



**MICHELE NAYARA RIBEIRO**

**USE OF MACHINE LEARNING TO PREDICT FRUIT  
QUALITY: A SENSORY STUDY USING AFFECTIVE SCALES**

**LAVRAS-MG  
2021**

**MICHELE NAYARA RIBEIRO**

**USE OF MACHINE LEARNING TO PREDICT FRUIT QUALITY: A SENSORY  
STUDY USING AFFECTIVE SCALES**

Tese apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Ciência dos Alimentos, área de concentração em Nutrição e Desenvolvimento de Produtos e Embalagens, para a obtenção do título de Doutora.

Profa. Dra. Ana Carla Marques Pinheiro  
Orientadora

**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).**

Ribeiro, Michele Nayara.

Use of machine learning to predict fruit quality: a sensory study using  
affective scales / Michele Nayara Ribeiro. - 2021.

129 p. : il.

Orientador(a): Ana Carla Marques Pinheiro.

Tese (doutorado) - Universidade Federal de Lavras, 2021.

Bibliografia.

1. Aprendizado de máquina. 2. Frutas. 3. Respostas sensoriais. I.  
Pinheiro, Ana Carla Marques. II. Título.

**MICHELE NAYARA RIBEIRO**

**USO DE APRENDIZADO DE MÁQUINA NA PREDIÇÃO DA QUALIDADE DE FRUTAS: UM ESTUDO SENSORIAL UTILIZANDO ESCALAS AFETIVAS**

**USE OF MACHINE LEARNING TO PREDICT FRUIT QUALITY: A SENSORY STUDY USING AFFECTIVE SCALES**

Tese apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Ciência dos Alimentos, área de concentração em Nutrição e Desenvolvimento de Produtos e Embalagens, para a obtenção do título de Doutora.

APROVADA em 13 de agosto de 2021.

Dra. Márcia Arocha Gularte UFPEL

Dr. Erick Almeida Esmerino UFRRJ

Dr. Danton Diego Ferreira UFLA

Dr. Eduardo Valério de Barros Vilas Boas UFLA

Dr. Roney Alves da Rocha UFLA



Profa. Dra. Ana Carla Marques Pinheiro  
Orientadora

**LAVRAS-MG  
2021**

*Aos meus pais, Reinalda e Dijalma.  
À minha irmã Mikaelle.  
O meu esforço foi do tamanho do amor de vocês!  
Com amor,  
Dedico!*

## AGRADECIMENTOS

Agradeço a Deus, por me trazer até aqui e por ter me fortalecido durante a caminhada. Foi confiando em seu amor e misericórdia, que cada obstáculo foi vencido.

À Nossa Senhora por ser minha maior intercessora e por sempre estar ao meu lado.

À Universidade Federal de Lavras, pela oportunidade de aprimorar os meus conhecimentos.

Ao Departamento de Ciência dos Alimentos, em especial ao Laboratório de Análise Sensorial pela oportunidade de desenvolver os meus projetos de pesquisa.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão da bolsa de estudos. Agradeço ao CNPq, CAPES e FAPEMIG pelo suporte financeiro.

À professora Ana Carla, pela orientação, ensinamentos, confiança e amizade. Obrigada pela oportunidade de fazer parte da sua equipe.

Aos professores Danton, Eduardo, Cirillo e Renato, pela dedicação e direcionamentos.

Aos meus pais, Reinalda e Dijalma, e minha irmã Mikaelle pelo apoio incondicional. Obrigada por todo o amor que destinaram a mim, vocês são meus exemplos de vida!

Agradeço a toda a minha família, em especial à minha avó Iracina, meu tio Nelson e às minhas madrinhas, Renilda, Daiane e Consola. Obrigada por cada oração, carinho, apoio, e por terem cuidado de mim, mesmo estando longe.

Ao Iago por toda parceria, obrigada por viver esse sonho comigo e por lutar ao meu lado.

Aos amigos do laboratório de Análise Sensorial, especialmente a Jéssica Guimarães, Lenízy, Juliana, Laiza, Lívia e Leonardo, obrigada por toda ajuda, convívio e ensinamentos.

Aos meus queridos amigos Wagner, Carol, Sofia, Renata, Mateus, Vanúbia e a todos que não foram citados, muito obrigada pela amizade, força e incentivo.

Aos amigos, colegas e funcionários do Programa de Pós-Graduação em Ciência dos Alimentos.

Ao Movimento Universidades Renovadas, com um carinho muito especial ao Grupo de Oração Universitário Magnificat, por me aproximarem mais de Deus durante minha jornada acadêmica.

À equipe UFLARunners e ao treinador Alberto por me incentivarem a seguir uma vida saudável e feliz.

Aos professores que tive durante minha formação, desde o ensino básico até a pós-graduação, obrigada por fazerem a diferença na minha vida!

A todos os provadores que participaram das análises sensoriais, vocês foram fundamentais para a realização deste trabalho.

Enfim, a todos que contribuíram para a concretização deste trabalho. **MUITO OBRIGADA!**

*“Seu lar ficou para trás agora.  
O mundo está à sua frente.”  
(Gandalf - O Hobbit)*

## RESUMO GERAL

A qualidade das frutas é um dos fatores mais importantes para garantir que a sua comercialização seja consistente, bem como a satisfação do consumidor. É indiscutível o papel da análise sensorial na aferição das respostas dos consumidores sobre a qualidade dos alimentos. Entretanto, a qualidade sensorial das frutas geralmente não é monitorada devido a restrições de tempo e dinheiro, sendo necessária a participação de muitos consumidores para a realização dos testes sensoriais, tornando-os mais difíceis. Deste modo, o presente trabalho teve como objetivos: (i) gerar modelos matemáticos baseados em aprendizado de máquina para prever a aceitação, expectativa, ideal de doçura, ideal de acidez e o ideal de suculência com base nos dados físico-químicos de diferentes frutas e classificar as frutas quanto à satisfação do consumidor e sua intenção de pagar mais por elas; e (ii) utilizar diferentes escalas afetivas para avaliar as respostas sensoriais e entender os fatores que influenciam no comportamento do consumidor de morangos. Para isso, no primeiro tópico abordado neste trabalho foi utilizado o algoritmo *Random Forest* (RF) para prever as respostas sensoriais (aceitação, expectativa, ideal de doçura, suculência e acidez) dos consumidores de morangos utilizando medidas físicas e físico-químicas. Além disto, o RF foi utilizado para classificar os morangos em “satisfeitos” ou “não satisfeitos” e “pagaria mais” ou “não pagaria mais” com base nas respostas sensoriais dos consumidores. O RF gerou excelentes resultados para a tarefa de predição, o que indica que é possível estimar corretamente as medidas sensoriais de morangos usando dados físicos e físico-químicos. Além disso, o RF foi capaz de classificar corretamente as amostras de morango nas classes “satisfeito” e “não satisfeito” e nas classes “pagaria mais” ou “não pagaria mais”. O segundo aspecto abordado foi avaliar o uso de diferentes algoritmos para prever as respostas sensoriais de consumidores de diferentes frutas. Para isto, 705 consumidores de laranja, 624 consumidores de tangerina e 477 consumidores de uva, avaliaram as amostras de frutas de acordo com sua aceitação, expectativa, ideal de doçura, suculência e acidez, utilizando escalas afetivas. Os resultados demonstraram que não existe um único algoritmo que supere todos os outros em prever a resposta do consumidor em relação às frutas avaliadas por meio de seus parâmetros físicos, químicos e físico-químicos. No terceiro tópico um total de 715 consumidores avaliaram trinta amostras de morangos utilizando diferentes escalas afetivas para quantificar a sua aceitação, expectativa, ideal de doçura, suculência e acidez. Além disso, aferiram-se a satisfação e intenção de pagar mais ou não pela fruta. Foi observado que os atributos de doçura, suculência e acidez influenciaram diretamente na aceitação e expectativa dos consumidores, o que conseqüentemente pode gerar maior satisfação. A correlação de diferentes escalas afetivas pode ser uma alternativa para entender melhor o comportamento dos consumidores. Portanto, os resultados indicam que os modelos desenvolvidos podem ser utilizados no controle de qualidade de frutas, subsidiando o estabelecimento de padrões de qualidade que considerem a resposta do consumidor. Além disso, a metodologia proposta pode ser estendida para controlar a qualidade sensorial de outras frutas.

**Palavras-chave:** Frutas. Escalas afetivas. Regressão. Classificação. Respostas sensoriais.

## GENERAL ABSTRACT

Fruit quality is one of the most important factors to ensure consistent fruit commercialization and consumer satisfaction. The role of sensory analysis in measuring consumer responses about food quality is indisputable. However, the sensory quality of fruit is generally not monitored due to time and money constraints, requiring the participation of many consumers, making sensory testing unfeasible. Thus, the present work aimed to: (i) generate mathematical models based on machine learning to predict acceptance, expectation, sweetness ideal, acidity ideal, and succulence ideal based on physicochemical data of different fruits and classify fruits according to consumer satisfaction and intention to pay more; and (ii) use different affective scales to assess sensory responses and understand the factors that influence strawberry consumer behavior. For this, in the first topic addressed in this work, the Random Forest (RF) algorithm was used to predict the sensory responses (acceptance, expectation, sweetness ideal, succulence ideal, and acidity ideal) of strawberry consumers using physical and physicochemical measurements. In addition, RF was used to classify strawberries into “satisfied” or “not satisfied” and “would pay more” or “would not pay more” based on the sensory responses of consumers. The RF obtained excellent results for the prediction task, which indicates that it is possible to correctly estimate the sensory measurements of strawberries using physical and physicochemical data. In addition, the RF was able to correctly classify the strawberry samples into the “satisfied” and “not satisfied” classes and into the “would pay more” or “would not pay more” classes. The second aspect addressed was to evaluate the use of different algorithms to predict the sensory responses of consumers of different fruits. For this, 705 orange consumers, 624 tangerine consumers, and 477 grape consumers evaluated the fruit samples according to their acceptance, expectation, ideal sweetness, succulence, and acidity, using affective scales. The results showed that there is no single algorithm that surpasses all others in predicting the consumer's response regarding the fruits evaluated through their physical, chemical, and physical-chemical parameters. In the third topic, a total of 715 consumers evaluated thirty samples of strawberries using different affective scales to quantify their acceptance, expectation, ideal sweetness, juiciness, and acidity. In addition, satisfaction and intention to pay more or not for the fruit were measured. It was observed that the attributes of sweetness, succulence and acidity directly influenced the acceptance and expectation of consumers, which consequently can generate greater satisfaction. The correlation of different affective scales can be an alternative to better understand consumer behavior. Therefore, the results indicate that the developed models can be used in fruit quality control, supporting the establishment of quality standards that consider the consumer's response. Furthermore, the proposed methodology can be extended to control the sensory quality of other fruits.

**Keywords:** Fruits. Affective scales. Regression. Classification. Sensory responses.

## SUMÁRIO

	<b>PRIMEIRA PARTE</b> .....	<b>10</b>
<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>10</b>
<b>2</b>	<b>OBJETIVOS</b> .....	<b>12</b>
<b>2.1</b>	<b>Objetivo geral</b> .....	<b>12</b>
<b>2.2</b>	<b>Objetivos específicos</b> .....	<b>12</b>
<b>3</b>	<b>REFERENCIAL TEÓRICO</b> .....	<b>13</b>
<b>3.1</b>	<b>Produção e comercialização de frutas no Brasil</b> .....	<b>13</b>
<b>3.1.1</b>	<b>Morango</b> .....	<b>14</b>
<b>3.1.2</b>	<b>Uva ‘Itália’</b> .....	<b>15</b>
<b>3.1.3</b>	<b>Tangor ‘Murcote’</b> .....	<b>16</b>
<b>3.1.4</b>	<b>Laranja ‘Bahia’</b> .....	<b>17</b>
<b>3.2</b>	<b>Qualidade dos frutos consumidos no Brasil</b> .....	<b>19</b>
<b>3.3</b>	<b>Análise sensorial</b> .....	<b>21</b>
<b>4</b>	<b>CONSIDERAÇÕES GERAIS</b> .....	<b>24</b>
	<b>REFERÊNCIAS</b> .....	<b>25</b>
	<b>SEGUNDA PARTE</b> .....	<b>30</b>
	<b>CAPÍTULO - APRENDIZADO DE MÁQUINA: UMA ABORDAGEM DA INTELIGÊNCIA ARTIFICIAL APLICADA À CIÊNCIA DOS ALIMENTOS</b> .....	<b>30</b>
	<b>TERCEIRA PARTE - ARTIGOS</b> .....	<b>68</b>
	<b>ARTIGO 1 - QUALITY CONTROL OF FRESH STRAWBERRIES BY A RANDOM FOREST MODEL</b> .....	<b>68</b>
	<b>ARTIGO 2 - A COMPARISON OF MACHINE LEARNING ALGORITHMS FOR PREDICTING CONSUMER RESPONSES BASED ON PHYSICAL, CHEMICAL, AND PHYSICAL-CHEMICAL DATA OF FRUITS</b> .....	<b>94</b>
	<b>ARTIGO 3 - ENTENDENDO A PERCEPÇÃO DOS CONSUMIDORES POR MEIO DE DIFERENTES ESCALAS AFETIVAS E SUAS INTERAÇÕES: UM ESTUDO DE CASO COM MORANGOS</b> .....	<b>103</b>

## PRIMEIRA PARTE

### 1 INTRODUÇÃO

O Brasil é o terceiro maior produtor de frutas no mundo (ABAFRUTAS, 2021; EMBRAPA, 2021), fato que demonstra a importância do setor de fruticultura no país. Além de ser destaque do agronegócio brasileiro, as frutas estão cada vez mais presentes nas refeições, sendo possível observar um aumento significativo do consumo de frutas e hortaliças ao longo dos anos. Seguindo a tendência de saudabilidade e bem-estar, as frutas são uma boa alternativa para os consumidores que buscam alimentos saudáveis e naturais. Os consumidores estão cada vez mais exigentes e conscientes, e muitos deles estão atentos aos nutrientes, compostos antioxidantes, vitaminas e minerais que as frutas oferecem. Também pode-se destacar a ação dos governos nacionais e organismos internacionais visando à implementação de políticas nutricionais e campanhas educacionais para conscientizar a população sobre a necessidade de aumentar o consumo desses produtos (SPAGNOL *et al.*, 2018).

