



MAÍSA AZARIAS DE OLIVEIRA

**ESTIMATIVA DE ÍNDICES FÍSICO-QUÍMICOS E
SENSORIAIS DE FRUTAS USANDO IMAGENS DIGITAIS**

LAVRAS - MG

2021

MAÍSA AZARIAS DE OLIVEIRA

**ESTIMATIVA DE ÍNDICES FÍSICO-QUÍMICOS E SENSORIAIS DE FRUTAS
USANDO IMAGENS DIGITAIS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Agroquímica, área de concentração em Agroquímica-Bioquímica e Produtos Naturais, para a obtenção do título de Mestre.

Prof. Dr. Cleiton Antônio Nunes

Orientador

LAVRAS - MG

2021

Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).

Oliveira, Máisa Azarias de.

Estimativa de índices físico-químicos e sensoriais de frutas
usando imagens digitais / Máisa Azarias de Oliveira. - 2021.
53 p. : il.

Orientador(a): Cleiton Antônio Nunes.

Dissertação (mestrado acadêmico) - Universidade Federal de
Lavras, 2021.

Bibliografia.

1. Qualidade. 2. Amadurecimento. 3. Imagens digitais. I.
Nunes, Cleiton Antônio. II. Título.

MAÍSA AZARIAS DE OLIVEIRA

**ESTIMATIVA DE ÍNDICES FÍSICO-QUÍMICOS E SENSORIAIS DE
FRUTAS USANDO IMAGENS DIGITAIS**

**PHYSICOCHEMICAL AND SENSORY INDEX ESTIMATION OF
FRUITS USING DIGITAL IMAGES**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Agroquímica, área de concentração em Agroquímica-Bioquímica e Produtos Naturais, para a obtenção do título de Mestre.

APROVADA em 27 de Agosto de 2021.

Prof. Dr. Cleiton Antônio Nunes	UFLA
Prof ^a . Dra. Ana Carla Marques Pinheiro	UFLA
Prof. Dr. Thalles Ramon Rosa	IFES

Prof. Dr. Cleiton Antônio Nunes
Orientador

LAVRAS - MG

2021

AGRADECIMENTOS

Agradeço à Deus e à Nossa senhora pelo dom da vida, por sempre estar presente nessa caminhada me iluminando, abençoando e me dando forças para chegar ao fim.

Aos meus pais Edimilson e Rosângela pelo carinho, atenção, compreensão, apoio. Às minhas irmãs Mayara e Elaine que sonharam esse sonho comigo me dando forças e me amparando. Ao meu namorado Leandro, gratidão por sua compreensão, companheirismo e incentivo. A vocês agradeço por tudo que conquistei e sou hoje.

Ao professor Cleiton pela orientação para o desenvolvimento deste trabalho, acolhimento, pela oportunidade, incentivo, amizade, por meu crescimento pessoal e profissional e principalmente pela paciência.

Aos meus amigos Thaís Cristina, Thaís Duque, Raniele, Leonardo, Vitor, Andressa, Karoline, Lara e em especial Evanise e Michele, que direta ou indiretamente contribuíram para a realização desse projeto. Por sempre estarem comigo nos momentos tristes e alegres, me dando força para nunca desistir. Gratidão!

Aos provadores pela disponibilidade e paciência.

Às equipes de análise sensorial e análises físico-químicas pela contribuição.

À FAPEMIG, pela concessão da bolsa. À CAPES, CNPq e ao Programa de Pós-Graduação em Agroquímica.

À Universidade Federal de Lavras (UFLA) pela oportunidade oferecida. Ao Departamento de Química pela oportunidade e aos professores pelos ensinamentos conduzidos. Ao LAPEQCA e LAS pela infraestrutura na realização deste trabalho.

MUITO OBRIGADA!

RESUMO

A procura por um estilo de vida mais saudável vem demonstrando que a procura por alimentos saudáveis como frutas tem sofrido alterações. Porém, os consumidores procuram por produtos de qualidade e para isso procuram avaliar aspectos visuais como cor e frescor. A determinação dos parâmetros de qualidade em frutas normalmente é realizada por meio de análises convencionais, o que causa um desperdício e destruição da amostra. No entanto, os smartphones, nos últimos anos, vêm sendo utilizados como instrumento em análises químicas. Sendo assim, este trabalho teve por objetivo construir modelos de calibração baseados em imagens digitais obtidas com smartphone para estimar características sensoriais e físico-químicas de bananas e mamões em diferentes estágios de maturação. Amostras de banana e de mamão foram analisadas em diferentes estágios de maturação. Três abordagens foram usadas para obter informações das imagens: (i) valores RGB médios de toda a imagem da fruta, (ii) quantidade de pixels em cada valor de RGB (denominado neste trabalho de perfil RGB) e (iii) porcentagens das diferentes cores exibidas pela fruta durante seu amadurecimento. Modelos preditivos foram construídos para predição dos parâmetros sensoriais de doçura ideal, firmeza ideal e aceitação global, bem como físico-químicos de SST e firmeza. Os modelos foram calibrados por Regressão Linear Múltipla (MLR) e Regressão pelo Método dos Quadrados Mínimos Parciais (PLS). A abordagem baseada na média de RGB mostrou melhor desempenho para prever os parâmetros analisados sensorialmente e instrumentalmente. Assim, o uso de imagens obtidas por smartphone apresenta grande potencial para estimar os parâmetros de qualidade os quais influenciam na aceitação do consumidor.

Palavras-chave: Qualidade. Amadurecimento. Imagens digitais. Análise sensorial.

ABSTRACT

An increase in fruit consumption has been observed in the last decade, which demonstrates that the population has sought healthier lifestyles. Nevertheless, since consumers look for quality products, they often seek to evaluate visual aspects such as color and freshness. The determination of quality parameters in fruits is normally carried out using conventional analyses, which have disadvantages such as residue production and samples destruction. In recent years, smartphones have been used as an instrument in chemical analysis. Therefore, this study aimed to build calibration models based on digital images obtained with a smartphone to estimate sensory and physicochemical characteristics of bananas and papayas at different stages of maturation. Banana and papaya samples were analyzed at different stages of maturation. Three approaches were used to obtain image information: (i) average RGB values of the entire fruit image, (ii) number of pixels in each RGB value (RGB profile) and (iii) percentages of different colors exhibited by the fruit during ripening. Predictive models were built to predict sensory parameters of ideal sweetness, ideal firmness and global acceptance, as well as SST and firmness instruments. The models were calibrated by multiple linear regression (MLR) and partial least squares regression (PLS). The approach based on average RGB values showed better performance to predict sensory and instrumentally analyzed parameters. Thus, the use of images obtained by smartphone has great potential to estimate the quality parameters that most influence acceptance by consumers.

Keywords: Quality. Maturation. Digital images. Sensory analysis.

LISTA DE ILUSTRAÇÕES

LISTA DE FIGURAS

Figura 1	Variação cronológica do número de publicações científicas envolvendo smartphones.....	21
Figura 2	Modelo de cor representado geometricamente.....	22
Figura 3	Suporte utilizado para aquisição das imagens com controle da iluminação.....	25
Figura 4	Dendrograma obtido por HCA e gráfico de escores e pesos da PCA para as características sensoriais (doçura ideal – DI, firmeza ideal – FI e aceitação global - AG) e instrumentais (SST e firmeza - Fir) das bananas e dos mamões nos diferentes estágios de maturação.....	33
Figura 5	Representação gráfica dos valores medidos e preditos da doçura ideal das frutas com base nos modelos que apresentam menor RMSE na etapa de teste.....	35
Figura 6	Representação gráfica dos valores medidos e preditos de ideal de firmeza das frutas com base nos modelos que apresentaram menor RMSE na etapa de teste.....	36
Figura 7	Representação gráfica dos valores medidos e preditos da aceitação global das frutas com base nos modelos que apresentaram menor RMSE na etapa de teste.....	37
Figura 8	Representação gráfica dos valores medidos e preditos SST das frutas com base nos modelos que apresentaram menor RMSE na etapa de teste.....	40
Figura 9	Representação gráfica dos valores medidos e preditos da firmeza das frutas com base nos modelos que apresentaram menor RMSE na etapa de teste.....	42

LISTA DE TABELAS

Tabela 1	Número de consumidores e amostras analisadas por estágio de maturação.....	27
Tabela 2	Variáveis independentes (X) e variáveis dependentes (Y) utilizados no modelos preditivos.....	28
Tabela 3	Características sensoriais e físico-químicas das bananas em cada estágio de maturação.....	30
Tabela 4	Características sensoriais e físico-químicas dos mamões em cada estágio de maturação.....	31
Tabela 5	Parâmetros de desempenho dos modelos preditivos da doçura das frutas.....	34

Tabela 6	Parâmetros de desempenho dos modelos preditivos da firmeza das frutas.....	36
Tabela 7	Parâmetros de desempenho dos modelos preditivos da aceitação global das frutas.....	37
Tabela 8	Parâmetros de desempenho dos modelos preditivos da SST das frutas.....	39
Tabela 9	Parâmetros de desempenho dos modelos preditivos da firmeza das frutas.....	41

SUMÁRIO

1	INTRODUÇÃO	11
2	REFERENCIAL TEÓRICO	13
2.1	Frutos climatéricos	13
2.1.1	Amadurecimento dos frutos climatéricos	14
2.2	Atributos de qualidade de frutas	15
2.2.1	Cor e aparência	16
2.2.2	Sabor	16
2.2.3	Textura	17
2.3	Técnicas convencionais para caracterização de frutas	18
2.3.1	Refratometria	18
2.3.2	Reologia	19
2.3.3	Colorimetria	19
2.3.4	Avaliação sensorial	20
2.4	Imagens digitais na avaliação da qualidade de frutos	20
3	MATERIAIS E MÉTODOS	24
3.1	Amostras	24
3.2	Aquisição das imagens digitais	24
3.3	Determinação de parâmetros físicos e físico-químicos	25
3.3.1	Sólidos solúveis totais	25
3.3.2	Firmeza	25
3.4	Análise Sensorial	26
3.5	Análise exploratória	27
3.6	Processamento das imagens digitais	27
3.7	Construção dos modelos preditivo	28
4	RESULTADOS E DISCUSSÕES	30
4.1	Caracterizações sensorial e físico-química das frutas	30
4.2	Modelos preditivos dos parâmetros sensoriais	33
4.3	Modelos preditivos dos parâmetros instrumentais	39
5	CONCLUSÃO	43
	REFERÊNCIAS	44

1 INTRODUÇÃO

Em se tratando da satisfação do consumidor, a rejeição ou a aceitação de um alimento depende de alguns fatores como cor, textura e da qualidade interna dos produtos. No geral, a aparência é o primeiro atributo avaliado pelo consumidor e possui um grande impacto na definição da qualidade dos alimentos (TREVISAN et al., 2010).

Entretanto, para se avaliar esses parâmetros se faz necessária a realização de testes convencionais, com os quais parâmetros externos e internos são analisados com mais critérios. Porém, os métodos convencionais usados para este fim são comumente demorados, requerem muitas amostras e são destrutivos (IBBA et al., 2020).

Tradicionalmente, os atributos sensoriais dos alimentos são avaliados por um painel humano por meio da análise sensorial que, de acordo com a definição do *United States Food Institute*, é uma metodologia científica indicada para mensurar, interpretar e analisar as reações humanas em relação a um determinado produto (PENSÉ-LHÉRITIER et al., 2006). Além do painel humano, pode-se recorrer a métodos instrumentais. A cor, por exemplo, pode ser determinada instrumentalmente por meio de um colorímetro, que apesar de ser um equipamento de custo elevado, é capaz de determinar com boa precisão a cor da amostra. No entanto o colorímetro possui algumas desvantagens, como uma área de medição limitada (apenas alguns cm^2), sendo assim, incapaz de capturar e descrever bem amostras com coloração heterogênea (MILOVANOVIC et al., 2021).

Outras características, como teor de sólidos solúveis e textura, também influenciam diretamente a aceitação, sobretudo das frutas. O teor de sólidos solúveis totais (SST) está relacionado à porcentagem de açúcar presente na amostra e pode ser determinado por meio de um refratômetro. Para se realizar a análise de textura faz-se uso de um texturometro, o qual simula o ato da mastigação humana, determinando assim, a firmeza do alimento (MURTA; AGUIRRE; PAUL, 2017).

Considerando a necessidade de se ter sistemas de controle de qualidade mais eficientes e rápidos, o desenvolvimento de métodos para avaliação de amostras em linha de produção tem sido feito na agroindústria, tais como: safra de grãos (PATRÍCIO; RIEDER, 2018); frutos de café durante a colheita (BAZAME et al., 2021) e criação de gado (CHEN et al.; 2021). Nesses casos, as técnicas de análise descritas anteriormente se tornam indesejáveis por serem demoradas e destrutivas. Nesse sentido, o uso de imagens digitais têm se mostrado apropriados para prever características sensoriais e físico-químicas de vários produtos, tais

como Chá Preto Congou (REN et al., 2021), produtos cárneos (TAHERI-GARAVAND et. al., 2019); azeite de oliva (GILA et al., 2020) e frutas (ISMAIL et al., 2021).

Assim, o presente trabalho teve como objetivo construir modelos de calibração baseados em imagens digitais obtidas com smartphone para prever características sensoriais e físico-químicas de bananas e mamões em diferentes estágios de maturação.

2 REFERENCIAL TEÓRICO

As frutas são uma importante fonte de nutrição e desempenham um papel fundamental na saúde humana, fornecendo fatores reguladores do crescimento essenciais para uma boa saúde (MAHANTI; CHAKRABORTY, 2020). Quase sempre a qualidade comercial das frutas é baseada em atributos externos como tamanho, forma e cor (BOUSSA et al., 2019). Entretanto, em se tratando de frutos não climatéricos, a cor da pele nem sempre indica sua adequação para o consumo, e atributos internos como sólidos solúveis totais e acidez também devem ser considerados para atender aos requisitos do mercado (FAWOLE; OPARA, 2013; BOUSSA et al., 2019).

Os padrões de maturação da fruta variam de país para país, dependendo da expectativa de vida exigida pela fruta antes de ocorrer a maturação. Os atributos de qualidade de uma fruta são categorizados como sensoriais, ocultos e quantitativos. Os atributos sensoriais incluem cor, brilho, tamanho, forma, defeitos, sabor, textura (firmeza, crocância e dureza) e sabor. Os atributos ocultos são valores nutritivos, presença de contaminantes perigosos e materiais tóxicos. Os parâmetros quantitativos são aqueles que contribuem para a qualidade geral dos alimentos, tais como teor de açúcares, firmeza, conteúdo de sólidos solúveis, acidez titulável e conteúdo nutricional. (MAGWAZA; OPARA, 2015; KANDAKER et al., 2018; ZHANG et al., 2018).

Diversos métodos vêm sendo usados para determinar os estágios de maturação das frutas, mas as técnicas comumente adotadas são destrutivas e demoradas, envolvendo a determinação da relação polpa/casca e firmeza do fruto (RAMMA; MADHU; PEERTHUM, 1999). Portanto, qualquer tecnologia rápida e não destrutiva que possa classificar os frutos com base em cor, textura e sabor contribuirá para garantir mais qualidade aos produtos, fazendo com que a satisfação e aceitação do consumidor aumentem (LU; ARIANA, 2002).

