dos dados, modelagem de relações entre variáveis e agrupamento de amostras semelhantes (PEREIRA *et al.*, 2022).

3.4.1 Análise por Componentes Principais (PCA)

A PCA é uma técnica estatística fundamental na análise multivariada que busca reduzir a complexidade dos dados. Ela faz isso ao transformar um conjunto de variáveis correlacionadas em um novo conjunto de variáveis, denominadas componentes principais, que são ortogonais e não correlacionadas. Essa abordagem visa simplificar a interpretação dos dados ao reestruturar as variáveis em um formato mais manejável. Introduzida por Pearson em 1901, a técnica foi subsequentemente refinada por Hotelling nas décadas de 1930, tornando-se uma ferramenta

amplamente utilizada para explorar e visualizar grandes conjuntos de dados (HONGYU *et al.*, 2016).

O objetivo da PCA é converter um conjunto de variáveis que podem estar inter-relacionadas em um novo conjunto de variáveis, denominadas componentes principais, que são independentes entre si. Essas componentes são organizadas de maneira que a primeira componente captura a maior parte da variabilidade presente nos dados, com a segunda componente retendo a maior variabilidade possível entre as restantes, e assim sucessivamente. PCA é particularmente valiosa em cenários com um elevado número de variáveis, pois facilita a simplificação da análise ao manter as informações mais relevantes, sem comprometer a integridade dos dados (PRADO *et al.*, 2020).

No estudo de Yagmur *et al.* (2021), PCA foi utilizada para avaliar os efeitos das bactérias promotoras de crescimento de plantas (PGPR) nos parâmetros de rendimento e qualidade de tomates cultivados em sistemas orgânicos. A PCA permitiu a redução dimensional dos dados, identificando os componentes principais que explicam a maior parte da variabilidade observada. O primeiro componente principal (PC1) explicou 35,33% da variância e foi associado a variáveis de qualidade como sólidos solúveis e vitamina C, enquanto o segundo componente (PC2), que explicou 24,46%, foi relacionado ao rendimento total e comercializável. O terceiro componente (PC3) abordou o rendimento de descarte e a razão de rendimento comercializável. A PCA facilitou a identificação das variáveis mais influentes no experimento, permitindo uma compreensão detalhada dos impactos das diferentes cepas e métodos de aplicação de PGPR.

Sivakumar *et al.* (2023) utilizaram a PCA como uma ferramenta para avaliar a tolerância ao sal em diferentes genótipos de tomate. A PCA, uma técnica multivariada, transforma um conjunto extenso de variáveis correlacionadas em um conjunto menor de componentes principais não correlacionados, facilitando a interpretação de dados complexos obtidos de características morfológicas, bioquímicas e fisiológicas. No estudo, dados de onze genótipos de tomate foram coletados sob condições de controle e de estresse salino. A aplicação da PCA permitiu identificar padrões de variabilidade entre os genótipos, classificando-os em grupos de tolerância ao sal. Os resultados indicaram que os genótipos TG8 e TG7 apresentaram maior tolerância, enquanto TG1, TG9 e TG10 foram classificados como sensíveis. Essa classificação foi corroborada por dados de campo, validando a abordagem utilizada. A PCA também possibilitou a visualização dos genótipos em gráficos do tipo *biplot*, onde os tolerantes e

sensíveis foram projetados em posições opostas, facilitando a interpretação e fornecendo uma base para futuras pesquisas em melhoramento genético visando a resistência à salinidade.

A utilização da PCA em estudos com tomates, como demonstrado por Yagmur *et al.* (2021) e Sivakumar *et al.* (2023), pode ser expandida para análises classificatórias mais sofisticadas por meio da Análise Discriminante de Componentes Principais (PCA-DA). Enquanto a PCA é eficaz para reduzir a dimensionalidade dos dados e identificar os componentes principais que explicam a variabilidade, a PCA-DA vai além, integrando a discriminação entre grupos predefinidos. A combinação de PCA com métodos discriminantes permite uma análise mais robusta e direcionada, facilitando a tomada de decisões em pesquisas de melhoramento genético e otimização de práticas.

3.4.2 Análise Discriminante por Componentes Principais (PCA-DA)

A PCA-DA é uma técnica valiosa em estudos de tomates, especialmente em contextos que exigem a classificação precisa de amostras em grupos distintos, como genótipos com diferentes níveis de tolerância a estresses ou tratamentos que afetam a qualidade e o rendimento das plantas. A PCA, por si só, transforma um conjunto de variáveis possivelmente correlacionadas em componentes principais que explicam a variabilidade dos dados, permitindo uma visualização clara e a identificação de padrões. No entanto, ao combinar a PCA com a Análise Discriminante (DA), a PCA-DA não apenas reduz a dimensionalidade dos dados, mas também maximiza as diferenças entre grupos predefinidos, melhorando a precisão da classificação. Essa técnica é especialmente útil para categorizar amostras de tomate com base em características morfológicas, bioquímicas e fisiológicas, auxiliando na construção de modelos que possam prever e classificar novos dados de forma eficiente, com aplicações que vão desde o melhoramento genético até o controle de qualidade em sistemas de produção (BONIFAZI *et al.*, 2021).

A PCA-DA é uma técnica de classificação especialmente útil em estudos com tomates para distinguir entre diferentes grupos de amostras, como genótipos ou tratamentos que afetam a qualidade e o rendimento. A PCA é inicialmente aplicada para reduzir o número de variáveis, simplificando a estrutura dos dados ao identificar componentes principais que retêm a maior parte da variância. Em seguida, a DA utiliza essas variáveis reduzidas para calcular combinações lineares que maximizam as diferenças entre os grupos, enquanto minimizam as variações dentro de cada grupo. A eficácia da PCA-DA depende da escolha adequada do número de componentes principais, frequentemente determinada por métodos de validação

cruzada, como o algoritmo Venetian Blinds (VB). Essa abordagem é particularmente benéfica quando há muitas variáveis, permitindo a construção de um modelo simplificado, mas ainda capaz de discriminar com precisão entre diferentes classes de amostras de tomate (TOSATO *et al.*, 2020).

3.4.3 Análise Discriminante por Regressão de Mínimos Quadrados Parciais (PLS-DA)

O PLS-DA é uma variação da técnica de regressão por PLS que foi ajustada para abordar problemas de classificação. O propósito do PLS-DA é determinar a classe de uma amostra desconhecida com base em um conjunto de dados de treinamento com classes conhecidas. Esse processo é realizado através da utilização de informações espectrais ou outras características multivariadas das amostras para fazer previsões precisas sobre a categoria a que a amostra pertence (PEREIRA *et al.*, 2022).

O modelo PLS-DA é desenvolvido utilizando um conjunto de dados no qual as amostras estão associadas a classes específicas. O objetivo do modelo é otimizar a separação entre essas classes no espaço das variáveis latentes. Para isso, as classes são representadas por variáveis binárias (0 ou 1), o que permite a categorização das amostras em diferentes grupos. Após o treinamento do modelo, novas amostras são classificadas com base em sua proximidade aos centros das classes no espaço latente. (JIMÉNEZ-CARVELO *et al.*, 2021).

PLS-DA foi utilizada por Barros *et al.* (2021) para classificar plantas saudáveis e infectadas com base em dados hiperespectrais. Após a coleta e pré-processamento dos dados, a PLS-DA permitiu identificar padrões espectrais que distinguiam entre diferentes estados de saúde das plantas, com uma acurácia de 93% na validação cruzada. O índice vegetativo NDWI foi uma variável significativa na discriminação, associando infecção a alterações na senescência e no conteúdo hídrico. Essa técnica contribui para a análise precisa e quantitativa no monitoramento agrícola.

Pilon *et al.* (2020) discutem a aplicação de técnicas quimiométricas na análise de dados metabolômicos, com foco em métodos como PCA e PLS-DA. A centralização e o escalonamento dos dados são destacados como essenciais para remover compensações e identificar variações biológicas sutis entre amostras. A PLS-DA é enfatizada como uma técnica importante para discriminação de classes em dados complexos, com a avaliação do modelo realizada através de parâmetros estatísticos como R^2 e Q^2 , além da validação cruzada e análise detalhada dos resultados para identificação de biomarcadores. O texto também aborda a importância de um planejamento experimental sistemático, incluindo o uso de planejamentos

fatoriais para otimizar a coleta de dados e maximizar a extração de informações relevantes, visando um entendimento aprofundado das interações entre variáveis na metabolologia.

3.4.4 Análise de Componentes Independentes por Modelagem Classificatoria (SIMCA)

O SIMCA é um método de modelagem que se fundamenta na ideia de que as semelhanças entre objetos podem ser representadas e analisadas por meio de componentes principais (CHEN *et al.*, 2019). No SIMCA, um modelo de componentes principais é desenvolvido separadamente para cada classe de interesse, criando um subespaço específico para cada classe. A complexidade desse subespaço, ou seja, o número de componentes principais utilizados, deve ser ajustada de maneira a otimizar a representação da classe. As amostras são então classificadas com base na sua proximidade a esse subespaço; amostras que estão distantes do subespaço têm uma maior probabilidade de não pertencer à classe analisada (DAVIDE *et al.*, 2024).

SIMCA é uma técnica estatística utilizada para classificação e análise de dados, especificamente na discriminação de amostras de tomates em diferentes estágios de maturação e na avaliação de defeitos e conteúdo de sólidos solúveis (CSS). Através da análise por PCA, o SIMCA reduz a dimensionalidade dos dados, facilitando a visualização e discriminação das classes em um espaço de menor dimensão. No estudo, os modelos desenvolvidos com SIMCA apresentaram 100% de precisão durante o treinamento, evidenciando sua robustez na separação das classes. Comparado a outras técnicas como PLS-DA, SVM e KNN, o SIMCA demonstrou desempenho competitivo na classificação de tomates. A combinação do SIMCA com a técnica de TD-NMR é apontada como promissora para a indústria de processamento de tomates, oferecendo uma abordagem rápida e precisa para assegurar a qualidade dos produtos (BORBA *et al.*, 2021).

O estudo realizado por Van Tonder *et al.* (2023) utilizou a técnica de SIMCA para analisar dados cromatográficos de compostos orgânicos voláteis (VOC, do inglês *Volatile organic compounds*) em campos de tomate. A PCA foi aplicada inicialmente para explorar a variabilidade nos dados, identificando agrupamentos e diferenças na composição química dos VOCs. Em seguida, a Análise Discriminante por Projeções Ortogonais em Estruturas Latentes (OPLS-DA, do inglês *Orthogonal partial least squares discriminant analysis*) foi usada para melhorar a separação dos grupos identificados na PCA, destacando compostos específicos que discriminavam as amostras em diferentes momentos. Os resultados indicaram variações

significativas na emissão de VOCs ao longo do tempo, ressaltando a utilidade do SIMCA na interpretação dos dados.

4 MATERIAL E MÉTODOS

4.1 AQUISIÇÃO E PREPARAÇÃO DAS AMOSTRAS

Um total de 150 unidades de tomate foram adquiridas em mercados de pequeno (mercearias de bairros) à grande porte (redes de supermercados) na cidade de Campina Grande. Os tomates tipo Roma foram selecionados de acordo com os estágios de maturação segundo Nishidate *et al.* (2013) por inspeção visual como: 50 tomates Verdes, 50 tomates semi-maduros e 50 maduros. Após aquisição dos tomates, as amostras foram higienizadas com banho em 1 L de água morna entre 35 e 43 °C, com a adição de 5 mL hipoclorito de sódio (NaClO) com concentração de cloro ativo de 1%, para evitar que bactérias ou outros micro-organismos afetassem os parâmetros obtidos (RODRIGUES *et al.*, 2017). O processo foi repetido para cada um dos dez lotes de amostras.

4.2 ANÁLISES POR SENSORES TCS3472

Para a obtenção das escalas de cor RGB três sensores ópticos do modelo TCS3472 foram utilizados em conjunto com uma placa Arduino MEGA 2560. Esses sensores foram instalados em uma cabine montada sobre uma esteira desenvolvida pela empresa Alcalitech, incubada na Fundação Parque Tecnológico da Paraíba (PaqTcPB). A adaptação dos sensores sobre a esteira foi realizada utilizando barras metálicas e polímero plástico de poliuretano, sendo a esteira dividida em segmentos de 20 cm com fita marcadora para permitir a obtenção dos parâmetros de cor RGB para cada tomate.

Figura 1. Esteira transportadora com cabine de análise colorimétrica



Fonte: Elaborado pelo autor, 2024

4.2.1 Algoritmo de controle dos sensores, aquisição e tratamento dos sinais

Um algoritmo para controle dos sensores e medidas dos seus canais R (vermelho), G (verde), (B) azul e tons de cinza foi desenvolvido em linguagem C++, utilizando a plataforma de desenvolvimento Luna, Arduino e Nextion. Primeiramente, são configurados os pinos GPIO para os motores, sensores de posição e diodos emissores de luz (LEDs, do inglês *Light Emitting Diodes*) além da comunicação serial para interação com os sensores ópticos. A utilização de PWM é destacada para o controle eficiente dos motores. Foi implementado um filtro de média móvel nos dados para suavizar as leituras dos sensores, garantindo estabilidade nas medições. Tarefas temporizadas controlam o tempo de funcionamento do motor após a detecção de um tomate maduro ou verde, e LEDs são utilizados como indicadores visuais para representar o status do sistema.

O algoritmo foi dividido em blocos de códigos: inicialização, leitura de sensores, cálculo de médias, normalização de valores e saída de dados.

Inicialmente foram declaradas as variáveis globais. A variável ``tempo`` é um contador inteiro, e ``readSerial`` é uma variável booleana usada para controlar a leitura dos dados dos sensores e a impressão no monitor serial. Em seguida, são definidos os pinos de conexão dos três sensores de cor utilizando diretivas ``#define``. Isso facilita a identificação e configuração dos pinos digitais conectados aos sensores. São então declaradas variáveis para armazenar as leituras de largura de pulso (PWM) das cores vermelha, verde e azul para cada sensor. Essas variáveis (``redPW``, ``greenPW``, ``bluePW`` para o primeiro sensor, ``redPW_B``, ``greenPW_B``, ``bluePW_B`` para o segundo, e ``redPW_C``, ``greenPW_C``, ``bluePW_C`` para o terceiro) armazenam os valores medidos pelos sensores.

Além disso, são declaradas variáveis para armazenar as médias móveis das leituras de cores para cada sensor. Os contadores (``countRed``, ``countGreen``, ``countBlue``) acompanham o número de leituras usadas para calcular as médias móveis. Esses contadores ajudam a determinar quando os valores devem ser reinicializados para evitar o estouro de variáveis. A constante ``numReadings`` define o número de leituras usadas para calcular a média móvel. A função ``getColorPW`` é responsável por ler a largura de pulso (PWM) correspondente a uma cor específica (vermelho, verde ou azul) de um sensor específico. Ela configura os pinos do sensor para selecionar a cor desejada e mede a largura de pulso do sinal de saída.

A função ``computeMovingAverage`` calcula a média móvel de uma série de valores, atualizando a média com um novo valor a cada chamada. A função ``mapToRGBScale`` mapeia

um valor lido do sensor para a escala RGB (0-255), normalizando-o com base nos valores mínimos e máximos esperados.

Para a função `setup`, que é executada uma vez quando o microcontrolador é ligado, a comunicação *serial* é configurada com `Serial.begin(9600)`. Os pinos dos sensores de cor são configurados como saídas com `pinMode`. A escala da largura de pulso dos sensores é definida para 20% usando `digitalWrite`. Já a `loop`, que é executada repetidamente, primeiro incrementa a variável `tempo`. Em seguida, verifica se há dados disponíveis no serial com `Serial.available() > 0`. Se houver, lê o comando recebido com `Serial.read()` e atualiza `readSerial` com base no comando: `'1'` para iniciar as leituras e `'2'` para parar.

Se `readSerial` for `true`, os valores PWM para vermelho, verde e azul de cada sensor são lidos utilizando a função `getColorPW`. Um pequeno atraso (`delay(10)`) é introduzido entre as leituras para garantir precisão. As médias móveis das leituras de cores para cada sensor são calculadas usando a função `computeMovingAverage`. Os contadores de leituras são incrementados e, se atingirem o número máximo de leituras definido (`numReadings - 1`), são reinicializados. A média dos valores normalizados dos três sensores para cada cor é então calculada, seguida da normalização dos valores de cor para a escala RGB utilizando a função `mapToRGBScale`. A diferença entre os valores normalizados de vermelho e verde é calculada (`redRGB - greenRGB`). Os valores RGB e a diferença de cor são impressos no monitor serial. Um pequeno atraso (`delay(10)`) é introduzido para facilitar a leitura no monitor serial.

4.3. ANÁLISE PELO COLORIMETRO DIGITAL CS-420

Para obtenção dos índices de cor CIE L^* a^* b^* , foram feitas leituras utilizando um colorímetro digital CS-420 da marca CNHspec. Foram realizados nove pontos de medição para cada tomate, sendo eles três no topo do tomate, na região em torno do pedúnculo do fruto, mais três no meio do fruto, com a finalidade de identificar os pontos em toda a sua circunferência, e os outros três na parte inferior do fruto. A escala tridimensional foi composta por L^* (luminosidade), a^* (variação verde-vermelho) e b^* (variação azul-amarelo) simultaneamente com os espectros de refletância na escala de 400 a 700 nm.

4.4 ANÁLISES FÍSICO-QUÍMICAS DOS TOMATES

Para a realização das análises físico-químicas cada tomate foi triturado inteiro separadamente em um liquidificador Mix LQ30/220 (Arno Power). Em seguida, foi realizada

uma filtração simples, utilizando papel de filtro qualitativo com gramatura de 80 g/m² e poros de 14 µm.

4.4.1 Determinação dos Sólidos Solúveis (°Brix)

A determinação do brix seguiu método indicado por Cocco *et al.* (2020) que utilizou um densímetro digital para identificar o °Brix em bebidas derivadas da uva. Esta metodologia foi adaptada para tomates seguindo o mesmo processo. O teor de sólidos solúveis, expresso em graus Brix, foi determinado utilizando Densímetro DM 35 da Anton Paar GmbH na faixa de 0 a 70 °Brix com precisão de 0,025 °Brix. A metodologia adotada envolveu a calibração prévia do densímetro e a análise das amostras conforme protocolos estabelecidos pelo fabricante. As medidas foram feitas em triplicata.