Apesar de ser um grande mercado produtor e consumidor, as frutas são geralmente comercializadas sem qualquer controle da qualidade intrínseca, que são os aspectos físico-químicos e sensoriais. A variação da qualidade relacionada a esses aspectos impede que a comercialização de frutas e os preços de venda sejam estabelecidos de acordo com a qualidade percebida. A falta de controle dos aspectos físico-químicos e sensoriais leva à comercialização de frutas com base na oferta e demanda.

A aparência das frutas tem influência direta na decisão de compra do consumidor, que geralmente avalia a qualidade da fruta apenas se baseando na percepção visual. Entretanto, sabe-se que a qualidade de uma fruta vai além da aparência e está diretamente ligada à atributos sensoriais como aroma, sabor e textura. Desta forma, escolher as frutas se baseando em um único aspecto, como a aparência, pode levar o consumidor a adquirir produtos de baixa qualidade, o que pode culminar com a insatisfação e frustração do consumidor.

Uma forma de garantir a qualidade das frutas é monitorar a sua qualidade sensorial, por meio de testes relacionados à aceitação do consumidor. Assim, a qualidade deve ser definida levando em consideração as percepções dos consumidores. Porém, a aceitação do consumidor não é monitorada devido à sua inviabilidade, pois testes sensoriais exigem um grande número de consumidores e um tempo incompatível com os ritmos de produção e comercialização.

Uma alternativa para esse problema em estudo, seria a utilização do aprendizado de máquina para inferir a qualidade das frutas, de forma a garantir a satisfação do consumidor. O

aprendizado de máquina é uma abordagem da inteligência artificial, que aprende com os exemplos e pode prever uma saída com base nos dados de entrada. Ou seja, com o aprendizado de máquina é possível prever uma resposta sensorial, com base nos parâmetros físico-químicos, que são medidas mais fáceis de serem coletadas.

Recentemente, alguns estudos relataram uma boa correlação entre as medidas físicas, químicas e físico-químicas com as respostas sensoriais (CHANG *et al.*, 2021; CORRÊA *et al.*, 2014; GONZALEZ VIEJO; FUENTES, 2020; NUNES *et al.*, 2017; RODRIGUES *et al.*, 2019; TIAN *et al.*, 2020; YU *et al.*, 2018). Esses estudos desenvolveram modelos matemáticos para prever a aceitação sensorial dos consumidores e as respostas sensoriais de provadores treinados por meio de análises físicas e físico-químicas fáceis e rápidas. Dentre eles, destaca-se o estudo de Corrêa *et al.* (2014), que demonstrou viabilidade na construção de modelos na predição da aceitação de laranja ‘Pêra Rio’, abacaxi ‘Pérola’ e uva ‘Niágara’. Desta forma, é possível utilizar o aprendizado de máquina para prever respostas sensoriais de morango, laranja, tangerina e uva, com base em parâmetros físico-químicos, a fim de garantir sua qualidade e atender as demandas dos consumidores.

## 2 OBJETIVOS

### 2.1 Objetivo geral

Identificar as variáveis físicas e físico-químicas que mais influenciam nas respostas sensoriais de morango, tangerina ‘Murcorte’, uva ‘Itália’ e laranja ‘Bahia’ para prever a aceitação, expectativa, ideal de doçura, ideal de suculência e ideal de acidez percebidos pelos consumidores, estabelecendo padrões de qualidade para as frutas, a fim de atender as expectativas e alcançar a satisfação dos consumidores. Utilizar diferentes escalas afetivas para avaliar as respostas sensoriais e entender os fatores que influenciam no comportamento do consumidor.

### 2.2 Objetivos específicos

- I. Caracterizar, com base em análises físicas, físico-químicas e sensoriais, a qualidade de morango, tangerina ‘Murcote’, laranja ‘Bahia’ e uva ‘Itália’, comercializadas em Minas Gerais, obtidas de diferentes fornecedores;
- II. Avaliar a interação de diferentes escalas afetivas, como a escala hedônica, escala do ideal e escala de atitude, na avaliação das respostas sensoriais de consumidores;
- III. Desenvolver modelos preditivos das respostas sensoriais dos consumidores (aceitação, expectativa e ideal de doçura, suculência e acidez) baseados em respostas físicas e físico-químicas rápidas (acidez titulável, sólidos solúveis, pH, diâmetro, altura, rendimento de suco, firmeza e cor) de baixo custo e objetivas;
- IV. Avaliar o uso de diferentes algoritmos para prever respostas sensoriais dos consumidores de frutas;
- V. Estabelecer padrões de qualidade para frutas, que garantam a satisfação sensorial do consumidor;

### 3 REFERENCIAL TEÓRICO

#### 3.1 Produção e comercialização de frutas no Brasil

O setor de fruticultura é um dos grandes destaques do agronegócio brasileiro. A fruticultura vem conquistando mercado e gerando oportunidades para os pequenos negócios brasileiros, devido à grande variedade de culturas, produzidas em diversos climas e em todo o país (SEBRAE, 2015). O Brasil é o terceiro maior produtor mundial de frutas, ficando atrás apenas da China e Índia, o que demonstra a relevância deste setor para a economia brasileira (ABAFRUTAS, 2021; EMBRAPA, 2021). De acordo com a Embrapa (2021), o Brasil apresenta uma produção anual de aproximadamente 45 milhões de toneladas, sendo que cerca de 65% das frutas produzidas são consumidas internamente e 35% são destinadas ao mercado externo. Assim, as frutas têm apresentado importância crescente, tanto no mercado interno como no internacional.

A produção nacional de frutas é representada por 22 produtos, sendo três classificados como de lavouras temporárias (abacaxi, melancia e melão) e 19 pertencentes às lavouras permanentes (abacate, banana, caqui, castanha-de-caju, coco-da-baía, figo, goiaba, laranja, limão, maçã, mamão, manga, maracujá, marmelo, noz, pera, pêssego, tangerina e uva) (IBGE, 2016). Em relação à exportação de frutas, no primeiro bimestre de 2021, o valor das exportações foi de US\$ 114.984.012,00, e a quantidade exportada foi de 155.863.893 kg. Em comparação ao primeiro bimestre de 2020, houve um aumento de 3% no valor das exportações de frutas, com destaque para as frutas abacaxi, ameixa, cocos, maçãs, bananas, goiabas, laranjas, melancias, melões, mamões, pêssegos, tangerinas e uvas, que apresentaram aumento no valor da exportação (ABAFRUTAS, 2021).

Entretanto, mesmo com a expansão recente do mercado de fruticultura no Brasil, é possível constatar que os brasileiros não consomem a quantidade de frutas recomendada pela Organização Mundial da Saúde (OMS), o que revela um mercado em potencial para o setor (SEBRAE, 2015). A Organização Mundial da Saúde (OMS) recomenda a ingestão diária de pelo menos 400 gramas de frutas e hortaliças (WHO, 2003), o que equivale, aproximadamente, ao consumo diário de cinco porções desses alimentos. Em um estudo realizado em 27 cidades brasileiras, em 2017, pela Vigilância de Fatores de Risco e Proteção para Doenças Crônicas (VIGITEL, 2018), foi constatado que somente 23,7% da população pesquisada ingeria a quantidade de frutas e hortaliças recomendadas pela OMS, sendo menor por homens (18,5%) do que por mulheres (28,2%).

Apesar disso, diante da tendência crescente de saudabilidade e bem-estar e na busca por novos hábitos alimentares e um novo estilo de vida, os consumidores estão cada vez mais em busca de alimentos saudáveis. Além disto, uma pesquisa realizada pelo Instituto Brasileiro de Geografia e Estatística entre 2017 e 2018 (IBGE, 2020) relatou um aumento significativo no consumo de frutas e hortaliças frescas pela população brasileira. Vale destacar que o consumo de frutas e hortaliças tem sido associado a uma dieta saudável no mundo inteiro. Além disto, os governos nacionais e organismos internacionais têm se dedicado à implementação de políticas nutricionais e campanhas educacionais, para conscientizar a população quanto ao aumento do consumo desses alimentos (SPAGNOL *et al.*, 2018).

Deve-se, deve-se enfatizar que estes consumidores buscam por alimentos mais naturais e saudáveis, porém sem perder a qualidade sensorial. Assim, a qualidade do produto, além de atender a demanda pela alimentação saudável, também deve satisfazer as exigências e desejos do consumidor. Portanto, diante de todas as frutas que são produzidas pelo Brasil, vale destacar as culturas da tangerina, uva e laranja, pois, além de estarem entre as frutas mais produzidas no país, são frutas que agradam os consumidores. Outra opção relevante é o morango, que é um alimento bem aceito pela população.

### **3.1.1 Morango**

O morangueiro é uma hortaliça herbácea e perene, pertencente à família das Rosáceas, gênero *Fragaria*. Comumente seu cultivo ocorre anualmente ou bianualmente, em decorrência de questões relacionadas à fitossanidade e produtividade (FERLA *et al.*, 2007; PADOVANI, 1991). Embora existam diversas espécies de morangueiros, os morangos comercializados no mundo são oriundos, principalmente, do híbrido *Fragaria x ananassa* e suas distintas variedades e cultivares. O sucesso no cultivo do morangueiro em regiões de clima temperado se deve às suas temperaturas ótimas que variam de 10 a 26° C durante os períodos de desenvolvimento (SARIDAS, 2021).

Na última década houve um aumento global na produção de morango (FAO, 2020). Sua produção é estimada nas diversas regiões do mundo, sendo o Brasil o segundo maior produtor da América Latina (CARVALHO *et al.*, 2013; ROSA *et al.*, 2013). O morango (*Fragaria x ananassa* Duch) é a parte comestível da planta, sendo designado como um pseudofruto de aparência, aroma e sabor muito apreciado pelos consumidores. Além disso, é considerado um fruto não-climatérico, ou seja, seu amadurecimento só acontece quando permanece na planta,

visto que não há aumento da produção de etileno depois de colhido (CHITARRA; CHITARRA, 2005; PADOVANI, 1991; SIQUEIRA *et al.*, 2009).

O morango está entre os frutos mais consumidos no mundo por apresentar características sensoriais atrativas e nutricionais bem definidas, sendo assim, muito valorizado na comercialização (GIMENEZ *et al.*, 2008; FILHO *et al.*, 2018; PENG *et al.*, 2020). Segundo Galli *et al.* (2015), o interesse contínuo no consumo do morango está associado às suas características sensoriais, como o seu sabor agradável, aroma, coloração, textura, e aos seus nutrientes, minerais e vitaminas.

O fruto é considerado suculento, rico em compostos antioxidantes, principalmente antocianinas, que são associados à cor vermelha do morango. Além disso, é uma fonte relevante de compostos bioativos por causa de seus altos níveis de vitamina C e constituintes fenólicos. Também é fonte de minerais e vitaminas do complexo B, ácido ascórbico, potássio, cálcio e fósforo (de JESUS FILHO *et al.*, 2020; GIAMPIERI *et al.*, 2015; GINÉ-BORDONABA; TERRY, 2016; LI *et al.*, 2017). Ainda, os morangos são economicamente e comercialmente importantes e amplamente consumidos *in natura* ou em formas processadas, como compotas, sucos e geleias. Por isso estão entre os frutos mais estudados do ponto de vista agrônomo, genômico, nutricional e sensorial (GIAMPIERI *et al.*, 2012).