2.1 Frutos climatéricos

Os frutos podem ser classificados de acordo com a taxa respiratória e a produção de etileno, sendo denominados como climatéricos e não climatéricos (HU et al., 2019). Frutos que possuem um amadurecimento acompanhado por um aumento na atividade respiratória são denominados climatéricos. Estes possuem um valor mínimo na atividade respiratória e este valor é denominado de pré-climatérico. O pós-climatérico segue com um declínio na atividade

respiratória após o pico máximo estabelecido como máximo climatérico. Como exemplos de frutos climatéricos temos banana, mamão, manga, pera e abacate. O processo de maturação de um fruto climatérico está associado ao hormônio etileno, o qual tem um pico de produção que pode coincidir ou não com a atividade máxima respiratória (BIALE; YOUNG; OLMSTEAD, 1954).

Devido ao processo de maturação ser aparentemente rápido e por apresentarem uma alta taxa de respiração, esses frutos são colhidos verdes para ampliar o tempo de conservação e continuam o processo de amadurecimento após a colheita (KAYS; PAULL, 2004). A produção auto catalítica do etileno é o que desencadeia todas as reações que levam os frutos climatéricos a desenvolver características de frutos maduros, como amolecimento da fruta, desenvolvimento do sabor e aroma (GIOVANNONI, 2004; KLEE; GIOVANNONI, 2011).

2.1.1 Amadurecimento dos frutos climatéricos

O amadurecimento é um processo no qual ocorrem alterações fisiológicas e bioquímicas, alterando assim sabor, cor, aroma e textura da fruta, o que aumenta a sua palatabilidade (ALEXANDER; CRIERSON, 2002).

O hormônio presente nas frutas, o etileno, foi descoberto no início do século 20 (LACEY; BINDER, 2014) e está envolvido na maioria dos aspectos de desenvolvimento de plantas, incluindo germinação de sementes, alongamento de raízes, desenvolvimento de flores e amadurecimento dos frutos (JU; CHANG, 2015). Este hormônio é fundamental para o amadurecimento adequado das frutas e regula vários processos incluindo mudança de cor e produção de ácidos orgânicos (BAPAT et al., 2010). O etileno frequentemente leva ao amadurecimento excessivo e até mesmo à decomposição, além de acelerar o amadurecimento da fruta, causando uma redução na vida útil e perdas excessivas (WEI et al., 2021). O amadurecimento das frutas é afetado por dois tipos de hormônio etileno: etileno endógeno, que é produzido pela própria planta por meio de uma via biológica, e o hormônio exógeno, que se origina de vias adjacentes, como escapamento de automóveis, fumaça e plásticos (KELLER et al., 2013).

Durante o processo de amadurecimento, o fruto sofre mudanças de composição e de estrutura. Alterações na textura e amolecimento dos frutos ocorrem devido à despolimerização e solubilização dos componentes da parede celular e à perda da estrutura celular (LI et al., 2010). Em algumas frutas, como as bananas, que contêm alto nível de amido na polpa das frutas, a hidrólise enzimática do amido é um fator importante no amolecimento das frutas. (MADUWANTHI; MARAPANA, 2019).

A modificação da cor é um importante fator associado ao amadurecimento de muitos frutos. Em alguns casos, a mudança de cor durante o amadurecimento dos frutos se dá pela degradação das clorofilas e pela síntese de antocianinas e carotenoides. Os carotenoides são derivados de terpenoides e são sintetizados em frutas a uma taxa alta durante a transição do cloroplasto para o cromoplasto. O pigmento responsável pela coloração verde é a clorofila, que durante o amadurecimento é degradada, enquanto há a revelação de outros pigmentos como β -caroteno, licopeno, xantofila (CHITARRA; CHITARRA, 2005).

O perfil volátil de aromas e sabores das frutas consiste principalmente de ésteres, álcoois, aldeídos, cetonas e terpenos. Quando a biossíntese de etileno é inibida pelo uso de aminoetoxivinilglicina, a produção de aroma é reduzida, indicando assim, que a síntese de aroma está correlacionada com a produção e ação do hormônio etileno nos frutos (EL-KEREAMY et al., 2003).

A adstringência que surge devido à presença de taninos nos frutos mostra uma tendência decrescente durante o amadurecimento de muitos frutos. É relatado que a adstringência depende da estrutura molecular do tanino, que determina a reticulação com proteínas e glicoproteínas. Portanto, os taninos dão sensação adstringente quando são dissolvidos na saliva. Um aumento no peso molecular do tanino por polimerização que ocorre durante o amadurecimento causa falta de adstringência devido à insolubilidade dos taninos (JACKSON, 2015).

2.2 Atributos de qualidade de frutas

De acordo com Chitarra e Chitarra (2005) a qualidade é definida como o conjunto de características que diferem os componentes individuais de um mesmo produto, sendo que esses componentes interferem significativamente no grau de aceitação pelo consumidor. Assim, atributos físicos, sensoriais e a composição química devem ser considerados para um estudo mais abrangente das transformações sofridas pelo fruto ao longo do tempo.

Os principais atributos que podem ser usados para avaliar a qualidade de frutas são cor, aparência, sabor, textura e teor de sólidos solúveis. A aparência do produto tem o maior impacto para decidir sua aceitação ou rejeição no mercado. Com isso, a aparência é um dos atributos de qualidade mais críticos. Contudo, a satisfação do consumidor depende também do sabor e da qualidade interna dos produtos, os quais podem ser determinados pelo teor de sólidos solúveis, acidez e textura (KRAMER, 1965). Como os atributos sensoriais são pouco

representativos se considerados isoladamente, é interessante que os mesmos sejam considerados em conjunto.

2.2.1 Cor e aparência

A cor de uma fruta é resultado dos pigmentos naturais presentes em sua composição. Os pigmentos que dão cor às frutas incluem clorofilas (verde), carotenoides (amarelo, laranja e vermelho), antocianinas (vermelho e azul) e flavonoides (amarelo). As reações de escurecimento enzimático e não enzimático podem resultar no desenvolvimento de pigmentos marrons, cinzas e pretos. As clorofilas são relativamente estáveis em meio alcalino e são altamente sensíveis à ação do ácido e do calor. No entanto, os carotenoides são estáveis à ação do calor enquanto sensíveis à luz e à oxidação. As antocianinas são sensíveis ao pH e ao calor, enquanto os flavonoides são sensíveis à oxidação, mais estáveis ao calor (CLYDESDALE; FRANCIS, 1976).

A aparência dos produtos é caracterizada por sua forma, tamanho, compacidade, uniformidade e presença de defeitos. O tamanho e a forma das frutas são influenciados pela natureza do ambiente em que é cultivado, maturidade da planta e insumos durante a produção. O brilho é propriedade dos produtos para refletir a luz e é afetado pelo teor de umidade e pela deposição de cera na superfície (MITCHAM; CANTWELL; KADER, 1996).

2.2.2 Sabor

O sabor é uma combinação de gosto e aroma. O gosto é classificado como doce, azedo, salgado, amargo e é atribuído aos compostos não voláteis nos alimentos. Os aromas são formados por diferentes substâncias químicas, como ésteres, ácidos, cetonas, aldeídos, álcoois e terpenos, utilizados em quantidades mínimas, que não se relacionam com o valor nutricional do alimento. Para as frutas, o sabor é geralmente expresso em termos da combinação de princípios agridoces, que são uma indicação de maturação e qualidade da alimentação (CHITARRA; CHITARRA, 2005).

O teor de SST é uma boa estimativa do teor de açúcar presente no produto. Os ácidos orgânicos (cítrico, málico, oxálico, tartárico) são componentes do paladar que possuem suma importância, principalmente na relação sólidos solúveis. Com o processo de maturação das frutas, os ácidos orgânicos presentes tendem a diminuir e ocorre o aumento dos açúcares e com isso a relação SST/acidez tende a aumentar. O conteúdo de sólidos solúveis inclui açúcar

e ácidos, além de pequenas quantidades de vitaminas, proteínas, fenólicos, minerais e pigmentos dissolvidos. O teor de SST é o principal fator de qualidade que indica a doçura de produtos hortícolas frescos e processados para fins de pesquisa em laboratórios e indústrias para determinar vários padrões de comercialização (CHOPE; TERRY; WHITE, 2006).

2.2.3 Textura

De um modo abrangente, textura pode ser definida como o conjunto de propriedades de um alimento que é composta por características físicas e que estão correlacionadas com a deformação e desintegração de um alimento sob o uso de força (CHITARRA; CHITARRA, 2005). Sensações como dureza, maciez, suculência dentre outras são responsáveis por caracterizar a textura de frutas.

A textura das frutas pode ser avaliada colhendo-as nas mãos ou mastigando. Ao contrário dos parâmetros de sabor, esses atributos podem ser facilmente medidos usando instrumentos físicos. Quase todas as frutas contêm uma proporção significativa de água e outros materiais solúveis em líquidos geralmente envolvidos por uma membrana semipermeável e parede celular. A pressão do turgor, a composição e a estrutura das paredes celulares individuais é que mantém várias camadas juntas, determinando a textura das frutas. As paredes celulares são compostas principalmente por celulose, hemiceluloses, substâncias pécnicas, proteínas. O tomate é um exemplo de um vegetal com aproximadamente 93 a 95% de água e 5 a 7% de sólidos totais. Este último é composto por aproximadamente 80 a 90% de sólidos solúveis e 10 a 20% de sólidos insolúveis. O maior contribuinte para a textura dos produtos de tomate são os sólidos insolúveis, derivados da parede celular (WALDRON; PARKER; SMITH, 2003).

As propriedades texturais do alimento são percebidas pela sensação de toque, estão relacionadas à deformação, desintegração e fluxo do alimento sob uma força e são medidas objetivamente por funções de massa, tempo e distância. Os termos textura, reologia, consistência e viscosidade são frequentemente usados de forma intercambiável, apesar de descreverem propriedades que são diferentes em uma extensão. Na prática, o termo textura é usado principalmente com referência a alimentos sólidos ou semissólidos. No entanto, a maioria das frutas é visco elástica, o que implica que exibem propriedades combinadas de líquidos ideais, que demonstram apenas viscosidade (fluxo) e sólidos ideais, que transmite apenas elasticidade (deformação) (BOURNE, 1982).

2.3 Técnicas convencionais para caracterização de frutas

Os índices usados para descrever a qualidade de frutas incluem medições não destrutivas, tais como cor da casca e tamanho do fruto, ou análises destrutivas, tais como teor de SST e firmeza da polpa. Atualmente, técnicas modernas não destrutivas podem ser aplicadas (HAYES; WALSH; GREENSILL, 2016). A análise não destrutiva refere-se ao teste de superfície de frutas e vegetais sem nenhuma técnica intrusiva que afeta o aspecto e a qualidade dos alimentos. Os métodos de avaliação não destrutivos fornecem dados sobre características dos alimentos, como estrutura, propriedades mecânicas, físicas e químicas (EL-MESERY et al., 2019). Apesar da possibilidade de usar alguns métodos não destrutivos, métodos clássicos e destrutivos ainda são amplamente usados.

2.3.1 Refratometria

O índice de refração pode variar de acordo com o comprimento de onda e com a temperatura. Quando estes índices são constantes, conseqüentemente, o índice de refração se apresentará constante. Sendo assim, este parâmetro é muito útil para confirmar a identidade de um composto ou avaliar seus componentes (OHLWEILER, 1981). O índice de refração é estipulado pela variação da direção quando a mesma passa de um meio para o outro.

A refratometria na escala Brix é um método físico utilizado para medir a quantidade de sólidos solúveis. A escala Brix é calibrada pelo número de gramas de açúcar contidos em 100g de solução. O índice de refração, o Brix e o teor de sólidos solúveis podem ser determinados por meio de um refratômetro. Vários tipos de refratômetros estão disponíveis para este tipo de análise, porém o refratômetro de índice de refração baseado no ângulo crítico é o mais adequado e preciso, pois não é afetado por sólidos em suspensão e cor da amostra (DONGARE et al., 2014).

O refratômetro Brix tem vantagens sobre outros métodos de estimativa da concentração de SST, pois é barato, prontamente disponível, menos frágil e menos sensível à variação da temperatura da amostra e da temperatura ambiente, estação do ano e outros fatores. No entanto, o refratômetro geralmente apresenta algum erro se a leitura é feita muito rapidamente, antes que o equilíbrio da temperatura seja alcançado e a partir de partículas (como amido) que se depositam no prisma, causando variações no índice de refração (DONGARE et al., 2014).

Um cuidado especial deve ser tomado ao se referir ao teor de açúcares, que geralmente é expresso como teor de sólidos solúveis ou conteúdo de sólidos solúveis. Alguns pesquisadores referem-se à concentração de sólidos solúveis, enquanto outros se referem ao teor de sólidos solúveis, tornando-se uma prática comum usar esses termos de forma intercambiável (LU, 2004; BAIANO et al., 2012; MCDONALD et al., 2013; PEREIRA et al., 2013).

2.3.2 Reologia

A reologia trata do estudo da deformação e do fluxo da matéria, sendo a deformação aplicada aos materiais predominantemente sólidos. A textura dos alimentos é definida pelo conjunto de todas as propriedades reológicas e estruturais (geométricas e de superfície), perceptíveis pelos receptores mecânicos, táteis e eventualmente pelos receptores visuais e auditivos (ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS - ABNT, 1993). A textura pode ser alterada pelos diferentes métodos de cocção ao considerar a temperatura, a duração do cozimento e o meio de cocção.

O texturômetro é um equipamento que simula o ato da mastigação humana e determina a dureza do alimento. O equipamento funciona com a ação de uma haste de metal que mede, em função do tempo, a força necessária para romper a amostra do produto. Os resultados são obtidos a partir da interpretação das curvas geradas, que revelam a diferença da resistência pelo produto a uma força sobreposta a ele em determinado período (MURTA; AGUIRRE; PAUL, 2017).

É um método relativamente simples, desde que seja aplicado em conformidade com os protocolos adequados e facilita a análise de textura quando comparado aos provadores humanos (SZCZESNIAK, 2002).

2.3.3 Colorimetria

Instrumentos que fornecem uma medição consistente da verdadeira cor da superfície da fruta facilitam uma comparação justa da qualidade entre locais, época e estações e, posteriormente, podem ser usados para julgar a qualidade e o valor da fruta. A prática atual de laboratório para medir instrumentalmente as mudanças de cor das frutas faz uso de um colorímetro (LEON et al., 2006). No entanto, este instrumento tem uma área de visualização de cerca de 5 cm², e conseqüentemente, é incapaz de capturar e descrever toda a fruta em uma

única medição. Descrições de cores heterogêneas de frutas só são possíveis através da medição de vários locais, enquanto erros são introduzidos devido à escolha do local ao rastrear as alterações de qualidade dos mesmos produtos à medida que amadurecem. A redução parcial do erro experimental na medição de frutos coloridos heterogêneos pode ser alcançada através da aplicação de alguma forma de lógica na escolha da posição no fruto. (PORAT et al., 2003; HERTOOG et al., 2007).

2.3.4 Avaliação sensorial

Na análise sensorial, avaliadores ou de consumidores são usados para avaliar atributos sensoriais, sendo uma técnica mais realista para obter informações da percepção humana sobre o alimento (BEULLENS et al., 2006, 2008; RUDNITSKAYA et al., 2006). No entanto, a avaliação sensorial apresenta algumas características pouco desejáveis, incluindo a correção do treinamento, padronização de medidas, estabilidade e reprodutibilidade. Outras desvantagens da técnica de avaliação sensorial são o alto custo e a saturação do paladar do participante em certos casos. De acordo com Shewfelt (2009), um mínimo de 24 membros de um painel não treinado é essencial para ter confiança nos resultados dos testes, sendo necessário de 50 a 100 membros para fornecer informações adequadas.