4.4.2 Determinação do pH

Na análise de pH foi utilizado um pHmetro AK90 da AKSO, em que o eletrodo foi imerso no extrato de cada uma das amostras de tomate e foi feito o registro do pH. Para assegurar a precisão dos resultados, as medições de pH foram realizadas em triplicata e seguem os pontos de controles de qualidade conforme as diretrizes estabelecidas pela Associação de Químicos Agrícolas Oficiais (AOAC, do inglês *Association of Official Agricultural Chemists*) (ADEDEJI *et al.*, 2006).

4.4.3 Determinação da Acidez Titulável

A acidez foi determinada pela titulação de neutralização titulação dos ácidos presentes na amostra com uma solução padronizada de hidróxido de sódio 0,096 mol/L, com indicador fenilftaleína. Uma alíquota de 5 mL do filtrado da amostra de tomate foi colocado em erlenmeyer de 125 mL e o meio foi aquecido até o início do ponto de ebulição. Para resfriamento da amostra foi adicionado 25 ml de água destilada para as amostras claras e 50 mL para as amostras escuras. Em seguida foi executada a titulação propriamente dita com agitação constante utilizando Agitador Magnético Digital com Aquecimento e Sensor Externo SL-92/H da Solab Científica a 70 rpm (AGIUS *et al.*, 2022).

A acidez titulável em g/L foi determinada seguindo a equação 1 a seguir:

$$Ca = \frac{(Cb * Vb)}{Va}$$

Na qual: Ca: Concentração do ácido; Vb: Volume da base; Va: Volume do ácido; Cb: Concentração da base.

4.5 TRATAMENTOS QUIMIOMÉTRICOS

4.5.1 Pré-processamento

Inicialmente, o pré-processamento dos dados da escala RGB foi realizado utilizando o toolbox *icoshift3.0*. Este programa alinha perfis de espectros ou outros tipos de dados que possam sofrer variações de deslocamento. No contexto desta análise, o *icoshift* foi aplicado para centralizar os picos obtidos pelo escaneamento superficial do tomate por meio dos sensores RGB, garantindo a correção de variações indesejadas que poderiam interferir na precisão das análises subsequentes.

4.5.2 Análise de Componentes Principais (PCA)

Com os dados devidamente pré-processados e os limiares definidos, foi realizada PCA utilizando o *software Unscrambler 9.7*.

4.5.3 Obtenção dos limiares

A obtenção dos valores de todos os limiares foi realizada em quatro etapas. Primeiramente, calculou-se a média dos valores de início e término de cada curva para cada tomate. Em seguida, foi calculada a média específica para cada pico em cada espaço de cor. Posteriormente, os valores foram ordenados em ordem crescente para cada estágio de maturação. Na etapa seguinte, foi calculada a média considerando os 10 valores próximos da fronteira entre cada estágio de maturação. Para determinar o índice de separação entre os estágios de maturação verde e semi-maduro, foram calculados os 10 últimos valores dos picos do estágio verde e os 10 primeiros valores dos picos do estágio semi-maduro. A partir desses cálculos, obteve-se um limiar que separa os estágios de maturação tanto para os sinais de RBG, quanto CIE L*a*b*.

4.5.4 Separação dos conjuntos de teste e treinamento.

A separação das amostras foi realizada em dois conjuntos, um de treino e o outro de teste. Das 150 amostras disponíveis, 90 foram alocadas para o conjunto de treino e as 60 restantes para o conjunto de teste, utilizando o programa *data_hand_gui* executado em , versão 2010b,. Cada estágio de maturação dos tomates — maduro, semi-maduro e verde — foi

representado igualmente nos conjuntos de treino e teste, com 30 amostras designadas para o treinamento e 20 para o teste em cada estágio.

4.5.5 Análise de Reconhecimento de Padrões

Após a PCA, utilizou-se o *classification_Toolbox* em Matlab, versão 2010b, para a etapa de classificação. Este conjunto de ferramentas oferece diversos algoritmos de classificação, que calculam PCA-DA, PLS-DA e SIMCA, permitindo a escolha do método mais adequado para os dados em questão.

4.5.6 Técnicas de Análise Multivariada

No estudo, foram empregadas várias técnicas de análise multivariada para a classificação e diferenciação das amostras. A PCA-DA foi aplicada após a PCA para otimizar a separação entre as classes, ao projetar os dados em um espaço onde as diferenças entre categorias são mais evidentes. A PLS-DA envolveu a seleção das variáveis preditoras e a variável de resposta categórica para desenvolver um modelo que maximizasse a discriminação entre as classes com base nas variáveis preditoras. O SIMCA foi utilizado para identificar a separação entre classes e avaliar o impacto das variáveis preditoras na discriminação das categorias, fornecendo uma estrutura para classificar as amostras em diferentes grupos.

4.5.7 Comparação de Métodos

A aplicação de métodos univariados, como a classificação pela cor, foi realizada para comparar o desempenho com os métodos multivariados. A ideia era verificar se os métodos multivariados proporcionariam uma melhoria significativa em relação aos métodos univariados, considerando que a classificação de tomates pela cor não é algo complexo o suficiente para justificar o uso exclusivo de métodos multivariados.

5 RESULTADOS E DISCUSSÃO

5.1 ANÁLISES FÍSICO-QUÍMICAS

Os estágios de maturação dos tomates podem ser definidos por meio de análises físico-químicas que avaliam o pH, o teor de sólidos solúveis (medido em °Brix) e a concentração de ácido cítrico (AMR *et al.*, 2022). A **Tabela 1** resume as métricas físico-químicas de 150 tomates, divididos em três estágios de maturação: maduro, semi-maduro e verde. As variáveis analisadas incluem o pH, o teor de Brix e a acidez cítrica. Para cada estágio de maturação e variável, são apresentados a média, o desvio padrão, a mediana, os valores mínimos e máximos, e a amplitude.

Tabela 1. Métricas gerais para os ensaios Físico-químicos dos 150 tomates.

	Amostra*	Média	Desvio padrão	Mediana	Mínimo	Máximo	Amplitude
pH	M	4,72	0,33	4,65	4,14	5,64	1,50
	S	4,56	0,27	4,53	4,04	5,09	1,05
	V	4,42	0,25	4,46	3,95	4,92	0,97
°Brix	M	4,02	0,44	4,08	3,13	4,83	1,7
	S	4,05	0,69	3,93	2,93	5,97	3,03
	V	4,14	0,55	4,03	3,10	5,33	2,23
Ácido Cítrico (g/L)	M	0,33	0,11	0,33	0,14	0,63	0,49
	S	0,37	0,13	0,35	0,17	0,71	0,54
	V	0,45	0,13	0,42	0,22	0,71	0,49

Fonte: Elaborado pelo autor, 2024

* M – maduro; S – semi-maduro; V – verde.

Como mostrado na **Tabela 1**, no estágio de maturação verde, os tomates apresentam um pH médio de 4,42, com variações de 3,95 a 4,92, indicando uma acidez elevada. O teor de sólidos solúveis é o mais alto entre os estágios, com uma média de 4,14 °Brix e uma variação de 3,10 a 6,33 °Brix, o que sugere um conteúdo significativo de açúcares, apesar da alta acidez. A concentração de ácido cítrico nos tomates verdes é a maior, com uma média de 0,45 g/L, variando de 0,22 a 0,71 g/L, reforçando o caráter ácido dessa fase.

Os tomates semi-maduros, por sua vez, apresentam características intermediárias entre os verdes e os maduros. O pH médio é de 4,56, com uma variação de 4,04 a 5,09, indicando uma redução na acidez em comparação com os tomates verdes. O teor de sólidos solúveis é ligeiramente inferior, com uma média de 4,05 °Brix e variações de 2,93 a 5,97 °Brix, refletindo

um equilíbrio entre acidez e doçura. A concentração de ácido cítrico nesses tomates é de 0,37 g/L em média, com variações de 0,16 a 0,63 g/L, demonstrando uma acidez menor que a dos tomates verdes, mas ainda presente.

Finalmente, os tomates maduros exibem as menores taxas de acidez e sólidos solúveis. O pH médio é de 4,72, variando de 4,14 a 5,64, indicando que a acidez diminui consideravelmente à medida que o tomate atinge a maturidade. O teor de sólidos solúveis tem uma média de 4,02 °Brix, com variações de 3,64 a 4,83 °Brix, sugerindo uma estabilização do conteúdo de açúcares, embora seja ligeiramente inferior aos estágios anteriores. A concentração de ácido cítrico nos tomates maduros é a menor, com uma média de 0,33 g/L e variações de 0,14 a 0,62 g/L, refletindo uma acidez significativamente reduzida.

Estudos como o de Osorio-Gracia *et al.* (2020) indicam que fatores ambientais como temperatura e umidade, assim como práticas de polinização, impactam a qualidade dos tomates, refletindo nas diferenças observadas nos perfis de pH e Brix entre os lotes. Mazzei *et al.* (2021) adicionam que o tipo de plantio, incluindo o uso de agrotóxicos e práticas sustentáveis, também afeta a qualidade dos frutos, evidenciado pelas variações na acidez e doçura entre os lotes. Assim, as diferenças na qualidade dos tomates entre os lotes analisados podem ser atribuídas não apenas ao estágio de maturação, mas também ao manejo agrícola e às condições ambientais durante o cultivo, destacando a complexa interação entre esses fatores na formação do perfil sensorial dos tomates. No entanto, essas diferenças físico-químicas são essenciais para a classificação dos tomates em diferentes estágios de maturação, auxiliando na análise quimiométrica no controle de qualidade dos produtos.


Esses parâmetros permitem uma caracterização precisa dos tomates em seus diferentes estágios de desenvolvimento, sendo fundamentais para a classificação dos frutos como verdes, semi-maduros ou maduros. Tomates verdes são mais ácidos e possuem um maior teor de sólidos solúveis, os semi-maduros têm características intermediárias, e os maduros exibem menor acidez e uma estabilização nos sólidos solúveis. Esses dados são essenciais para a correta aplicação dos tomates em diferentes processos industriais e comerciais. Os resultados das análises individuais de cada amostras se encontram no apêndice A para pH, apêndice B para Brix e apêndice C para a concentração de ácido cítrico.

5.2 COLORIMETRIA

5.2.1 Sinais de intensidade RGB obtidos pelos sensores TCS3472

A **Figura 2** apresenta os sinais de intensidade de RGB obtidos quando os tomates foram escaneados pela esteira empregando o arranjo de sensores TCS3472. Os picos foram determinados com base no tempo de exposição dos tomates aos sensores, este tempo variava de acordo com o tamanho do tomate, que era exposto entre 1,7 e 2 segundos por tomate. Observou-se três curvas principais, cada uma representando a intensidade de uma das cores primárias do modelo R, G, e B. Além desses sinais, a quarta curva representa a diferença entre as intensidades de B e R.

Figura 2. Variação dos sinais de intensidade de cor (B: Azul, R: Vermelho, G: Verde) captados por sensores ópticos TCS3472 em cinco tomates maduros, cinco tomates semi-maduros e cinco tomates verdes, conforme eram expostos nos sensores em relação ao tempo de exposição



Fonte: Elaborado pelo autor, 2024

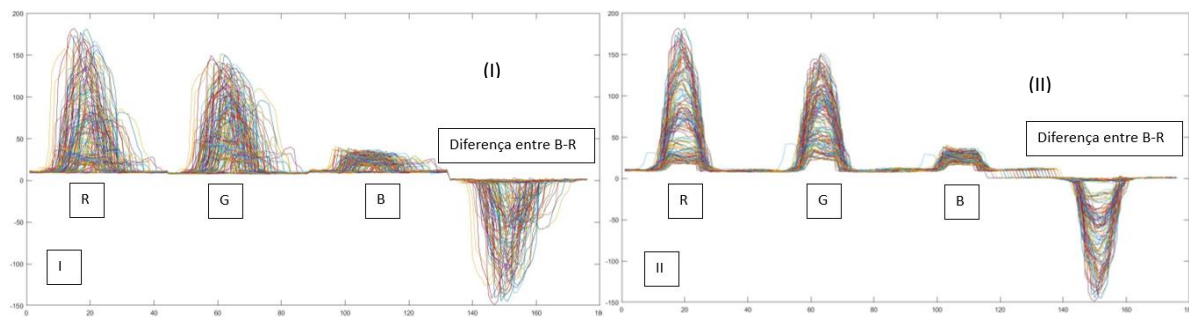
Os picos observados no gráfico correspondem aos momentos em que os tomates passam pelos sensores da cabine. Cada grau de maturação do tomate apresentou um padrão distinto de picos nas curvas RGB, refletindo as diferentes características de cor associadas a cada estágio de maturação. Os picos para tomates verdes são menos intensos e menos pronunciados, com uma maior intensidade no canal verde (G), o que indica uma predominância da cor verde. Para os tomates semi-maduros os picos são mais equilibrados entre as canal vermelho (R) e verde (G), indicando uma transição de cor à medida que os tomates começam a amadurecer. Nos

tomates maduros, os picos no canal vermelho (R) são mais intensos e pronunciados, refletindo a predominância da cor vermelha típica dos tomates completamente maduros.

A curva que mostra a diferença entre B e R é útil para facilitar a identificação do estágio de maturação dos tomates. O cálculo da diferença permite a classificação automática dos tomates enquanto eles são transportados pela esteira, melhorando a eficiência do processo de seleção e classificação na cadeia de produção agrícola.

Na **Figura 3**, todas as 150 amostras foram levadas em consideração. Cada tomate foi posicionado em um espaço específico para garantir uma medição consistente, assim, cada linha representa um tomate, e cada pico e vale se refere ao tomate escaneado. Para a centralização dos dados e a obtenção dos espectros, foi realizado um procedimento de alinhamento dos picos.

Figura 3 Espectros de variação RGB (Vermelho, Verde, Azul) para tomates em diferentes estágios de maturação. (I) medidas brutas e (II) medidas após alinhamento dos dados.



Fonte: Elaborado pelo autor, 2024

Os espectros apresentados nas imagens mostram as variações nos valores de RGB (Vermelho, Verde, Azul) para diferentes estágios de maturação de tomates: verde, semi-maduro e maduro. A **Figura 3(II)** mostra os mesmos dados centraliza os picos dos espectros. Essa centralização é realizada para facilitar a comparação entre os diferentes tomates, garantindo que os picos estejam alinhados e permitindo uma visualização mais clara das diferenças e similaridades nos espectros.

5.2.1.1 Classificação univariada por análise de limiar para os sinais de intensidade RGB

Os dados apresentados na **Tabela 2** refletem os resultados de uma classificação automatizada de tomates em diferentes estágios de maturação, utilizando limiares de intensidade para distinguir entre tomates verdes, semi-maduros e maduros.

Tabela 2. Métricas obtidas por meio da definição dos limiares para os sinais RGB

	Diferença B-R			G			R		
limiar 1*	-10.7			54			37		
limiar 2**	-63			97			89		
	M	S	V	M	S	V	M	S	V
Sensibilidade	98%	94%	100%	84%	78%	92%	96%	94%	98%
Especificidade	97%	99%	100%	89.2%	88%	91.8%	96.96	97.9%	100%
TCC	97%			83%			96%		

Fonte: Elaborado pelo autor, 2024

* limiar para separação entre os tomates verdes e semi-maduros.

** limiar para separação entre os tomates semi-maduro e maduros

Na análise da **Tabela 2** foram definidos limiares de cor baseados na diferença entre os sinais de azul (B) e vermelho (R) para distinguir tomates em vários estágios de maturação. Os limiares estabelecidos foram -10,7 para separar tomates verdes de semi-maduros e -63 para diferenciar semi-maduros de maduros.