### 3.1.2 Uva ‘Itália’

*Vitis* sp. são frutíferas de origem asiática. A uva, seu fruto, é do tipo baga, de formato, tamanho, cor, consistência e aroma variáveis, dependendo da espécie, variedade e cultivar. A parte comestível é caracterizada pelo gosto doce, ácido, amargo ou até mesmo sabor adstringente. Suas bagas podem ou não conter sementes. A uva é um fruto não climatérico, ou seja, não amadurece após a colheita, devendo ser colhida em seu ponto ideal de maturação (SEBRAE, 2016).

De acordo com a *Food and Agriculture Organization* (FAO), a uva é um dos frutos mais produzidos em todo o mundo, com estimativa de produção de mais de 79 milhões de toneladas em 2018 (FAO, 2021). O Brasil é o 11º maior mercado produtor de uva (FAOSTAT, 2014), e a produção de uvas está em constante aumento. Segundo o IBGE (2016), a uva está entre as 10 frutas mais produzidas no Brasil, sendo responsável por 6,4% do total das frutas colhidas nos pomares brasileiros.

A produção brasileira está distribuída principalmente nas regiões Sul (67,4%), Nordeste (19,7%) e Sudeste (12,9%). O Estado do Rio Grande do Sul aparece como o maior produtor

nacional, representando 57,7% da produção total, seguido pelos Estados de Pernambuco (15,4%) e São Paulo (12,2%) (SEBRAE, 2018).

A cultivar Itália (*Vitis vinífera x Vitaceae*) é uma uva de película branca, resultado do cruzamento entre a cultivar Bicane e Moscatel de Hamburgo. A uva Itália é a principal uva fina de mesa cultivada nos principais polos produtores brasileiros. A cultivar Itália apresenta várias características positivas, como a boa produtividade (podendo facilmente atingir até 30t/ha/ciclo) e a boa aceitação pelo mercado consumidor, tanto nacional como internacional, além de boas características sensoriais, como um bom tamanho de bagas e o agradável sabor moscatel. Apresenta também boa resistência ao transporte e armazenamento (EMBRAPA, 2005).

Uma das formas preferidas do consumo de uva é na forma *in natura*. De acordo com a Pesquisa de Orçamentos Familiares 2017–2018, em relação aos anos de 2008–2009, houve um aumento de 25% no consumo de uva na zona rural brasileira (IBGE, 2020). Ademais, a uva também é utilizada na fabricação de diversos produtos, como vinhos, sucos, geleias, doces, vinagre e passas, além de fornecer subprodutos, como corantes naturais, ácido tartárico, óleo de semente e taninos (SEBRAE, 2018). Aproximadamente 75% das uvas produzidas são destinadas à produção de vinho, das quais 20-30% representam produtos residuais (ANTONIC *et al.*, 2020).

A uva, juntamente com seus derivados, constitui uma importante fonte de compostos fenólicos, que podem ser classificados entre flavonoides e não flavonoides (estilbenos e ácidos fenólicos). Do primeiro grupo fazem parte os flavanois catequina, epicatequina e epigallocatequina, os flavanois kaempferol, quercetina e miricetina e as antocianinas. Já ao segundo grupo pertencem os estilbenos (por exemplo, o resveratrol), os derivados de ácido cinâmico e benzoico e uma larga variedade de taninos (ABE *et al.*, 2007; FRANCIS, 2000). Além disso, a uva é rica em carboidratos e vitaminas, como tiamina, riboflavina e vitamina C, contendo também minerais como cálcio, fósforo, magnésio, cobre e potássio (SEBRAE, 2018).

### 3.1.3 Tangor ‘Murcote’

Durante a última década, houve um aumento contínuo no consumo e na comercialização global de tangerinas frescas que são frutas fáceis de descascar, em contraste com os níveis estáveis de consumo de frutas cítricas difíceis de descascar, como por exemplo, a laranja (GOLDENBERG *et al.*, 2017). De acordo com o relatório de comercialização de *citrus* do Departamento de Agricultura dos Estados Unidos (USDA), a comercialização global de

tangerinas atinge atualmente 29 milhões de toneladas por ano, sendo a China o maior produtor, com 20 milhões de toneladas, seguida pela União Europeia (2,9 milhões de toneladas), Japão (1,1 milhão de toneladas) Marrocos e Turquia (1 milhão de toneladas cada) (USDA, 2016). A tangerina é uma das dez principais frutas produzidas no Brasil (IBGE, 2016). Em 2017 a produtividade total de tangerina no Brasil foi de 965.354 toneladas colhidas em uma área plantada de 50.028 hectares. A produção brasileira é distribuída nas Regiões Sudeste (60,75%), Sul (30,71%), Nordeste (3,11%), Norte (3,06%) e Centro-Oeste (2,37%) (IBGE, 2017).

As tangerinas constituem um grupo de frutas cítricas (GOLDENBERG *et al.*, 2017). Entre os cítricos, a tangerineira ocupa a maior faixa de adaptação climática, pois a planta é tolerante a altas e baixas temperaturas. Os frutos da tangerineira são de tamanho médio e com a casca fina, firme e pouco aderente, sua forma varia de achatada a altamente comprida e elas possuem núcleos abertos relativamente grandes. Em comparação com as laranjas, as tangerinas possuem maior facilidade de descascamento e separação dos segmentos, além de possuir um sabor delicado e único, uma cor de casca laranja/avermelhada e uma composição diferente de carotenoides (GOLDENBERG *et al.*, 2017). A tangerina, assim como os demais frutos cítricos, é um fruto não climatérico, portanto não amadurece após a colheita (SEBRAE, 2016).

O grupo das tangerinas compreende vários subgrupos naturais, incluindo a tangerina comum (*C. reticulata* Blanco) e os híbridos de tangerina, como o Tangor (*C. reticulata* × *C. sinensis*) (GOLDENBERG *et al.*, 2017). O híbrido Murcott, denominado de Tangor, é o resultado do cruzamento da tangerina com a laranja doce (*Citrus reticulata* Blanco x *Citrus sinensis* Osbeck). O Tangor Murcote possui frutos de tamanho médio, peso médio de 140 g, cerca de 20 sementes por fruto, formato achatado, com uma pequena cavidade no seu eixo central. Esses frutos se destacam pela qualidade da polpa, sendo frutos mais aromáticos, apresentando uma casca com espessura fina, levemente rugosa e rica em glândulas com óleos essenciais (CHIARINI *et al.*, 2017; SEBRAE, 2016).

Seu suco possui sabor intenso, mais doce e com coloração mais alaranjada do que o suco da tangerina Ponkan. Devido às suas características sensoriais, sua comercialização ocorre de forma *in natura* e principalmente para a produção de sucos. Seu suco é abundante, representando cerca de 48% do peso do fruto, com teor de sólidos solúveis de 12,6° Brix e 0,92% de acidez titulável (CHIARINI *et al.*, 2017; FIGUEIREDO, 1991; SEBRAE, 2016).

### **3.1.4 Laranja ‘Bahia’**

A laranja (*Citrus Sinensis x Rutaceae*) é uma das frutas mais cultivadas em todo o mundo. A laranjeira pertence ao gênero *Citrus* e à família das Rutaceae. Assim como todas as plantas cítricas, é nativa da Ásia, e foi introduzida no Brasil pelos portugueses na época da colonização. Atualmente, os pomares mais produtivos encontram-se nas regiões de clima tropical e subtropical, destacando-se como grandes produtores de *citrus* o Brasil, Estados Unidos, Espanha, países do Mediterrâneo, México, China e África do Sul (CITRUS, 2018; TOPUZ *et al.*, 2005).

O Brasil é considerado o maior produtor de laranjas no mundo, ocupando o 1º lugar no *ranking* dos países produtores (FAOSTAT, 2014; TEIXEIRA *et al.*, 2020). A laranja é a principal fruta produzida no Brasil sendo responsável por 25,1% da produção total de frutas no país (IBGE, 2016). Em 2017 a produtividade total de laranja no Brasil foi de 17.459.908 toneladas colhidas em uma área plantada de 631.686 hectares. A produção Brasileira é distribuída nas Regiões Sudeste (82,35%), Sul (7,28%), Nordeste (7,25%), Norte (2,06%) e Centro Oeste (1,06%) (IBGE, 2017). O Estado de São Paulo aparece como o maior produtor nacional de laranja, com produção de 13.357.732 toneladas, representando 76,5% da produção nacional (IBGE, 2017) e 98% do suco que o país produz (FAOSTAT, 2014). Minas Gerais aparece em segundo lugar, com produção de 951.240 toneladas, representando 5,45% da produção nacional (IBGE, 2017).

Os frutos da laranjeira são denominados bagas, recebendo o nome particular de hesperídio. Seu tamanho e sua forma mudam segundo a variedade. O fruto apresenta epicarpo (flavedo), mesocarpo (albedo), endocarpo e sementes (SIMÃO, 1998). Na casca encontram-se as substâncias responsáveis pelo aroma e cor da fruta; na parte comestível a laranja é composta por segmentos que possuem vesículas de suco e sementes. Apesar de compartilharem essas características gerais, os tipos de laranja divergem em tamanho, cor, quantidade de açúcares, de sementes, acidez, época de colheita, etc. São mais de 100 variedades de laranja cultivadas pelo mundo, porém, no Brasil, as mais comuns são as laranjas Bahia, Pera, Natal, Valência, Hamlin, Westin e Rubi (CITRUS, 2018).

A laranja é um alimento altamente nutritivo, fonte de compostos fitoquímicos como vitamina C, flavonoides e carotenoides, que também lhe conferem propriedade antioxidante, além de conter óleo essencial e alguns minerais (TEIXEIRA *et al.*, 2020; TOPUZ *et al.*, 2005). Quase todas as laranjas produzidas são consumidas *in natura* ou como suco natural, suco pasteurizado e suco reconstituído (TOPUZ *et al.*, 2005). Mas a laranja também é comumente consumida em geleias (IGUAL *et al.*, 2016), extratos para medicamentos fitoterápicos (MENICHINI *et al.*, 2011) e suplementos dietéticos (RESTANI *et al.*, 2017).

### 3.2 Qualidade dos frutos consumidos no Brasil

De acordo com Molnar (1995),

A qualidade dos produtos alimentares, em conformidade com os requisitos e aceitação dos consumidores, é determinada pelos seus atributos sensoriais, composição química, propriedades físicas, nível de contaminantes microbiológicos e toxicológicos, prazo de validade, embalagem e rotulagem.

Kyriacou e Roupael (2018) enfatizam que a qualidade das frutas e hortaliças é uma síntese dinâmica de suas propriedades físico-químicas relacionadas à percepção do consumidor.

Em geral, a qualidade do fruto inclui um amplo grupo de características externas e internas. A qualidade externa da fruta inclui cor, forma, tamanho e ausência de defeitos, enquanto a qualidade interna consiste em sabor, textura, aroma, valor nutricional, doçura, acidez, prazo de validade e ausência de defeitos (MUSACCHI; SERRA, 2018). Por isso, os aspectos sensoriais, como aparência, aroma, sabor e textura (Tabela 1), percebidos pelos sentidos humanos e influenciados pelas características físicas e físico-químicas dos alimentos, devem ser levados em consideração para caracterizar a qualidade dos alimentos. Ademais, deve-se salientar que esses atributos sejam avaliados como um todo e não isoladamente, pois separados eles são poucos representativos da qualidade (CHITARRA; CHITARRA, 2005).

Tabela 1 - Atributos Sensoriais de qualidade para frutas e hortaliças.

Atributos Sensoriais	Componentes
Aparência	<ul style="list-style-type: none"> <li>• Tamanho: dimensões, peso, volume</li> <li>• Forma: diâmetro longitudinal x transversal, uniformidade</li> <li>• Brilho: lustre, aparência externa</li> <li>• Defeitos: externos e internos (morfológicos, físicos x mecânicos, fisiológicos, patológicos, entomológicos)</li> </ul>
Textura	<ul style="list-style-type: none"> <li>• Firmeza, dureza, maciez, fragilidade, succulência, granulabilidade, resistência e fibrosidade</li> </ul>
Sabor e aroma	<ul style="list-style-type: none"> <li>• Doçura, acidez, adstringência, amargor, aroma (voláteis), sabores e odores estranhos</li> </ul>

Fonte: Chitarra e Chitarra (2005).