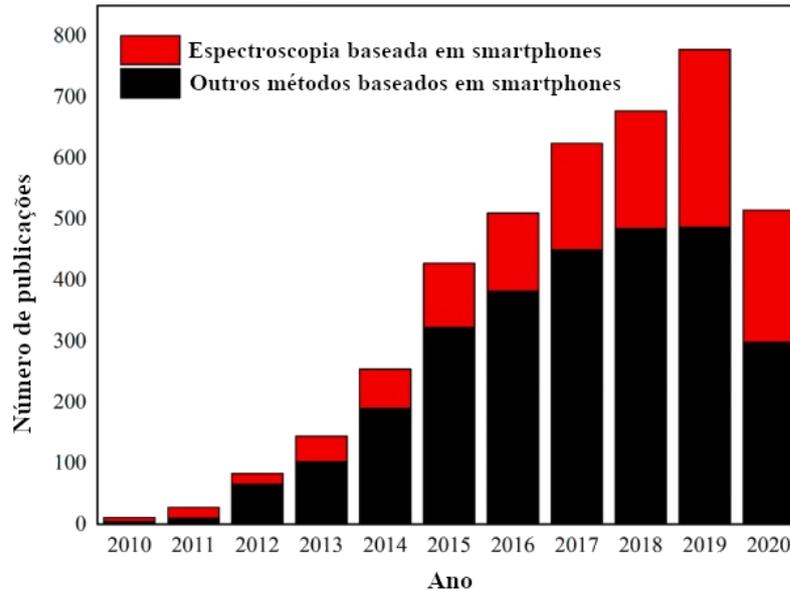
Portanto, a análise sensorial vem sendo utilizada como uma ferramenta complementar, onde a abordagem depende dos avaliadores humanos que são os responsáveis pelos dados fornecidos (HAWKO et al., 2021). A análise sensorial pode ser contestada em relação à subjetividade do painel humano, já que fatores psicológicos podem afetar a análise (CONTI; GUARINO; BACENETTI, 2020)

2.4 Imagens digitais na avaliação da qualidade de frutos

A utilização de dispositivos móveis para a captura de imagens tem se mostrado uma fonte potencial para estimar diversos parâmetros de qualidades de frutos. Este tipo de método se baseia na obtenção de imagens por meio de celulares, webcams, scanners e outros (FIRDAUS et al., 2014), as quais são processadas por meio de softwares apropriados a fim de predizerem a propriedade de interesse. Em geral, os métodos baseados em análise de imagens digitais fazem uso de ferramentas estatísticas multivariadas, sobretudo métodos para classificação e calibração multivariada.

Originalmente, os smartphones foram desenvolvidos como um meio de comunicação, mas com o passar dos anos avanços tecnológicos fizeram com que os smartphones não fossem mais usados apenas como uma ferramenta de comunicação (KANJI et al., 2018). Assim, o uso dos smartphones em diferentes campos científicos tem tido um grande crescimento. A Figura 1 mostra a tendência no aumento de publicações apresentando o uso de smartphones.

Figura 1 - Variação cronológica do número de publicações científicas envolvendo smartphones.



Fonte: Adaptado de Chen et al. (2021).

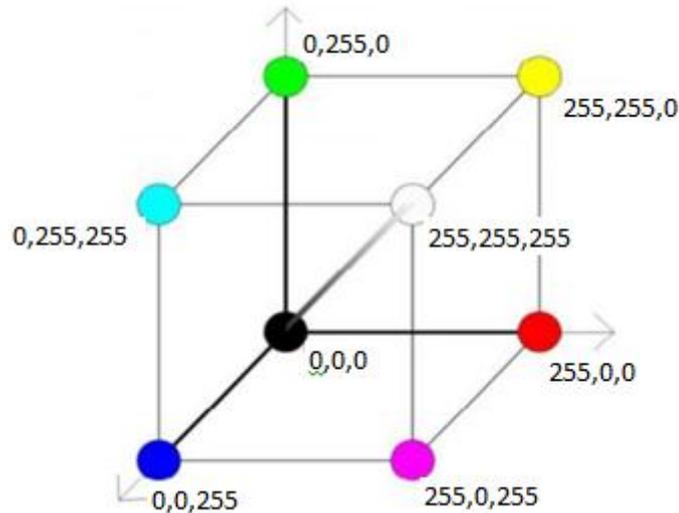
A fim de promover uma especificação padronizada, diferentes sistemas de cores são usados para descrever as imagens digitais, sendo CMYK, XYZ, $L^*a^*b^*$, HSV (HSB) e principalmente o RGB (RYU et al., 2014).

As cores no sistema RGB são definidas por um conjunto de três valores, cada um representando as intensidades das três cores componentes do sistema: vermelho (700 nm), verde (546,1 nm) e azul (435,8 nm) (RYU et al., 2014). Esses componentes são comumente descritos numericamente com valores entre zero e 255, onde zero é o valor mais baixo de intensidade da cor e 255 a cor no valor máximo (FIRDAUS et al., 2014).

O modelo de cor RGB é representado através de um cubo tridimensional (FIGURA 2), no qual os valores RGB primários estão em três vértices, as cores secundárias ciano, magenta e amarelo estão nos outros três vértices mais distantes da origem. A escala de cinza, a diagonal principal do cubo, possui quantidades iguais de cores primárias que vão do preto ao branco. As diferentes cores obtidas nesse modelo são pontos no cubo ou dentro dele e são definidas por vetores que se estendem a partir da origem. Com isso, cada tonalidade, que

corresponde a um único ponto no cubo, pode ser descrita por um conjunto de três valores também únicos, que definem inequivocamente uma cor (ELGAMMAL; MUANG; HU, 2009; GONZALES; WOODS, 2010; KHAIRY; DUERKOP, 2019;).

Figura 2 - Modelo de cor representado geometricamente.



Fonte: Adaptado de Gonzales e Woods (2010).

As propriedades de frutas como cor, textura, tamanho, forma, entre outras são comumente analisadas por meio de técnicas convencionais demoradas e destrutivas. Além disso, essas análises são limitadas, podendo não representar a variabilidade físico-química típica encontrada nos lotes (MAGWZA; OPARA, 2015). Ao longo dos anos, a aplicação de imagens digitais para identificação e análises de qualidade alimentar vem sendo relatada com sucesso, devido ao método ser rápido, econômico e fornece análises não destrutivas (WU; SUN, 2013; COSTA et al., 2015; MAROUBO et al., 2021).

Características de cores foram usadas para prever o amadurecimento de mangas com baixas taxas de classificação incorreta (NAMBI et al., 2016). Os autores conduziram um estudo para descobrir as características de imagem mais adequadas para previsão da qualidade da manga usando imagens RGB. A Análise de Agrupamento Hierárquico (HCA) foi empregada para a classificação com base em parâmetros de qualidade (físico-química, cor e textura). A partir dos resultados, observou-se que características de área extraídas de canais RGB seriam mais eficazes na previsão. Esses resultados seriam adequados para desenvolver um algoritmo de visão computacional para prever o nível de maturação da manga com uma imagem e um algoritmo.

Santos et al. (2019) apresentaram um método de baixo custo utilizando imagens obtidas com smartphones para determinação de ácido ascórbico em frutas nativas e exóticas da Amazônia brasileira. Os autores conseguiram obter um modelo capaz de quantificar ácido ascórbico com uma boa precisão comparada com resultados de um método padrão. Além da simplicidade, baixo custo e portabilidade, o método pode ser considerado um método de química verde pelo baixo consumo de energia elétrica e um menor desperdício de alimentos nas análises.

O método tradicional para avaliar se um morango está maduro ou não é baseado no julgamento subjetivo da aparência, sabor, cor e textura, o que é difícil de padronizar e não garante precisão. Com isso, Yue et al. (2019) avaliaram um método que fosse rápido, não destrutivo, preciso e conveniente para identificação da maturação de morangos e classificá-los de acordo com o nível de maturação. Os autores equiparam um smartphone com filtro ótico de 535 nm e 670nm, padronizando a altura e condição de iluminação. O método permitiu classificar as amostras de morango em três categorias: madura, quase madura e imatura, demonstrando um potencial considerável como meio rápido para reconhecimento da maturação de morangos.

Cubero et al. (2018) desenvolveram um aplicativo para estimar o índice de cores cítricas para analisar laranjas em diferentes estágios de maturação. As laranjas foram fotografadas dentro de um sistema de inspeção contendo a câmera e a iluminação. Um aplicativo foi utilizado para capturar as imagens de cada fruto. Os autores concluíram que um sistema de visão computacional portátil permite que o índice de cores seja medido automaticamente, enquanto a fruta está sendo colhida ou em outro tipo de processamento.

No entanto, o uso de smartphones tem alguns obstáculos a serem resolvidos. As características das câmeras não atendem às demandas da espectrofotometria de precisão. Assim, comprimento de onda preciso, resposta rápida e robustez são atualmente problemas desafiadores, mas espera-se que vá sendo minimizado com o desenvolvimento tecnológico. Outra questão são os espectros de emissão e sua estabilidade quando se usa a fotografia como fonte primária de dados experimentais (TIUFTIAKOV et al, 2021; REZAZADEH et al., 2019).

Em contrapartida, o uso de imagens digitais como meio de análise química baseada em smartphones possuem como vantagens o baixo custo operacional (funcionamento e manutenção), combinam alto rendimento com um curto tempo de análise, são portáteis e fáceis de operar.

3 MATERIAIS E MÉTODOS

3.1 Amostras

Foram usadas amostras de bananas da variedade Nanica (*Dwarf Cavendish*) e mamão da variedade Formosa (*Carica Papaya*) adquiridas no comércio local de Lavras-MG. No total, 117 amostras de banana e 20 amostras de mamão foram e analisadas em diferentes estágios de maturação. Os frutos foram transportados para o Laboratório de Análise Sensorial do Departamento de Ciências da Alimentação da Universidade Federal de Lavras, onde foram armazenadas em temperatura ambiente (24°C), higienizados e preparados para análise. Para análise, cada estágio de maturação foi avaliado seguindo os padrões de coloração de amadurecimento. O preparo das amostras e o pré-processamento seguiram a metodologia empregada por Côrrea et al. (2014). Todas as frutas selecionadas eram visivelmente saudáveis e não apresentavam qualquer lesão física. As frutas foram lavadas em água corrente para remoção de eventuais pequenas partículas de pó ou sujeira.

3.2 Aquisição das imagens digitais

As frutas, em cada estágio de maturação, foram fotografadas em uma cabine de cor branca, iluminada por uma lâmpada de LED com 9 W de potência, com as dimensões 70 cm de largura x 50 cm de profundidade x 110 cm de altura. As imagens das bananas foram obtidas com um smartphone Samsung J7 Prime com 13 MP e resolução 4160 x 3120 pixel. As imagens dos mamões foram adquiridas usando um smartphone Motorola Moto G4 com 8 MP e resolução 3266 x 2449. As imagens foram obtidas em triplicata. Para que houvesse uma padronização, fez-se uso de um suporte para manter uma distância de 30 cm entre a fruta e a câmera (FIGURA 3). O conjunto foi posicionado de maneira que não se produzisse sombras e que a luz iluminasse homogeneamente a amostra. Para o processamento das imagens e obtenção dos valores do sistema de cor RGB foi utilizado o programa *ImageJ*.

Figura 3 - Suporte utilizado para aquisição das imagens com controle da iluminação.



Fonte: Da autora (2021).

3.3 Determinação de parâmetros físicos e físico-químicos

Para padronização das amostras, as bananas foram fatiadas perpendicularmente ao seu eixo principal e as pontas retiradas. Mesmo processo foi feito para o mamão. Por fim, as frutas foram separadas em dois grupos: um grupo foi submetido à análise física e físico-química e o outro foi utilizado para a análise sensorial. As análises físicas, físico-químicas e sensoriais foram realizadas imediatamente após essas etapas.

3.3.1 Sólidos solúveis totais

O teor de SST foi determinado por meio de um refratômetro digital Atago PR100, previamente calibrado e com compensação automática de temperatura para 25° C (AOAC, 1998). Os resultados foram expressos em °Brix.

3.3.2 Firmeza

A firmeza dos frutos foi medida por teste de punção utilizando um penetrômetro Magness Taylor, com sonda de 3 mm e 5 mm de diâmetro para banana e mamão respectivamente. As medidas foram feitas utilizando um terço médio dos frutos, sendo as medidas realizadas na parte interna do mesocarpo (polpa). Os resultados foram expressos em Newtons (N).

3.4 Análise Sensorial

A análise sensorial foi realizada no Laboratório de Análise Sensorial da Universidade Federal de Lavras. Foram realizados em condições ideais, sob luz branca, temperatura controlada de 25 ° C e em cabines individuais. Para a banana, a análise foi realizada em sete sessões, e para o mamão foi feita em cinco sessões relativas aos diferentes estágios de maturação. Cada sessão de teste foi realizada usando um desenho de bloco completo balanceado no qual um consumidor avaliou três amostras diferentes de banana e mamão. Água foi servida junto com as amostras para limpar o paladar entre as avaliações das amostras. As amostras foram codificadas em números aleatórios de três dígitos e apresentadas em ordem monádica e balanceada, seguindo a metodologia sensorial proposta por WAKELING e MACFIE (1995). As amostras foram apresentadas em copos plásticos descartáveis de 50 mL, cada um contendo um pedaço da fruta de aproximadamente 20 g.

Os consumidores foram solicitados a avaliar a doçura ideal, firmeza ideal e aceitação global. Essas avaliações foram realizadas usando três escalas numéricas não estruturadas de 9 cm, cujos pontos extremos esquerdos foram respectivamente ancorados com os termos 'extremamente menos doce do que o ideal' e 'extremamente menos firme do que o ideal', o centro com os termos 'doçura ideal' e 'firmeza ideal', e o ponto extremo direito certo com os termos 'extremamente mais doce do que o ideal' e 'extremamente mais firme do que o ideal'.

Os consumidores foram solicitados a avaliar o quanto gostaram ou não gostaram das amostras por meio da aceitação global, considerando os aspectos sensoriais de cor, aroma, textura e sabor. Assim, os consumidores avaliaram as diferentes amostras usando uma escala numérica não estruturada de 9 cm, cujo ponto extremo esquerdo era ancorado com o termo 'extremamente desagradável', o centro com o termo 'não gostei nem desgostei' e o ponto extremo direito com o termo 'gostei muito'.

A análise sensorial foi realizada após a aprovação deste projeto pelo Comitê de Ética em Pesquisa com Seres Humanos (COEP) da Universidade Federal de Lavras (parecer # 238.755).

O número de consumidores e amostras analisadas em cada coleta de dados estão na Tabela 1.

Tabela 1 - Número de consumidores e amostras analisadas por estágio de maturação.

		Estágios de maturação							Total
		I	II	III	IV	V	VI	VII	
Banana	Amostras	15	20	20	19	16	13	14	117
	Consumidores	30	30	30	30	30	30	30	210
Mamão	Amostras	4	4	4	4	4	-	-	19
	Consumidores	30	30	30	30	30	-	-	150

Fonte: Da autora (2021).

3.5 Análise exploratória

As médias das características sensoriais (doçura ideal, firmeza ideal e aceitação global) e instrumentais (teor de SST e firmeza) foram analisadas por Análise de Agrupamento Hierárquico (HCA) e Análise de Componentes Principais (PCA). Os dados foram organizados em uma matriz com as amostras em linhas e as variáveis em colunas. A matriz foi autoescalada e as análises executadas no programa Chemoface versão 1.64 (NUNES et al., 2012).