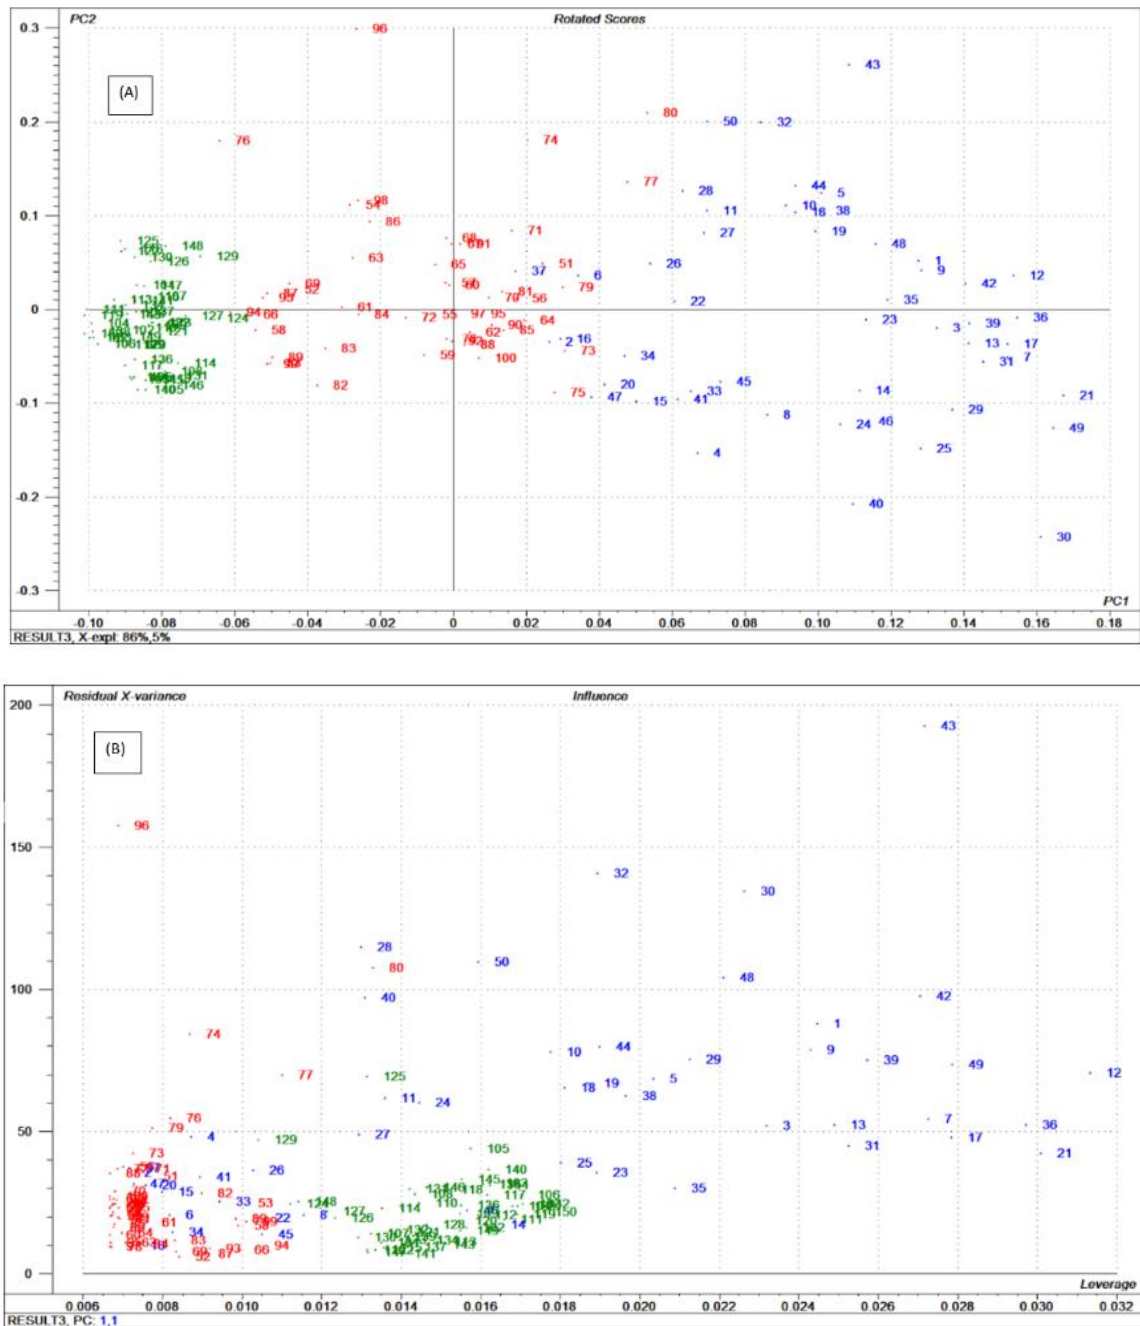
Os resultados mostraram alta precisão na classificação: tomates maduros foram corretamente identificados em 49 de 52 casos, com 3 erros, resultando em uma sensibilidade de 98% e uma especificidade de 97%. Tomates semi-maduros foram classificados corretamente em 47 de 48 casos, com 1 erro, resultando em uma sensibilidade de 94% e uma especificidade de 99%. Todos os tomates verdes foram corretamente identificados, com uma sensibilidade e especificidade de 100%. A taxa de classificação correta (TCC) geral foi de 97%, evidenciando a eficácia do sistema na triagem dos tomates com base nos limiares de cor estabelecidos.

Ademais, a aplicação dos limiares não apenas garantiu uma classificação acertada na maioria dos casos, como também minimizou erros, conforme evidenciado pelos baixos índices de classificação incorreta para tomates semi-maduros e maduros. Esse desempenho magnífico é resultado direto da aplicação rigorosa de conceitos quimiométricos, que permitem uma análise multivariada dos dados espectrais, maximizando a distinção entre as diferentes fases de maturação

5.2.1.2 Análise por Componentes Principais (PCA) - RGB

Os gráficos apresentados na Figura 4 utilizam a Análise de Componentes Principais (PCA) para avaliar os dados de reflectância e RGB de tomates em diferentes estágios de maturação: verde, semi-maduro e maduro.

Figura 4 Gráfico (A) Scores, (B) Influência de PCA para a escala de cores RGB.



Fonte: Elaborado pelo autor, 2024

No gráfico de scores (**Figura 4A**), as amostras de tomates são projetadas nos eixos das duas primeiras componentes principais, PC1 e PC2, que capturam, respectivamente, 86% e 5% da variância total dos dados. As amostras estão representadas por cores: verde para tomates verdes, vermelho para tomates semi-maduros e azul para tomates maduros. A projeção das amostras nos scores indica que há uma separação evidente entre os tomates verdes e os demais estágios de maturação. Entretanto, observa-se uma sobreposição significativa entre as amostras

de tomates semi-maduros e maduros. Essa sobreposição sugere que as características espectrais desses dois estágios de maturação são similares, dificultando a discriminação clara entre eles.

No gráfico de influence (**Figura 4B**), é avaliada a influência e o leverage das amostras sobre o modelo PCA. O leverage mede a distância de uma amostra em relação ao centroide da distribuição no espaço das componentes principais, enquanto a influência combina o leverage com a variância residual, indicando o impacto potencial de uma amostra no modelo. Um ponto específico, destacado no gráfico, apresenta alto leverage e alta influência, posicionando-se afastado das demais amostras. Essa amostra foi considerada uma outlier, mas sua remoção não resultou em uma resposta adequada, sugerindo que a inclusão dessa amostra é necessária para a robustez do modelo.

5.2.1.3 Reconhecimento de padrão supervisionado - RGB

Foram abordados três métodos para calibração e determinação da maturação do tomate através de análise de sua coloração, utilizando a escala RGB. Serão discutidos PCA-DA, PLS-DA e SIMCA. Cada um desses métodos constitui uma ferramenta robusta para análise multivariada dos dados espectrais obtidos dos tomates, permitindo a identificação precisa dos estágios de maturação com base nos padrões distintos de cor capturados pelos sensores durante a aquisição dos dados experimentais.

5.2.1.3.1 PCA-DA para dados RGB

Para a classificação dos tomates em seus três estágios de maturação utilizando o PCA-DA, utilizando 5 variáveis latentes. Os resultados encontrados na **Tabela 3**.

Tabela 3. Métricas obtidas por PCA-DA para os modelos de treinamento RGB

PCA-DA						
	Modelo			Predição		
	M	S	V	M	S	V
Precisão	87%	84%	86%	87%	84%	86%
Especificidade	93%	93%	92%	93%	93%	92%
Sensibilidade	87%	70%	100%	87%	70%	100%
TCC	86%			86%		

Fonte: Elaborado pelo autor, 2024

Foram separadas da seguinte maneira: para tomates maduros, 26 foram corretamente classificados, enquanto 4 foram erroneamente identificados como semi-maduros. Entre os tomates semi-maduros, 21 foram corretamente identificados, 4 foram incorretamente

classificados como maduros e 5 como verdes. Todos os 30 tomates verdes foram corretamente classificados.

Os resultados obtidos para o modelo PCA-DA na classificação de tomates em diferentes estágios de maturação foram analisados com base nas métricas de precisão, especificidade, sensibilidade e taxa de correção classificatória (TCC). A precisão do modelo variou entre 84% e 87% para os diferentes estágios de maturação, indicando uma taxa de acerto geral consistente. A variação observada pode refletir dificuldades na distinção entre tomates semi-maduros e outros estágios.

A especificidade do modelo, com valores entre 92 e 93%, demonstra a capacidade do PCA-DA para identificar corretamente os tomates que não pertencem a um estágio específico de maturação, minimizando a ocorrência de falsos positivos. Esta consistência sugere que o modelo é eficaz na rejeição de classificações incorretas. A sensibilidade apresentou uma variação considerável, de 70 a 100%. A sensibilidade de 100% para tomates verdes indica que o modelo consegue identificar de forma precisa este estágio. No entanto, a sensibilidade para tomates semi-maduros foi de 70%, o que sugere dificuldades na distinção deste estágio em relação aos tomates maduros e verdes. Esta variação na sensibilidade pode estar relacionada a características visuais ou espectrais que tornam a identificação dos tomates semi-maduros menos precisa.

A taxa de correção classificatória (TCC) foi de 86%, refletindo a taxa geral de sucesso do modelo na classificação correta dos tomates. Embora a TCC sugira um desempenho sólido, a variação na sensibilidade, particularmente para tomates semi-maduros, aponta para a necessidade de melhorias. Ajustes no modelo, como a inclusão de mais dados específicos para os tomates semi-maduros ou a otimização dos parâmetros do modelo, poderiam contribuir para uma maior precisão e uma identificação mais eficaz dos diferentes estágios de maturação.

5.2.1.3.2 PLS-DA para dados RGB

Os resultados para o modelo PLS-DA utilizando o sistema de cores RGB, conforme detalhado na **Tabela 4**, demonstram um desempenho eficaz na classificação de tomates em três estágios de maturação: maduros (M), semi-maduros (S) e verdes (V), com 29 tomates maduros corretamente identificados e apenas 1 erroneamente classificado como semi-maduro. Entre os tomates semi-maduros, 29 foram classificados corretamente, com 1 confundido como maduro. Todos os 30 tomates verdes foram corretamente identificados.

Tabela 4. Métricas obtidas por PLS-DA para os modelos de treinamento RGB

PLS-DA						
	Modelo			Predição		
	M	S	V	M	S	V
Precisão	97%	97%	100%	97%	97%	100%
Especificidade	98%	98%	100%	98%	98%	100%
Sensibilidade	97%	97%	100%	97%	97%	100%
TCC	98%			98%		

Fonte: Elaborado pelo autor, 2024

Utilizando cinco variáveis latentes, o modelo exibiu uma precisão geral de 97% para tomates maduros e semi-maduros, e 100% para tomates verdes. Estes valores indicam que o modelo é altamente competente na identificação correta dos tomates em todos os estágios, com uma precisão particularmente alta para tomates verdes.

A especificidade do modelo, que foi de 98% para todas as categorias, reflete a capacidade do modelo de identificar corretamente os tomates que não pertencem ao estágio específico de maturação. Esta alta especificidade sugere que o modelo minimiza a ocorrência de falsos positivos, assegurando uma distinção clara entre os diferentes estágios de maturação. Em termos de sensibilidade, o modelo apresentou uma taxa de 97% para tomates maduros e semi-maduros, e 100% para tomates verdes. Esses resultados indicam que o modelo é eficaz na detecção da maioria dos tomates maduros e semi-maduros, enquanto a sensibilidade de 100% para tomates verdes demonstra uma precisão total na identificação deste estágio específico. A alta sensibilidade geral reforça a capacidade do modelo de identificar corretamente os tomates em seus respectivos estágios de maturação.

A taxa de correção classificatória (TCC) foi de 98%, evidenciando a alta taxa de sucesso global do modelo na classificação correta dos tomates. A TCC indica uma forte concordância entre as previsões do modelo e os dados reais, destacando a robustez do modelo PLS-DA na discriminação dos diferentes estágios de maturação dos tomates.

5.2.1.3.3 SIMCA para dados RGB

Os resultados apresentados na **Tabela 5** para o modelo SIMCA utilizando o sistema de cores RGB fornecem uma análise detalhada do desempenho na classificação de tomates em três estágios de maturação: maduros (M), semi-maduros (S) e verdes (V), para tomates maduros, 23 foram corretamente classificados, 1 foi erroneamente identificado como semi-maduro, e 6 não

foram classificados. Entre os tomates semi-maduros, 19 foram classificados corretamente, 2 foram confundidos com maduros, e 9 não foram classificados. Para tomates verdes, 27 foram corretamente classificados, e 3 não foram classificados.

Tabela 5. Métricas obtidas por SIMCA para os modelos de treinamento RGB

SIMCA						
	Modelo			Predição		
	M	S	V	M	S	V
Precisão	92%	95%	100%	92%	95%	100%
Especificidade	96%	98%	100%	96%	90%	100%
Sensibilidade	76%	63%	90%	76%	63%	90%
TCC	77%			77%		

Fonte: Elaborado pelo autor, 2024

O modelo, avaliado com seis variáveis latentes, mostra uma precisão de 92% para tomates maduros, 95% para semi-maduros e 100% para verdes. Esses valores indicam que o modelo é eficaz em classificar corretamente os tomates, especialmente os verdes, que foram classificados com precisão total. No entanto, a precisão para tomates maduros e semi-maduros é ligeiramente menor, refletindo alguns erros de classificação que afetam a taxa geral de acerto.

A especificidade do modelo foi de 96% para tomates maduros, 98% para semi-maduros e 100% para verdes. Estes valores demonstram que o modelo é eficiente na identificação correta dos tomates que não pertencem ao estágio específico de maturação. A exceção é a especificidade para semi-maduros, que foi de 90%, indicando uma dificuldade em evitar falsos positivos para este estágio. Isso sugere que o modelo pode ter dificuldades adicionais em distinguir os tomates semi-maduros dos maduros.

A sensibilidade do modelo foi de 76% para tomates maduros, 63% para semi-maduros e 90% para verdes. A sensibilidade mais baixa para tomates maduros e semi-maduros sugere que o modelo encontrou desafios na identificação correta desses estágios, resultando em uma menor taxa de detecção precisa. Em contraste, a alta sensibilidade para tomates verdes mostra que o modelo é particularmente eficaz na detecção deste estágio. Essa variação na sensibilidade está relacionada justamente pela dificuldade de classificar alguns tomates em nenhum dos estágios de maturação estudados, podendo levar em conta às características visuais dos tomates que afetam a capacidade do modelo em diferenciar entre os estágios maduros e semi-maduros.

Por fim, a taxa de correção classificatória (TCC) foi de 77%, indicando uma taxa geral de sucesso moderada na classificação dos tomates. A TCC reflete a capacidade global do modelo em correlacionar as previsões com os dados reais. A TCC relativamente baixa pode ser atribuída à variação nas taxas de sensibilidade e especificidade, especialmente para tomates maduros e semi-maduros.


5.2.2 Sinais de refletância e da escala CIE L* a* b* obtidos pelo colorímetro digital CS-420

Os gráficos apresentados na **Figura 4** representam os espectros de refletância dos tomates em diferentes estágios de maturação: verde, semi-maduro e maduro. Esses espectros foram empregados para a construção de modelos multivariados com o objetivo de discriminar os estágios de maturação dos tomates com base em suas propriedades ópticas

A **Figura 5A** mostra os espectros de refletância das amostras nos três estágios de maturação. Nota-se uma tendência de incremento da refletância com o aumento do comprimento de onda, indicando variações nas propriedades ópticas dos tomates à medida que avançam no processo de maturação. A sobreposição das curvas espectrais reflete a variabilidade inerente entre as amostras, sugerindo a existência de diferenças nas características ópticas, mesmo dentro de um mesmo estágio de maturação. Tal variabilidade pode ser influenciada por fatores como a concentração de pigmentos, a composição química e a estrutura celular dos tomates.

A **Figura 5B** apresenta os espectros de refletância dos tomates maduros. Nesse estágio, observa-se um aumento na refletância com o comprimento de onda, caracterizado por uma curva espectral mais acentuada e uma variação entre as medições. Esse comportamento pode estar relacionado às modificações na composição de pigmentos, como o licopeno, responsáveis pela coloração vermelha do tomate maduro. As flutuações nos espectros podem estar associadas às mudanças na estrutura e na textura do tomate durante a maturação.

Figura 5 Espectros de refletância obtidos pelo colorímetro CS-420 (A) das amostras em diferentes estágios de maturação, (B) tomates maduros, (C) tomates semi-maduros, (D) tomates verdes



Fonte: Elaborado pelo autor, 2024

Na **Figura 5C** os espectros de reflectância correspondem aos tomates semi-maduros. Em comparação com os espectros dos tomates maduros, os tomates semi-maduros apresentam uma curva de reflectância ascendente com o comprimento de onda, porém de forma menos acentuada. Esse comportamento indica que os tomates semi-maduros possuem propriedades ópticas intermediárias entre os tomates verdes e maduros, refletindo a transição na composição de pigmentos e na estrutura do fruto durante o amadurecimento.

A **Figura 5D** apresenta os espectros de reflectância dos tomates verdes. A curva de reflectância para os tomates verdes também aumenta com o comprimento de onda, mas de maneira mais uniforme em relação aos estágios semi-maduro e maduro. A menor variabilidade nas medições sugere uma homogeneidade nas propriedades ópticas dos tomates verdes, possivelmente devido à predominância da clorofila nesta fase de maturação.

5.2.2.1 Classificação por análise de limiar para dados CIE L^* a^* b^*

Na análise das amostras de tomate utilizando a escala CIE Lab, não foi possível estabelecer um limiar definido para os valores dos componentes a^* e b^* da cor. Isso ocorreu porque os valores de a^* (representando a componente vermelho-verde) e b^* (representando a componente amarelo-azul) não exibiram variações substanciais entre os diferentes lotes e

estados de maturação dos tomates. Por outro lado, o valor L^* (que indica a luminosidade) demonstrou mudanças significativas e consistentes ao longo do processo de maturação.

Essas variações nos valores L^* proporcionaram uma distinção clara entre os tomates maduros, semi-maduros e verdes, refletindo as alterações na aparência visual dos frutos à medida que evoluem na maturação. No entanto, a estabilidade dos valores de a^* e b^* indicou que esses parâmetros não foram suficientemente sensíveis para discriminar os estados de maturação com base na cor.

Os resultados obtidos para tomates maduros, a classificação foi precisa, com 49 acertos e apenas 1 erro, no caso dos tomates semi-maduros, foram obtidos 45 acertos e 5 erros, para os tomates verdes, a precisão apresentou alguns erros significativos, com 47 acertos e 3 erros, onde esses erros levando em consideração que a separação dos tomates verdes dos outros dois estágios de maturação, é feita por parâmetros de cor evidentes. Os valores das métricas obtidos para determinar a eficácia do modelo se encontram na **Tabela 6**.

Tabela 6. Métricas obtidas por meio da definição dos limiares para os dados CIE $L^* a^* b^*$

Luminosidade			
limiar *		53.67	
limiar **		42.73	
	M	S	V
Sensibilidade	98%	90%	94%
Especificidade	99%	96%	93%
TCC	94%		

Fonte: Elaborado pelo autor, 2024

* limiar para separação entre os tomates verdes e semi-maduros.

** limiar para separação entre os tomates semi-maduro e maduros.

A classificação dos tomates em diferentes estágios de maturação foi realizada com base em limiares de luminosidade (L^*) da escala CIE $L^* a^* b^*$. Foram estabelecidos dois limiares: 53,67, que diferencia tomates verdes de semi-maduros, e 42,73, que separa semi-maduros de maduros. Esses limiares desempenham um papel crucial na segmentação das amostras de tomate, permitindo uma distinção eficiente entre os diferentes estágios de maturação.