Todos os atributos sensoriais devem ser levados em consideração para se avaliar a qualidade das frutas. Entretanto, normalmente o consumidor julga o produto inicialmente pela aparência (cor, tamanho e forma) e depois pelos demais atributos de qualidade, embora estes possam determinar se o produto será comprado ou não novamente (VANOLI; BUCCHERI, 2012). Um produto que não seja bem avaliado visualmente possivelmente não passará por nenhuma outra avaliação e provavelmente será rejeitado (VILAS BOAS, 2006).

Como destacado por Musacchi e Serra (2018), a aparência das frutas frescas é o primeiro traço de direcionamento de compra que impacta a decisão do consumidor. No conceito de “aparência”, várias características externas da fruta estão incluídas, como tamanho, forma, ausência de defeitos e cor.

Dentre as características de aparência, a cor é uma das características de qualidade mais atrativas para o consumidor, pois determina a percepção visual do consumidor e influencia a decisão de compra da fruta (GOLDENBERG *et al.*, 2017). A cor, além de ser utilizada como indicador de qualidade, também é utilizada como indicador de maturação dos frutos, e conseqüentemente, aroma, textura, valor nutritivo e integridade do fruto (FERNANDES; SOUZA, 2001). Os pigmentos vegetais, com destaque para as clorofilas, carotenoides e antocianinas, desempenham um papel fundamental na coloração dos vegetais. Genericamente, os frutos quando imaturos apresentam uma coloração esverdeada que vai cedendo lugar a outras cores (amarelo, vermelho, azul, violeta) com o amadurecimento (VILAS BOAS, 2006).

Em relação à textura das frutas e hortaliças, Chitarra e Chitarra (2005) a descrevem como um conjunto de propriedades do alimento, compostas por características físicas perceptíveis pelo tato e que se relacionam com a deformação, desintegração e fluxo do alimento, sob a aplicação de uma força. Nas frutas em geral, a textura é em grande parte ditada pela maciez ou pela firmeza da polpa. Na sua maioria, a perda progressiva da firmeza ou seu amaciamento ocorre como consequência do amadurecimento normal, um processo complexo que envolve diferentes mecanismos, tais como a perda do turgor celular, redução no tamanho e distribuição dos polímeros das paredes celulares, ação de enzimas hidrolíticas, dentre outras (CHITARRA; CHITARRA, 2005). A firmeza da fruta é usada principalmente no nível comercial para decidir o tempo ideal de colheita, além de ser referência em conjunto com outros parâmetros para determinar o estágio de maturidade (MUSACCHI; SERRA, 2018).

O sabor é um fator decisivo na escolha e na aceitação dos alimentos. É determinado pelos estímulos do gosto, aroma e textura, sendo que o gosto é marcado por cinco sensações básicas: doce, ácido, amargo, salgado e umami (CHITARRA; CHITARRA, 2005; DUTCOSKY, 2013), enquanto inúmeros aromas podem ser sentidos em função da emissão

volátil. A textura tem participação fundamental na percepção sensorial, pois a liberação de compostos presentes nas frutas que são perceptíveis ao paladar, também está relacionada com a estrutura do tecido (CHITARRA; CHITARRA, 2005).

O amadurecimento das frutas, em geral, conduz a um aumento na doçura devido ao aumento no teor de açúcares simples, decréscimo da acidez e da adstringência, respectivamente, pela redução nos teores de ácidos e fenólicos. A doçura e a acidez são predominantes em alguns produtos (CHITARRA; CHITARRA, 2005). A doçura é uma característica interna da qualidade da maioria das frutas, crucial para a aceitação do consumidor. A acidez é uma característica fundamental para a qualidade interna da fruta, representando a intensidade sensorial dos ácidos orgânicos totais, com ênfase para os ácidos málico, cítrico e tartárico (MUSACCHI; SERRA, 2018). O amargor também é importante, do mesmo modo que a adstringência, sendo ambos decorrentes do tipo de compostos fenólicos presentes (CHITARRA; CHITARRA, 2005).

Por fim, pode-se descrever o aroma como um conjunto de sensações percebidas pelo olfato, que é estimulado pelos componentes voláteis dos alimentos. Os compostos voláteis, responsáveis pelo aroma, são de diferentes classes químicas, termolábeis e presentes em quantidades extremamente diminutas (FRANCO, 2003). Embora presentes em concentrações muito baixas, os compostos orgânicos voláteis, formados durante as transformações bioquímicas da maturação, são responsáveis pelo aroma típico e têm grande importância na aceitação dos produtos hortícolas, notadamente das frutas (CHITARRA; CHITARRA, 2005).

### **3.3 Análise sensorial**

A análise sensorial é uma disciplina científica que evoca, mede, analisa e interpreta reações às características de alimentos e outros materiais da forma com que são percebidos pelos cinco sentidos: visão, olfato, gosto, tato e audição (IFT, 1981). Além disso, a análise sensorial é considerada um fator essencial que liga a pesquisa e o desenvolvimento de novos produtos, focando nos aspectos tecnológicos dos alimentos, levando em consideração tanto o comportamento dos consumidores quanto o *marketing* (MOUSSAOUI; VARELA, 2010).

Nos últimos anos, a indústria de alimentos tem reconhecido a análise sensorial como uma importante ferramenta para o controle e gestão da qualidade, com o intuito de avaliar a qualidade de um produto (MINIM, 2013). Na comercialização de alimentos *in natura* ou mesmo durante seu processo de desenvolvimento e aprimoramento, a indústria e os pesquisadores devem se esforçar para entender os desejos e as necessidades dos consumidores (VARELA *et al.*, 2010), bem como sua percepção em relação aos alimentos, a fim de garantir-

lhes satisfação no consumo dos produtos (CRUZ *et al.*, 2013). A qualidade sensorial está relacionada à aceitação e confiança do consumidor no produto, sendo definida pela interação entre o alimento e o consumidor. Assim, a qualidade sensorial depende tanto das características sensoriais dos alimentos quanto de como os consumidores as percebem (ARES *et al.*, 2009). Para entender a satisfação do consumidor, é possível medir a reação a estímulos resultantes do consumo dos alimentos por meios de testes sensoriais, como os testes afetivos (MOUSSAOUI; VARELA, 2010).

Os testes afetivos, que também são chamados de testes de consumidores, não requerem treinamento de provadores e são importantes ferramentas para determinar a opinião do consumidor em relação a ideias, características específicas ou globais dos produtos analisados (MINIM, 2013). Os métodos afetivos medem o quanto o consumidor gostou de um determinado alimento ou produto, avaliando sua preferência ou aceitabilidade (DUTCOSKY, 2013).

Os testes de aceitabilidade são exemplos de teste afetivo. A aceitação sensorial é um importante elemento para determinar a qualidade do produto e a consequente influência na decisão do consumidor. A qualidade sensorial pode ser aferida com base nos resultados dos testes de aceitação, que são testes capazes de medir com precisão as respostas afetivas do consumidor (KIM; HOUT; LEE, 2018).

Diferentes escalas podem ser utilizadas para quantificar as respostas afetivas dos consumidores (YEUNG *et al.*, 2021). A escala hedônica é um dos métodos mais empregados para medir a aceitação de produtos. Nela, o consumidor expressa sua aceitação em uma escala previamente estabelecida que varia, gradativamente, indicando o grau de gostar ou não gostar (CHAVES; SPROESSER, 1993; KIM *et al.*, 2018). A escala hedônica pode ser apresentada de forma estruturada, não estruturada, facial, numericamente ou verbalmente, horizontalmente ou verticalmente (DRAKE, 2007; MINIM, 2013).

Outras escalas podem ser utilizadas para aferir as respostas dos consumidores. Dentre elas, tem-se a escala do ideal (*Just About Right*), que tem como objetivo determinar a intensidade de atributos pré-estabelecidos que são desejados pelos consumidores em um produto, ou seja a intensidade que o consumidor considera no produto como ideal (DUTCOSKY, 2013). Assim, as intensidades de atributos também podem ser escaladas pelos consumidores usando escalas de ideal de 9 pontos (DRAKE, 2007). Já a escala de atitude tem o objetivo de determinar o grau de aceitação dos consumidores com base em suas atitudes. Nesta escala, pode-se aferir o quanto o consumidor estaria disposto a consumir o produto ou a pagar mais por ele. Essa escala é considerada mais sensível que a escala hedônica, pois o fato

de registrar uma atitude do consumidor é mais realista do que registrar o interesse afetivo pelo produto (MINIM, 2013).

A aceitação sensorial do consumidor é um elemento essencial para determinar a qualidade do produto. Consequentemente, a decisão da qualidade sensorial deve ser tomada com base nos resultados dos métodos de teste de aceitação do consumidor, que são capazes de medir com precisão as respostas afetivas do consumidor a produtos com validade e confiabilidade (KIM *et al.*, 2018).

#### **4 CONSIDERAÇÕES GERAIS**

A qualidade de um alimento ou produto está intimamente ligada aos aspectos físico-químicos, microbiológicos e sensoriais. O aspecto de qualidade sensorial é aquele relacionado à qualidade percebida pelo consumidor, o que influencia na decisão de compra do produto. Diante do fato de a qualidade estar diretamente ligada à satisfação do consumidor, é necessário levar em consideração que esse consumidor deve ditar essa qualidade. Portanto, as características de qualidade sensorial, necessitam ser monitoradas e avaliadas por meio de estudos com consumidores. Ao estabelecer padrões de qualidade sensorial de frutas, automaticamente garantimos a satisfação do consumidor.

Desta forma, conhecer as expectativas e preferência dos consumidores de frutas é essencial para detectar os mercados que podem ser explorados com maior precisão e qualidade. Por isso, torna-se necessário o uso de novas técnicas para avaliar a interação das características físicas, químicas e físico-químicas com a aceitação sensorial dos consumidores para garantir a satisfação do consumidor.

## REFERÊNCIAS

- ABE, L. T. *et al.* Compostos fenólicos e capacidade antioxidante de cultivares de uvas *Vitis lambrusca* L. e *Vitis vinífera* L. **Ciência e Tecnologia de Alimentos**, Campinas, v. 27, n. 2, p. 394-400, 2007.
- ABAFRUTAS – Associação Brasileira dos Produtores e Exportadores de Frutas e Derivados, 2021. Disponível em: <<https://abrafrutas.org/2021/04/dados-de-exportacao-1a-bimestre-2021/>>. Acesso em: 15 jul. 2021.
- ABECITRUS – Associação Nacional dos Exportadores de Sucos Cítricos. Laranja e suco, 2018. Disponível em: <<http://www.citrusbr.com/laranjaesuco/?ins=20>>. Acesso em: 15 jul. 2021.
- ANTONIĆ, B. *et al.* Grape pomace valorization: A systematic review and meta-analysis. **Foods**, v. 9, n. 11, p. 1627, 2020.
- CARVALHO, S. F. *et al.* Comportamento e qualidade de cultivares de morango (*Fragaria x ananassa* Duch.) na região de Pelotas-RS. **Revista Iberoamericana de Tecnología Postcosecha**, v.14, p.176-180, 2013.
- CHANG, Y. T. *et al.* Prediction of specialty coffee flavors based on near-infrared spectra using machine-and deep-learning methods. **Journal of the Science of Food and Agriculture**, v. 101, n. 11, p. 4705-4714, 2021.
- CHAVES, J. B. P.; SPROESSER, R. L. **Práticas de laboratório de análise sensorial de alimentos e bebidas**. Viçosa: UFV, 1993.
- CHIARINI, R. F. *et al.* Processamento mínimo de tangor ‘Murcott’: tipos de corte, sanificação e eliminação do excesso de líquidos. **Brazilian Journal of Food Technology**, v. 20, e2016041, p. 1-9, 2017.
- CHITARRA, M. I. F.; CHITARRA, A. B. **Pós-colheita de frutas e hortaliças: fisiologia e manuseio**. 2. ed. Lavras: UFLA, 2005.
- CORRÊA, S. C. *et al.* Prediction of the sensory acceptance of fruits by physical and physical-chemical parameters using multivariate models. **LWT – Food Science and Thecnology**, v. 59, n. 2, p. 666-672, 2014.
- CRUZ, A. G. *et al.* 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, n. 4, p. 549-556, 2011.
- DE JESUS FILHO, M.; *et al.* Physicochemical, microbiological and sensory acceptance alterations of strawberries caused by gamma radiation and storage time. **Scientia Horticulturae**, v. 238, p. 187-194, 2018.
- Departamento de Agricultura dos Estados Unidos, Citrus: World Markets and Trade. [Conectados]. USDA (2016). Disponível em: <<http://apps.fas.usda.gov/psdonline/circulars/citrus.pdf>>. Acessado em 14 Jul. 2021.