3.6 Processamento das imagens digitais

Três abordagens foram usadas para obter informações das imagens: (i) valores RGB médios de toda a imagem da fruta, (ii) quantidade de pixels em cada valor de RGB (histograma, denominado neste trabalho de perfil RGB) e (iii) porcentagens das diferentes cores exibidas pela fruta durante seu amadurecimento (% de cor). Neste último caso, três cores foram consideradas para as bananas: verde (RGB 20, 150,10), amarelo (RGB 180, 180, 0) e marrom (RGB 40, 0, 0). Para os mamões também foram consideradas três cores: verde (RGB 75, 90, 35), amarelo (RGB 160, 120, 20) e laranja (RGB 130, 60, 5). Essas cores foram definidas por meio de análise prévia das amostras levando em consideração as cores predominantes durante seu processo de amadurecimento. Para obtenção da porcentagem de cada uma dessas cores na imagem da fruta, foi calculada a distância Euclidiana entre os valores RGB de cada cor referência e os valores RGB de cada pixel da imagem. A cor do pixel foi associada à cor referência pela menor distância Euclidiana. Por fim, a porcentagem de pixels da imagem em cada cor referência foi computada. Todos os cálculos foram implementados GNU Octave (Eaton et al., 2019).

3.7 Construção dos modelos preditivo

Foram construídos modelos para predição dos parâmetros sensoriais doçura ideal, firmeza ideal e aceitação global, bem como dos instrumentais SST e firmeza, a partir de informações obtidas das imagens digitais das frutas. Os modelos foram obtidos por Regressão Linear Múltipla (MLR) e Regressão pelo Método dos Quadrados Mínimos Parciais (PLS) (TABELA 2).

Tabela 2 - Variáveis independentes (X) e variáveis dependentes (Y) utilizados nos modelos preditivos.

X	Método de regressão	Y	
		Sensoriais	Instrumentais
RGB médio	MLR	Doçura Ideal	SST (°Brix)
Perfil RGB	PLS	Firmeza Ideal	Firmeza (N)
% cor	MLR	Aceitação Global	

Fonte: Da autora (2021).

O conjunto de dados foi dividido em um grupo de calibração e um grupo de teste usando o algoritmo Kennard-Stone (KENNARD et al., 1969), sendo 75% para calibração e 25% para teste. O desempenho dos modelos foi avaliado com base no RMSE (raiz quadrada do erro médio quadrático) e R^2 (coeficiente de determinação) (Equações 1 e Equação 2).

$$RMSE = \sqrt{\sum_i \frac{(y_i - \hat{y}_i)^2}{M}} \quad (1)$$

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (2)$$

onde: y_i é a resposta experimental, \hat{y}_i é o valor estimado pelo modelo, \bar{y} é a resposta experimental média e M é o número de amostras.

Foi realizada validação cruzada do tipo *leave-one-out*, na qual uma amostra do conjunto de calibração é deixada de fora da obtenção do modelo e este é usado para prever a resposta de interesse da amostra que ficou de fora. O processo é repetido para todas as amostras do conjunto. Os modelos também foram confrontados por meio do teste de randomização de Y, que consiste em manter a matriz X fixa e embaralhar o vetor y para obtenção do modelo, esperando assim que os parâmetros de desempenho tenham uma piora considerável para se atestar uma relação válida entre X e Y (ROY et al., 2009).

Por meio do parâmetro R_p^2 (Equação 3) calculou-se a diferença entre o coeficiente de correlação do teste de randomização de Y (R_{rand}^2) e o coeficiente de correlação de calibração

(R^2_{cal}). Para um modelo aceitável assume-se valor de $R^2_p > 0.5$ (ROY et al., 2009; MITRA et al., 2010).

$${}^eR^2_p = R^2_{cal} (R^2_{cal} - R^2_{rand})^{1/2} \quad (3)$$

O parâmetro adicional R^2_m (Equação 4) também foi usado para validação (MITRA et al., 2010). O parâmetro R^2_m é usado para garantir que não apenas um bom coeficiente de correlação na validação externa tenha sido alcançado, mas também que os valores absolutos medidos e preditos são congruentes. Então R^2_m dá uma visão da inclinação da curva entre os valores experimentais e previstos. Um $R^2_m > 0,5$ é considerado aceitável.

$$R^2_m = R^2 [1 - (R^2 - R^2_0)^{1/2}] \quad (4)$$

onde R^2 e R^2_0 correspondem ao coeficiente de correlação quadrática entre os valores observados e preditos para o conjunto de teste com e sem intercepto, respectivamente.

Para evitar que amostras anômalas influenciassem de forma inadequada no desempenho dos modelos construídos, realizou-se sua detecção e retirada através da análise dos seus leverages (Equação 5) e Resíduos de Student (Equação 6) com limite de $\pm 2,5$:

$$h = \frac{1}{n} + \frac{(x_0 - \bar{X})^2}{\sum(x - \bar{X})^2} \quad h_{critico} = \frac{3k}{n} \quad (5)$$

$$res_y = \frac{\sum(y - y_i)^2 - \frac{(y - y_i)^2}{l - k}}{n - p - 1} \quad res_{student} = \frac{y - y_i}{\sqrt{res_y \cdot (l - h)}} \quad (6)$$

em que k (e p) é o número de parâmetros do modelo, n é o número de amostras, h é o leverage, y_i é o i -ésimo elemento do vetor de respostas experimentais e \hat{y}_i é o i -ésimo elemento do vetor de valores estimados pelo modelo.

Todos os cálculos foram realizados usando o programa Chemoface versão 1.64 (NUNES et al., 2012).

4 RESULTADOS E DISCUSSÕES

4.1 Caracterizações sensorial e físico-química das frutas

Entre os parâmetros de qualidade das frutas a aparência e a cor da casca são os principais responsáveis pelas diferenças visuais entre as amostras. Contudo, as propriedades internas como o teor de SST e a firmeza da polpa são parâmetros importantes para determinação da maturação. Assim, as propriedades físicas e físico-químicas foram analisadas de acordo com cada estágio de maturação (TABELAS 3 e 4).

Tabela 3 - Características sensoriais e físico-químicas das bananas em cada estágio de maturação.

Banana						
Imagem	Estágio de maturação	Doçura ideal	Firmeza ideal	Aceitação Global	SST (°Brix)	Firmeza (N)
	I	2,95	5,16	4,34	12,68	4,87
	II	3,78	4,74	5,29	16,42	3,53
	III	4,03	4,41	5,48	18,13	3,27
	IV	4,06	4,72	5,94	18,17	3,38
	V	4,45	4,48	6,49	19,67	2,72
	VI	5,10	4,27	6,12	20,88	2,57
	VII	5,41	3,94	6,37	24,32	2,51

Fonte: Da autora (2021).

Os frutos, durante seu desenvolvimento, passam por diferentes mudanças fisiológicas, devido às sucessivas divisões e crescimento celulares seguido da pré-maturação, maturação, amadurecimento e finalmente a senescência. Nesse processo ocorrem muitas mudanças físicas e físico-químicas, fazendo com que os frutos adquiram a qualidade desejável (EVAGELISTA, 1999).

Tabela 4 - Características sensoriais e físico-químicas dos mamões em cada estágio de maturação.

Mamão						
Imagem	Estágio de maturação	Doçura ideal	Firmeza ideal	Aceitação Global	SST (°Brix)	Firmeza (N)
	I	2,99	8,14	3,92	3,03	110,92
	II	3,05	6,68	4,04	3,93	91,53
	III	4,31	6,00	6,76	5,87	69,40
	IV	4,73	4,89	7,22	6,80	9,00
	V	4,54	4,84	6,19	5,73	6,70

Fonte: Da autora (2021).

Visualmente, como esperado, foi observada uma variação de cor na casca das frutas com o avanço do amadurecimento (TABELAS 3 e 4). As bananas, predominantemente verdes no estágio I, foram adquirindo pigmentação amarelada, e, a partir do estágio V, passaram a ter pontos amarronzados. Os mamões, praticamente verdes nos estágios I e II, passaram a adquirir mais coloração alaranjada até sua predominância nos estágios finais. Os principais pigmentos presentes em produtos vegetais são clorofilas, carotenóides e antocianinas. Esses pigmentos sofrem processos degradativos, fazendo com que a coloração presente nas frutas sofra modificações. Durante a maturação, os cromoplastos presentes nos frutos se desintegram, ocorrendo assim a degradação da clorofila em decorrência da ativação da enzima clorofilase e agentes oxidantes, havendo uma perda na intensidade do verde, modificando para um verde claro ou mesmo a perda total. Conseqüentemente, os carotenóides presentes nos tecidos tornam-se visíveis. Com a biodegradação dos carotenóides os compostos voláteis são formados contribuindo para aroma e sabor das frutas. A coloração amarronzada ou mesmo o escurecimento dos tecidos presentes em algumas frutas se dá pela degradação das antocianinas e antoxantinas (CHITARRA; CHITARRA, 2005).

É esperado que a doçura tenda a um aumento na medida em que o processo de maturação ocorre. Devido à formação de carboidratos, como sacarose, glicose e frutose, há um aumento no teor SST durante o amadurecimento dos frutos. Esse aumento se dá pela degradação do amido pela enzima amilase (NAMBI; THANGAVEL; JESUDAS, 2015). Para a banana (TABELA 3) este aumento ocorreu gradativamente, ou seja, a doçura passou de 2,95 no estágio considerado verde para 5,41 no seu último estágio (considerado como passada).

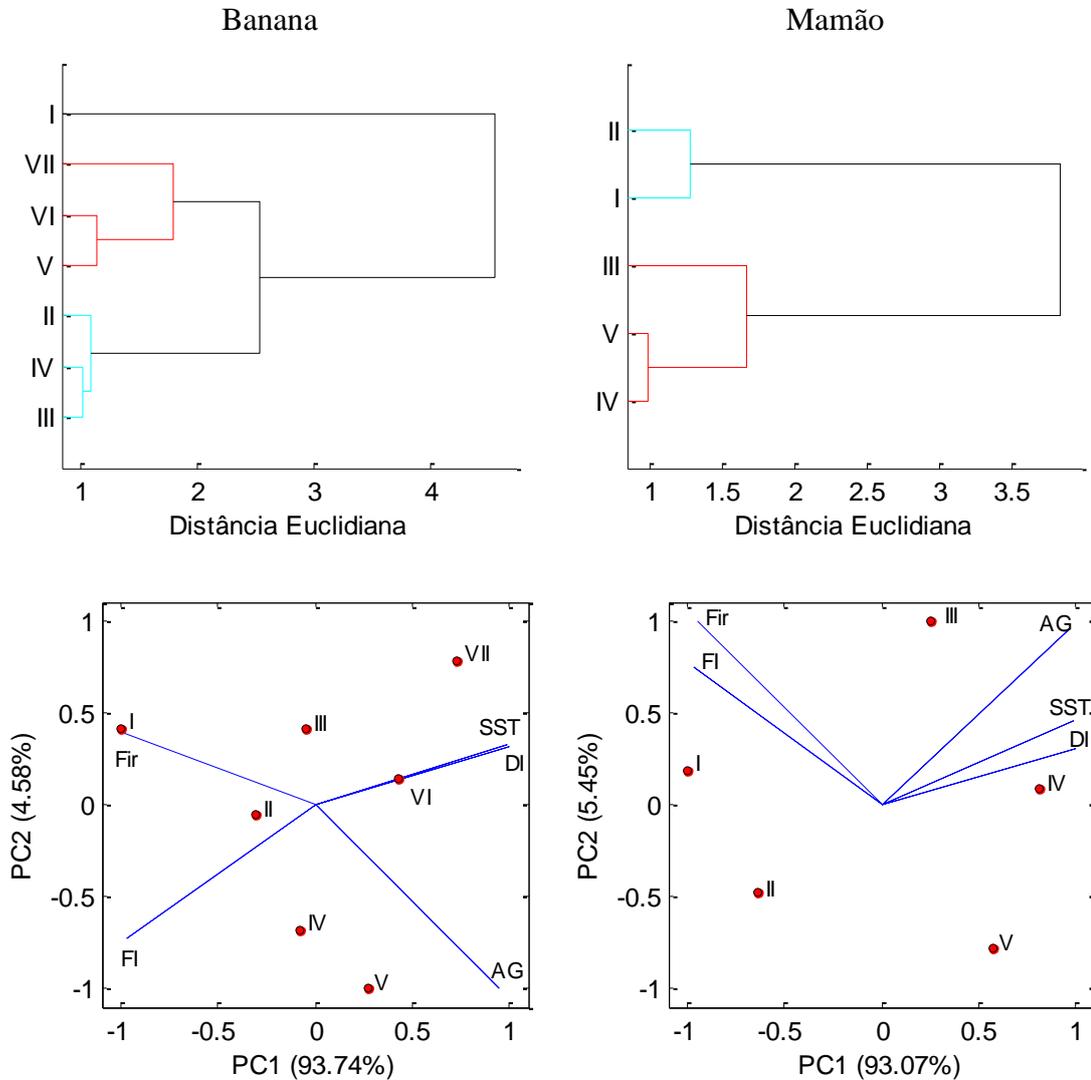
Para o mamão (TABELA 4), o aumento ocorreu gradativamente até o estágio IV. Segundo Chitarra e Chitarra (2005), o valor de SST alcançado para diversas variedades de frutas aumenta com o estágio de maturação. Isso foi constatado nas bananas, para as quais o teor de SST variou de 12,68 a 24,32 °Brix, e nos mamões, variando de 3,03 a 5,73 °Brix entre o primeiro e o último estágio de maturação.

Sabe-se que a firmeza diminui durante o processo de maturação devido às mudanças no conteúdo de água e transformação da pectina, levando a uma perda da integridade da parede celular e mudanças na estrutura do tecido (CYBULSKA et al., 2012; ZUDE et al., 2006). Considerando a firmeza obtida sensorialmente e instrumentalmente, esta diminuição foi constatada para ambas as frutas. O ideal de firmeza e a firmeza instrumental passou de 8,14 e 110,92 N no primeiro estágio para 4,84 e 6,70 N no último estágio dos mamões respectivamente. Nas bananas, a variação do ideal de firmeza e da firmeza instrumental entre o primeiro e o último estágio foi menos pronunciada, passando de 5,16 e 4,87 N para 3,94 e 2,51 N, respectivamente.

Para aceitação global, é esperado que os consumidores iniciem com uma aceitação baixa e vá aumentando à medida que sofre um aumento na doçura e uma perda de firmeza ao longo do processo de amadurecimento. A aceitação das bananas iniciou com uma média de 4,34, passando por um aumento e atingindo um máximo de 6,49 no estágio V, a partir do qual não sofreu grandes variações. O primeiro estágio do mamão teve uma aceitação inicial de 3,92, passando por um aumento até atingir 7,22 no estágio IV, voltando a diminuir para 6,19 no estágio V. Neste último estágio a fruta já é considerada passada, pois já deve estar no seu período de senescência, passando por seu envelhecimento e perdendo assim alguns padrões de qualidade.

As médias das características sensoriais e instrumentais (Tabelas 3 e 4) foram analisadas por HCA e PCA (Figura 4). As bananas tiveram o estágio I nitidamente distinto dos demais, tendo alguma similaridade nos estágios intermediários (II, III e IV) e apresentando o estágio V similar aos VI e VII. Os estágios iniciais (I e II) dos mamões se mostraram similares, com o estágio III tendo alguma similaridade com os estágios finais (IV e V). Para as duas frutas, firmeza (sensorial e instrumental) mais elevada prevaleceu nos estágios iniciais, enquanto que a doçura ideal, o teor de SST e a aceitação global caracterizaram os estágios finais. A aceitação global tendeu a ser maior no estágio V da banana e nos estágios III e IV do mamão.