A análise dos dados revela uma acurácia impressionante, particularmente para os tomates maduros, onde a sensibilidade de 98% e a especificidade de 99% destacam a eficácia do limiar inferior. Esses resultados são indicativos de um sistema robusto, capaz de minimizar erros de classificação e garantir uma identificação correta na maioria dos casos. A alta taxa de

acertos para os tomates maduros, com 49 classificações corretas em 50 casos, demonstra a confiabilidade do modelo.

Por outro lado, a classificação dos tomates semi-maduros, com uma sensibilidade de 90% e especificidade de 96%, também confirma a adequação do limiar superior, embora com uma precisão ligeiramente inferior. Este desempenho ainda é considerável, refletindo um equilíbrio entre os parâmetros de classificação, mesmo que tenha havido 5 erros em 50 tentativas.

No entanto, os tomates verdes apresentaram uma taxa de precisão um pouco menor, com 47 acertos e 3 erros, o que resulta em uma sensibilidade de 94% e especificidade de 93%. Esses valores, embora sólidos, indicam que a separação dos tomates verdes dos demais estágios, apesar de baseada em parâmetros de cor visíveis, poderia ser refinada para aumentar a precisão.


A TCC geral de 94% alcançada pelo sistema evidencia sua eficácia global na segmentação dos estágios de maturação, validando os limiares de luminosidade escolhidos. A aplicação desses limiares na análise quimiométrica das amostras de tomate confirma o potencial do método para ser amplamente adotado em processos industriais de controle de qualidade, contribuindo para uma seleção mais precisa e eficiente.

5.2.2.2 Análise por Componentes Principais (PCA) – Refletância

Nos gráficos de scores e loadings da **Figura 6** apresentados, são analisadas as características espectrais com base na refletância de tomates em três estágios de maturação: maduros (azul escuro), semi-maduros (verde escuro) e verdes (verde neon), por meio de Análise de Componentes Principais (PCA). As amostras foram projetadas nos eixos das duas primeiras componentes principais, PC1 e PC2.

(A)

Figura 6 Gráfico (A) Scores, (B) Influência de PCA para reflectância.



Fonte: Elaborado pelo autor, 2024

Na **Figura 6A** a PC1 explica a maior parte da variância total dos dados (72%), enquanto a PC2 captura uma porção adicional da variabilidade (23%), permitindo a visualização da distribuição das amostras. Observa-se que as amostras de tomates verdes (verde neon) estão claramente separadas dos demais estágios ao longo da PC1, sugerindo que essa componente principal está fortemente associada às diferenças espectrais características dos tomates verdes. Em contraste, as amostras de tomates maduros (azul escuro) e semi-maduros (verde escuro)

apresentam uma sobreposição considerável, indicando que a PC2, embora capture variabilidade adicional, não é suficiente para discriminar de forma clara entre esses dois estágios. Essa sobreposição pode refletir a similaridade nas propriedades espectrais entre tomates maduros e semi-maduros.

Na **Figura 6B**, é possível identificar quais variáveis espectrais (comprimentos de onda) têm maior influência na formação das componentes principais. As variáveis associadas à PC1 estão relacionadas principalmente à discriminação entre tomates verdes e os outros estágios, enquanto as variáveis carregadas na PC2 fornecem informações adicionais que podem ajudar na distinção, embora com menor eficácia, entre tomates semi-maduros e maduros.

A análise do leverage e da influência das amostras no modelo revela que algumas amostras de tomates verdes apresentam leverage elevado, indicando que elas se encontram distantes do centroide no espaço das componentes principais. Essas amostras, que também apresentam alta influência, podem ser consideradas outliers e possuem um impacto significativo na modelagem, sendo cruciais para a robustez do modelo.

5.2.1.3 Reconhecimento de padrão supervisionado – Refletância

Foram analisados três métodos para calibrar e determinar o estágio de maturação dos tomates com base na refletância: PCA-DA, PLS-DA e SIMCA. Esses métodos permitem identificar com precisão os estágios de maturação a partir dos dados espectrais obtidos.

5.2.2.3.1 PCA-DA para dados de reflectância

A análise dos resultados obtidos com o modelo PCA-DA para a classificação de tomates com base na refletância classificou da seguinte maneira: 25 tomates maduros foram corretamente classificados, enquanto 5 foram erroneamente identificados como semi-maduros. Entre os semi-maduros, 24 foram corretamente classificados, com apenas 5 sendo confundidos com maduros e 1 com verde. Já para os tomates verdes, todos os 30 tomates verdes foram corretamente identificados. A **Tabela 7** apresenta as métricas de precisão, especificidade, sensibilidade e taxa de concordância global (TCC), que são fundamentais para a avaliação da eficácia do modelo.

A precisão, que varia de 83% a 97%, reflete a capacidade do modelo de realizar classificações corretas dentro de cada categoria de maturação. Os valores relativamente elevados indicam uma boa capacidade de discriminação do modelo, embora haja variação entre as categorias. A especificidade, alcançando até 97%, demonstra a competência do modelo em

identificar corretamente tomates dentro de uma classe específica sem confundí-los com outras categorias. Essa métrica é particularmente importante para evitar falsas identificações de tomates maduros como semi-maduros e vice-versa.

Tabela 7. Métricas obtidas por PCA-DA para os modelos de treinamento Refletância.

PCA-DA						
	Modelo			Predição		
	M	S	V	M	S	V
Precisão	83%	83%	97%	83%	83%	97%
Especificidade	92%	92%	98%	92%	92%	98%
Sensibilidade	83%	80%	100%	83%	80%	100%
TCC	88%			88%		

Fonte: Elaborado pelo autor, 2024

A sensibilidade, que apresenta valores de 92% a 98% e uma taxa de 100% para tomates verdes, evidencia a habilidade do modelo em detectar corretamente cada estágio de maturação, especialmente os tomates verdes. A alta sensibilidade para tomates verdes sugere que a refletância é particularmente eficaz na identificação deste estágio específico, o que pode ser crucial para aplicações que exigem precisão na identificação de tomates verdes, como em processos de colheita e comercialização.

A taxa de concordância global (TCC) de 88% indica a proporção geral de classificações corretas realizadas pelo modelo. Este valor sugere uma leve melhoria em comparação com o modelo baseado na escala RGB, o que pode ser atribuído à capacidade superior da refletância em capturar detalhes sutis na coloração dos tomates.

Os resultados demonstram que o modelo PCA-DA baseado na refletância é eficaz na classificação dos tomates em diferentes estágios de maturação. A refletância proporciona uma vantagem na sensibilidade e especificidade, especialmente para tomates verdes e semi-maduros, indicando que este método pode ser mais apropriado para situações que exigem uma distinção precisa entre diferentes estágios de maturação. No entanto, as confusões observadas na classificação de tomates maduros como semi-maduros e vice-versa sugerem que ainda há espaço para otimização do modelo, possivelmente através da combinação de diferentes técnicas ou da incorporação de mais variáveis na análise.

5.2.1.3.2 PLS-DA para dados de reflectância

A análise do modelo PLS-DA para a classificação de tomates com base na reflectância revela um desempenho consistente, embora com variações em relação às diferentes categorias de maturação, onde para tomates maduros, 25 foram corretamente classificados, 2 foram erroneamente identificados como semi-maduros e 3 como verdes. Para os semi-maduros, 23 foram corretamente classificados, com 5 sendo confundidos com maduros e 2 com verdes. No caso dos tomates verdes, 27 foram classificados corretamente e 3 foram confundidos com semi-maduros. A **Tabela 8** apresenta as métricas de precisão, especificidade, sensibilidade e taxa de concordância global (TCC), que são fundamentais para a avaliação da eficácia do modelo.

Tabela 8. Métricas obtidas por PLS-DA para os modelos de treinamento para reflectância

PLS-DA						
	Modelo			Predição		
	M	S	V	M	S	V
Precisão	83%	82%	84%	83%	82%	84%
Especificidade	92%	92%	92%	92%	92%	92%
Sensibilidade	83%	77%	90%	83%	77%	90%
TCC	83%			83%		

Fonte: Elaborado pelo autor, 2024

A precisão do modelo, que mede a proporção de classificações corretas, variou de 82 a 84% entre as diferentes categorias. Esses valores sugerem que o modelo tem uma capacidade razoável de distinguir entre tomates maduros, semi-maduros e verdes, embora não seja tão preciso quanto outros modelos, como o PCA-DA. A especificidade, que foi consistente em 92% para todas as categorias, indica que o modelo tem uma boa capacidade de evitar a classificação incorreta de tomates em classes erradas, uma característica importante para minimizar erros em aplicações práticas.

A sensibilidade, que variou de 77 a 90%, mostra que o modelo é particularmente eficaz na identificação de tomates verdes, com uma taxa de 90%. No entanto, a sensibilidade reduzida para tomates semi-maduros (77%) sugere uma limitação na capacidade do modelo em diferenciar corretamente este estágio específico de maturação, resultando em confusões com tomates maduros e verdes.

A taxa de concordância global (TCC) de 83% indica uma classificação geral eficaz, embora não tão robusta quanto a observada em modelos alternativos. A análise dos erros de

classificação revela que, enquanto o modelo PLS-DA é razoavelmente preciso na identificação de tomates maduros e verdes, há uma tendência a confundir tomates semi-maduros com outras categorias, o que pode limitar sua aplicabilidade em cenários onde a precisão é crítica.

5.2.1.3.3 SIMCA para dados de refletância

A análise do modelo SIMCA aplicado à classificação de tomates com base na refletância revela um desempenho misto, com variações significativas entre as diferentes categorias de maturação, onde para tomates maduros, 19 foram corretamente classificados, 3 foram erroneamente identificados como semi-maduros, e 8 não foram classificados. Entre os tomates semi-maduros, 20 foram classificados corretamente, com 10 não classificados. Todos os 30 tomates verdes foram corretamente identificados. A **Tabela 9** detalha as métricas de precisão, especificidade, sensibilidade e taxa de concordância global (TCC), fornecendo uma visão abrangente da eficácia do modelo.

Tabela 9. Métricas obtidas por SIMCA para os modelos de treinamento para a refletância

SIMCA						
	Modelo			Predição		
	M	S	V	M	S	V
Precisão	86%	87%	100%	86%	87%	100%
Especificidade	94%	94%	100%	94%	94%	100%
Sensibilidade	63%	66%	100%	63%	66%	100%
TCC	77%			77%		

Fonte: Elaborado pelo autor, 2024

A análise do modelo SIMCA aplicado à classificação de tomates com base na refletância revela um desempenho misto, com variações significativas entre as diferentes categorias de maturação. A tabela detalha as métricas de precisão, especificidade, sensibilidade e taxa de concordância global (TCC), fornecendo uma visão abrangente da eficácia do modelo. A precisão do modelo foi de 86% para tomates maduros, 87% para semi-maduros e 100% para tomates verdes, indicando que o SIMCA é eficaz na classificação correta, especialmente para tomates verdes. A especificidade, que mede a capacidade do modelo de evitar falsas classificações, foi de 94% para tomates maduros e semi-maduros, e de 100% para tomates verdes, reforçando a robustez do modelo na diferenciação entre tomates verdes e outros estágios.

No entanto, a sensibilidade, que reflete a capacidade do modelo de identificar corretamente todos os tomates de uma categoria específica, foi menor para tomates maduros (63%) e semi-maduros (66%), o que indica uma limitação do modelo na detecção completa desses estágios. Essa limitação é evidenciada pela quantidade significativa de tomates que não foram classificados (8 maduros e 10 semi-maduros), o que pode comprometer a aplicabilidade do modelo em cenários que exigem alta sensibilidade. A taxa de concordância global (TCC) de 77% sugere que, embora o modelo SIMCA baseado na reflectância tenha um desempenho geral aceitável, ele é inferior em comparação com outros modelos, como o PCA-DA e o PLS-DA, especialmente no que se refere à sensibilidade para tomates maduros e semi-maduros.

5.2.3 Comparação Entre Modelos

5.2.3.1 Limiares

A comparação entre os métodos RGB e CIE L* a* b* destaca que ambos apresentam vantagens e limitações. O método RGB apresentou uma alta sensibilidade e especificidade, especialmente para tomates maduros e verdes, com uma taxa de classificação correta global superior. No entanto, a abordagem RGB pode enfrentar desafios em cenários com variações sutis de cor. Por outro lado, a metodologia CIE L* a* b* demonstrou uma robustez significativa na discriminação de tomates maduros com alta sensibilidade e especificidade, mas a precisão para tomates semi-maduros e verdes foi um pouco menor em comparação ao método RGB. A taxa de classificação correta global foi ligeiramente inferior para a escala CIE L* a* b*, refletindo uma eficácia geral um pouco reduzida na separação dos estágios de maturação.

Enquanto o método RGB oferece uma solução eficaz e com alta precisão geral, o método CIE L* a* b* proporciona uma análise detalhada com melhor discriminação de luminosidade, porém com menor precisão relativa em alguns estágios de maturação. A escolha entre os métodos pode depender das condições específicas de aplicação e dos requisitos de precisão para a classificação dos tomates.

5.2.3.2 PCA

Comparando os dois métodos, o método RGB oferece uma separação eficaz entre tomates verdes e os outros estágios, com a PC1 desempenhando um papel dominante na discriminação. A PC2 do método RGB, no entanto, não melhora significativamente a separação entre tomates semi-maduros e maduros. Por outro lado, o método com base na reflectância também utiliza a PC1 para separar os tomates verdes dos demais estágios, com um desempenho

semelhante. No entanto, a PC2 no método de reflectância explica uma proporção maior da variância (23% em comparação com 5% no RGB), mas ainda assim não proporciona uma discriminação clara entre tomates maduros e semi-maduros.

Ambos os métodos utilizam a PC1 de forma eficaz para separar os tomates verdes, mas enfrentam desafios na discriminação entre tomates semi-maduros e maduros. O método de reflectância oferece uma PC2 que explica uma proporção maior da variância, mas isso não se traduz em uma melhoria substancial na separação dos estágios de maturação mais próximos. O método RGB, por outro lado, mostra uma alta variância explicada pela PC1, mas com uma contribuição menor da PC2 para a discriminação adicional. Ambos os métodos indicam que a separação entre tomates semi-maduros e maduros é uma área crítica onde melhorias podem ser necessárias.

5.2.3.3 PCA-DA

Comparando os métodos, o modelo PCA-DA baseado na reflectância demonstrou uma precisão e especificidade geral superiores em comparação com o modelo RGB. A maior taxa de concordância global no modelo de reflectância (88% contra 86% no RGB) sugere uma capacidade melhor para classificar corretamente os tomates em seus diferentes estágios de maturação.

A sensibilidade do modelo baseado na reflectância também foi superior para tomates verdes e semi-maduros, indicando uma vantagem na identificação desses estágios. No entanto, a sensibilidade para tomates maduros foi ligeiramente inferior no modelo de reflectância em comparação com o modelo RGB. Isso sugere que, embora o modelo de reflectância seja mais eficaz na identificação de tomates verdes e semi-maduros, ainda há desafios na distinção precisa entre tomates maduros e semi-maduros.

Ambos os métodos mostram que a identificação precisa de tomates semi-maduros é uma área crítica para otimização. O modelo de reflectância parece oferecer vantagens na capacidade de capturar detalhes sutis na coloração dos tomates, o que pode melhorar a precisão na classificação dos diferentes estágios de maturação. A combinação de métodos ou a incorporação de mais variáveis pode ser considerada para superar as limitações atuais e melhorar a discriminação entre todos os estágios de maturação dos tomates.

5.2.3.4 PLS-DA

Comparando os modelos, o PLS-DA com RGB apresentou desempenho superior em termos de precisão, especificidade e taxa de correção classificatória. A precisão geral do modelo RGB foi de 97% para tomates maduros e semi-maduros e 100% para tomates verdes, enquanto a precisão do modelo baseado na refletância variou de 82 a 84%. A especificidade também foi mais alta no modelo RGB, com 98% em comparação com 92% no modelo de refletância, o que demonstra uma melhor capacidade de evitar falsos positivos.

A sensibilidade foi melhor para tomates verdes no modelo de refletância, mas o modelo RGB teve uma sensibilidade geral mais alta e mais consistente. A taxa de correção classificatória foi também superior no modelo RGB (98 versus 83% para o modelo refletância), indicando um desempenho mais robusto e confiável.

O modelo PLS-DA utilizando dados RGB mostrou-se mais eficiente na classificação dos tomates em diferentes estágios de maturação em comparação com o modelo baseado na refletância. A diferença na precisão e taxa de correção global sugere que o sistema RGB pode ser mais adequado para aplicações que exigem alta precisão e confiabilidade na classificação dos estágios de maturação dos tomates.

5.2.3.5 SIMCA

Comparando os modelos, o SIMCA com dados RGB mostrou uma precisão mais alta para tomates maduros e semi-maduros e uma taxa de correção global superior (77% ambos). A especificidade também foi mais alta para tomates maduros e semi-maduros no modelo RGB (96 e 98% versus 94% para ambos no modelo refletância). No entanto, a sensibilidade foi comparável entre os dois modelos para tomates verdes (90% para RGB e 100% para refletância), mas o modelo baseado em RGB demonstrou uma capacidade superior em identificar tomates maduros e semi-maduros.

O modelo SIMCA com dados RGB revelou-se mais eficaz na classificação geral dos tomates, com melhor precisão e especificidade, enquanto o modelo baseado na refletância CIE L^* a^* b^* apresentou melhores resultados na identificação de tomates verdes, mas com dificuldades significativas na classificação de tomates maduros e semi-maduros. A escolha do modelo pode depender da necessidade específica de precisão e sensibilidade em diferentes contextos de aplicação.