DRAKE, M. A. Invited review: Sensory analysis of dairy foods. **Journal of dairy science**, v. 90, n. 11, p. 4925-4937, 2007.

DUTCOSKY, S. D. **Análise sensorial de alimentos**. 4 ed. Curitiba: Champagnat, 2013.

EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária. Frutas e hortaliças, 2021. Disponível em: <<https://www.embrapa.br/grandes-contribuicoes-para-a-agricultura-brasileira/frutas-e-hortalicas>>. Acesso em: 15 jul. 2021.

EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária. Sistema de Produção de Uva de Mesa do Norte de Minas Gerais, 2005. Disponível em: <https://sistemasdeproducao.cnptia.embrapa.br/FontesHTML/Uva/MesaNorteMinas/cultivares.htm>. Acesso em: 15 jul. 2021.

FAO - Food and Agriculture Organization of the United Nations. Disponível em: <http://faostat.fao.org/>. Acesso em: 15 jul. 2021.

FAOSTAT – FOOD AGRICULTURAL ORGANIZATION OF THE UNITED NATIONS. Production: Countries by commodity, 2014. Disponível em: <<http://faostat.fao.org/site/339/default.aspx>>. Acesso em: 15 jul. 2021.

FERLA, N. J.; MARCHETTI, M. M.; GONÇALVES, D. Predatory mites (Acari) associated with strawberry and neighboring plants in the State of Rio Grande do Sul. **Biota Neotrop**, v. 7, n. 2, p. 1-8, 2007.

FERNANDES, P. H. S.; SOUZA, S. D. O. **Tecnologia de produtos de origem vegetal: processamento de frutas e hortaliças**. Uberlândia: SENAI-MG, 2001.

FIGUEIREDO, J.O. Variedades copa de sabor comercial. **Citricultura brasileira**. 2. ed. Campinas: Fundação Cargil, p. 228-264, 1991.

FRANCIS, F. J. Anthocyanins and betalains: composition and applications. **Cereal Foods World**, v. 45, n. 5, p. 208-213, 2000.

FRANCO, M. R. B. **Aroma e sabor de alimentos: temas atuais**. São Paulo: Varela, 2003.

GALLI, V. *et al.* Validation of reference genes for accurate normalization of gene expression for real time-quantitative PCR in strawberry fruits using different cultivars and osmotic stresses. **Gene**, v. 554, n. 2, p. 205-214, 2015.

GASTÓN, A. *et al.* Development of a sensory quality index for strawberries based on correlation between sensory data and consumer perception. **Postharvest Biology and Technology**, v. 51, n. 1, p. 97-102, 2009.

GIAMPIERI, F. *et al.* The strawberry: Composition, nutritional quality, and impact on human health. **Nutrition**, v. 28, n. 1, p. 9-19, 2012.

GIAMPIERI, F. *et al.* Strawberry as a health promoter: an evidence based review. **Food & Function**, v. 6, n. 5, p. 1386-1398, 2015.

GIMENEZ, G.; ANDRIOLO, J.; GODOI, R. Cultivo sem solo do morangueiro. **Ciência Rural**, v. 38, n. 1, p. 273-279, 2008.

GINÉ-BORDONABA, J.; TERRY, L. A. Effect of deficit irrigation and methyl jasmonate application on the composition of strawberry (*Fragaria ananassa*) fruit and leaves. **Scientia Horticulturae**, v. 199, p. 63-70, 2016.

GOLDENBERG, L. *et al.* Mandarin fruit quality: a review. **Journal of the Science of Food and Agriculture**, v. 98, n. 1, p. 18-26, 2018.

GONZALEZ VIEJO, C.; FUENTES, S. Low-cost methods to assess beer quality using artificial intelligence involving robotics, an electronic nose, and machine learning. **Fermentation**, v. 6, n. 4, p. 104, 2020.

IBGE – Instituto Brasileiro de Geografia e Estatística. **Pesquisa de Orçamentos Familiares: POF 2017-2018. Análise do consumo alimentar pessoal no Brasil.** Rio de Janeiro, 2020.

IBGE – Instituto Brasileiro de Geografia e Estatística. **Produção agrícola municipal. Culturas temporárias e permanentes,** Rio de Janeiro, v. 43, p. 1-62, 2016.

IBGE – Instituto Brasileiro de Geografia e Estatística. **Produção Agrícola Municipal,** 2017. Disponível em: <https://sidra.ibge.gov.br/pesquisa/pam/tabelas>. Acesso em: 15 Jul. 2021.

IGUAL, M. *et al.* Stability of micronutrients and phytochemicals of grapefruit jam as affected by the obtention process. **Food Science and Technology International**, v. 22, n. 3, p. 203-212, 2016.

INSTITUTE OF FOOD TECHNOLOGISTS. Sensory evaluation division. Guidelines for the preparation and review of papers reporting sensory evaluation date. **Food Technology**, Chicago, v. 35, n. 4, p. 16-17, 1981.

KIM, M. A.; HOUT, D. V.; LEE, H. S. Degree of satisfaction-difference (DOSD) method for measuring consumer acceptance: Comparative and absolute measures of satisfaction based on signal detection theory. **Food Quality and Preference**, v. 68, p. 167-172, 2018.

KYRIACOU, M. C.; ROUPHAEL, Y. Towards a new definition of quality for fresh fruits and vegetables. **Scientia Horticulturae**, v. 234, p. 463-469, 2018.

LI, D.; YE, Q.; JIANG, L.; LUO, Z. Effects of nano-tio<sub>2</sub>-ldpe packaging on postharvest quality and antioxidant capacity of strawberry (*fragaria ananassa* Duch.) stored at refrigeration temperature. **Journal of the Science of Food and Agriculture**, v. 97, n. 4, p. 1116-1123, 2017.

MENICHINI, F. *et al.* Phytochemical profile, antioxidant, anti-inflammatory and hypoglycemic potential of hydroalcoholic extracts from *Citrus medica* L. cv Diamante flowers, leaves and fruits at two maturity stages. **Food and Chemical Toxicology**, v. 49, n. 7, p. 1549-1555, 2011.

MINIM, V. P. R. **Análise sensorial: estudos com consumidores.** 3 ed. Viçosa, MG: UFV, 2013.

MOLNAR, P. A model for overall description of food quality. **Food Quality and preference**, v. 6, n. 3, p. 185-190, 1995.

MOUSSAOUI, K. A.; VARELA, P. Exploring consumer product profiling techniques and their linkage to a quantitative descriptive analysis. **Food Quality and Preference**, v. 21, n. 8, p. 1088-1099, 2010.

MUSACCHI, S.; SERRA, S. Apple fruit quality: Overview on pre-harvest factors. **Scientia Horticulturae**, v. 234, p. 409–430, 2018.

NUNES, C. A. *et al.* Prediction of consumer acceptance in some thermoprocessed food by physical measurements and multivariate modeling. **Journal of Food Processing and Preservation**, v. 41, n. 5. e13178, 2017.

PADOVANI, M. I. **Morango**: o delicado e o saboroso fruto da integração dos povos. São Paulo: Ícone, 1991. 68 p. (Coleção Brasil Agrícola).

PENG, X. *et al.* Variations in aroma and specific flavor in strawberry under different colored light-quality selective plastic film. **Flavour and Fragrance Journal**, v. 35, n. 3, p. 350-359, 2020.

RESTANI, P. **Food Supplements Containing Botanicals: Benefits, Side Effects and Regulatory Aspects**. Cham: Springer International Publishing, 2017.

RODRIGUES, N. *et al.* Application of an electronic tongue as a single-run tool for olive oils' physicochemical and sensory simultaneous assessment. **Talanta**, v. 197, p. 363–373, 2019.

ROSA, H. T. *et al.* Crescimento vegetativo e produtivo de duas cultivares de morango sob épocas de plantio em ambiente subtropical. **Revista Ciência Agronômica**, v. 44, p. 604-613, 2013.

SARIDAŞ, M. A. Seasonal variation of strawberry fruit quality in widely grown cultivars under Mediterranean climate condition. **Journal of Food Composition and Analysis**, v. 97, p. 103733, 2021.

SEBRAE - Serviço Brasileiro de Apoio às Micro e Pequenas Empresas. O cultivo e o mercado da uva, 2016. Disponível em: <http://www.sebrae.com.br>. Acesso em: 15 jul. 2021.

SEBRAE - Serviço Brasileiro de Apoio às Micro e Pequenas Empresas. O cultivo e o mercado da tangerina, 2016. Disponível em: <http://www.sebrae.com.br/>. Acesso em: 15 jul. 2021.

SEBRAE – Serviço Brasileiro de Apoio às Micro e Pequenas Empresas. Agronegócio: fruticultura, 2015. Disponível em: <http://www.sebraemercados.com.br/fruticultura>. Acessado em: 15 jul. 2021.

SIMÃO, S. **Tratado de fruticultura**. Piracicaba: FEALQ, 1998.

SIQUEIRA, H. H. *et al.* Armazenamento de morango sob atmosfera modificada e refrigeração. **Ciência e Agrotecnologia**, v. 33, p. 1712-1715, 2009.

SPAGNOL, W. A. *et al.* Redução de perdas nas cadeias de frutas e hortaliças pela análise da vida útil dinâmica. **Brazilian Journal of Food Technology**, v. 21, e2016070, 2018.

TEIXEIRA, F. *et al.* Addition of orange peel in orange jam: evaluation of sensory, physicochemical, and nutritional characteristics. **Molecules**, v. 25, n. 7, p. 1670, 2020.

TIAN, H. *et al.* Combined application of electronic nose analysis and back-propagation neural network and random forest models for assessing yogurt flavor acceptability. **Journal of Food Measurement and Characterization**, v. 14, n. 1, p. 573–583, 2020.

TOPUZ, A. *et al.* Physical and nutritional properties of four orange varieties. **Journal of Food Engineering**, v. 66, n. 4, p. 519-523, 2005.

VANOLI, M.; BUCCHERI, M. **Overview of the methods for assessing harvest maturity.** 2012.

VARELA, P. *et al.* Influence of brand information on consumers' expectations and liking of powdered drinks in central location tests. **Food Quality and Preference**, v. 21, n. 7, p. 873-880, 2010.

VIGITEL - Vigilância de fatores de risco e proteção para doenças crônicas por inquérito telefônico. **Estimativas sobre frequência e distribuição sociodemográfica de fatores de risco e proteção para doenças crônicas nas capitais dos 26 estados brasileiros e no distrito federal em 2017.** Ministério da Saúde, Brasília, p. 1 -130, 2018.

VILAS BOAS, E. V. B. **Qualidade de alimentos vegetais.** Lavras: UFLA/FAEPE, 2006.

WHO - World Health Organization. **Diet, nutrition and the prevention chronic diseases.** Geneva: World Health Organization, 2003.

YEUNG, H. F. *et al.* A tale of 3 scales: How do the 9-pt, labeled affective magnitude, and unstructured visual analog scales differentiate real product sets of fresh berries? **Food Quality and Preference**, v. 88, p. 104109, 2021.

YU, P.; LOW, M. Y.; ZHOU, W. Development of a partial least squares-artificial neural network (PLS-ANN) hybrid model for the prediction of consumer liking scores of ready-to-drink green tea beverages. **Food Research International**, v. 103, p. 68-75, 2018.

## **SEGUNDA PARTE**

### **CAPÍTULO - APRENDIZADO DE MÁQUINA: UMA ABORDAGEM DA INTELIGÊNCIA ARTIFICIAL APLICADA À CIÊNCIA DOS ALIMENTOS**

Capítulo a ser publicado no livro “Análise Sensorial aplicada a sabores e texturas de produtos de panificação e confeitaria”

Editora: Appris

**Michele Nayara RIBEIRO<sup>1</sup>, Ana Carla Marques PINHEIRO<sup>1</sup>, Danton Diego FERREIRA<sup>2</sup>**

<sup>1</sup>Departamento de Ciência dos Alimentos, Universidade Federal de Lavras – UFLA, Lavras, MG, Brasil

<sup>2</sup>Departamento de Automática, Universidade Federal de Lavras – UFLA, Lavras, MG, Brasil

## 1 INTRODUÇÃO

Quando pensamos em qualidade de alimentos, automaticamente estamos pensando em qualidade sensorial. Sabe-se que a qualidade depende tanto dos fatores extrínsecos dos alimentos como dos fatores intrínsecos, e uma forma de determinar a qualidade é através das medidas sensoriais. Desta forma, a ciência sensorial de alimentos é extremamente importante para o desenvolvimento de novos produtos, pois são essenciais para compreender os consumidores e determinar os parâmetros de qualidade, fazendo a ponte entre as características dos alimentos e a aceitação do consumidor.