Figura 4 - Dendrograma obtido por HCA e gráfico de escores e pesos da PCA para as características sensoriais (doçura ideal – DI, firmeza ideal – FI e aceitação global - AG) e instrumentais (SST e firmeza - Fir) das bananas e dos mamões nos diferentes estágios de maturação.



Fonte: Da Autora (2021).

4.2 Modelos preditivos dos parâmetros sensoriais

Nesta etapa do trabalho, informações extraídas das imagens digitais das frutas obtidas com câmera de smartphone foram usadas como descritores em modelos preditivos dos parâmetros sensoriais ideais de doçura, ideias de firmeza e aceitação global conforme descritores e métodos de regressão apresentados na Tabela 2.

Tabela 5 - Parâmetros de desempenho dos modelos preditivos de ideal de doçura das frutas.

		Banana			Mamão		
		Média RGB	Perfil RGB	% de cor	Média RGB	Perfil RGB	% de Cor
Calibração	RMS	0,14	0,13	0,33	0,19	0,09	0,24
	E						
	R ²	0,95	0,97	0,79	0,94	0,98	0,89
	n	94	94	99	57	48	54
Randomização de y	RMS	0,59	0,49	0,60	0,72	0,44	0,70
	E						
	R ²	0,05	0,56	0,05	0,08	0,9	0,1
	R ^{2p}	0,92	0,63	0,78	0,91	0,33	0,85
Validação cruzada	RMS	0,13	0,25	0,27	0,17	0,39	0,22
	E						
	R ²	0,95	0,88	0,81	0,95	0,92	0,91
Teste	RMS	0,10	0,21	0,28	0,17	0,37	0,19
	E						
	R ²	0,96	0,89	0,72	0,94	0,96	0,94
	R ^{2m}	0,87	0,81	0,35	0,91	0,82	0,88
	n	23	23	24	14	12	13

n: total – outliers

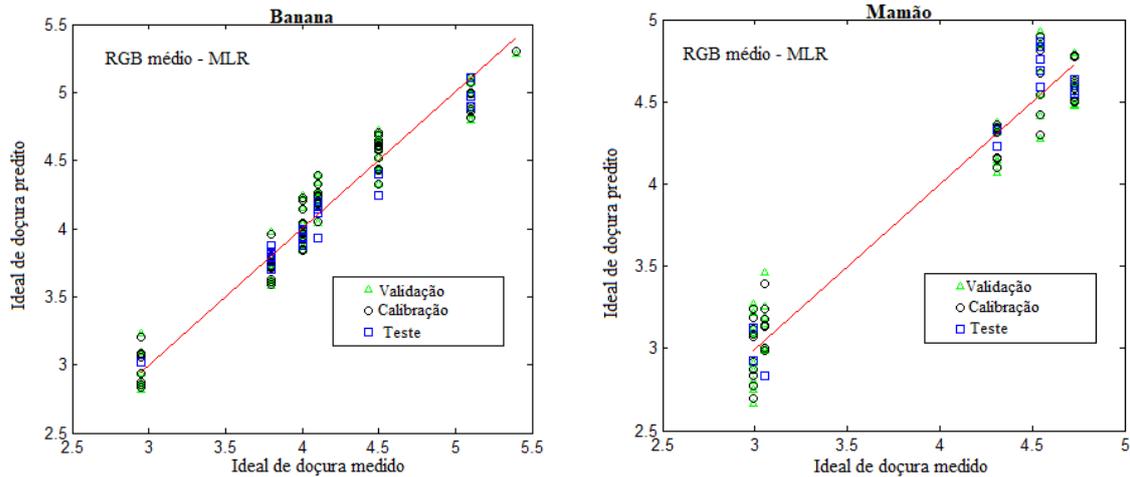
Fonte: Da autora (2021).

Para o ideal de doçura, os valores de R^2 alcançados na etapa da calibração para as três abordagens foram maiores que 0,9, com exceção da abordagem baseada na % de cor, para qual o R^2 ficou um pouco abaixo de 0,8 para banana e de 0,9 para o mamão. Para as duas frutas, a abordagem baseada no perfil RGB teve o menor RMSE. O teste de randomização de Y atestou a robustez dos modelos, com R^2 menores e RMSE maiores que os de calibração, além de R^{2p} maiores que 0,5 (MITRA; SAHA; ROY, 2010). Entretanto, apesar de o modelo baseado no perfil RGB dos mamões ter apresentado elevado RMSE, o R^2 foi alto e o R^{2p} foi menor que 0,5, indicando possível ajuste ao acaso. Os valores de RMSE e R^2 na etapa de validação cruzada foram próximos aos obtidos na etapa de calibração, com exceção do modelo baseado na % e cor dos mamões, cujo RMSE foi mais elevado.

Na etapa de validação externa (teste), verificou-se que tanto para a banana quanto para o mamão, o modelo que apresentou melhor capacidade preditiva de amostras diferentes daquelas usadas na calibração foi aquele baseado no RGB médio, com R^2 de 0,96 e 0,94 e RMSE de 0,10 e 0,17 para banana e mamão respectivamente. Além disso, esses modelos

tiveram R^2m menor que 0,5, atestando uma boa congruência entre os valores medidos e preditos para o grupo teste, o que pode ser constatado na Figura 5.

Figura 5 - Representação gráfica dos valores medidos e preditos de ideal de doçura das frutas com base nos modelos que apresentaram menor RMSE na etapa de teste.



Fonte: Da Autora (2021).

Os modelos para predição do ideal de firmeza baseados no perfil RGB tiveram os melhores desempenhos na etapa de calibração, com $R^2 > 0,9$ e os menores RMSE. Entretanto, o R^2 da etapa de randomização de Y do modelo baseado no perfil RGB para mamão foi alto ($>0,8$) e o R^2p foi menor que 0,5 (0,38), indicando um possível ajuste ao acaso. Na etapa de validação cruzada, os modelos tiveram R^2 e RMSE próximos aos da etapa de calibração, com exceção do modelo baseado no RGB médio dos mamões, que teve R^2 de 0,3. Mesmo assim, este modelo teve capacidade preditiva de ideal de doçura dos mamões relativamente boa para amostras externas ao grupo de calibração (grupo teste), tendo o menor RMSE entre as três abordagens, R^2 de 0,95 e boa congruência entre os valores medidos e preditos ($R^2m > 0,5$) conforme Figura 5. Para as bananas, o modelo baseado no perfil RGB teve o menor RMSE e o maior R^2 entre as três abordagens, e, embora o R^2m tenha ficado próximo de 0,5, a comparação gráfica mostrou alguma congruência entre os valores medidos e preditos (FIGURA 6).

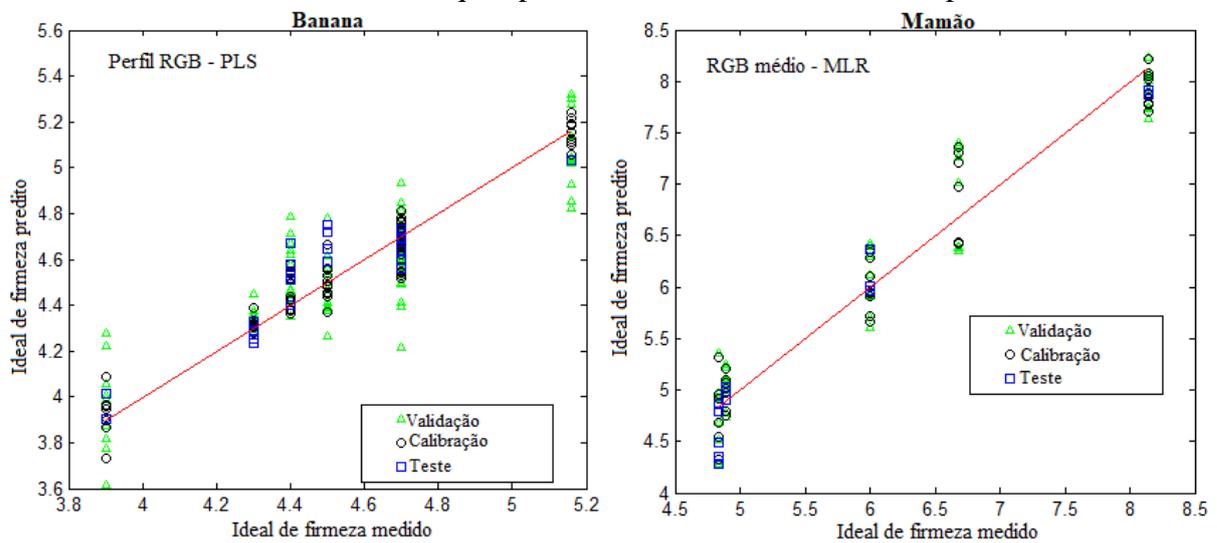
Tabela 6 - Parâmetros de desempenho dos modelos preditivos de ideal de firmeza das frutas.

		Banana			Mamão		
		RGB médio	Perfil RGB	% de cor	RGB médio	Perfil RGB	% de Cor
Calibração	RMSE	0,17	0,09	0,18	0,34	0,19	0,53
	R ²	0,73	0,93	0,57	0,93	0,97	0,81
	n	109	94	100	55	48	55
Randomização de y	RMSE	0,32	0,24	0,28	1,23	0,50	1,17
	R ²	0,45	0,56	0,04	0,69	0,82	0,06
	R ² p	0,73	0,58	0,60	0,91	0,38	0,82
Validação cruzada	RMSE	0,16	0,16	0,17	0,94	0,43	0,47
	R ²	0,76	0,78	0,62	0,30	0,88	0,85
Teste	RMSE	0,16	0,13	0,20	0,27	0,30	0,44
	R ² p	0,60	0,81	0,43	0,95	0,96	0,92
	R ² m	0,40	0,45	0	0,95	0,77	0,75
	n	27	23	25	13	12	13

n: total – outliers

Fonte: Da autora (2021).

Figura 6 - Representação gráfica dos valores medidos e preditos de ideal de firmeza das frutas com base nos modelos que apresentaram menor RMSE na etapa de teste.



Fonte: Da Autora (2021).

Os modelos para predição da aceitação global também tiveram desempenhos distintos dependendo da fruta e da abordagem de obtenção de dados das imagens (TABELA 7). Para banana e mamão, o modelo baseado no perfil RGB teve o melhor desempenho na etapa de calibração, com $R^2 > 0,95$ e o menor RMSE entre as três abordagens. Entretanto, apesar de um bom desempenho na validação cruzada (com R^2 de aproximadamente 0,9), o elevado R^2 (0,88) para randomização de Y e

o R^2p menor que 0,5 indicaram um possível ajuste ao acaso ao usar o perfil RGB como descritor da aceitação global dos mamões. De qualquer maneira, a abordagem baseada no RGB médio produziu modelos com melhor capacidade preditiva de amostras externas ao grupo de calibração (grupo teste), tendo $R^2 > 0,9$ e menor RMSE entre as três abordagens, além de boa congruência ($R^2m > 0,5$) entre valores medidos e preditos (FIGURA 7).

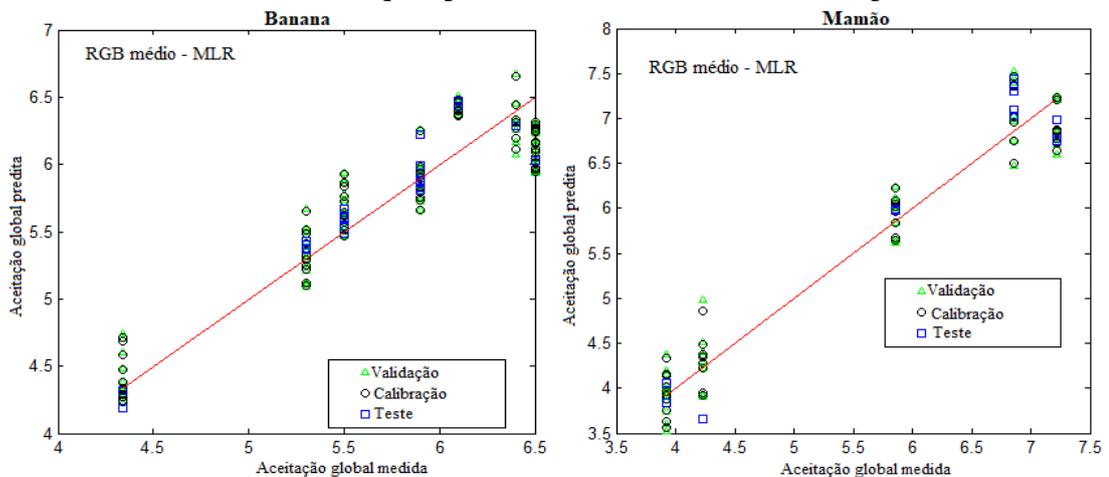
Tabela 7 - Parâmetros de desempenho dos modelos preditivos da aceitação global das frutas.

		Banana			Mamão		
		RGB médio	Perfil RGB	% de cor	RGB médio	Perfil RGB	% de cor
Calibração	RMSE	0,26	0,14	0,32	0,33	0,14	0,42
	R^2	0,86	0,96	0,61	0,94	0,99	0,89
	n	109	94	98	57	48	54
Randomização de y	RMSE	0,68	0,48	0,50	1,30	0,44	1,24
	R^2	0,04	0,52	0,057	0,07	0,88	0,10
	R^2p	0,85	0,65	0,62	0,91	0,33	0,86
Validação cruzada	RMSE	0,25	0,23	0,30	0,30	0,39	0,39
	R^2	0,87	0,88	0,65	0,95	0,92	0,91
Teste	RMSE	0,18	0,20	0,22	0,35	0,37	0,36
	R^2	0,90	0,84	0,68	0,93	0,95	0,94
	R^2m	0,89	0,68	0,34	0,89	0,82	0,85
	n	27	23	24	14	12	13

n : total – outliers

Fonte: Da autora (2021).

Figura 7 - Representação gráfica dos valores medidos e preditos da aceitação global das frutas com base nos modelos que apresentaram menor RMSE na etapa de teste.



Fonte: Da Autora (2021).

Ribeiro et al. (2021) usaram dados físicos e físico-químicos de morangos para prever a aceitação do consumidor usando calibração por floresta aleatória. Para o parâmetro doçura ideal, os autores obtiveram R^2 de 0,86 e RMSE de 0,16 na fase de treinamento e R^2 de 0,89 e RMSE 0,17 na validação. Desse modo, os valores de R^2 e RMSE são próximos aos obtidos neste estudo.

Cejudo-Bastante et al. (2021) avaliaram o uso de imagens digitais com o intuito de estabelecer o nível de maturidade de sementes de uva com base nas suas características sensoriais (cor, dureza, amargor e adstringência) e instrumental (firmeza). O uso de imagens digitais permitiu a caracterização precisa do perfil sensorial e das propriedades físicas, havendo uma boa diferenciação das sementes ao longo do processo de maturação e permitindo classificar as sementes em quatro estágios.

Koyama et al. (2021) usaram modelo de aprendizado de máquina e imagens digitais obtidas com smartphone para predição de avaliação sensorial do frescor de espinafre. Modelos baseados em Máquinas de Vetor de Suporte e em Redes Neurais Artificiais classificaram com sucesso as amostras de espinafre com acurácia geral de 70% em quatro classes, 77% em três classes e 84% em duas classes, o que foi semelhante ao das avaliações do painel sensorial.