6 CONCLUSÃO

A comparação dos resultados obtidos com diferentes modelos de classificação revelou várias conclusões importantes. Para as análises univariadas, os limiares definidos, com -10,7 para a diferença entre os canais azul (B) e vermelho (R), e -63 para distinguir tomates semi-maduros de maduros, resultaram em uma taxa de classificação correta (TCC) de 97%. As sensibilidades e especificidades foram altas, com 98% de sensibilidade para tomates maduros, 94% para semi-maduros e 100% para verdes, indicando a eficácia da diferença B-R na diferenciação dos estágios de maturação. Comparado aos limiares baseados apenas nos sinais individuais de R e G, a abordagem baseada na diferença B-R demonstrou desempenho superior em termos de sensibilidade e especificidade. Em particular, o sinal verde (G) mostrou desempenho inferior, com valores de 84% para maduros e 79% para semi-maduros, sugerindo que a abordagem B-R é mais discriminativa e precisa para capturar as variações de cor e luminosidade associadas aos diferentes estágios de maturação.

Na análise das componentes principais (PCA), ambos os métodos utilizaram a primeira componente principal (PC1) de forma eficaz para distinguir tomates verdes dos demais estágios. No entanto, a segunda componente principal (PC2) ofereceu uma explicação maior da variância para o método de refletância, mas não resultou em uma melhora substancial na discriminação entre tomates maduros e semi-maduros, o que sugere que melhorias são necessárias nessa área para ambos os métodos. Os resultados do modelo PCA-DA indicam que o modelo baseado na refletância apresentou uma precisão e especificidade gerais superiores em comparação ao modelo RGB. A maior taxa de concordância global no modelo de refletância sugere uma capacidade aprimorada para classificar corretamente os tomates. Contudo, a sensibilidade para tomates maduros foi um pouco inferior no modelo de refletância, indicando desafios na distinção precisa entre tomates maduros e semi-maduros.

O modelo PLS-DA com dados RGB demonstrou um desempenho superior em termos de precisão, especificidade e taxa de correção classificatória, destacando-se na identificação de tomates maduros e semi-maduros, além de oferecer uma taxa de correção global mais alta. Por outro lado, o modelo de refletância teve uma sensibilidade superior para tomates verdes, mas com uma precisão geral inferior, o que sugere que o sistema RGB pode ser mais adequado para aplicações que exigem alta precisão e confiabilidade na classificação dos estágios de maturação dos tomates. Finalmente, o modelo SIMCA revelou que a abordagem RGB ofereceu uma melhor precisão e especificidade na classificação de tomates maduros e semi-maduros, enquanto o modelo de refletância demonstrou melhores resultados na identificação de tomates

verdes. A escolha entre os modelos deve considerar a necessidade específica de precisão e sensibilidade, com a possibilidade de integrar diferentes métodos ou variáveis adicionais para aprimorar a discriminação entre todos os estágios de maturação dos tomates.

Portanto, o método utilizando os sensores TCS3472 que obteve dados de intensidade RGB demonstrou ser superior ao método de refletância em termos de precisão, especificidade, e taxa de correção classificatória. O modelo RGB foi mais eficaz na classificação dos tomates em seus diferentes estágios de maturação, especialmente para tomates maduros e semi-maduros. O método de refletância, por outro lado, teve um desempenho melhor na identificação de tomates verdes, mas com uma precisão geral e taxa de correção inferior. Portanto, o método RGB é geralmente mais recomendado para aplicações que exigem alta precisão e confiabilidade na classificação dos estágios de maturação dos tomates.

REFERÊNCIAS

- ABDELHAMID, M. A.; SUDNIK, Y. A.; ALSHINAYYIN, H. J.; SHAABAN, F. Chlorophyll fluorescence for classification of tomato fruits by their maturity stage. *E3S Web of Conferences*, v. 193, p. 01065–01065, 2020. <https://doi.org/10.1051/e3sconf/202019301065>.
- ABERA, G.; IBRAHIM, A. M.; FORSIDO, S. F.; KUYU, C. G. Assessment on post-harvest losses of tomato (*Lycopersicon esculentum* Mill.) in selected districts of East Shewa Zone of Ethiopia using a commodity system analysis methodology. *Heliyon*, v. 6, n. 4, p. e03749, 2020. <https://doi.org/10.1016/j.heliyon.2020.e03749>.
- ADEDEJI, O.; TAIWO, K. A.; AKANBI, C. T.; AJANI, R. Physicochemical properties of four tomato cultivars grown in Nigeria. *Journal of Food Processing and Preservation*, v. 30, n. 1, p. 79–86, 2006. <https://doi.org/10.1111/j.1745-4549.2005.00049.x>.
- AGIUS, C.; VON TUCHER, S.; ROZHON, W. The effect of salinity on fruit quality and yield of cherry tomatoes. *Horticulturae*, v. 8, n. 1, p. 59, 2022. <https://doi.org/10.3390/horticulturae8010059>.
- AGUIAR, F. C. O.; GUARIGLIA, B. A. D.; DE BRITO, A. A.; CAMPOS, L. F. C.; NASCIMENTO, A. D. R.; DE CARVALHO CORRÊA, G.; CUNHA, L. C.. Validação prática de modelos de infravermelho próximo para tomate: sólidos solúveis e acidez. *Revista De Ciências Agroveterinárias*, v. 21, n. 2, p. 114–122, 2022. <https://doi.org/10.5965/223811712122022114>.
- AGUNG, A. S.; DIRGANTARA, A. F.; HERSYAM, M. S.; KASWAR, A. B.; ANDAYANI, D. D. Classification of tomato quality based on color features and skin characteristics using image processing based artificial neural network. *Jurnal Teknik Informatika (Jutif)*, v. 4, n. 5, p. 1021-1032, 2023. <https://doi.org/10.52436/1.jutif.2023.4.5.730>.
- ANDRADE, J. C.; GALVAN, D.; EFFTIG, L.; LELIS, C.; MELQUIADES, F. L.; BONA, E.; CONTE-JUNIOR, C. A.. An Easy-to-Use and Cheap Analytical Approach Based on NIR and Chemometrics for Tomato and Sweet Pepper Authentication by Non-volatile Profile. *Food Analytical Methods*, v. 16, n. 3, p. 567–580, 2022. <https://doi.org/10.1007/s12161-022-02439-4>.
- BARROS, F. M. Universidade Federal de Alagoas Centro de Tecnologia - CTEC Engenharia Química. Estudo cinético da fermentação de bebida alcoólica de tomate (*Lycopersicon esculentum* Mill).
- BARROS, P. P. D. S.; ROSALEN, D. L.; IOST FILHO, F. H.; MARTINS, G. D.; DI LEO, N. Monitoring plant health using remote sensing: advances and challenges. *Revista Brasileira de Cartografia*. <https://doi.org/10.14393/rbcv73n2-56597>.
- BHARGAVA, A.; BANSAL, A. Fruits and vegetables quality evaluation using computer vision: A review. *Journal of King Saud University - Computer and Information Sciences*, v. 33, n. 3, p. 312–319, 2018. <https://doi.org/10.1016/j.jksuci.2018.06.002>. Acesso em: 21 jul. 2024.

- BISSACOTTI, A. P.; LONDERO, P. M. G.; COSTABEBER, I. H. Tomate: Botânica, produção, composição nutricional e benefícios à saúde. *Cadernos de Ciência & Tecnologia*, v. 38, n. 2, p. 26643, 12 ago. 2021.
- BONIFAZI, G.; CAPOBIANCO, G.; GASBARRONE, R.; SERRANTI, S. Contaminant detection in pistachio nuts by different classification methods applied to short-wave infrared hyperspectral images. *Food Control*, v. 130, p. 108202, 2021. <https://doi.org/10.1016/j.foodcont.2021.108202>.
- BORBA, K. R.; OLDONI, F. C.; MONARETTO, T.; COLNAGO, L. A.; FERREIRA, M. D. Selection of industrial tomatoes using TD-NMR data and computational classification methods. *Microchemical Journal*, v. 164, p. 106048, 2021. <https://doi.org/10.1016/j.microc.2021.106048>.
- BRERETON, R. G.; JANSEN, J.; LOPES, J.; MARINI, F.; POMERANTSEV, A.; RODIONOVA, O.; ROGER, J. M.; WALCZAK, B.; TAULER, R. Chemometrics in analytical chemistry— part II: modeling, validation, and applications. *Analytical and Bio.*
- CARDOSO, B.; REIS, D. Universidade Estadual Paulista Faculdade de Ciências Agrárias e Veterinárias - Câmpus de Jaboticabal. Utilização do resíduo industrial do tomate na alimentação de vacas leiteiras: revisão bibliográfica. [S.l.: s.n.]. Disponível em: <https://repositorio.unesp.br/handle/11449/49647>. Acesso em: 4 out. 2023.
- CARVALHO, S. A.; FIGUEIREDO NETO, A.; COSTA, M. de S.; COSTA, J. D. de S.; PEREIRA FILHO, A.; ARAGÃO, C. A. Efeitos da aplicação de revestimentos biodegradáveis na conservação pós-colheita de tomate. *Research, Society and Development*, v. 11, n. 9, p. e59011931677, 2022. <https://doi.org/10.33448/rsd-v11i9.31677>.
- CHEN, Z.; DE BOVES HARRINGTON, P. Automatic soft independent modeling for class analogies. *Analytica Chimica Acta*, v. 1090, p. 47–56, 2019. <https://doi.org/10.1016/j.aca.2019.09.035>.
- COCCO, C.; PAULETTI, G. F.; DA SILVA, L. C.; LAGUNA, S. E. Aplicação de ácido abscísico e etefom na qualidade de uvas Merlot para vinificação. 2020.
- CONSTANTINO, L.; REGINA, S. A.; SIMÕES-NOGUEIRA, A.; BARROS, R.; ZEFFA, D. M.; NICIO, T. T.; OLIVEIRA, C.; SIMÕES, L. Post-harvest characterization and sensory analysis of Roma tomato cultivars under organic cultivation: A strategy using consumers and chefs. *International Journal of Gastronomy and Food Science*, v. 29, p. 100564–100564, 2022. <https://doi.org/10.1016/j.ijgfs.2022.100564>.
- DAVIDE DE ANGELIS; SUMMO, C.; PASQUALONE, A.; FACCIA, M.; SQUEO, G. Advancements in food authentication using soft independent modelling of class analogy (SIMCA): a review. *Food Quality and Safety*, 2024. <https://doi.org/10.1093/fqsafe/fyae032>.
- DI, M.; CHEN, S. Bayesian compressive principal component analysis. *Frontiers of Computer Science*, v. 14, n. 4, p. 144303, 2020. <https://doi.org/10.1007/s11704-019-8308-9>.
- DOMICIANO, S. A.; CASAGRANDE, J. G.; REALTO, G. B.; DA SILVA, I. V.; DE CARVALHO, M. A. C.; ZANUZO, M. R.; JÚNIOR, S. S.. Análise sensorial, físico-química e bioquímica de tomate italiano cultivados nos sistemas orgânico e convencional. *Revista*

Ibero-Americana De Ciências Ambientais, v. 12, n. 3, p. 72–81, 2021.
<https://doi.org/10.6008/cbpc2179-6858.2021.003.0007>.

DUSSÁN-SARRIA, S.; GARZÓN-GARCÍA, A. M.; MELO-SEVILLA, R. E.
Desenvolvimento e avaliação de um protótipo de medição de cor em vegetais frescos.
Informação Tecnológica, v. 31, n. 1, p. 253-264, 2020. <https://doi.org/10.4067/S0718-07642020000100001>.

FARIA, S. E. S.; AZEVEDO, A. M. Fenotipagem de alta eficiência pela análise computacional de imagens no melhoramento genético do tomateiro. Tese (Doutorado) – Área de Concentração em Produção Vegetal. Universidade Federal de Minas Gerais / Instituto de Ciências Agrárias, 2024.

FAROOQ, A.; NIAZ, B.; SAEED, F.; AFZAAL, M.; KHALID, M. A.; RAZA, M. A.; JBAWI, E. A.. Exploring the potential of aloe vera gel-based coating for shelf life extension and quality preservation of tomato. *International Journal of Food Properties*, v. 26, n. 2, p. 2909–2923, 2023. <https://doi.org/10.1080/10942912.2023.2263661>.

FEDATO, B. N.; VIEITES, R. L. Qualidade nutricional e compostos bioativos de tomates submetidos a diferentes métodos de processamento. Faculdade de Ciências Agrônômicas da Unesp – Câmpus de Botucatu, 2023.

FELFÖLDI, Z.; RANGA, F.; ROMAN, I. A.; SESTRAS, A. F.; VODNAR, D. C.; PROHENS, J.; SESTRAS, R. E.. Analysis of Physico-Chemical and Organoleptic Fruit Parameters Relevant for Tomato Quality. *Agronomy*, v. 12, n. 5, p. 1232, 2022.
<https://doi.org/10.3390/agronomy12051232>.

FILOTEO-RAZO, J. D.; ESTUDILLO-AYALA, J. M.; HERNÁNDEZ-GARCÍA, J. C.; JÁUREGUI-VÁZQUEZ, D.; ROJAS-LAGUNA, R.; VALLE-ATILANO, F. J.; SÁMANO-AGUILAR, L. F. Sensor RGB para detectar cambios de color en piel de frutas. *Acta Universitaria*, v. 26, n. 1, p. 24-29, 2016.
<http://www.redalyc.org/articulo.oa?id=41648312006>.

GOISSER, S.; FERNANDES, M.; WITTMANN, S.; ULRICHS, C.; MEMPEL, H.. Evaluating the practicability of commercial food-scanners for non-destructive quality assessment of tomato fruit. *Journal of Applied Botany and Food Quality*, 2020.
<https://doi.org/10.5073/JABFQ.2020.093.025>.

GOMES, A. D. A.; GALVÃO, R. K. H.; DE ARAÚJO, M. C. U.; VÉRAS, G.; DA SILVA, E. C. The successive projections algorithm for interval selection in PLS. *Microchemical Journal*, v. 110, p. 202–208, 2013. <https://doi.org/10.1016/j.microc.2013.03.015>.

GÓMEZ, R.; COSTA, J.; AMO, M.; ALVARRUIZ, A.; PICAZO, M.; PARDO, J. E.. Physicochemical and colorimetric evaluation of local varieties of tomato grown in SE Spain. *Journal of the Science of Food and Agriculture*, v. 81, n. 11, p. 1101–1105, 2001.
<https://doi.org/10.1002/jsfa.915>.

HIRAM, A. A. C.; RAGOZZINO, M.; MOURA, N.; RENAN CABRITA VALLADÃO. Estudo espectroscópico e colorimétrico do corante amarelo usado em impressora a jato de tinta. *Brazilian Journal of Development*, v. 9, n. 1, p. 3242–3257, 2023.
<https://doi.org/10.34117/bjdv9n1-226>.

HONGYU, K.; SANDANIELO, V. L. M.; JUNIOR, G. J. D. O.. Análise de Componentes Principais: resumo teórico, aplicação e interpretação. *E&S - Engineering and Science*, v. 5, n. 1, p. 83–84, 2016.

HU, T.; LAI, Q.; FAN, W.; ZHANG, Y.; LIU, Z.. Advances in Portable Heavy Metal Ion Sensors. *Sensors*, v. 23, n. 8, p. 4125, 2023. <https://doi.org/10.3390/s23084125>.

HUANG, Y.; DONG, W.; CHEN, Y.; WANG, X.; LUO, W.; ZHAN, B.; LIU, X.; ZHANG, H.. Online detection of soluble solids content and maturity of tomatoes using Vis/NIR full transmittance spectra. *Chemometrics and Intelligent Laboratory Systems*, v. 210, p. 104243, 2021. <https://doi.org/10.1016/j.chemolab.2021.104243>.

HUANG, Y.; LU, R.; CHEN, K. Nondestructive measurement of tomato postharvest quality using a multichannel hyperspectral imaging probe. In: *Conference on Precision Agriculture*, Spokane, Washington, 16-19 jul. 2017. <https://doi.org/10.13031/aim.201700195>.

IBGE. Produção agropecuária: tomate, 2022. <https://www.ibge.gov.br/explica/producao-agropecuaria/tomate/br>.

IRERI, D.; BELAL, E.; OKINDA, C.; MAKANGE, N.; JI, C.. A computer vision system for defect discrimination and grading in tomatoes using machine learning and image processing. *Artificial Intelligence in Agriculture*, v. 2, p. 28–37, 2019. <https://doi.org/10.1016/j.aiaa.2019.06.001>.

JANUS, J.. A new approach to calculating distances to parcels: A way to increase the accuracy of farm efficiency analyses and the assessment of land consolidation projects. *Computers and Electronics in Agriculture*, v. 175, p. 105512, 2020. <https://doi.org/10.1016/j.compag.2020.105512>.

JIMÉNEZ-CARVELO, A. M.; MARTÍN-TORRES, S.; ORTEGA-GAVILÁN, F.; CAMACHO, J. PLS-DA vs sparse PLS-DA in food traceability. A case study: Authentication of avocado samples. *Talanta*, v. 224, p. 121904, 2021. <https://doi.org/10.1016/j.talanta.2020.121904>.

JIMÉNEZ-CARVELO, A. M.; SALLOUM-LLERGO, K. D.; CUADROS-RODRÍGUEZ, L.; CAPITÁN-VALLVEY, L. F.; FERNÁNDEZ-RAMOS, M. D. A perfect tandem: Chemometric methods and microfluidic colorimetric twin sensors on paper. *Microchemical Journal*, v. 157, p. 104930, 2020. <https://doi.org/10.1016/j.microc.2020.104930>.

JOHANNES, E.; TUWO, M.; KATAPPANAN, N.; HENRA, H.; WIRIANTI, G. Edible Coating Berbasis Pati Ubi Kayu Manihot esculenta Crantz dan Jahe Merah Zingiber officinale var. rubrum Memperpanjang Umur Simpan Buah Tomat Solanum lycopersicum L. *Agrotrop Journal on Agriculture Science*, v. 12, n. 2, p. 204, 2022. <https://doi.org/10.24843/ajoas.2022.v12.i02.p03>.

KONAGAYA, K.; RIZA, D. F. A.; NIE, S.; YONEDA, M.; HIRATA, T.; TAKAHASHI, N.; KURAMOTO, M.; OGAWA, Y.; SUZUKI, T.; KONDO, N.. Monitoring mature tomato (red stage) quality during storage using ultraviolet-induced visible fluorescence image. *Postharvest Biology and Technology*, v. 160, p. 111031, 2020. <https://doi.org/10.1016/j.postharvbio.2019.111031>.