Como uma rota alternativa para as ciências sensoriais, o aprendizado de máquina, que faz parte da inteligência artificial, surge com técnicas avançadas para acelerar as descobertas e representar uma nova tendência em resolução de problemas. Hoje a tecnologia de aprendizado de máquina aparece em muitos produtos e tem sido aplicado com sucesso em análises sensoriais de alimentos e bebidas. Desta forma, o nosso objetivo é fazer uma introdução ao aprendizado de máquina e suas aplicações. Este capítulo fornece uma revisão sobre as principais abordagens do aprendizado de máquina, os algoritmos utilizados, as vantagens dos métodos e suas aplicações, principalmente aquelas voltadas para estudos sensoriais. O principal objetivo é que o leitor entenda o que é o aprendizado de máquina, e como ele pode utilizá-lo para avaliar os dados sensoriais de alimentos.

### 1.1 O que é aprendizado de máquina

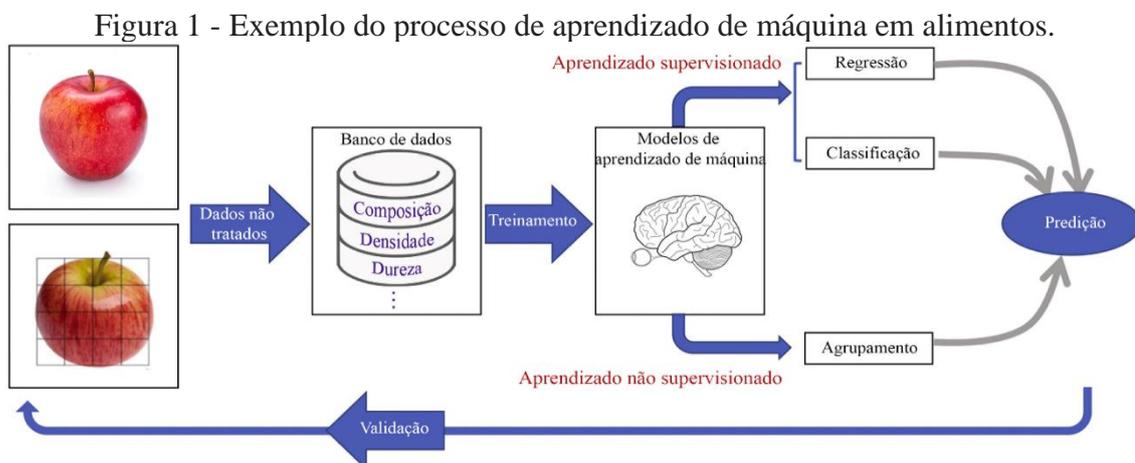
O termo aprendizado de máquina foi criado em 1959 por Arthur Samuel, um americano pioneiro no campo de jogos de computador e inteligência artificial (SAMUEL, 1959). Desde então, houve uma constante busca pela criação de máquinas inteligentes e capazes de se igualar ao raciocínio humano, utilizando-se de tomadas de decisões inteligentes (SOLOMONOFF, 1957). O objetivo era permitir que as máquinas desempenhassem funções cognitivas, aprendendo com experiências anteriores e resolvendo problemas complexos em condições que variam em relação às observações anteriores. Alimentado pelo crescimento exponencial do poder de computação e coleta de dados, juntamente com a ampla variedade de aplicações práticas, o aprendizado de máquina é hoje um campo de importância estratégica (GAMBELLA; GHADDAR; NAOUM-SAWAYA, 2021).

O *machine learning* (ML), em português aprendizado de máquina, é a área de pesquisa que utiliza métodos estatísticos para construir algoritmos inteligentes e que podem se aprimorar

automaticamente por meio da experiência adquirida a partir dos dados. O ML é visto como parte da Inteligência Artificial (IA), que se concentra no uso de dados e de algoritmos para imitar a forma como os seres humanos aprendem, melhorando gradualmente sua precisão (SINDHU; NIVEDHA; PRAKASH, 2020). De acordo com Muller e Massaron (2019), o ML é apenas parte do que um sistema exige para se tornar IA. Ela permite que a IA execute algumas tarefas, como, adaptar-se a novas circunstâncias não previstas pelo desenvolvedor original; detectar padrões em diferentes conjuntos de dados; definir comportamentos com base em padrões reconhecidos; e tomar decisões com base no sucesso ou na falha desses comportamentos. Assim, o ML surgiu como o método preferido para o desenvolvimento de *software* prático para visão computacional, reconhecimento de fala, processamento de linguagem natural, e controle de robôs, dentre outras aplicações (JORDAN; MITCHELL, 2015).

O ML se concentra na capacidade das máquinas de abstrair e generalizar os dados à medida que alteram o algoritmo com base nos dados que está processando, ou seja, a máquina aprende conforme vai recebendo e processando os dados. Algoritmos de ML podem ser usados para preparar as máquinas para pensar como humanos (SINDHU; NIVEDHA; PRAKASH, 2020). De modo geral, o ML depende do aprendizado de um modelo estatístico, que gera uma saída com base em determinadas entradas. As entradas, ou seja, as medidas do preditor, são dados que representam os parâmetros que definem um problema. A saída, ou seja, a resposta é um valor que representa a solução (GAMBELLA; GHADDAR; NAOUM-SAWAYA, 2021).

O objetivo principal do ML é que os algoritmos aprendam com os dados e dessa forma possa tomar decisões com o mínimo de intervenção humana. Em detalhes, o ML pode “aprender com o exemplo”, analisando conjuntos de dados existentes (LIU *et al.*, 2021). A Figura 1 ilustra um cenário geral para métodos de aprendizado de máquina.



Fonte: Adaptado Liu *et al.* (2021).

Como demonstrado na Figura 1, o primeiro passo é escolher o objeto de estudo. Pode-se escolher qualquer objeto de estudo, visível ou não, como alimentos, bebidas, imagens, ondas eletromagnéticas, circuitos elétricos, radiografias, vidros, agricultura, questionários entre outros. Logo após, é necessário realizar o levantamento das características ou atributos os quais identificam o objeto de estudo definido. Nesta etapa a extração dos parâmetros (características/atributos) pode ser realizada por intermédio de medidas instrumentais, como análises físico-químicas, sensoriais, medidas de sensores químicos entre outros. Estes dados podem ser gerados por meio de experimentos, simulações ou mineração em bancos de dados existentes. Estes atributos podem ser os mais diversos possíveis, como: a cor dos olhos de uma pessoa, a doçura de uma fruta, a acidez de uma bebida, a cor de um pão, os dados de composição de qualquer alimento, a temperatura ambiente em um determinado instante do dia ou a velocidade de movimento de um projétil. Os parâmetros são utilizados para treinar o algoritmo para que ele consiga aprender as características do objeto de estudo.

Os dados disponíveis são, geralmente, divididos em dois, treinamento e teste. Algoritmos de aprendizado de máquina constroem um modelo baseado em dados de amostra, conhecidos como "dados de treinamento", a fim de fazer previsões ou decisões sem serem explicitamente programados para isso. O treinamento oferece ao algoritmo todos os exemplos de entrada e os resultados esperados a partir delas. Assim o algoritmo cria uma função ou um modelo capaz de prever uma saída a partir dos dados de entrada. A saída é a probabilidade de acertar uma classe ou valor numérico. Desta forma, o aprendizado de máquina é então utilizado para inferir alguns padrões dentro do conjunto de dados e estabelecer um modelo preditivo.

O ponto crucial do ML é a generalização, ou seja, o objetivo é generalizar a função de saída para que funcione em dados além do conjunto de treinamento (MULLER; MASSARON, 2019). Portanto, a função dos dados de teste é verificar a capacidade de generalização do modelo construído. Para isso, é importante que os dados de teste não tenham tido algum contato com o modelo durante o seu treinamento. Por exemplo, no trabalho realizado por Nunes *et al.* (2017) os autores utilizaram medidas físico-químicas do pão francês ao longo do tempo de armazenamento para prever a aceitação global dos consumidores. Os autores separaram 20% dos dados para utilizar como teste, ou seja, estas amostras não foram usadas no treinamento (são amostras independentes de todo o processo de construção dos modelos) e foram utilizadas para testar a capacidade preditiva do modelo.

O ML conta com algoritmos para analisar grandes conjuntos de dados. Deve-se ressaltar que nenhum destes algoritmos é capaz de exercitar o livre-arbítrio e não conseguem por si só pensar, sentir ou apresentar qualquer forma de autoconhecimento. O que o ML pode fazer é

realizar análise preditiva bem mais rápido que qualquer ser humano e, como resultado, pode ajudar as pessoas a trabalharem de forma mais eficiente (MULLER; MASSARON, 2019).

O ML pode ser utilizado em muitas áreas da tecnologia e da ciência. Além disto, é possível acompanhar ao longo dos anos diferentes aplicações de ML em diversas áreas, como em detecção de fraudes em alimentos (GOYAL; KUMAR; VERMA, 2021), diagnósticos relacionados a saúde (FATIMA; PASHA, 2017; UDDIN *et al.*, 2019), tecnologia de veículos autônomos (SANTOS; VICTORINO, 2021), reconhecimento de imagens (SOOD; SINGH, 2021; XIONG *et al.*, 2021), classificação de documentos (SHARIF *et al.*, 2020), avaliação financeira (BAO; LIANJU; YUE, 2019), detecção de fraudes em cartão de crédito (DHANKHAD *et al.*, 2018), segmentação de clientes (WU *et al.*, 2021), sistemas de recomendação como em serviços de *streaming* Netflix e Amazon (EL FIKY; HUSSEIN; GOHARY, 2021), aplicativos (SARKER, 2021), mecanismos de busca como o Google (KUCUKYILMAZ *et al.*, 2017), na ciência do vidro (LIU *et al.*, 2021) e no controle de qualidade e desenvolvimento de novos produtos (JIMÉNEZ-CARVELO *et al.*, 2019; RIBEIRO *et al.*, 2021).

## 1.2 Abordagens do aprendizado de máquina

No geral, o ML usa algoritmos que aprendem e otimizam suas operações analisando os dados de entrada para assim prever a saída, ou seja, as respostas. Com a alimentação de novos dados, esses algoritmos tendem a se aprimorar e realizar previsões cada vez mais precisas (UDDIN *et al.*, 2019). Existem algumas variações de como agrupar e classificar os algoritmos de ML, de acordo com seus propósitos e objetivos. É possível dividir os algoritmos do ML em três abordagens principais, sendo elas o aprendizado supervisionado, o aprendizado não supervisionado e o aprendizado por reforço (SIMEONE, 2018).

No aprendizado supervisionado, uma medida de resposta está disponível para cada observação das medidas do preditor e o objetivo é ajustar um modelo que preveja com precisão a resposta das observações futuras (GAMBELLA; GHADDAR; NAOUM-SAWAYA, 2021). Assim, os algoritmos de aprendizado supervisionado constroem um modelo matemático de um conjunto de dados que contém as entradas e as saídas desejadas (RUSSELL; NORVIG, 2010). Mais especificamente, no aprendizado supervisionado, os valores da entrada  $x$  e de saída  $y$  correspondentes estão disponíveis e o objetivo é aprender uma função  $f$  que se aproxime com uma margem de erro aceitável da relação entre a entrada e a saída correspondente. Uma boa função de aprendizado  $f$  permitirá que o algoritmo determine corretamente a saída para entradas

que não faziam parte dos dados de treinamento (GAMBELLA; GHADDAR; NAOUM-SAWAYA, 2021).

A estratégia supervisionada é semelhante a aprendizagem humana sob a supervisão de um professor. O professor fornece exemplos para o aluno aprender e, então, infere regras gerais a partir dos exemplos (MULLER; MASSARON, 2019). Em resumo, no ML supervisionado, o conjunto de dados conterá uma série de entradas. No caso de alimentos e bebidas a entrada pode ser a composição do produto a ser avaliado ou dados descritivos e a saída pode ser, por exemplo, a aceitação dos consumidores. Outro exemplo é utilizar a imagem como dados de entrada. Cotrim *et al.* (2020, 2021) utilizaram imagens dos pães como entrada, com o objetivo de construir uma ferramenta para o reconhecimento e classificação das etapas de panificação, baseada exclusivamente nas mudanças de cor da crosta do pão. Desta forma, o aprendizado de máquina supervisionado pode aprender com os exemplos existentes e assim inferir a relação entre entradas e saídas (LIU *et al.*, 2021).