Considerando a média da faixa calibrada, os erros relativos dos modelos com menor RMSE para o grupo teste foram de 2,39 e 4,40 % para doçura ideal, 2,86 e 4,16 % para firmeza ideal e 3,32 e 6,28 % para aceitação global para bananas e mamões respectivamente.

Em geral, descritores baseados na média de RGB das imagens das frutas produziram modelos com melhores capacidades preditivas de suas características sensoriais, ou seja, a coloração média de toda a fruta pareceu estar mais bem correlacionada com seus aspectos sensoriais do que a informação de cor contida em cada ponto (pixel) ou a proporção de cada cor exibida pela fruta. Isso pode ter ocorrido devido à heterogeneidade na distribuição das cores pela superfície da casca de cada fruta, o que é mais facilmente captado no sequenciamento da imagem pixel a pixel (perfil RGB) ou ao obter a proporção de cada cor (% de cor) do que ao considerar sua média de RGB.

4.3 Modelos preditivos dos parâmetros instrumentais

Nesta etapa, foram construídos modelos para predição do teor de SST e da firmeza (N) usando informações obtidas das imagens digitais das frutas usando as mesmas abordagens e métodos de regressão usados anteriormente.

Para predição do teor de SST, modelo baseado no perfil RGB teve melhor desempenho na etapa de calibração para ambas as frutas, com R^2 acima de 0,9 (TABELA 8). Entretanto, assim como ocorrido em modelos para predição de características sensoriais, o teste de randomização de Y indicou um possível ajuste a acaso ($R^2p < 0,5$) para o mamão. Na validação cruzada, os valores de RMSE e R^2 não sofreram grandes variações quando comparados com os valores obtidos na calibração. Os modelos mantiveram desempenho equivalente à calibração na etapa de validação externa (grupo teste). Para banana, o modelo baseado no RGB médio teve o menor RMSE (1,08 °Brix) e $R^2 > 0,8$, Apesar de o modelo baseado no perfil RGB ter tido o menor RMSE (0,48 °Brix) para mamão, houve a indicação de possível ajuste ao acaso como discutido anteriormente. Então, o modelo com melhor desempenho para predição do teor de SST nos mamões passou a ser aquele baseado no RGB médio, com RMSE de 0,63 °Brix e R^2 de 0,76 para o grupo teste. Ainda considerando o grupo teste, os valores medidos e preditos tiveram uma boa congruência ($R^2m > 0,5$) conforme Figura 8.

Tabela 8 - Parâmetros de desempenho dos modelos preditivos dos SST das frutas.

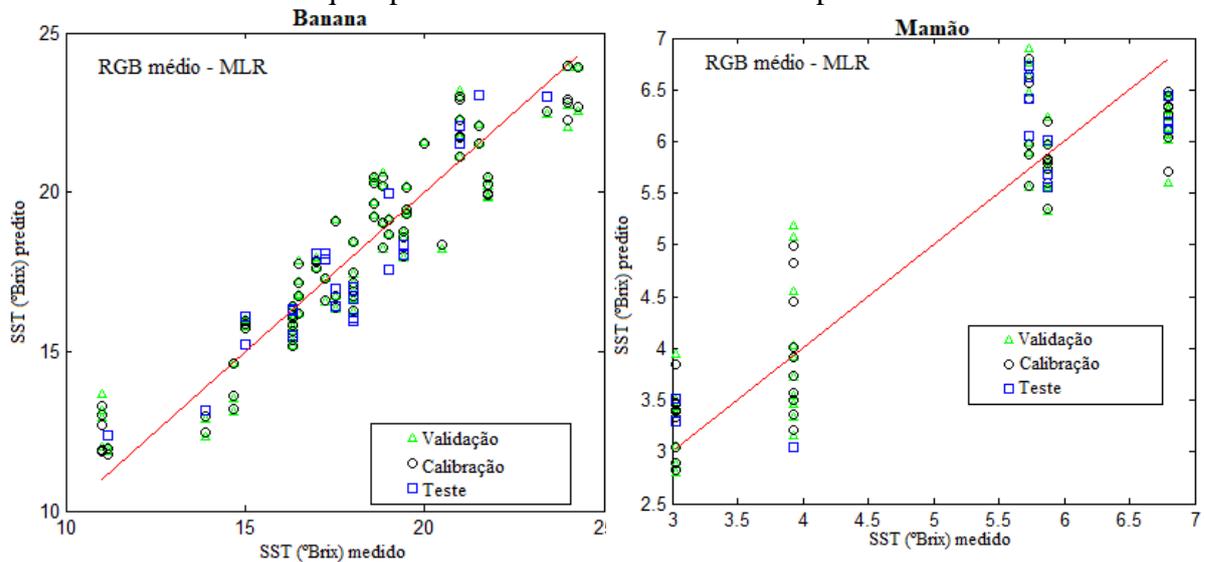
		Banana			Mamão		
		RGB médio	Perfil RGB	% de cor	RGB médio	Perfil RGB	% de Cor
Calibração	RMS E	1,18	0,98	1,70	0,58	0,24	0,79
	R^2	0,88	0,92	0,62	0,83	0,97	0,69
	n	103	94	97	59	48	55
	RMS E	3,31	2,43	2,71	1,37	0,57	1,33
Randomização de y	R^2	0,33	0,53	0,04	0,62	0,82	0,08
	R^2p	0,87	0,60	0,64	0,83	0,38	0,71
	RMS E	1,11	1,80	1,61	0,52	0,48	0,69
Validação cruzada	R^2	0,89	0,73	0,66	0,86	0,88	0,75
	RMS E	1,08	1,77	1,60	0,63	0,48	0,66
Teste	R^2	0,83	0,64	0,57	0,76	0,92	0,84
	R^2m	0,81	0,27	0	0,69	0,68	0,70
	n	25	23	24	14	12	13

n: total – outliers, RMSE em °Brix

Fonte: Da autora (2021).

Ma et al. (2021) desenvolveram um trabalho com objetivo de oferecer uma abordagem não destrutiva e rápida para determinar o teor de SST em kiwis. Para digitalizar as superfícies inteiras dos kiwis foi utilizada uma câmera de imagem hiperespectral no infravermelho próximo. Os comprimentos de ondas na faixa de 1002-2300 nm foram extraídos para a construção do modelo de calibração de SST por PLS. O modelo apresentou R^2 de 0,76 e RMSE de 0,6 na etapa calibração R^2 de 0,74 e RMSE de 0,7 na validação cruzada, concluindo que o método estudado é uma proposta promissora para mapeamento não destrutivo de SST em kiwis. ElMasry et al. (2007) usaram imagens hiperespectrais para estimar alguns atributos de qualidade do morango, dentre eles o teor de SST. O modelo apresentou R^2 de 0,80 e erro médio padrão de 0,22 para o conjunto de treinamento e R^2 de 0,80 e erro médio padrão de 0,21 para validação. Portanto, os resultados do presente trabalho, baseado em imagens obtidas com smartphone, foram comparáveis àqueles obtidos por meio de técnicas mais sofisticadas e de maior custo, como as câmeras hiperespectrais, constituindo uma ferramenta rápida e de baixo custo com potencial para determinação do teor de SST em frutas.

Figura 8 - Representação gráfica dos valores medidos e preditos de SST das frutas com base nos modelos que apresentaram menor RMSE na etapa de teste.



Fonte: Da autora (2021).

As três abordagens foram capazes de gerar modelos válidos para predição da firmeza das bananas e dos mamões (TABELA 9), com exceção daquela baseada no perfil RGB para os mamões, a qual teve indícios de ajuste ao acaso de acordo com o teste de randomização de Y ($R^2 p < 0,5$). Este modelo também apresentou RMSE de validação cruzada consideravelmente maior que o de calibração, reforçando sua baixa robustez. Nos demais

casos, o R^2 na etapa de calibração variou de 0,68 a 0,98 e os valores de R^2 e RMSE de validação cruzada foram próximos aos de calibração. Na validação externa (grupo teste), o modelo baseado na média de RGB teve o menor RMSE na predição da firmeza das bananas, enquanto que o modelo baseado na proporção de cores da casca (% de cor) teve o menor RMSE na predição da firmeza dos mamões. Além disso, uma boa congruência ($R^2_m > 0,5$) entre os valores medidos e preditos por esses modelos foi verificada (FIGURA 9).

Considerando a média da faixa calibrada, os erros relativos dos modelos com menor RMSE para o grupo teste foram de 5,84 e 12,82 % para teor de SST e 5,42 e 13,31 % para firmeza para bananas e mamões, respectivamente.

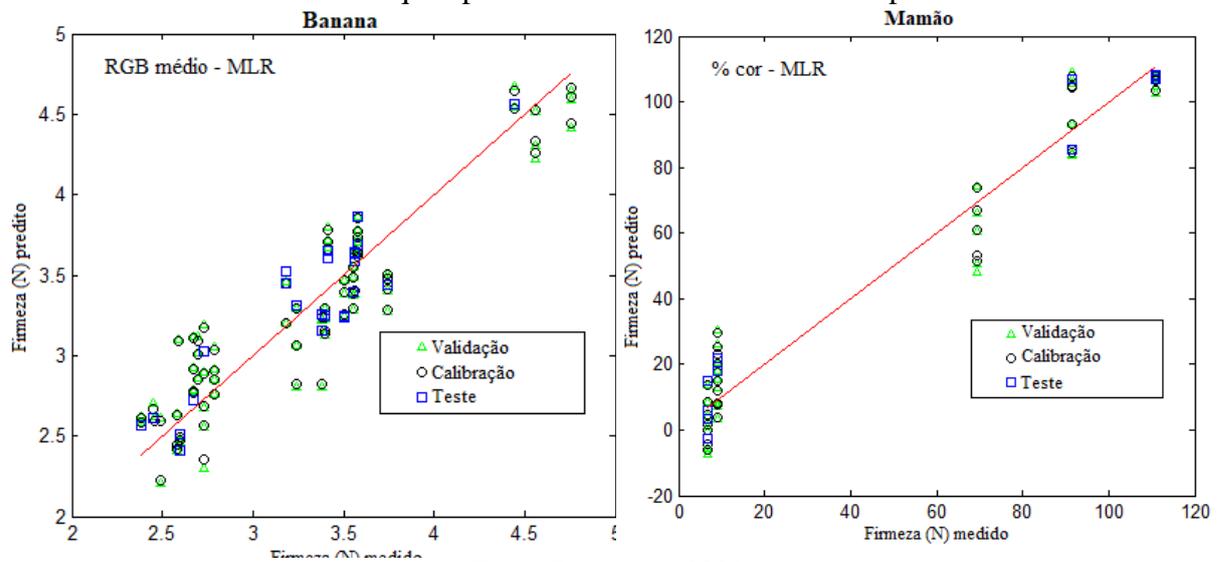
Tabela 9 - Parâmetros de desempenho dos modelos preditivos da firmeza em frutas.

		Banana			Mamão		
		RGB médio	Perfil RGB	% de cor	RGB médio	Perfil RGB	% de cor
Calibração	RMSE	0,24	0,35	0,26	11,92	6,28	10,18
	R^2	0,86	0,80	0,68	0,92	0,98	0,95
	n	97	94	91	57	48	49
Randomização de y	RMSE	0,62	0,66	0,45	41,21	16,96	42,14
	R^2	0,042	0,30	0,04	0,63	0,82	0,10
	R^2_p	0,85	0,63	0,69	0,90	0,39	0,90
Validação cruzada	RMSE	0,23	0,47	0,24	10,89	15,02	9,18
	R^2	0,87	0,64	0,71	0,93	0,88	0,96
Teste	RMSE	0,20	0,42	0,35	10,51	12,49	7,83
	R^2	0,84	0,72	0,41	0,94	0,93	0,97
	R^2_m	0,78	0,28	0	0,93	0,74	0,93
	n	24	23	22	14	12	12

n: total – outliers, RMSE em N

Fonte: Da autora (2021).

Figura 9 - Representação gráfica dos valores medidos e preditos da firmeza das frutas com base nos modelos que apresentaram menor RMSE na etapa de teste.



Fonte: Da autora (2021).

Xie et al. (2018) determinaram a cor e a firmeza de bananas usando um método de seleção de comprimentos de onda de imagens hiperespectrais. Para firmeza, o R^2 de calibração foi de 0,759. Para validação cruzada, os valores de R^2 e RMSE foram de 0,719 e 3,181, respectivamente. Para predição (grupo teste), o R^2 foi de 0,736 com RMSE de 3,084 N. Em outro estudo (LEIVA-VALENZUELA et al., 2013), imagens hiperespectrais foram usadas para prever a firmeza de mirtilos. Na análise de quatro conjuntos de dados, os valores de R^2 variaram de 0,88 e 0,92 na etapa de calibração, enquanto os valores de R^2 ficaram entre 0,83 e 0,87 na etapa de validação externa. Logo, o uso de imagens digitais obtidas com smartphone foi capaz de fornecer modelos com desempenho equivalente aos relatados em outros estudos que empregaram técnicas mais sofisticadas e de custo mais elevado, tais como imagens hiperespectrais.

5 CONCLUSÃO

Informações extraídas de imagens digitais obtidas com smartphones foram eficientes como descritores em modelos preditivos de parâmetros sensoriais e instrumentais em bananas e mamões.

Uma vez que as respostas sensoriais para doçura, firmeza e aceitação global foram obtidas por meio de consumidores não treinados, sua alta variância pode limitar a qualidade dos modelos obtidos, da mesma forma que a variabilidade natural da qualidade entre as frutas amostradas. Mesmo assim, considerando a média da faixa calibrada de cada parâmetro, os erros relativos dos melhores modelos obtidos podem ser considerados aceitáveis para este tipo de aplicação.

Entre as três abordagens para extração de informação das imagens digitais, quais sejam a média de RGB da imagem, a quantidade de pixels em cada valor de RGB e a porcentagem das diferentes cores exibidas pela fruta, a primeira foi a que teve, em geral, um melhor desempenho na predição dos parâmetros sensoriais e instrumentais, sobretudo das bananas.

Embora a abordagem baseada na proporção das cores da fruta (% de cor) tenha tido desempenho aceitável, mas inferior às demais, é importante salientar que este tipo de obtenção de informação de imagem deve ser menos susceptível às distorções associadas às condições analíticas, tais como modelo de celular e tipo de iluminação, e por isso seu uso não deve ser desconsiderado.