- KONSTANTINO, G.; KOUTOULI, I.; BILDAKIS, V.; ZACHAROPOULOU, A.; PAPAIOANNOU, S.; STAMOULIS, D.; PAPAIOANNOU, M.; ANDRIANAKIS, I.; GEORGIADIS, N.; KALOGIROU, M. A review on tomato cultivation in greenhouse conditions. *Agronomy*, v. 12, n. 4, p. 806, 2022. <https://doi.org/10.3390/agronomy12040806>.
- KUSUMA, A.; SETIADI, D. R. I. M.; PUTRA, M. D. M. Tomato maturity classification using Naive Bayes algorithm and histogram feature extraction. *Journal of Applied Intelligent System*, v. 3, n. 1, p. 39-48, 2018. <https://doi.org/10.33633/jais.v3i1.1988>.
- LI, J. *et al.* Nondestructive assessment of tomato fruit quality based on terahertz spectral imaging. *Frontiers in Plant Science*, v. 12, p. 700452, 2021. <https://doi.org/10.3389/fpls.2021.700452>.
- LI, Y.; ZHAO, S.; LI, Y.; RAGAUSKAS, A. J.; SONG, X.; LI, K. Revealing the relationship between molecular weight of lignin and its color, UV-protecting property. *International Journal of Biological Macromolecules*, v. 223, p. 1287–1296, 2022. <https://doi.org/10.1016/j.ijbiomac.2022.11.067>.
- LINO, A. C. L.; SANCHES, J.; FABBRO, I. M. D. Image processing techniques for lemons and tomatoes classification. *Bragantia*, v. 67, n. 3, p. 785-789, 2008. <https://doi.org/10.1590/s0006-87052008000300029>.
- LOYOLA-GONZÁLEZ, O.; MEDINA-PÉREZ, M. A.; CHOO, K.-K. R. A review of supervised classification based on contrast patterns: applications, trends, and challenges. *Journal of Grid Computing*, v. 18, n. 4, p. 797-845, 2020. <https://doi.org/10.1007/s10723-020-09526-y>.
- LYSENKO, V. P.; BOLBOT, I. M.; LENDIEL, T. I.; NAKONECHNA, K. V.; KOVALSKIY, V. P.; RYSYNETS, N. O.; GROMASZEK, K.; AMIRGALDIYEV, Y.; NURSEITOVA, K. Mobile Robot With Optical Sensors For Remote Assessment Of Plant Conditions And Atmospheric Parameters In An Industrial Greenhouse. 2021. <https://doi.org/10.1117/12.2613975>.
- MARQUES, A. V. L.; CARON, V. C. Técnicas de seleção e classificação de produtos hortícolas: uma revisão bibliográfica. *Brazilian Journal of Development*, v. 8, n. 11, p. 72393–72408, 2022. <https://doi.org/10.34117/bjdv8n11-107>.
- MAZZEI, J. R. F.; CARDOSO, M. H. W. M.; SERRA, E. G.; DE MACEDO, J. R.; DE OLIVEIRA, A. C.; BASTOS, L. H. P.; CARDOSO, M. H. W. M. Estudo comparativo das concentrações de agrotóxicos no solo provenientes dos métodos de plantio do tomate convencional, orgânico e sustentável / Comparative study of pesticide concentrations in soil from conventional, organic and sustainable tomato growing methods. *Brazilian Journal of Development*, v. 7, n. 3, p. 22981-23000, 2021. <https://doi.org/10.34117/bjdv7n3-150>.
- MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO. Instrução Normativa nº 33, de 18 de julho de 2018. Brasília, 2018. Disponível em: <https://sistemasweb.agricultura.gov.br/sislegis/action/detalhaAto.do?method=visualizarAtoPortalMapa&chave=1269749901>. Acesso em: 29 jul. 2024.

NARANJO, D. *et al.* Prediction of fruit quality attributes of tomatoes using near-infrared (NIR) spectroscopy. *Scientia Horticulturae*, v. 244, p. 238–247, 2018. <https://doi.org/10.1016/j.scienta.2018.09.051>.

NASCIMENTO, M. F.; MELO, C. A.; OLIVEIRA, J. A.; CAMARGO, C. M. Caracterização físico-química de frutos de tomate orgânico e convencional. *Ciência Rural*, v. 51, n. 2, p. 202–211, 2021. <https://doi.org/10.1590/0103-8478cr20200440>.

NISHIDATE, I.; OO, S.; TODOROKI, S.; ASAMIZU, E. In situ nondestructive imaging of functional pigments in Micro-Tom tomato fruits by multispectral imaging based on Wiener estimation method. *Proceedings of SPIE, the International Society for Optical Engineering*, 2013. <https://doi.org/10.1117/12.2031049>.

OLESZKIEWICZ, T.; PACIA, M. Z.; GRZEBELUS, E.; BARANSKI, R. Light Microscopy and Raman Imaging of Carotenoids in Plant Cells In Situ and in Released Carotene Crystals. *Methods in Molecular Biology*, p. 245–260, 2019. https://doi.org/10.1007/978-1-4939-9952-1_19.

OSORIO-GRACIA, N.; ORTIZ-GONZALEZ, D.; SANDOVAL-CONTRERAS, H.; GOMES, C. Produtividade de tomates oriundos da polinização natural e mecânica em duas épocas de plantio. *Rev. Agron. Noroeste Argent.*, v. 40, n. 1, p. 51-61, 2020. <https://doi.org/10.36489/doi.12345>.

ÖZTEKİN, Y. B.; VURSAVUŞ, K. K.; KESİLMİŞ, Z. Domates meyvelerinin renk parametrelerine göre sertlik sınıflandırması. *Anadolu Journal of Agricultural Sciences*, 2021. <https://doi.org/10.7161/omuanajas.952786>.

ÖZTEKİN, Y. B.; VURSAVUŞ, K. K.; KESİLMİŞ, Z. Domates meyvelerinin renk parametrelerine göre sertlik sınıflandırması. *ANADOLU JOURNAL OF AGRICULTURAL SCIENCES*, 2021. <https://doi.org/10.7161/omuanajas.952786>.

PEDROSO, M. T.; REZENDE MOREIRA, L.; VICENTE BITENCOURT DE ALMEIDA, G.. A cadeia produtiva de tomate indústria: implicações para a agenda tecnológica e pesquisa agrônômica. In: *Sociedade Brasileira De Economia, Administração E Sociologia Rural - SOBER*, 2020. <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/218042/1/2464492.pdf>.

PÉREZ-MARÍN, J.; ISSA-ISSA, H.; CLEMENTE-VILLALBA, J.; GARCÍA-GARVÍ, J. M.; HERNÁNDEZ, F.; CARBONELL-BARRACHINA, Á. A.; CALÍN-SÁNCHEZ, Á.; NOGUERA-ARTIAGA, L. Physicochemical, volatile, and sensory characterization of promising cherry tomato (*Solanum lycopersicum* L.) cultivars: fresh market aptitudes of pear and round fruits. *Agronomy*, v. 11, n. 4, 618, 2021. <https://doi.org/10.3390/agronomy11040618>.

PÉREZ-MARÍN, J.; ISSA-ISSA, H.; CLEMENTE-VILLALBA, J.; GARCÍA-GARVÍ, J. M.; HERNÁNDEZ, F.; CARBONELL-BARRACHINA, Á. A.; CALÍN-SÁNCHEZ, Á.; NOGUERA-ARTIAGA, L. Physicochemical, Volatile, And Sensory Characterization Of Promising Cherry Tomato (*Solanum Lycopersicum* L.) Cultivars: Fresh Market Aptitudes Of Pear And Round Fruits. *Agronomy*, v. 11, n. 4, p. 618, 2021. <https://doi.org/10.3390/agronomy11040618>.

PILON, A.; SELEGATO, D.; FERNANDES, R.; BUENO, P.; PINHO, D.; NETO, F. C.; FREIRE, R.; CASTRO-GAMBOA, I.; BOLZANI, V.; LOPES, N.. Metabolômica de plantas: métodos e desafios. *Química Nova*, 2020. <https://doi.org/10.21577/0100-4042.20170499>.

PRADO, B.; CESAR, C. P. C.; VINÍCIUS, M.; SANTOS, C. P. C.; ALMEIDA, R.; SERGIO A. R.; ESCODEDO, J. F. Estimativa da evapotranspiração de referência do Planalto Paulista por meio de regressões múltiplas com dados ausentes estimados via análise de componentes principais. *Research, Society and Development*, v. 11, n. 8, e43211831120-e43211831120, 2022. <https://doi.org/10.33448/rsd-v11i8.31120>.

RAFFO, A.; BAIAMONTE, I.; NARDO, N.; NICOLI, S.; MONETA, E.; PEPARAIO, M.; SINESIO, F.; PAOLETTI, F. Impact of early harvesting and two cold storage technologies on eating quality of red ripe tomatoes. *European Food Research and Technology*, v. 244, p. 805-818, 2018. <https://doi.org/10.1007/s00217-017-2996-x>.

RAHMAN, M.; ISLAM, M.; NASRIN, T.; BEGUM, M. Non-Destructive Quality Assessment Of Tomato Fruit Using Differential Absorbance Technique. *International Journal Of Agricultural Research, Innovation And Technology*, v. 9, n. 2, p. 42–50, 2020. <https://doi.org/10.3329/ijarit.v9i2.45409>.

RAJAPAKSHA, L.; GUNATHILAKE, C. Reducing Post-Harvest Losses In Fruits And Vegetables For Ensuring Food Security – Case Of Sri Lanka. *MOJ Food Processing & Technology*, v. 9, n. 1, 2021. <https://doi.org/10.15406/mojfpt.2021.09.00255>.

RODRIGUES, A. A. Z.; DE QUEIROZ, M. E. L. R.; DE OLIVEIRA, A. F.; NEVES, A. A.; HELENO, F. F.; ZAMBOLIM, L.; FREITAS, J. F.; MORAIS, E. H. C. Pesticide residue removal in classic domestic processing of tomato and its effects on product quality. *Journal of Environmental Science and Health Part B*, v. 52, n. 12, p. 850–857, 2017. <https://doi.org/10.1080/03601234.2017.1359049>.

RODRIGUES, T. S.; PINTO, A. L.; CAMPOS, S. M.; MIRANDA, A. P.; NUNES, G. S. Implementação de um sistema de visão computacional para classificação de frutos de tomate. *Tecnologia em Análise e Processos*, v. 35, n. 2, p. 59–66, 2023. <https://doi.org/10.5304/tap.2023.035.02.007>.

SALONEN, T.; AHRENS, B.; BOVENS, M.; ELIAERTS, J.; HUHTALA, S.; NORDGAARD, A.; ALBERINK, I. Chemometrics in forensic chemistry — Part II: Standardized applications – Three examples involving illicit drugs. *Forensic Science International*, v. 307, p. 110138, 2020. <https://doi.org/10.1016/j.forsciint.2019.110138>.

SAMPAIO, I. M. G.; SILVA JÚNIOR, M. L.; MORAES PALHA BITTENCOURT, R. F.; SANTOS, G. A. M. D.; SOUZA LEMOS NETO, H. Production and postharvest quality of jambu in hydroponics under nitrogen application in nutrient solution. *Ciência Agrônômica/Revista Ciência Agrônômica*, v. 52, 2021. <https://doi.org/10.5935/1806-6690.20210021>.

SHCHELKANOVA, E.; SHCHELKANOV, A.; SHCHAPOVA, L.; SHIBATA, T. An exploration of blue PPG signal using a novel color sensor-based PPG system. In: 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). IEEE, 2020. <https://doi.org/10.1109/embc44109.2020.9175745>.

SHERAFATI, A.; MOLLAZADE, K.; SABA, M. K.; VESALI, F. TomatoScan: an Android-based application for quality evaluation and ripening determination of tomato fruit. *Computers and Electronics in Agriculture*, v. 200, 107214, 2022. <https://doi.org/10.1016/j.compag.2022.107214>.

SIVAKUMAR, J.; REDDY, M. S.; SERGEANT, K.; HAUSMAN, J. F.; KHAN, P. S. S.; BASHA, P. O. Principal component analysis-assisted screening and selection of salt-tolerant tomato genotypes. *Plant Physiology Reports*, v. 28, n. 2, p. 272–288, 2023. <https://doi.org/10.1007/s40502-023-00726-8>.

SUBRATA, I. D. M.; RAMADHAN, A. Z.; SUTEJO, A. Pengembangan Sistem Pendeteksi Mutu Buah Tomat Cherry Berdasarkan Warna Menggunakan Sensor Optis TCS230. *Jurnal Ilmiah Teknologi Pertanian Agrotech*, v. 18, n. 1, 2022. <https://doi.org/10.24014/ja.v18i1.20048>.

SUBRATA, I. D. M.; RAMADHAN, A. Z.; SUTEJO, A. Pengembangan sistem pendeteksi mutu buah tomat cherry berdasarkan warna menggunakan sensor optis TCS230. *Jurnal Ilmiah Rekayasa Pertanian dan Biosistem*, v. 10, n. 2, p. 171-183, 2022. <https://doi.org/10.29303/jrpb.v10i2.389>.

TCS3472 COLOR LIGHT-TO-DIGITAL CONVERTER with IR FILTER. (2012). In TAOS135. TAOS Inc. Retrieved June 25, 2024, from <https://cdn-shop.adafruit.com/datasheets/TCS34725.pdf>

TOLASA, M.; GEDAMU, F.; WOLDETSADIK, K. Impacts of harvesting stages and pre-storage treatments on shelf life and quality of tomato (*Solanum lycopersicum* L.). *Cogent Food & Agriculture*, v. 7, n. 1, 1863620, 2021. <https://doi.org/10.1080/23311932.2020.1863620>.

VAN TONDER, A. J.; NORTJÉ, G. P.; BOTHA, B. M. T.V. PheroLure®: Volatile emission by semiochemical lures and the impact thereof on the volatile profile of a commercial tomato field. *African Entomology*, v. 31, 2023. <https://doi.org/10.17159/2254-8854/2023/a14027>.

WANG, Y.; HUANG, X.; LU, X.; XU, Z.; HU, L.; CHEN, Q. A review of computer vision systems for fruit and vegetable quality assessment. *Computers and Electronics in Agriculture*, v. 153, p. 227–238, 2018. <https://doi.org/10.1016/j.compag.2018.08.029>.

WONGRAVEE, K.; ISHIGAKI, M.; OZAKI, Y.. Chemometrics as a Green Analytical Tool. In: *The Royal Society of Chemistry eBooks*, p. 277–336, 2020. <https://doi.org/10.1039/9pr781788016148-00277>.

WU, T.; ZHANG, W.; JIAO, X.; GUO, W.; HAMOUD, Y. A.. Evaluation of stacking and blending ensemble learning methods for estimating daily reference evapotranspiration. *Computers and Electronics in Agriculture*, v. 184, p. 106039, 2021. <https://doi.org/10.1016/j.compag.2021.106039>.

YAGMUR, B.; GUNES, A. Evaluation of the effects of plant growth promoting rhizobacteria (PGPR) on yield and quality parameters of tomato plants in organic agriculture by principal component analysis (PCA). *Gesunde Pflanzen*, v. 73, n. 2, p. 219–228, 2021. <https://doi.org/10.1007/s10343-021-00543-9>.

YANG, W.; KOBAYASHI, I.; HAGIWARA, S.; MAEDA, R.; YOKOYAMA, H. Comparison of Physical and Functional Properties in Edible Films Based on Tomato Peel Powders, Tomato Peel Powders and Tomato Pulp Powders. *Molecules*, v. 28, n. 4, p. 1686, 2023. <https://doi.org/10.3390/molecules28041686>.

ZHAO, X.; JIN, Y.; LI, J.; LIU, Y.; LIU, Y.; YANG, W. Detecting quality of tomato fruit based on hyperspectral imaging technique and deep learning. *Computers and Electronics in Agriculture*, v. 179, p. 105835, 2020. <https://doi.org/10.1016/j.compag.2020.105835>.