O ML supervisionado contém algoritmos de regressão e de classificação. Os algoritmos de regressão podem prever a saída como uma função das entradas. A regressão nos fornece a resposta ou os resultados de “quanto” e “qu岸tos” (FATIMA; PASHA, 2017). No caso de alimentos como pães, cafés e frutas, a entrada pode ser características físico-químicas do alimento, como cor, firmeza, acidez, sólidos solúveis, dentre outros. As saídas podem ser, por exemplo, valores de aceitação sensorial. Assim, é possível prever a resposta sensorial de um alimento a partir dos parâmetros físico-químicos (CORRÊA *et al.*, 2014; NUNES *et al.*, 2017; RIBEIRO *et al.*, 2021). Já os algoritmos de classificação podem ser utilizados para rotular ou classificar os alimentos em diferentes categorias. A classificação nos fornece a previsão de *Sim* ou *Não*. Por exemplo, um cookie pode ser classificado de acordo com os padrões de qualidade (FATIMA; PASHA, 2017), ou podemos classificar se o consumidor está satisfeito ou não com a fruta avaliada (RIBEIRO *et al.*, 2021).

O grau de complexidade do modelo depende do tamanho do conjunto de dados de treinamento e do algoritmo utilizado. É aconselhável que modelos mais simples sejam utilizados para pequenos conjuntos de dados de treinamento que não cobrem uniformemente os intervalos de dados. Já os modelos mais complexos necessitam de um grande conjunto de dados de treinamento para evitar *overfitting* (GAMBELLA; GHADDAR; NAOUM-SAWAYA, 2021).

O *overfitting* é uma questão fundamental no aprendizado de máquina supervisionado, que nos impede de generalizar os modelos para ajustar bem os dados observados nos dados de treinamento, bem como os dados não vistos no conjunto de teste. Ele ocorre quando uma função

de aprendizado  $f$  está extremamente ajustada a um determinado conjunto de dados e pode, portanto, não se ajustar a dados adicionais ou prever observações futuras de forma confiável. Assim, o modelo não consegue generalizar dados diferentes, pois devido à presença de ruído, ao tamanho limitado do conjunto de treinamento e à complexidade dos classificadores, ocorre o *overfitting* (YING, 2019).

No aprendizado não supervisionado, o conjunto de treinamento consiste em entradas não rotuladas, ou seja, entradas onde os valores de saída não são conhecidos (SIMEONE, 2018). Portanto, o aprendizado não supervisionado ocorre quando um algoritmo aprende a partir dos exemplos, mas sem nenhuma resposta associada. Neste caso, o algoritmo determina os padrões por conta própria (MULLER; MASSARON, 2019). Desta forma, ele tenta aprender com a distribuição dos dados as características distintivas e as associações nos dados através de medidas de similaridade e dissimilaridade. O principal uso de aprendizado não supervisionado é a análise exploratória de dados, onde o objetivo é segmentar e agrupar as amostras a fim de extrair *insights* (GAMBELLA; GHADDAR; NAOUM-SAWAYA, 2021). Os algoritmos, portanto, aprendem com os dados que não foram rotulados, classificados ou categorizados (JAIN; MURTY; FLYNN, 1999; LIU *et al.*, 2021).

Já o aprendizado por reforço encontra-se, de certo modo, entre o aprendizado supervisionado e não supervisionado. Ao contrário do aprendizado não supervisionado, existe alguma forma de supervisão, mas isso não vem na forma de especificação de uma saída desejada para cada entrada nos dados (SIMEONE, 2018). O aprendizado por reforço ocorre quando você apresenta aos algoritmos exemplos não rotulados e ele necessita tomar decisões, sendo similar ao aprendizado humano por tentativa e erro. Os erros ajudam a aprender, mas causam algumas consequências (seja custo, tempo etc.), ensinando-o qual procedimento tem maior probabilidade de sucesso que outros (MULLER; MASSARON, 2019). O algoritmo de aprendizado por reforço recebe *feedback* do ambiente somente depois de selecionar uma saída para uma determinada entrada ou observação. O *feedback* indica o grau em que a saída, conhecida como ação no aprendizado por reforço, atende aos objetivos (SIMEONE, 2018).

O aprendizado supervisionado e o não supervisionado diferem principalmente pelo fato de que o supervisionado envolve o mapeamento da entrada para a saída. Enquanto o não supervisionado não visa produzir saída na resposta da entrada. E o por reforço aprende com os exemplos e necessita da interação humana ou do ambiente para aprender. O Quadro 1 compara as três principais abordagens do aprendizado de máquina (GOUSE; HELINI, 2019).

Quadro 1 – Comparação entre o aprendizado supervisionado, não supervisionado e por reforço (Continua).

<b>Base</b>	<b>Aprendizado supervisionado</b>	<b>Aprendizado não supervisionado</b>	<b>Aprendizado por reforço</b>
Dados	Dados rotulados	Dados não rotulados	Processo de decisão de Markov
Método	Valores de entrada e saída fornecidos	Apenas valores de entrada fornecidos	Trabalha na interação com o meio ambiente
Complexidade computacional (custo)	Alto (demanda muito tempo de computador, é demorado para treinar e mais complexo para o modelo aprender)	Baixo (resultados de forma bem mais rápida)	Alto (demanda muito tempo de computador, é demorado para treinar e mais complexo para o modelo aprender)
Meta	Predizer a saída com base na entrada. Predizer valores discretos ou contínuos	Predizer padrões ocultos com base na entrada fornecida	Tomada de decisão sequencial, sendo que a próxima entrada depende da decisão do sistema de aprendizado
Análise de dados	Análise assíncrona, tempo não real (modelo é treinado primeiro e usado depois)	Análise síncrona, tempo real (o dado é analisado e o modelo é treinado em tempo real)	Análise síncrona, tempo real (o dado é analisado e o modelo é treinado em tempo real)
Classes	Os rótulos são conhecidos	Os rótulos não são conhecidos	Trabalha na interação com o meio ambiente
Precisão dos resultados	Preciso e confiável	Moderado, mas confiável	Moderado, mas confiável com muitas soluções

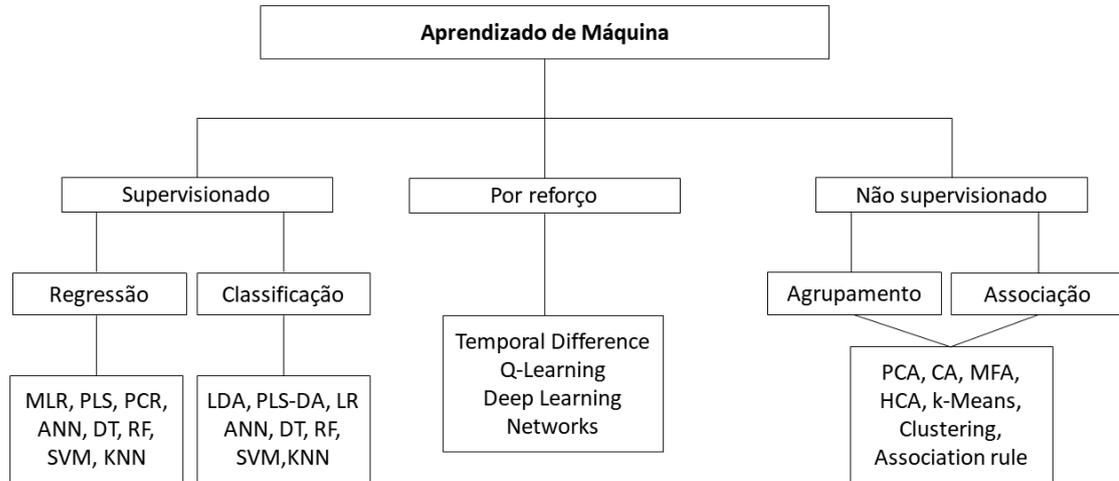
Quadro 1 – Comparação entre o aprendizado supervisionado, não supervisionado e por reforço (Conclusão).

<b>Base</b>	<b>Aprendizado supervisionado</b>	<b>Aprendizado não supervisionado</b>	<b>Aprendizado por reforço</b>
Subáreas	Classificação, regressão, regressão linear, máquinas de vetores de suporte	Clustering, regras de associação, k-médias, clustering hierárquico, algoritmos de redução de dimensionalidade, detecções de anomalias	Processos de decisão de Markov, Policy Learning, Deep Learning e value learning
Aplicações	Reconhecimento de imagem, reconhecimento de fala, previsão, e treinamento de redes neurais e árvores de decisão	Pré-processamento de dados, análise exploratória ou para pré-treinar algoritmos de aprendizagem supervisionada	Teoria do controle, teoria de jogos, direção autônoma, robôs que refletem o comportamento humano e funcionam como um humano, assistentes virtuais

Fonte: Adaptado de Gouse e Helini (2019).

O aprendizado supervisionado é o método mais popular e frequentemente utilizado dentre as três abordagens. Porém, vale ressaltar que todos os algoritmos de ML respondem a mesma lógica, que é representar a realidade usando uma função matemática, que a princípio é desconhecida para o algoritmo, mas pode prever depois de ter observado um conjunto de dados (MULLER; MASSARON, 2019). A Figura 2 apresenta uma visão geral de algumas técnicas disponíveis de aprendizado de máquina nas três abordagens.

Figura 2 - Tipos de aprendizado de máquina.



Legenda: **MLR**: regressão linear múltipla; **PLS**: regressão por mínimos quadrados parciais; **PCR**: regressão por componentes principais; **ANN**: redes neurais artificiais; **DT**: árvore de decisão; **RF**: florestas aleatórias; **SVM**: máquina de vetores de suporte; **KNN**: K-vizinhos mais próximos; **LDA**: análise discriminante linear; **PLS-DA**: análise discriminante por quadrados mínimos parciais; **LR**: regressão logística; **PCA**: análise de componentes principais; **CA**: análise de correspondência; **MFA**: análise de múltiplos fatores; **HCA**: análise de agrupamento hierárquico.

Fonte: Da autora (2021).

### 1.3 Aprendizado de máquina supervisionado

Como explicado na Seção 1.2, o aprendizado supervisionado tem como objetivo inferir padrões, com base em conjunto de treinamento, relacionando os exemplos de dados de entrada e saída. Nesta abordagem é possível construir dois tipos de modelos, dependendo se as saídas são variáveis contínuas ou discretas. No primeiro caso, temos um modelo de regressão e no segundo um modelo de classificação. Como o aprendizado supervisionado é a abordagem mais utilizada, neste tópico abordaremos os principais algoritmos envolvidos na realização da regressão e classificação.

#### 1.3.1 Regressão

Frequentemente os métodos de regressão univariada, são insuficientes para encontrar padrões entre os atributos físico-químicos dos alimentos e bebidas, com os perfis sensoriais, devido à complexidade da matriz e a grande quantidade de compostos e atributos que estão presentes nos alimentos (ZIELINSKI *et al.*, 2014). Perrot *et al.* (2006) destacam que muitas

vezes, uma única propriedade do alimento, como a textura ou o sabor, pode estar relacionada a vários atributos sensoriais, conforme percebido pelo cérebro humano. Vale destacar também que dependendo do produto e de suas características, há o efeito sinérgico que pode mascarar a presença de alguns atributos, especialmente entre as características de sabor e aroma, criando assim uma relação não linear entre estes fatores (NOBLE; EBELER, 2002). Assim, todos estes fatores se combinam e formam então uma relação muito complexa, que dificilmente pode ser analisada por métodos univariados (YU; LOW; ZHOU, 2018).

Os modelos preditivos podem ser criados por análise univariada, em que cada variável é analisada individualmente, ou por análise multivariada, em que várias variáveis são analisadas simultaneamente (CORRÊA *et al.*, 2014). Na análise de alimentos, pode-se observar uma variedade de fatores, tanto intrínsecos como extrínsecos, que influenciam a qualidade de um produto. A qualidade de um produto geralmente é fornecida por parâmetros químicos, físicos, físico-químicos e por parâmetros sensoriais. Desta forma, muitas variáveis podem ser medidas, o que torna necessária a utilização de métodos de análise multivariada.

A regressão multivariada é um conjunto de métodos estatísticos utilizados para analisar dados onde mais de uma variável é medida para cada amostra (BEEBE; KOWALSKI, 1987). Estes métodos possibilitam o estudo simultâneo de diversos fatores de controle em uma determinada resposta. Além disso, possibilitam o desenvolvimento de modelos matemáticos que permitem avaliar a relevância e a significância estatística dos fatores em estudo (TARLEY *et al.*, 2009). O procedimento de calibração é realizado em duas etapas, sendo a construção do modelo e a validação. A primeira etapa da regressão multivariada consiste na construção de modelos de calibração multivariada, a partir da correlação entre a matriz de dados das variáveis instrumentais ( $x$ ) com a matriz de dados das variáveis de interesse ( $y$ ) (FERREIRA, 1999). O desempenho da calibração e da validação é avaliado usando o erro quadrático médio de calibração (RMSEC) e o coeficiente de correlação da calibração ( $R^2$ ) (FAGAN *et al.*, 2007).