REFERÊNCIAS

- ABDI, H. Partial least squares regression and projection on latent structure regression (PLS Regression). **Wires Computational Statistics**, v. 2, p. 97-106, 2010.
- ABROUGUI, K.; GABSI, K.; MERCATORIS, B.; KHEMIS, C.; AMAMI, R.; CHEHAIBI, S, Prediction of organic potato yield using tillage systems and soil properties by artificial neural network (ANN) and multiple regressions (MLR). **Soil and Tillage Research**, v. 190, p. 202-208, 2019.
- AGNOLETTI, B. Z.; FOLLI, G. S.; PEREIRA, L. L.; PINHEIRO, P. F.; GUARÇONI, R. C.; OLIVEIRA, E. C. DA S.; FILGUEIRAS, P. R. Multivariate calibration applied to study of volatile predictions of arabica coffee quality. **Food Chemistry**, v. 367, 2022.
- ALEXANDER, L.; GRIERSON, D. Ethylene biosynthesis and action in tomato: a model for climacteric fruit ripening. **Journal of Experimental Botany**, v. 53, n. 377, p. 2039-2055, 2002.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **Análise sensorial dos alimentos e bebidas: terminologia**, 1993.
- BAIANO, A., TERRACONE, C., PERI, G., ROMANIELLO, R. Application of hyper spectral imaging for prediction of physico-chemical and sensory characteristics of table grapes. **Computers and Electronics in Agriculture**, v. 87, p. 142–151, 2012.
- BAKSHI, A.; SHEMANSKY, J. M.; CHANG, C.; BINDER, B. M. History of research on the plant hormone ethylene. **Journal of Plant Growth Regulation**, v.34, p. 809–827, 2015.
- BAPAT, V. A.; TRIVEDI, P. K.; GHOSH, A.; SANE, V. A.; GANAPATHI, T. R.; NATH, P. Ripening of fleshy fruit: molecular insight and the role of ethylene. **Biotechnology Advances**, v. 28, p. 94–107, 2010.
- BAZAME, H. C.; MOLIN, J. P.; ALTHOFF, D.; MARTELLO, M. Detection, classification, and mapping of coffee fruits during harvest with computer vision. **Computers and Electronics in Agriculture**, v. 183, p. 106066, 2021.
- BEULLENS, K.; KIRSANOV, D.; IRUDAYARAJ, J.; RUDNITSKAYA, A.; LEGIN, A.; NICOLAÏ, B. M.; LAM-MERTYN, J. The electronic tongue and ATR–FTIR for rapid detection of sugars and acids in tomatoes. **Sensors and Actuators B: Chemical**, v. 116, p. 107–115, 2006.
- BIALE, J. B.; YOUNG, R. E.; OLMSTEAD, A. J. Fruit respiration and Ethylene Production. **Plant Physiology**, v. 29, n. 2, p. 168-174, 1954.
- BOURNE, M. C. **Food Texture and Viscosity**, 1st ed. New York: Academic Press, 1982.
- CEJUDO-BASTANTE, M. J.; RODRÍGUEZ-PILIDO, F. J.; HEREDIA, F. J.; GONZÁLEZ-MIRET, M. L. Assessment of sensory and texture profiles of grape seeds ate real maturity stages using image analysis. **The Application of Computer Vision in Food Analysis**, v. 10 n. 5, p. 1098, 2021.

CHAUVIN, M. A.; ROSS, C. F.; PITTS, M.; KUPFERMAN, E.; SWANSON, B. Relationship between instrumental and sensory determination of apple and pear texture. **Journal Food Quality**, v. 33, p. 181–198, 2010.

CHEN, W.; YAO, Y.; CHEN, T.; SHEN, W.; TANG, S.; LEE, H. K. Applications of smartphone-based spectroscopy to biosample analysis: A review. **Biosensors and Bioelectronics**, v. 172, p. 112788, 2021.

CHITARRA, M. I.; CHITARRA, A. B. Pós-Colheita de Frutas e Hortaliças. Fisiologia e Manuseio. Ed. UFLA, 2ª ed., p. 783, 2005.

CHOPE, G. A., TERRY, L. A., WHITE, P. J. Effect of controlled atmosphere storage on abscisic acid concentration and other biochemical attributes of onion bulbs. **Postharvest Biology and Technology**, v 39, p. 233–242, 2006.

CLYDESDALE, F. M; FRANCIS, F, J. Chlorophylls, in: Principles of Food Science, Part I, **Food Chemistry**, v. 1, 1976.

COLARIC, M.; VEBERIC, R.; STAMPAR, F.; HUDINA, M. Evaluation of peach and nectarine fruit quality and correlations between sensory and chemical attributes. **Journal of the Science of Food and Agriculture**, v. 85, p. 2611–2616, 2005.

CONTI, C.; GUARINO, M.; BACENETTI, J. Measurements techniques and models to assess odor annoyance: A review. **Environment International**, v. 134, p. 105261, 2020.

COSTA, G. B.; FERNANDES, D. D. S.; ALMEIDA, V. E.; ARAÚJO, T. S. P.; MELO, J. P.; DINIZ, P. H. G. D.; VÉRAS, G. Digital image-based classification of biodiesel. **Talanta**, v. 139, p. 50-55, 2015.

COSTA, R. C. **Determinação de parâmetros (sólidos solúveis, pH e acidez titulavel) em ameixas intactas usando espectroscopia no infravermelho e seleção de comprimento de onda**, Universidade Federal do Rio Grande do Norte, 2013.

CORRÊA, S. C.; PINHEIRO, A. C. M.; SIQUEIRA, H. E.; CARVALHO, E. M.; NUNES, C. A.; DE BARROS VILAS BOAS, E. V. Prediction of the sensory acceptance of fruits by physical and physical–chemical parameters using multivariate models. **LWT-Food Science Technology**, v. 59, p. 666–672, 2014.

CRUZ, A, G.; CADENA, R. S.; FARIA, J. A. F.; OLIVEIRA, C. A. F.; CAVALCANTI, R. N.; BONA, E.; BOLINI, H. M. A.; SILVA, M. A. A. P. Consumer acceptability and purchase intent of probiotic yoghurt with added glucose oxidase using sensometrics, artificial neural networks and logistic regression, **International Journal of Dairy Technology**, v. 64, p. 549-556, 2011.

CUBERO, S.; ALBERT, F.; PRATS-MOLTALBÁN, J, M.; FERNÁNDEZ-PACHECO, D. G.; BLASCO, J.; ALEIXOS, N. Application for the estimation of the standard citrus colour index (CCI) using image processing in mobile devices. **Biosystems Engineering**, v. 167, p. 63-74, 2018.

- CYBULSKA, J., PIECZYWEK, P. M., ZDUNEK, A. The effect of Ca^{2+} and cellulase structure on apple firmness and acoustic emission. **European Food Research and Technology**, v. 235, n. 1, p. 119–128, 2012.
- DONG, J.J.; LI, Q.L.; YIN, H.; ZHONG, C.; HAO, J.G.; YANG, P.F.; TIAN, Y.H.; JIA, S.R. Predictive analysis of beer quality by correlating sensory evaluation with higher alcohol and ester production using multivariate statistics methods. **Food Chemistry**, v. 161, p. 376-382. 2014.
- DONGARE, M. L.; BUCHADE, P. B.; AWATADE, M. N.; SHALIGRAM, A. D. Mathematical modeling and simulation of refractive index-based Brix measurement system. **Optik**, v. 125, p. 946–949, 2014.
- DUBOST, N. J.; SHEWFELT, R. L.; EITENMILLER, R.R. Consumer acceptability, sensory and instrumental analysis of peanut soy spreads. **Journal of Food Quality**, v. 26, p. 27-42, 2003.
- ELGAMMAL, A.; MUANG, C.; HU, D. Skin Detection – A Short Tutorial, Departamento of Computer Science, Rutgers University. **Encyclopedia of Biometrics**, Springer- Verlag Berlin Heidelberg, 2009.
- EL-KEREAMY, A.; CHERVIN, C.; ROUSTAN, J-P.; CHEYNIER, V. Exogenous ethylene stimulates the long-term expression of genes related to anthocyanin biosynthesis in grape berries, **Physiologia Plantarum**, v. 119, p. 175–182, 2003.
- ELMASRY, G.; WANG, N.; ELSAYED, A.; NGADI, M. Hyperspectral imaging for nondestructive determination of some quality attributes for strawberry. **Journal of Food Engineering**, v. 81, p. 98-107, 2007.
- EL-MESERY, H. S.; MAO, H.; ABOMOHRRA, A. E-F. Applications of Non-destructive Technologies for Agricultural and Food Products Quality Inspection. **Sensors**, v. 19, p. 846, 2019.
- EVANGELISTA, R. M. **Qualidade de mangas “Tommy Atkins” armazenadas sob refrigeração e tratadas com cloreto de cálcio**. Tese (Doutorado em Ciências dos Alimentos) – Faculdade Federal de Lavras, p. 129, 1999.
- EYARKAI NAMBI, V.; THANGAVEL, K.; SHAHIR, S.; THIRUPATHI, V. Comparison of various RGB image features for nondestructive prediction of ripening quality of alphonso mangoes for easy adoptability in machine vision applications: a multivariate approach. **Journal Food Quality**, v. 39, p. 816–825, 2016.
- FAN, Y.; LI, J.; GUO, Y.; XIE, L.; ZHANG, G. Digital image colorimetry on smartphone for chemical analysis: A review. **Measurement**, v. 171, p. 108829, 2021.
- FAWOLE, O. A.; OPARA, U. L. Effects of maturity status on biochemical content, polyphenol composition and antioxidant capacity of pomegranate fruit arils (*cv. 'Bhagwa'*). **South African Journal of Botany**, v. 85, p. 23-31, 2013.

FERREIRA, S. L. C.; LEMOS, V. A.; CARVALHO, V. S.; SILVA, E. G. P.; QUEIROZ, F. S.; FELIX, C. S. A.; SILVA, D. L. F.; DOURADO, G. B.; OLIVEIRA, R. V. Multivariate optimization techniques in analytical chemistry – a overview. **Microchemical Journal**, v. 140, p. 176-182, 2018.

FIRDAUS, M. L.; ALWI, W.; TRINOVELDI, F.; RAHAYU, I.; RAHMIDAR, L., WARSITO, K. Determination of chromium and iron using digital image-bases colorimetry, **Procedia Environmental Sciences**, v. 20, p. 298-304, 2014.

FLORES, F.; EL-YAHYAOU, F.; DE BILLERBECK, G.; ROMOJARO, F.; LATCHÉ, A.; BOUZAYEN, M.; PECH, J. C.; AMBID, C. Role of ethylene in the biosynthetic pathway of aliphatic ester aroma volatiles in Charentais Cantaloupe melons, **Journal Experimental Botany**, v. 53, p. 201–206, 2002.

GENIZI, A., COHEN, E. The chemical composition and sensory flavour quality of ‘Mineola’ tangerines, II, Relationship between composition and sensory properties. **Journal Horticulturae Science**, v. 63, p. 179–182, 1988.

GILA, A.; BEJAOU, M. A.; BELTRÁN, G.; JIMÉNEZ, A. Rapid method based on computer vision to determine the moisture and insoluble impurities conten in virgin olive oils. **Food Control**, v. 113, p. 107210, 2020.

GIOVANNONI, J. J. Genetic Regulation of Fruit Development and Ripening. **The Plant Cell**, v. 16, p. 170-180, 2004.

GOISSER, S.; WITTMANN, S.; FERNANDES, M., MEMPEL, H.; ULRICH, C. Comparison of colorimeter and diferente portable food-scanners for non-destructive prediction of lycopene content in tomato fruit. **Postharvest Biology and Technology**, v. 167, p. 111232, 2020.

GUARRASI, V.; FARINA, V.; GERMANÀ, M. A.; SAN BIAGIO, P. L.; MAZZAGLIA, A. Fruit quality evaluation of four loquat cultivars grown in Sicily. **Acta Horticulture**, v. 887, p. 299–304, 2011.

GOEL, N.; SEHGAL, P. Fuzzy classification of pre-harvest for ripeness estimation – An approach based on automatic rule learning using decision tree. **Applied Soft Computing**, v. 36, p. 45-56, 2015.

GONZALEZ, R. C.; WOODS, R. E. **Processamento digital de imagens**, 3^a ed, São Paulo: Pearson, p. 624, 2010.

GUNNESS, P.; KRAVCHUK, O.; NOTTINGHAM, S. M.; D’ARCY, B. R.; GIDLEY, M.J. Sensory analysis of individual strawberry fruit and comparison with instrumental analysis. **Postharvest Biology and Technology**, v. 52, p. 164–172, 2009.

HAYES, C. J.; WALSH, K. B.; GREENSILL, C. V. The impact of lamp environment on prediction of peach TSS content. **Acta Horticulture**, v. 1119, p. 155–162, 2016.

HERTOG, M. L. A. T. M.; LAMMERTYN, J.; SCHEERLINK, N.; NICOLAI, B. M. The impact of biological variation on postharvest behaviour: the case of dynamic temperature conditions. **Postharvest Biology and Technology**, v. 43, p. 183–192, 2007.

HU, B.; SUN, D. W.; PU, H.; WEI, Q. Recent advances in detecting and regulating ethylene concentrations for shelf-life extension and maturity control of fruit: A review. **Trends in Food Science & Technology**, v. 91, p. 66-82, 2019.

IBBA, P.; FALCO, A.; ABERA, B. D.; CANTARELLA, G.; PETTI, L.; LUGLI, P. Bio-impedance and circuit parameters: An analysis for tracking fruit ripening. **Postharvest Biology and Technology**, v. 159, p. 110978, 2020.

ISMAIL, N.; MALIK, O. A. Real-time visual inspection system for grading fruits using computer vision and deep learning techniques. **Information Processing in Agriculture**, 2021.

JACKSON, R. S. Wine Science: Principles and Applications. **Academic Press**, 4^a ed., 2015.

JU, C.; CHANG, C. Mechanistic insights in ethylene perception and signal transduction. **Plant Physiol**, v. 169, p. 85–95, 2015.

KAIRY, G. M.; DUERKOP, A. Dipsticks and sensor microtiterplate for determination of copper (II) in drinking water using reflectometric RGB readout of digital images, fluorescence or eye-vision. **Sensors and Actuators B: Chemical**, v. 281, p. 878-884, 2019.

KANCHI, S.; SABELA, M. I.; MDLULI, P. S.; INAMUDDIN; BISETTY. K. Smartphone based bioanalytical and diagnosis applications: A review. **Biosensors and Bioelectronics**, v. 102, p. 136-149, 2018.

KANDAKER, M. M.; AMIRAH, F. N.; MAJRASHI, A.; SAJILI, M. H.; MOHD, K. M., MAT, N. Peel colour, antocyanin, TSS content and sensory evaluation of some common fruits: A comparative study. **Australian Journal of Crop Science**, v. 12, n. 11, p. 1788-1795, 2018.

KAYS, S. J.; PAULL, R. E. **Postharvest biology**, Athens: EP press, p. 568, 2004.

KELLER, N.; DUCAMP, M. N.; ROBERT, D.; KELLER, V. Ethylene removal and fresh product storage: A challenge at the frontiers of chemistry. Toward an approach by photocatalytic oxidation. **Chemical Reviews**, v. 13, p. 5029-5070, 2013.

KENNARD, R. W., STONE, L. A. Computer aided design of experiments. **Technometric**, v. 11, p. 137–148, 1969.

KLEE, H. J., GIOVANNONI, J. J. Genetics and control of tomato fruit ripening and quality attributes. **Annual Reviews of Genetics**, v. 45, p. 41–59, 2011.

KOYAMA, K.; TANAKA, M., CHO, B. H.; YOSHIKAWA, Y.; KOSEKI, S. Predicting sensory evaluation of spinach freshness using machine learning model and digital images. **PLoS One**, v. 13(3), p. 1-16, 2021.

KRAMER, A, **Evaluation of quality of fruits and vegetables**, In: Food Quality, G. W., Irving, Jr.; S, R, Hoover, Eds, American Association for the Advancement of Science, Washington, DC, p. 9–18, 1965.

KRASULYA, O.; SMIRNOVA, A.; BOGUSH, V.; SHLENSKAYA, N.; VOSTRIKOVA, N.; METTU, S. Estimation of the stability of skeletal muscle myoglobin of chilled pork treated with brine activated by low-frequency high-intensity ultrasound. **Ultrasonics Snonochemistry**, v. 71, p. 105363, 2021.