APÊNDICE A – MEDIDAS DE pH PARA CADA AMOSTRA

Lote	Amostra *	média	desvio	mediana	mínimo	Máximo	amplitude
1	M1	4,56	0,10	4,63	4,42	4,64	0,22
	M2	4,15	0,03	4,14	4,13	4,19	0,06
	M3	4,44	0,03	4,45	4,40	4,46	0,06
	M4	4,64	0,02	4,65	4,61	4,66	0,05
	M5	4,14	0,03	4,13	4,10	4,18	0,08
	S1	4,04	0,03	4,03	4,00	4,08	0,08
	S2	4,44	0,01	4,43	4,43	4,45	0,02
	S3	4,18	0,04	4,19	4,12	4,22	0,10
	S4	4,23	0,03	4,22	4,21	4,27	0,06
	S5	4,12	0,01	4,12	4,11	4,14	0,03
	V1	4,06	0,04	4,04	4,02	4,11	0,09
	V2	4,10	0,02	4,10	4,08	4,12	0,04
	V3	4,24	0,01	4,24	4,23	4,25	0,02
	V4	4,12	0,01	4,12	4,10	4,13	0,03
	V5	4,29	0,02	4,29	4,27	4,32	0,05
2	M1	4,27	0,02	4,28	4,25	4,29	0,04
	M2	4,40	0,01	4,40	4,39	4,42	0,03
	M3	4,57	0,00	4,57	4,57	4,58	0,01
	M4	4,50	0,01	4,50	4,49	4,51	0,02
	M5	4,29	0,01	4,30	4,28	4,30	0,02
	S1	4,13	0,00	4,13	4,13	4,14	0,01
	S2	4,08	0,02	4,08	4,06	4,10	0,04
	S3	4,26	0,01	4,26	4,25	4,28	0,03
	S4	4,64	0,02	4,65	4,61	4,66	0,05
	S5	4,42	0,01	4,41	4,41	4,43	0,02
	V1	4,13	0,04	4,13	4,08	4,18	0,10
	V2	4,21	0,01	4,21	4,20	4,22	0,02
	V3	4,24	0,01	4,24	4,23	4,25	0,02
	V4	4,22	0,01	4,22	4,21	4,23	0,02
	V5	4,00	0,00	4,00	4,00	4,01	0,01
3	M1	4,64	0,19	4,50	4,50	4,91	0,41
	M2	4,99	0,13	4,91	4,89	5,18	0,29

	M3	4,97	0,06	4,95	4,91	5,05	0,14
	M4	5,24	0,20	5,15	5,05	5,51	0,46
	M5	4,46	0,03	4,45	4,43	4,50	0,07
	S1	4,53	0,07	4,54	4,44	4,60	0,16
	S2	4,54	0,13	4,45	4,44	4,72	0,28
	S3	4,69	0,16	4,59	4,56	4,91	0,35
	S4	4,52	0,14	4,43	4,41	4,71	0,30
	S5	4,55	0,21	4,40	4,40	4,85	0,45
	V1	4,52	0,13	4,44	4,41	4,70	0,29
	V2	4,51	0,00	4,51	4,50	4,51	0,01
	V3	4,48	0,06	4,52	4,40	4,53	0,13
	V4	4,17	0,05	4,20	4,10	4,21	0,11
	V5	4,35	0,06	4,33	4,30	4,43	0,13
4	M1	4,97	0,01	4,96	4,96	4,98	0,02
	M2	5,06	0,02	5,05	5,04	5,08	0,04
	M3	5,10	0,01	5,10	5,09	5,11	0,02
	M4	4,99	0,01	4,99	4,97	5,00	0,03
	M5	5,02	0,01	5,02	5,00	5,03	0,03
	S1	4,47	0,01	4,47	4,46	4,48	0,02
	S2	4,77	0,01	4,77	4,76	4,79	0,03
	S3	4,95	0,01	4,95	4,94	4,97	0,03
	S4	4,72	0,01	4,73	4,71	4,73	0,02
	S5	4,68	0,01	4,68	4,67	4,70	0,03
	V1	4,73	0,06	4,77	4,65	4,78	0,13
	V2	4,68	0,01	4,68	4,67	4,69	0,02
	V3	4,62	0,02	4,63	4,60	4,64	0,04
V4	4,90	0,00	4,90	4,90	4,91	0,01	
V5	4,60	0,02	4,61	4,58	4,62	0,04	
5	M1	4,88	0,00	4,88	4,87	4,88	0,01
	M2	4,71	0,02	4,71	4,69	4,73	0,04
	M3	4,78	0,01	4,77	4,77	4,79	0,02
	M4	4,97	0,02	4,96	4,94	5,00	0,06
	M5	4,93	0,02	4,92	4,90	4,96	0,06
	S1	4,82	0,02	4,81	4,80	4,85	0,05

	S2	4,90	0,01	4,90	4,89	4,92	0,03
	S3	4,75	0,03	4,75	4,71	4,78	0,07
	S4	4,81	0,03	4,81	4,78	4,85	0,07
	S5	4,75	0,00	4,75	4,75	4,76	0,01
	V1	4,55	0,01	4,55	4,53	4,56	0,03
	V2	4,53	0,02	4,52	4,51	4,56	0,05
	V3	4,59	0,02	4,58	4,56	4,62	0,06
	V4	4,57	0,01	4,57	4,56	4,59	0,03
	V5	4,56	0,00	4,56	4,55	4,56	0,01
6	M1	4,63	0,02	4,64	4,60	4,65	0,05
	M2	4,65	0,02	4,64	4,63	4,67	0,04
	M3	4,77	0,04	4,77	4,72	4,81	0,09
	M4	4,58	0,01	4,58	4,57	4,59	0,02
	M5	4,60	0,02	4,60	4,58	4,63	0,05
	S1	4,46	0,01	4,46	4,45	4,47	0,02
	S2	4,52	0,02	4,52	4,50	4,55	0,05
	S3	4,50	0,04	4,50	4,45	4,55	0,10
	S4	4,61	0,02	4,62	4,58	4,64	0,06
	S5	4,74	0,04	4,76	4,68	4,78	0,10
	V1	4,33	0,03	4,34	4,28	4,36	0,08
	V2	4,42	0,04	4,39	4,39	4,47	0,08
	V3	4,43	0,04	4,45	4,38	4,46	0,08
	V4	4,36	0,05	4,37	4,30	4,42	0,12
V5	4,25	0,01	4,25	4,24	4,26	0,02	
7	M1	4,52	0,02	4,53	4,50	4,54	0,04
	M2	4,65	0,01	4,65	4,64	4,67	0,03
	M3	4,82	0,00	4,82	4,82	4,83	0,01
	M4	4,75	0,01	4,75	4,74	4,76	0,02
	M5	4,54	0,01	4,55	4,53	4,55	0,02
	S1	4,38	0,00	4,38	4,38	4,39	0,01
	S2	4,33	0,02	4,33	4,31	4,35	0,04
	S3	4,51	0,01	4,51	4,50	4,53	0,03
	S4	4,89	0,02	4,90	4,86	4,91	0,05
	S5	4,67	0,01	4,66	4,66	4,68	0,02

	V1	4,38	0,04	4,38	4,33	4,43	0,10
	V2	4,46	0,01	4,46	4,45	4,47	0,02
	V3	4,49	0,01	4,49	4,48	4,50	0,02
	V4	4,47	0,01	4,47	4,46	4,48	0,02
	V5	4,25	0,00	4,25	4,25	4,26	0,01
8	M1	5,04	0,19	4,90	4,90	5,31	0,41
	M2	5,39	0,13	5,31	5,29	5,58	0,29
	M3	5,37	0,06	5,35	5,31	5,45	0,14
	M4	5,64	0,20	5,55	5,45	5,91	0,46
	M5	4,86	0,03	4,85	4,83	4,90	0,07
	S1	4,93	0,07	4,94	4,84	5,00	0,16
	S2	4,94	0,13	4,85	4,84	5,12	0,28
	S3	5,09	0,16	4,99	4,96	5,31	0,35
	S4	4,92	0,14	4,83	4,81	5,11	0,30
	S5	4,95	0,21	4,80	4,80	5,25	0,45
	V1	4,92	0,13	4,84	4,81	5,10	0,29
	V2	4,91	0,00	4,91	4,90	4,91	0,01
	V3	4,88	0,06	4,92	4,80	4,93	0,13
	V4	4,57	0,05	4,60	4,50	4,61	0,11
	V5	4,75	0,06	4,73	4,70	4,83	0,13
9	M1	4,96	0,10	5,03	4,82	5,04	0,22
	M2	4,55	0,03	4,54	4,53	4,59	0,06
	M3	4,84	0,03	4,85	4,80	4,86	0,06
	M4	5,04	0,02	5,05	5,01	5,06	0,05
	M5	4,54	0,03	4,53	4,50	4,58	0,08
	S1	4,44	0,03	4,43	4,40	4,48	0,08
	S2	4,84	0,01	4,83	4,83	4,85	0,02
	S3	4,58	0,04	4,59	4,52	4,62	0,10
	S4	4,63	0,03	4,62	4,61	4,67	0,06
	S5	4,52	0,01	4,52	4,51	4,54	0,03
	V1	4,46	0,04	4,44	4,42	4,51	0,09
	V2	4,50	0,02	4,50	4,48	4,52	0,04
	V3	4,64	0,01	4,64	4,63	4,65	0,02
V4	4,52	0,01	4,52	4,50	4,53	0,03	

	V5	4,69	0,02	4,69	4,67	4,72	0,05
10	M1	4,33	0,02	4,34	4,30	4,35	0,05
	M2	4,35	0,02	4,34	4,33	4,37	0,04
	M3	4,47	0,04	4,47	4,42	4,51	0,09
	M4	4,28	0,01	4,28	4,27	4,29	0,02
	M5	4,30	0,02	4,30	4,28	4,33	0,05
	S1	4,16	0,01	4,16	4,15	4,17	0,02
	S2	4,22	0,02	4,22	4,20	4,25	0,05
	S3	4,20	0,04	4,20	4,15	4,25	0,10
	S4	4,31	0,02	4,32	4,28	4,34	0,06
	S5	4,44	0,04	4,46	4,38	4,48	0,10
	V1	4,03	0,03	4,04	3,98	4,06	0,08
	V2	4,12	0,04	4,09	4,09	4,17	0,08
	V3	4,13	0,04	4,15	4,08	4,16	0,08
	V4	4,06	0,05	4,07	4,00	4,12	0,12
	V5	3,95	0,01	3,95	3,94	3,96	0,02

* M – maduro; S – semimaduro; V – verde.

APÊNDICE B – MEDIDAS DE BRUX PARA CADA AMOSTRA

Lote	Lote	Amostra*	Desvio	mediana	minimo	maximo	amplitude
1	M1	3,67	0,05	3,70	3,60	3,70	0,10
	M2	3,50	0,00	3,50	3,50	3,50	0,00
	M3	4,07	0,05	4,10	4,00	4,10	0,10
	M4	3,33	0,05	3,30	3,30	3,40	0,10
	M5	3,60	0,00	3,60	3,60	3,60	0,00
	S1	3,30	0,00	3,30	3,30	3,30	0,00
	S2	3,70	0,00	3,70	3,70	3,70	0,00
	S3	3,60	0,00	3,60	3,60	3,60	0,00
	S4	4,13	0,05	4,10	4,10	4,20	0,10
	S5	3,70	0,00	3,70	3,70	3,70	0,00
	V1	3,30	0,00	3,30	3,30	3,30	0,00
	V2	3,63	0,05	3,60	3,60	3,70	0,10
	V3	4,07	0,05	4,10	4,00	4,10	0,10
	V4	3,90	0,00	3,90	3,90	3,90	0,00
	V5	3,97	0,05	4,00	3,90	4,00	0,10
2	M1	4,13	0,05	4,10	4,10	4,20	0,10
	M2	3,90	0,00	3,90	3,90	3,90	0,00
	M3	4,37	0,05	4,40	4,30	4,40	0,10
	M4	4,41	0,00	4,41	4,41	4,41	0,00
	M5	4,10	0,00	4,10	4,10	4,10	0,00
	S1	3,83	0,05	3,80	3,80	3,90	0,10
	S2	3,90	0,00	3,90	3,90	3,90	0,00
	S3	4,20	0,00	4,20	4,20	4,20	0,00
	S4	3,70	0,00	3,70	3,70	3,70	0,00
	S5	3,43	0,05	3,40	3,40	3,50	0,10
	V1	3,60	0,00	3,60	3,60	3,60	0,00
	V2	3,60	0,00	3,60	3,60	3,60	0,00
	V3	3,70	0,00	3,70	3,70	3,70	0,00
	V4	3,60	0,00	3,60	3,60	3,60	0,00
	V5	3,53	0,05	3,50	3,50	3,60	0,10
3	M1	4,17	0,05	4,20	4,10	4,20	0,10
	M2	4,43	0,05	4,40	4,40	4,50	0,10

	M3	3,50	0,00	3,50	3,50	3,50	0,00
	M4	4,03	0,05	4,00	4,00	4,10	0,10
	M5	4,27	0,05	4,30	4,20	4,30	0,10
	S1	4,20	0,00	4,20	4,20	4,20	0,00
	S2	4,83	0,05	4,80	4,80	4,90	0,10
	S3	5,57	0,05	5,60	5,50	5,60	0,10
	S4	5,00	0,00	5,00	5,00	5,00	0,00
	S5	5,10	0,00	5,10	5,10	5,10	0,00
	V1	4,73	0,05	4,70	4,70	4,80	0,10
	V2	4,50	0	4,50	4,50	4,50	0,00
	V3	3,77	0,05	3,80	3,70	3,80	0,10
	V4	4,93	0,05	4,90	4,90	5,00	0,10
	V5	4,70	0,00	4,70	4,70	4,70	0,00
4	M1	4,23	0,05	4,20	4,20	4,30	0,10
	M2	3,77	0,05	3,80	3,70	3,80	0,10
	M3	3,27	0,05	3,30	3,20	3,30	0,10
	M4	3,73	0,05	3,70	3,70	3,80	0,10
	M5	3,63	0,10	3,70	3,50	3,70	0,20
	S1	4,00	0,00	4,00	4,00	4,00	0,00
	S2	4,50	0,00	4,50	4,50	4,50	0,00
	S3	3,90	0,00	3,90	3,90	3,90	0,00
	S4	3,17	0,05	3,20	3,10	3,20	0,10
	S5	3,90	0,00	3,90	3,90	3,90	0,00
	V1	5,00	0,00	5,00	5,00	5,00	0,00
	V2	4,13	0,05	4,10	4,10	4,20	0,10
	V3	3,70	0,00	3,70	3,70	3,70	0,00
V4	3,30	0,00	3,30	3,30	3,30	0,00	
V5	3,40	0,00	3,40	3,40	3,40	0,00	
5	M1	3,20	0,00	3,20	3,20	3,20	0,00
	M2	3,63	0,05	3,60	3,60	3,70	0,10
	M3	3,43	0,05	3,40	3,40	3,50	0,10
	M4	3,23	0,05	3,20	3,20	3,30	0,10
	M5	4,00	0,00	4,00	4,00	4,00	0,00
	S1	3,67	0,05	3,70	3,60	3,70	0,10

	S2	3,33	0,05	3,30	3,30	3,40	0,10
	S3	3,80	0,00	3,80	3,80	3,80	0,00
	S4	4,03	0,17	4,10	3,80	4,20	0,40
	S5	4,40	0,00	4,40	4,40	4,40	0,00
	V1	4,03	0,05	4,00	4,00	4,10	0,10
	V2	4,57	0,05	4,60	4,50	4,60	0,10
	V3	4,77	0,05	4,80	4,70	4,80	0,10
	V4	4,90	0,00	4,90	4,90	4,90	0,00
	V5	4,63	0,05	4,60	4,60	4,70	0,10
6	M1	3,43	0,05	3,40	3,40	3,50	0,10
	M2	4,17	0,05	4,20	4,10	4,20	0,10
	M3	4,77	0,05	4,80	4,70	4,80	0,10
	M4	4,40	0,00	4,40	4,40	4,40	0,00
	M5	4,43	0,05	4,40	4,40	4,50	0,10
	S1	3,50	0,00	3,50	3,50	3,50	0,00
	S2	3,23	0,05	3,20	3,20	3,30	0,10
	S3	3,83	0,05	3,80	3,80	3,90	0,10
	S4	3,30	0,00	3,30	3,30	3,30	0,00
	S5	4,00	0,00	4,00	4,00	4,00	0,00
	V1	3,40	0,00	3,40	3,40	3,40	0,00
	V2	4,70	0,00	4,70	4,70	4,70	0,00
	V3	4,27	0,05	4,30	4,20	4,30	0,10
V4	3,90	0,00	3,90	3,90	3,90	0,00	
V5	4,60	0,00	4,60	4,60	4,60	0,00	
7	M1	4,38	0,05	4,35	4,35	4,45	0,10
	M2	4,15	0,00	4,15	4,15	4,15	0,00
	M3	4,62	0,05	4,65	4,55	4,65	0,10
	M4	4,66	0,00	4,66	4,66	4,66	0,00
	M5	4,35	0,00	4,35	4,35	4,35	0,00
	S1	4,08	0,05	4,05	4,05	4,15	0,10
	S2	4,15	0,00	4,15	4,15	4,15	0,00
	S3	4,45	0,00	4,45	4,45	4,45	0,00
	S4	3,95	0,00	3,95	3,95	3,95	0,00
	S5	3,68	0,05	3,65	3,65	3,75	0,10

	V1	3,85	0,00	3,85	3,85	3,85	0,00
	V2	3,85	0,00	3,85	3,85	3,85	0,00
	V3	3,95	0,00	3,95	3,95	3,95	0,00
	V4	3,85	0,00	3,85	3,85	3,85	0,00
	V5	3,78	0,05	3,75	3,75	3,85	0,10
8	M1	4,57	0,05	4,60	4,50	4,60	0,10
	M2	4,83	0,05	4,80	4,80	4,90	0,10
	M3	3,90	0,00	3,90	3,90	3,90	0,00
	M4	4,43	0,05	4,40	4,40	4,50	0,10
	M5	4,67	0,05	4,70	4,60	4,70	0,10
	S1	4,60	0,00	4,60	4,60	4,60	0,00
	S2	5,23	0,05	5,20	5,20	5,30	0,10
	S3	5,97	0,05	6,00	5,90	6,00	0,10
	S4	5,40	0,00	5,40	5,40	5,40	0,00
	S5	5,50	0,00	5,50	5,50	5,50	0,00
	V1	5,13	0,05	5,10	5,10	5,20	0,10
	V2	4,90	0,00	4,90	4,90	4,90	0,00
	V3	4,17	0,05	4,20	4,10	4,20	0,10
	V4	5,33	0,05	5,30	5,30	5,40	0,10
	V5	5,10	0,00	5,10	5,10	5,10	0,00
9	M1	4,07	0,05	4,10	4,00	4,10	0,10
	M2	3,90	0,00	3,90	3,90	3,90	0,00
	M3	4,47	0,05	4,50	4,40	4,50	0,10
	M4	3,73	0,05	3,70	3,70	3,80	0,10
	M5	4,00	0,00	4,00	4,00	4,00	0,00
	S1	3,70	0,00	3,70	3,70	3,70	0,00
	S2	4,10	0,00	4,10	4,10	4,10	0,00
	S3	4,00	0,00	4,00	4,00	4,00	0,00
	S4	4,53	0,05	4,50	4,50	4,60	0,10
	S5	4,10	0,00	4,10	4,10	4,10	0,00
	V1	3,70	0,00	3,70	3,70	3,70	0,00
	V2	4,03	0,05	4,00	4,00	4,10	0,10
	V3	4,47	0,05	4,50	4,40	4,50	0,10
V4	4,30	0,00	4,30	4,30	4,30	0,00	

	V5	4,37	0,05	4,40	4,30	4,40	0,10
10	M1	3,13	0,05	3,10	3,10	3,20	0,10
	M2	3,87	0,05	3,90	3,80	3,90	0,10
	M3	4,47	0,05	4,50	4,40	4,50	0,10
	M4	4,10	0,00	4,10	4,10	4,10	0,00
	M5	4,13	0,05	4,10	4,10	4,20	0,10
	S1	3,20	0,00	3,20	3,20	3,20	0,00
	S2	2,93	0,05	2,90	2,90	3,00	0,10
	S3	3,53	0,05	3,50	3,50	3,60	0,10
	S4	3,00	0,00	3,00	3,00	3,00	0,00
	S5	3,70	0,00	3,70	3,70	3,70	0,00
	V1	3,10	0,00	3,10	3,10	3,10	0,00
	V2	4,40	0,00	4,40	4,40	4,40	0,00
	V3	3,97	0,05	4,00	3,90	4,00	0,10
	V4	3,60	0,00	3,60	3,60	3,60	0,00
	V5	4,30	0,00	4,30	4,30	4,30	0,00

* M – maduro; S – semimaduro; V – verde.

APÊNDICE C – MEDIDAS DE ACIDEZ TOTAL BRIX PARA CADA AMOSTRA

Lote	Amostra*	Média	Desvio	Mediana	Mínimo	Máximo	Amplitude
1	M1	0,39	0,03	0,37	0,37	0,43	0,06
	M2	0,42	0,01	0,43	0,41	0,43	0,01
	M3	0,57	0,01	0,57	0,56	0,59	0,02
	M4	0,23	0,02	0,24	0,21	0,24	0,03
	M5	0,25	0,00	0,25	0,24	0,26	0,01
	S1	0,34	0,01	0,34	0,33	0,34	0,01
	S2	0,31	0,00	0,31	0,31	0,31	0,01
	S3	0,55	0,01	0,54	0,53	0,56	0,03
	S4	0,54	0,01	0,53	0,53	0,55	0,02
	S5	0,66	0,01	0,66	0,65	0,66	0,01
	V1	0,49	0,00	0,49	0,48	0,49	0,01
	V2	0,64	0,01	0,65	0,63	0,65	0,02
	V3	0,62	0,00	0,62	0,62	0,62	0,01
	V4	0,61	0,02	0,60	0,60	0,64	0,04
	V5	0,59	0,01	0,59	0,59	0,60	0,01
2	M1	0,37	0,01	0,37	0,36	0,37	0,01
	M2	0,35	0,01	0,35	0,34	0,35	0,01
	M3	0,33	0,01	0,32	0,32	0,34	0,02
	M4	0,34	0,00	0,34	0,34	0,35	0,01
	M5	0,37	0,00	0,37	0,36	0,37	0,01
	S1	0,42	0,01	0,41	0,41	0,43	0,01
	S2	0,46	0,01	0,47	0,46	0,47	0,01
	S3	0,43	0,01	0,43	0,43	0,44	0,01
	S4	0,24	0,01	0,24	0,23	0,24	0,01
	S5	0,33	0,01	0,33	0,33	0,34	0,01
	V1	0,46	0,01	0,47	0,46	0,47	0,01
	V2	0,46	0,01	0,47	0,45	0,47	0,02
	V3	0,39	0,00	0,39	0,39	0,39	0,00
	V4	0,48	0,01	0,48	0,48	0,49	0,01
	V5	0,68	0,01	0,68	0,67	0,69	0,02
3	M1	0,25	0,01	0,25	0,23	0,26	0,03
	M2	0,37	0,02	0,36	0,35	0,39	0,04

	M3	0,20	0,00	0,20	0,20	0,21	0,01
	M4	0,18	0,02	0,17	0,15	0,20	0,05
	M5	0,54	0,02	0,53	0,53	0,56	0,03
	S1	0,36	0,01	0,36	0,35	0,37	0,02
	S2	0,35	0,01	0,35	0,34	0,36	0,02
	S3	0,44	0,02	0,45	0,41	0,46	0,05
	S4	0,44	0,01	0,45	0,44	0,45	0,01
	S5	0,57	0,01	0,56	0,56	0,57	0,02
	V1	0,48	0,01	0,48	0,47	0,48	0,01
	V2	0,38	0,01	0,37	0,36	0,39	0,03
	V3	0,26	0,01	0,27	0,24	0,27	0,02
	V4	0,47	0,00	0,47	0,46	0,47	0,01
	V5	0,54	0,01	0,53	0,53	0,55	0,02
4	M1	0,21	0,01	0,21	0,19	0,22	0,03
	M2	0,18	0,01	0,18	0,18	0,19	0,02
	M3	0,14	0,00	0,14	0,14	0,14	0,01
	M4	0,21	0,02	0,20	0,19	0,23	0,04
	M5	0,20	0,02	0,19	0,18	0,22	0,05
	S1	0,34	0,01	0,34	0,34	0,35	0,01
	S2	0,24	0,00	0,24	0,24	0,25	0,01
	S3	0,19	0,01	0,20	0,19	0,20	0,01
	S4	0,26	0,02	0,27	0,22	0,28	0,05
	S5	0,27	0,01	0,27	0,26	0,28	0,02
	V1	0,32	0,00	0,32	0,32	0,33	0,01
	V2	0,34	0,02	0,33	0,33	0,37	0,04
	V3	0,37	0,00	0,37	0,37	0,37	0,00
V4	0,22	0,01	0,22	0,21	0,23	0,02	
V5	0,33	0,01	0,33	0,32	0,34	0,02	
5	M1	0,17	0,01	0,17	0,16	0,18	0,02
	M2	0,34	0,01	0,34	0,32	0,35	0,03
	M3	0,25	0,00	0,24	0,24	0,25	0,01
	M4	0,21	0,00	0,21	0,21	0,22	0,01
	M5	0,26	0,00	0,26	0,26	0,27	0,01
	S1	0,24	0,01	0,23	0,23	0,24	0,02

	S2	0,21	0,00	0,21	0,21	0,22	0,01
	S3	0,24	0,01	0,24	0,23	0,25	0,02
	S4	0,22	0,00	0,22	0,21	0,22	0,01
	S5	0,30	0,02	0,31	0,27	0,31	0,04
	V1	0,33	0,01	0,34	0,32	0,34	0,01
	V2	0,32	0,01	0,32	0,31	0,34	0,02
	V3	0,39	0,01	0,39	0,38	0,40	0,02
	V4	0,38	0,01	0,37	0,37	0,38	0,01
	V5	0,41	0,00	0,40	0,40	0,41	0,01
6	M1	0,28	0,01	0,29	0,27	0,29	0,02
	M2	0,33	0,01	0,33	0,32	0,33	0,01
	M3	0,34	0,02	0,32	0,32	0,37	0,05
	M4	0,41	0,01	0,41	0,40	0,41	0,01
	M5	0,37	0,01	0,36	0,36	0,38	0,02
	S1	0,34	0,01	0,34	0,32	0,35	0,03
	S2	0,35	0,00	0,35	0,34	0,35	0,01
	S3	0,26	0,01	0,27	0,26	0,27	0,01
	S4	0,26	0,01	0,26	0,24	0,27	0,02
	S5	0,23	0,00	0,22	0,22	0,23	0,01
	V1	0,33	0,01	0,32	0,32	0,34	0,02
	V2	0,35	0,00	0,35	0,34	0,35	0,01
	V3	0,37	0,01	0,37	0,35	0,37	0,02
	V4	0,37	0,01	0,37	0,36	0,38	0,02
	V5	0,41	0,01	0,41	0,40	0,42	0,02
7	M1	0,40	0,01	0,40	0,39	0,40	0,01
	M2	0,37	0,01	0,38	0,37	0,38	0,01
	M3	0,35	0,01	0,35	0,35	0,37	0,02
	M4	0,37	0,00	0,37	0,37	0,37	0,01
	M5	0,39	0,00	0,39	0,39	0,40	0,01
	S1	0,45	0,01	0,44	0,44	0,45	0,01
	S2	0,49	0,01	0,49	0,48	0,49	0,01
	S3	0,46	0,01	0,45	0,45	0,46	0,01
	S4	0,27	0,01	0,27	0,26	0,27	0,01
	S5	0,36	0,01	0,36	0,36	0,37	0,01

	V1	0,49	0,01	0,49	0,48	0,49	0,01
	V2	0,49	0,01	0,49	0,47	0,49	0,02
	V3	0,42	0,00	0,42	0,42	0,42	0,00
	V4	0,51	0,01	0,51	0,51	0,52	0,01
	V5	0,71	0,01	0,71	0,70	0,72	0,02
8	M1	0,30	0,01	0,30	0,28	0,31	0,03
	M2	0,42	0,02	0,41	0,40	0,44	0,04
	M3	0,26	0,00	0,26	0,25	0,26	0,01
	M4	0,23	0,02	0,22	0,21	0,26	0,05
	M5	0,60	0,02	0,59	0,59	0,62	0,03
	S1	0,41	0,01	0,41	0,40	0,42	0,02
	S2	0,40	0,01	0,40	0,39	0,41	0,02
	S3	0,50	0,02	0,51	0,47	0,52	0,05
	S4	0,50	0,01	0,50	0,49	0,50	0,01
	S5	0,62	0,01	0,62	0,61	0,63	0,02
	V1	0,53	0,01	0,53	0,52	0,53	0,01
	V2	0,43	0,01	0,43	0,41	0,45	0,03
	V3	0,31	0,01	0,32	0,30	0,32	0,02
	V4	0,52	0,00	0,52	0,52	0,53	0,01
	V5	0,59	0,01	0,59	0,59	0,61	0,02
9	M1	0,42	0,00	0,42	0,42	0,43	0,01
	M2	0,48	0,01	0,48	0,47	0,48	0,01
	M3	0,63	0,01	0,63	0,62	0,64	0,02
	M4	0,29	0,02	0,30	0,27	0,30	0,03
	M5	0,30	0,00	0,30	0,30	0,31	0,01
	S1	0,39	0,01	0,39	0,38	0,39	0,01
	S2	0,36	0,00	0,36	0,36	0,37	0,01
	S3	0,60	0,01	0,60	0,59	0,62	0,03
	S4	0,59	0,01	0,59	0,59	0,61	0,02
	S5	0,71	0,01	0,71	0,70	0,71	0,01
	V1	0,54	0,00	0,54	0,54	0,54	0,01
	V2	0,70	0,01	0,70	0,69	0,70	0,02
	V3	0,67	0,00	0,67	0,67	0,68	0,01
V4	0,66	0,02	0,65	0,65	0,69	0,04	

	V5	0,64	0,01	0,64	0,64	0,65	0,01
10	M1	0,23	0,01	0,23	0,22	0,24	0,02
	M2	0,27	0,01	0,28	0,27	0,28	0,01
	M3	0,29	0,02	0,27	0,27	0,32	0,05
	M4	0,36	0,01	0,36	0,35	0,36	0,01
	M5	0,31	0,01	0,31	0,30	0,32	0,02
	S1	0,28	0,01	0,29	0,27	0,30	0,03
	S2	0,29	0,00	0,29	0,29	0,30	0,01
	S3	0,21	0,01	0,21	0,20	0,21	0,01
	S4	0,20	0,01	0,21	0,19	0,21	0,02
	S5	0,17	0,00	0,17	0,17	0,18	0,01
	V1	0,27	0,01	0,27	0,27	0,28	0,02
	V2	0,29	0,00	0,29	0,29	0,30	0,01
	V3	0,31	0,01	0,32	0,30	0,32	0,02
	V4	0,32	0,01	0,32	0,31	0,32	0,02
	V5	0,36	0,01	0,36	0,35	0,37	0,02

* M – maduro; S – semimaduro; V – verde.

APÊNDICE D – SCRIPT PARA ALGORITMO DE VISÃO DE MÁQUINA PARA OBTENÇÃO DOS ÍNDICES RG

```
int tempo;
bool readSerial = false; // Variável para controlar a impressão dos dados

// Define color sensor pins
#define S0 22
#define S1 27
#define S2 25
#define S3 28
#define sensorOut 26

#define S0B 9
#define S1B 10
#define S2B 13
#define S3B 12
#define sensorOutB 11

#define S0C 21
#define S1C 19
#define S2C 24
#define S3C 20
#define sensorOutC 23

// Variáveis do leitor de cor
float redPW = 0;
float greenPW = 0;
float bluePW = 0;
float redPW_B = 0;
float greenPW_B = 0;
float bluePW_B = 0;
float redPW_C = 0;
float greenPW_C = 0;
float bluePW_C = 0;

// Médias móveis dos canais de cor para cada sensor
```

```
float Mred = 0;
float Mgreen = 0;
float Mblue = 0;
float Mred_B = 0;
float Mgreen_B = 0;
float Mblue_B = 0;
float Mred_C = 0;
float Mgreen_C = 0;
float Mblue_C = 0;

// Contadores para a média móvel
int countRed = 0;
int countGreen = 0;
int countBlue = 0;

// Número de leituras para a média móvel
const int numReadings = 5;

// Função para ler o canal de cor de cada sensor
int getColorPW(int S2_pin, int S3_pin, int sensorOut_pin, int colorChannel) {
  switch (colorChannel) {
    case 0: // Red
      digitalWrite(S2_pin, LOW);
      digitalWrite(S3_pin, LOW);
      break;
    case 1: // Green
      digitalWrite(S2_pin, HIGH);
      digitalWrite(S3_pin, HIGH);
      break;
    case 2: // Blue
      digitalWrite(S2_pin, LOW);
      digitalWrite(S3_pin, HIGH);
      break;
  }
  return pulseIn(sensorOut_pin, LOW);
}
```

```
// Função para calcular a média móvel
float computeMovingAverage(float currentAvg, float newValue, int count) {
    // Calcula a nova média móvel
    currentAvg = (currentAvg * count + newValue) / (count + 1);
    return currentAvg;
}

// Função para normalizar e mapear os valores para a escala RGB (0-255)
int mapToRGBScale(float value, float minVal, float maxVal) {
    return (int)((value - minVal) * 255 / (maxVal - minVal));
}

void setup() {
    Serial.begin(9600);

    // Configuração dos sensores de cor
    // Sensor de cor 1
    pinMode(S0, OUTPUT);
    pinMode(S1, OUTPUT);
    pinMode(S2, OUTPUT);
    pinMode(S3, OUTPUT);

    // Sensor de cor 2
    pinMode(S0B, OUTPUT);
    pinMode(S1B, OUTPUT);
    pinMode(S2B, OUTPUT);
    pinMode(S3B, OUTPUT);

    // Sensor de cor 3
    pinMode(S0C, OUTPUT);
    pinMode(S1C, OUTPUT);
    pinMode(S2C, OUTPUT);
    pinMode(S3C, OUTPUT);

    // Define a escala da largura de pulso dos sensores para 20%
```

```

digitalWrite(S0, HIGH);
digitalWrite(S1, LOW);
digitalWrite(S0B, HIGH);
digitalWrite(S1B, LOW);
digitalWrite(S0C, HIGH);
digitalWrite(S1C, LOW);
}

void loop() {
  tempo = tempo + 1;

  // Verifica se há dados disponíveis para leitura no Serial
  if (Serial.available() > 0) {
    char command = Serial.read(); // Lê o comando do Serial

    // Verifica o comando recebido
    if (command == '1') {
      readSerial = true; // Inicia as leituras no Serial
    } else if (command == '2') {
      readSerial = false; // Para as leituras no Serial
    }
  }

  if (readSerial) {
    // Leitura dos canais de cor dos três sensores
    redPW = getColorPW(S2, S3, sensorOut, 0);
    delay(10); // Atraso para separar as leituras
    greenPW = getColorPW(S2, S3, sensorOut, 1);
    delay(10); // Atraso para separar as leituras
    bluePW = getColorPW(S2, S3, sensorOut, 2);
    delay(10); // Atraso para separar as leituras
    redPW_B = getColorPW(S2B, S3B, sensorOutB, 0);
    delay(10); // Atraso para separar as leituras
    greenPW_B = getColorPW(S2B, S3B, sensorOutB, 1);
    delay(10); // Atraso para separar as leituras
    bluePW_B = getColorPW(S2B, S3B, sensorOutB, 2);
  }
}

```

```

delay(10); // Atraso para separar as leituras
redPW_C = getColorPW(S2C, S3C, sensorOutC, 0);
delay(10); // Atraso para separar as leituras
greenPW_C = getColorPW(S2C, S3C, sensorOutC, 1);
delay(10); // Atraso para separar as leituras
bluePW_C = getColorPW(S2C, S3C, sensorOutC, 2);
delay(10); // Atraso para separar as leituras

// Calcula a média móvel para cada cor para cada sensor
Mred = computeMovingAverage(Mred, redPW, countRed);
Mgreen = computeMovingAverage(Mgreen, greenPW, countGreen);
Mblue = computeMovingAverage(Mblue, bluePW, countBlue);
Mred_B = computeMovingAverage(Mred_B, redPW_B, countRed);
Mgreen_B = computeMovingAverage(Mgreen_B, greenPW_B, countGreen);
Mblue_B = computeMovingAverage(Mblue_B, bluePW_B, countBlue);
Mred_C = computeMovingAverage(Mred_C, redPW_C, countRed);
Mgreen_C = computeMovingAverage(Mgreen_C, greenPW_C, countGreen);
Mblue_C = computeMovingAverage(Mblue_C, bluePW_C, countBlue);

// Incrementa os contadores
countRed++;
countGreen++;
countBlue++;

// Se atingir o número máximo de leituras, reinicia os contadores
if (countRed >= numReadings - 1) {
    countRed = 0;
}
if (countGreen >= numReadings - 1) {
    countGreen = 0;
}
if (countBlue >= numReadings - 1) {
    countBlue = 0;
}

// Calcula a média dos valores normalizados dos três sensores

```



```
float red_avg = (Mred + Mred_B + Mred_C) / 3.0;
float green_avg = (Mgreen + Mgreen_B + Mgreen_C) / 3.0;
float blue_avg = (Mblue + Mblue_B + Mblue_C) / 3.0;

// Normaliza e mapeia os valores para a escala RGB
float minVal = 0.0;
float maxVal = 1023.0; // Valor máximo de leitura do sensor (ajustar se necessário)
int redRGB = mapToRGBScale(red_avg, minVal, maxVal);
int greenRGB = mapToRGBScale(green_avg, minVal, maxVal);
int blueRGB = mapToRGBScale(blue_avg, minVal, maxVal);

// Calcula a diferença entre os valores normalizados de vermelho e verde
int colorDifference = redRGB - greenRGB;

// Saída dos valores RGB e da diferença de cor
Serial.print(redRGB);
Serial.print(" ");
Serial.print(greenRGB);
Serial.print(" ");
Serial.print(blueRGB);
Serial.print(" ");
Serial.println(colorDifference);

delay(10); // Pequeno atraso para permitir leitura confortável no serial monitor
}
}
```