LACEY, R. F.; BINDER, R. F. How plants sense ethylene gas the ethylene receptors. **Journal Inorganic Biochemistry**, v. 133, p. 58-62, 2014.

LEIVA-VALENZUELA, G.; LU, R.; AGUILERA, J. M. Prediction of firmness and soluble solids content of blueberries using hyperspectral reflectance imaging. **Journal of Food Engineering**, v. 115, p. 91-98, 2013.

LEÓN, K.; DOMINGO, M.; PEDRESCHI, F.; LEÓN, J, Color measurement in $L^*a^*b^*$ units from RGB digital images. **Food Research International**, v. 39, p. 1084–1091, 2006.

LI, X.; XU, C.; KORBAN, S. S.; CHEN, K. Regulatory mechanisms of textural changes in ripening fruits. **Critical Reviews in Plant Sciences**, v. 29, n. 4, p. 222–243, 2010.

LIN, Z.; ZHONG, S.; GRIERSON, D. Recent advances in ethylene research. **Journal of Experimental Botany**, v.60, p. 3311–3336, 2009.

LU, R. Multispectral imaging for predicting firmness and soluble solids content of apple fruit, **Postharvest Biology and Technology**, v. 31, p. 147–157, 2004.

LU, R.; ARIANA, D. A near-infrared sensing technique for measuring internal quality of apple fruit. **Applied Engineering in Agriculture**, v. 18, v. 5, p. 585-590, 2002.

MA, T.; XIA, Y.; INAGAKI, T.; TSUCHIKAWA, S. Non-destructive and fast method of mapping the distribution of the soluble solids content and pH in Kiwi fruit using object rotation near-infrared hyperspectral imaging approach. **Postharvest Biology and Technology**, v. 174, p. 111440, 2021.

MADUWANTHI, S. D. T.; MARAPANA, R. A. U. J. Induced Ripening Agents and Their Effect on Fruit Quality of Banana. **International Journal of Food Science**, p. 1-8, 2019.

MAGWAZA, L. S.; OPARA, U. L. Analytical methods for determination of sugars and sweetness of horticultural products: a review. **Scientia Horticulturae**, v. 184, p. 179–192, 2015.

MAHANTI, N. K.; CHAKRABORTY, S. K. Application of chemometrics to identify artificial ripening in sapota (*Manilkara Zapota*) using visible near infrared absorbance spectra. **Computers and Electronics in Agriculture**, v. 175, p. 105539, 2020.

MALUNDO, T. M. M., SHEWFELT, R. L., SCOTT, J. W. Quality enhancement, In: Erickson, M. C., Hung, Y-C. (Eds.). **Quality of Frozen Food**, Springer, p. 460–477, 1997.

- MAROUBO, L. A.; PEDRINA, G.; MELCHERT, W. R. Total sulfonamides determination in bovine milk using smartphone-based digital images. **Microchemical Journal**, v. 170, p. 106657, 2021.
- MCDONALD, H.; ARPAIA, M. L.; CAPORASO, F.; OBENLAND, D.; WERE, L.; RAKOVSKI, C.; PRAKASH, A. Effect of gamma irradiation treatment at phytosanitary dose levels on the quality of 'Lane Late' navel oranges. **Postharvest Biology and Technology**, v. 86, p. 91–99, 2013.
- MILOVANOVIC, B.; TOMOVIC, V.; DJEKIC, I.; MIOCINOVIC, J.; SOLOWIEJ, B. G.; LORENZO, J. M.; BARBA, F. J.; TOMASEVIC, I. Colour assessment of milk and milk products using computer vision system and colorimeter. **International Dairy Journal**, v. 120, p. 105084, 2021.
- MITCHAM, B.; CANTWELL, M.; KADER, A. Methods for determining quality of fresh commodities. **Perishables Handling Newsletter**, v. 85, p. 1–6, 1996.
- MITRA, I., SAHA, A., ROY, K. Exploring quantitative structure–activity relationship studies of antioxidant phenolic compounds obtained from traditional Chinese medicinal plants. **Molecular Simulation**, v. 36, p. 1067–1079, 2010.
- MURTA, B. H. P.; AGUIRRE, S. L.; PAUL, S. **Projeto, construção e caracterização de clausura para ensaios acústicos na indústria alimentícia murta**. XXVII Encontro da SOBRAC- Sociedade Brasileira de Acústica, Brasília, 2017.
- NAMBI, V. E.; THANGAVEL, K.; JESUDAS D. M. Scientific classification of ripening period and development of colour grade chart for Indian mangoes (*Mangifera indica L.*) using multivariate cluster analysis. **Scientia Horticulturae**, v. 193, p. 90-98, 2015.
- NAMBI, E. V.; THANGAVEL, K.; THIRUPATHI, V. Comparison of Various RGB Image Features for Nondestructive Prediction of Ripening of “Alphonso” Mangoes for Easy Adoptability in Machine Vision Applications: A Multivariate Approach. **Journal of Food Quality**, v. 39, p. 816-825, 2016.
- NUNES, C, A.; FREITAS, M, P, aug-MIA-QSAR modeling of antimicrobial activities and desing of multi-target anilide derivates. **Journal of Microbiological Methods**, v. 94, p. 217-220, 2013.
- NUNES, C. A.; SOUZA, V. R.; RODRIGUES, J, F.; PINHEIRO, A, C.; FREITAS; M, P.; BASTOS, S. C. Prediction of consumer acceptance in some thermoprocessed food by physical measurements and multivariate modeling. **Journal of Food Processing Preservation**, v. 41, p. 13178, 2017.
- OBENLAND, D.; COLLIN, S.; SIEVERT, J.; FJELD, K.; ARPAIA, M. L. Relationship of soluble solids, acidity and aroma volatiles to flavor in late-season navel oranges. **Acta Horticulturae**, v. 887, p. 749–755, 2010.
- OFFICIAL METHOD OF ANALYSIS – AOAC. **Association of Official Analytical Chemists**, Washington DC, 15 th Edition, 1998.

OHLWEILER, O. A. **Fundamentos de análise instrumental**, 1^a ed. Rio de Janeiro: Livros Técnicos e Científicos, 1981.

PATRÍCIO, D. I.; RIEDER, R. Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. **Computer and Electronics in Agriculture**, v. 153, p. 69-81, 2018.

PENSÉ-LHÉRITIER, A. M.; GUILABERT, C.; BUENO, M. A.; SAHNOU, M.; RENNER, M. Sensory evaluation of the touch of a great number of fabrics. **Food Quality and Preference**, v.17, p. 482-488, 2006.

PEREIRA, F. M. V.; DE SOUZA, A. C.; CABEC, A. L. F.; COLNAGO, L. A. Classification of intact fresh plums according to sweetness using time-domain nuclear magnetic resonance and chemometrics. **Microchemical Journal**, v. 108, p. 14–17, 2013.

PORAT, R.; WEISS, B.; COHEN, L.; DAUS, A.; COHEN, E. Effects of intermittent warming and temperature conditioning on postharvest quality of ‘Oroblanco’ citrus fruit following long-term storage. **Hort Technology**, v. 13, p. 70–74, 2003.

PULLANAGARI, R. R.; LI, M. Uncertainty assessment for firmness and total soluble solids of Sweet chrries using hyperspectral imaging and multivariate statistics. **Journal of Food Engineering**, v. 289, p. 110177, 2021.

RAMMA, I.; MADHU, S. P. B.; PEERTHUM, S. Post Harvest quality improvement of Banana, **Food and Agricultural Research Council**, Reudit Mauritius, 1999.

REN, G.; GAN, N.; SONG, Y.; NING, J.; ZHANG, Z. Evaluating Congou black tea using a labmade computer vision system coupled with morphological features and chemometrics. **Microchemical Journal**, v. 160, p. 105600, 2021.

REZAZADEH, M.; SEIDI, S.; LID, M.; PEDERSEN-BJERGAARD, S.; YAMINI, Y. The modern role of smartphones in analytical chemistry. **TrAC Trends in Analytical Chemistry**, v. 118, p. 548-555, 2019.

RIBEIRO, M. N.; CARVALHO, I. A.; FONSECA, G. A.; LAGO, R. C.; ROCHA, L. C. R. R.; FERREIRA, D. D.; DE BARROS VILAS BOAS, E. V.; PINHEIRO, A. C. M. Quality controlo f fresh strawwberries by a random forest model. **Journal of the Science of Food and Agriculture**, 2021.

ROGEZ, H.; POMPEU, D. R.; AKWIE, S. N. T.; LARONDELLE, Y. Sigmoidal kinetics of anthocyanin accumulation during fruit ripening: a comparison between ac₃ai fruits (Euterpe oleracea) and other anthocyanin-rich fruits. **Journal of Food Composition and Analysis**, v. 24, n. 6, p. 796–800, 2011.

ROY, P. P., PAUL, S., MITRA, I., ROY, K. On Two Novel Parameters for Validation of Predictive QSAR Models. **Molecules**, v.14, n,5, p. 1660-1701, 2009.

- RUDNITSKAYA, A.; KIRSANOV, D.; LEGIN, A.; BEULLENS, A.; LAMMERTYN, J.; NICOLAÏ, B. M.; IRU-DAYARAJ, J. Analysis of apples varieties comparison of electronic tongue with different analytical techniques. **Sensors and Actuators B: Chemical**, v. 116, p. 23–28, 2006.
- RYU, B.; KIM, K.; HA, Y.; BAE, J.; LEE, S.; SONG, J.; LEE, K.; LEE, J.; KIM, K.; KIM, H. New RGB primary for various multimedia systems. **Journal of Information Display**, v. 15, n. 2, p. 65-70, 2014.
- SANAEIFAR, A.; BAKHSHIPOUR, A.; LA-GUARDIA, M. Prediction of banana quality indices from color features using support vector regression. **Talanta**, v. 148, p. 54-61, 2016.
- SAHA, D.; MANICKAVASAGAN, A. Machine learning techniques for analysis of hyperspectral images to determine quality of food products: A review. **Currente Research in Food Science**, v. 4; p. 28-44, 2021.
- SANTOS, V. B.; SILVA, E. K. N.; OLIVEIRA, L. M. A.; SUAREZ, W. T. Low cost in situ digital image method, based on spot testing and smartphone images, for determination of ascorbic acid in Brazilian Amazon native and exotic fruits. **Food Chemistry**, v. 285, p. 340-346, 2019.
- SHEWFELT, R. L. Measuring quality and maturity, In: Florkowski, W. J., Shewfelt, R. L., Brueckner, B., Prussia, S.E. (Eds.). *Postharvest Handling: A System Approach*, second ed, Academic Press, Elsevier, Amsterdam, Netherlands, p. 461–481, 2009.
- SILVA, F. A.; MARSAIOLI, J. A. Perfil de textura de Amêndoas de Noz Macadâmia (*Macadamia integrifolia*) Secas com Aplicações de Energia de Micro-ondas e Ar Quente. **Revista Ciências Exatas e Naturais**, v. 8, p. 190-198, 2006.
- SONG, J.; LI, G.; YANG, X.; LIU, X.; XIE, L. Rapid analysis of soluble solid content in navel Orange based on visible-near infrared spectroscopy combined with a swarm intelligence optimization method. **Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy**, v. 228, pag. 117815, 2020.
- SOUZA, V. R.; PINHEIRO, A. C. M.; CARNEIRO, J. D. S.; PINTO, S. M. Analysis of various sweeteners in Petit Suisse Cheese: Determination of the ideal and equivalent sweetness. **Journal of Sensory Studies**, v. 26, n. 5, p. 339–345, 2011.
- SZCZESNIAK, A. S. Texture is a sensory property. **Food Quality and Preference**, v. 13, p. 215-225, 2002.
- TAHERI-GARAVAND, A.; FATAHI, S.; OMID, M.; MAKINO, Y. Meat quality evaluation based on computer vision technique: A review. **Meat Science**, v. 156, p. 183-195, 2019.
- TIUFTIAKOV, N. Y.; KALINICHEV, A. V.; POKHVISCGEVA, N. V.; PESHKOVA, M. A. Digital color analysis for colorimetric signal processing: Toward an analytically justified choice acquisition technique and color space. **Sensors and Actuators B: Chemical**, v. 344, p.130274, 2021.

TREVISAN, R., PIANA, C. F. DE B., TREPTOW, R. O., GONÇALVES, E. D., ANTUNES, L. E. C. Perfil e preferências do consumidor de pêsego (*Prunus persica*) em diferentes regiões produtoras no Rio Grande do Sul. **Revista Brasileira de Fruticultura**, v. 32, n. 1, p. 90–100, 2010.

VAN DER VOET, H. Pseudo-degrees of freedom for complex predictive models: the example of partial least squares. **Journal Chemometrics**, v. 13, p. 195–2008, 1999.

WAKELING, I. N.; MACFIE, H. J. Designing consumer trials balanced for first and higher orders of carry-over effect when only a subset of k samples from t may be tested. **Food Qual Preference**, v. 6, p. 299–308, 1995.

WALDRON, K.W., PARKER, M. L.; SMITH, A. C. Plant cell walls and food quality, **Comprehensive Reviews in Food Science and Food Safety**, v. 2, p. 101–119, 2003.

WEI, H.; SEIDI, F.; ZHANG, T.; JIN, Y.; XIAO, H. Ethylene scavengers for the preservation of fruits and vegetables: A review. **Food Chemistry**, v. 337, p. 127750, 2021.

WEI, X.; HE, J.; ZHENG, S.; YE, D. Modeling for SSC and firmness detection of persimmon based on NIR hyperspectral imaging by sample partitioning and variables selection. **Infrared Physics & Technology**, v. 105, p. 103099, 2020.

WU, D.; SUN, D. W. Colour measurements by computer vision for food quality control – a review. **Trends in Food Science & Technology**, v. 29, n. 1, p. 5–20, 2013.

XIE, C.; CHU, B.; HE, Y. Prediction of banana color and firmness using a novel wavelengths selection method of hyperspectral imaging. **Food Chemistry**, v. 245, p. 132-140, 2018.

YAO, M.; ZHOU, X.; ZHOU, Q.; WEI, B.; CHENG, S.; TAN, Z. Low temperature conditioning alleviates loss of aroma-related esters of ‘Nanguo’ pears by regulation of ethylene signal transduction. **Food Chemistry**, v. 264, p. 263-269, 2018.

YANG, S. F.; HOFFMAN, N. E. Ethylene biosynthesis and regulation in higher plants. **Annual Review of Plants Biology**, p. 155-189, 1984.

YUE, X-Q.; SHANG, Z-Y.; YANG, J-Y.; HUANG, L.; WANG, Y-Q. A smart data-driven rapid method to recognize the strawberry maturity. **Information Processing in Agriculture**, p. 1-28, 2019.

ZHANG, B.; GU, B.; TIAN, G.; ZHOU, J.; HUANG, J.; XIONG, Y. Challenges and solutions of optical-based nondestructive quality inspection for robotic fruit and vegetable grading systems: A technical review. **Trends in Food Science & Technology**, v. 81, p. 213-231, 2018.

ZHANG, J. H.; CHENG, D.; WANG, B. B.; KHAN, I.; NI, Y. H. Ethylene control technologies in extending postharvest shelf life of climacteric fruit. **Journal of Agricultural & Food Chemistry**, v. 65, p.7308-7319, 2017.

ZHOU, Y.; XIONG, Q.; YIN, C. C.; CHEN, S. Y.; ZHANG, J. S. Ethylene Biosynthesis, Signaling and Crosstalk with Other Hormones in Rice. **Small Methods**, v. 4, p. 1900278, 2019.