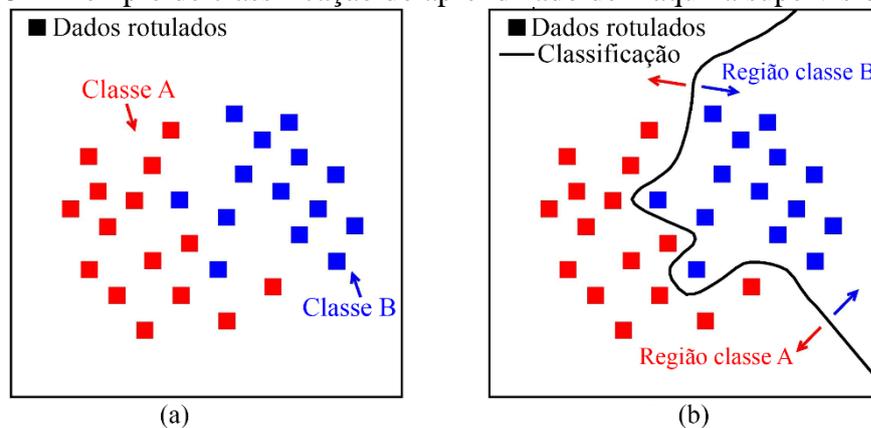
Vários trabalhos na literatura demonstraram que os modelos multivariados são mais apropriados e possuem melhores resultados em comparação com os modelos univariados, para correlacionar parâmetros físicos e físico-químicos a atributos sensoriais de provadores treinados e consumidores (CADENA *et al.*, 2013; CORRÊA *et al.*, 2014; MEHINAGIC *et al.*, 2004; NUNES *et al.*, 2017; PIOMBINO *et al.*, 2013). Assim, os métodos multivariados tornam-se essenciais para este tipo de análise.

### 1.3.2 Classificação

Na classificação supervisionada leva-se em consideração os rótulos, ou seja, há um conjunto prévio de padrões classificados que dão origem ao modelo que prediz a classe de novas amostras (DUDA; HART; STORK, 2012; THARWAT *et al.*, 2017). Desta forma, a tarefa da classificação é decidir a associação de classes dos dados não rotulados ( $x$ ) com o conjunto de dados de treinamento ( $x,y$ ) onde cada  $x_i$  tem uma associação de classe conhecida  $y_i$  (BAUMANN; HOCHBAUM; YANG, 2019; GAMBELLA; GHADDAR; NAOUM-SAWAYA, 2021).

Diferente da regressão, onde a saída é um valor contínuo, a classificação considera problemas onde a saída é discreta, correspondendo aos rótulos de categorias distintas. Por exemplo, como demonstrado na Figura 3, no caso de um problema de classificação binária, os pontos de dados pertencem a duas classes, sendo elas classe A e B. A saída destas classes pode ser representada por valores de saída igual a 0 ou 1 para as classes A e B, respectivamente (LIU *et al.*, 2021).

Figura 3 - Exemplo de classificação do aprendizado de máquina supervisionado.



Fonte: Adaptado Liu *et al.* (2021).

O objetivo dos modelos de classificação é prever a classe de dados desconhecidos, como por exemplo, se o consumidor ficará “satisfeito” ou “não satisfeito” ou se o consumidor “pagaria mais” ou “não pagaria mais”, como função das entradas, como por exemplo, respostas sensoriais do morango. Assim, a variável dependente indicará uma classe e não um valor quantitativo (LIU *et al.*, 2021; RIBEIRO *et al.*, 2021).

### 1.3.3 Algoritmos utilizados no aprendizado de máquina supervisionado

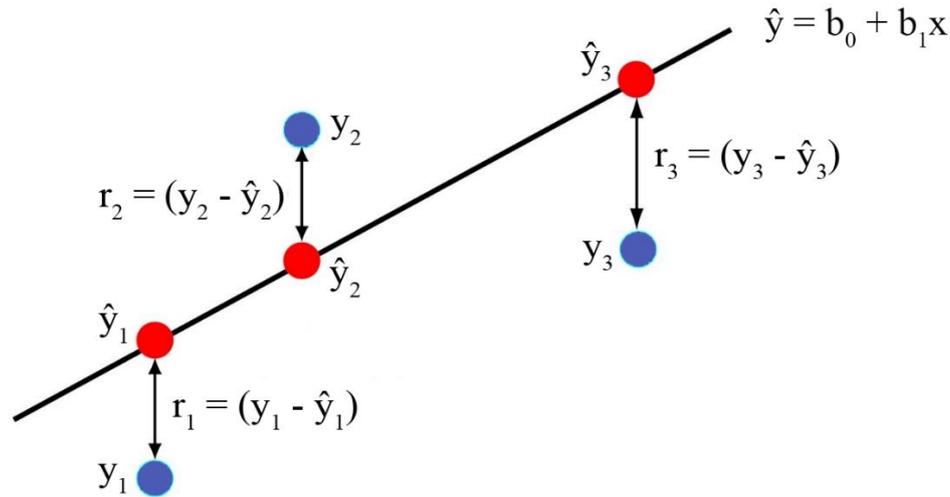
Um algoritmo é um procedimento ou conjunto de passos utilizados para resolver um problema. O objetivo de um algoritmo é gerar uma saída que resolva o problema em estudo. Em alguns casos, como no aprendizado supervisionado, o algoritmo recebe as entradas que irão auxiliar a definir a saída, mas o foco é sempre a saída (MULLER; MASSARON, 2019). Neste tópico será abordado alguns dos algoritmos mais utilizados para regressão e classificação dos dados no contexto do aprendizado supervisionado.

#### ➤ **Regressão linear**

Os modelos de regressão linear são comumente utilizados no aprendizado supervisionado para prever uma resposta quantitativa. A hipótese é que a relação entre as variáveis independentes, que são as medidas de entrada, e a variável dependente, que é a saída do valor real ou resposta, é representada como uma função linear, ou função de regressão com uma precisão razoável (FIGURA 4). Os modelos de regressão linear são considerados modelos simples, de fácil interpretação dos resultados, e possuem várias aplicações (DOSHI-VELEZ; KIM, 2017).

A regressão linear é usada para estudar a relação linear entre um grupo de variáveis independentes (variáveis preditoras, representadas por  $x$ ) e uma ou mais variáveis dependentes (representadas por  $y$ ) (YU; LOW; ZHOU, 2018). A regressão linear visa encontrar uma função linear  $f$  que expressa a relação entre um vetor de entrada  $x$  para uma saída de valor real  $y$  (GAMBELLA; GHADDAR; NAOUM-SAWAYA, 2021).

Figura 4 - Modelo de regressão linear.



Fonte: Da autora (2021).

Em geral, um modelo linear tem a seguinte equação 1:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n \quad (1)$$

Nesta equação,  $y$  é um vetor das variáveis dependentes,  $\beta$  é o vetor de coeficientes de regressão e  $x$  é um vetor para variáveis independentes (YU; LOW; ZHOU, 2018). Como demonstrado na Figura 5, existe uma relação entre a resposta medida ( $y$ ) e uma única variável preditora ( $x$ ). Por exemplo, a intensidade do atributo doçura em iogurte pode ser uma função de diferentes concentrações de sacarose presentes no produto. Desta forma, pode-se prever a concentração de sacarose que é considerada ideal pelos consumidores de iogurte (RIBEIRO *et al.*, 2020).

### ➤ Regressão linear múltipla (MLR)

Em uma regressão linear simples, existe uma relação entre a resposta medida  $y$  e uma única variável preditora  $x$ . Por exemplo, diferentes concentrações de sacarose para prever a doçura ideal de iogurte (RIBEIRO *et al.*, 2020). Entretanto, diversos sistemas e modelos tem como base mais de uma variável preditora. De forma a incorporar e analisar diversas variáveis predictoras e sua resposta média  $y$ , pode-se utilizar o MLR, que relaciona um conjunto de variáveis predictoras  $x = \{x_1, x_2, \dots, x_n\}$  a uma variável resposta através do ajuste de uma equação linear (BAYANE; KRAMER, 1999). Por exemplo, utilizar diferentes parâmetros físico-

químicos como cor, sólidos solúveis, firmeza, acidez, pH (como variáveis preditoras) para prever a doçura ideal de morangos (variável resposta) (RIBEIRO *et al.*, 2021).

Em resumo o MLR refere-se à predição de uma única variável dependente ou variável resposta a partir de várias variáveis independentes ou variáveis preditoras, sendo considerada a forma mais básica da regressão linear. Frequentemente, a regressão linear que utiliza uma única variável independente é insuficiente para explicar a relação entre as variáveis independentes e dependentes. Isso porque é possível encontrar uma grande quantidade de variáveis preditoras na avaliação sensorial de alimentos e bebidas (YU; LOW; ZHOU, 2018).

O método de MLR possui a vantagem de que toda a informação disponível nas variáveis empregadas nos cálculos é utilizada pelo modelo. Entretanto, isto pode resultar em uma colinearidade. Deste modo, para utilizar o MLR é necessário que o número de variáveis não seja maior que o número de amostras de calibração. Portanto, é necessário selecionar um número de variáveis inferior ao número de amostras e que sejam relevantes para a predição do valor de interesse (FERREIRA, 1999).

#### ➤ **Regressão por mínimos quadrados parciais (PLS)**

O PLS foi desenvolvido na década de 1970 como uma ferramenta das Ciências Econômicas. Desde então, ele foi adotado em vários campos, principalmente na quimiometria, na área das ciências, como método estatístico (ROSIPAL; KRÄMER, 2006; YU; LOW; ZHOU, 2018). O PLS é a abordagem mais utilizada para a regressão linear multivariada, constituindo um gráfico das variáveis independentes *versus* as variáveis dependentes em um espaço multidimensional, minimizando os erros da soma dos quadrados dos desvios (YU; LOW; ZHOU, 2018).

O método PLS permite análises de dados mais complexos e pode ser considerado uma combinação entre MLR e a análise de componentes principais (PCA). Ele é um método de regressão multivariada que tem como objetivo reduzir a dimensionalidade do problema estudado. Ao invés de utilizar todas as variáveis independentes para a regressão, ele constrói novas variáveis latentes conhecidas como componentes principais, que são as combinações lineares das variáveis originais e não são observadas ou medidas diretamente. Assim, o PLS cria o modelo utilizando somente as variáveis latentes. Desta forma, é possível desenvolver modelos utilizando unicamente as variáveis que realmente caracterizam os dados (ROSIPAL; KRÄMER, 2006; WOLD; SJÖSTRÖM; ERIKSSON, 2001).

Uma das grandes vantagens do PLS é poder trabalhar com um conjunto de dados com um grande número de variáveis descritoras. O MLR não é viável quando o número de variáveis é maior que o número de observações ou amostras. Assim, no PLS pode haver algumas variáveis latentes que são suficientes para explicar a maior parte da variação nas variáveis dependentes. Portanto, o PLS usa um conjunto extraído de variáveis latentes das variáveis independentes originais para prever as variáveis resposta usando os preditores (YU; LOW; ZHOU, 2018). Como os métodos descritos acima, o PLS busca uma correlação entre uma resposta medida  $y$  e um conjunto de variáveis predictoras  $x$ . Este método é extremamente útil quando temos muitas observações (um grande número de respostas medidas) e poucas variáveis predictoras ( $|x|$  é pequena) (LIN *et al.*, 2016).

O número de componentes escolhidos é um fator importante no PLS. Embora seja possível usar todos os componentes na construção do modelo PLS, isso nem sempre é feito, pois os primeiros componentes principais explicam uma maior parte dos dados, enquanto os outros costumam explicar uma quantidade menor de variância e conter ruídos. Entretanto, se os dados não forem lineares, vai resultar em componentes principais que explicam pouco a variância dos dados, fazendo com que o PLS precise de mais componentes principais. Métodos de transformação de dados podem ser aplicados antes de gerar o modelo para remover as não linearidades, o que pode diminuir o número de componentes necessários para construir modelos de PLS (GELADI; KOWALSKI, 1986).

### ➤ **Regressão por componentes principais (PCR)**

O método de PCR é também um método de regressão multivariada que objetiva reduzir a dimensionalidade dos dados analisados (LIN *et al.*, 2016). Ele combina os métodos de PCA com o PLS (OLIVIERI, 2018). Ao invés de utilizar todas as variáveis predictoras  $x$ , o PCR constrói um novo conjunto de variáveis predictoras  $x_p$ , que representa o conjunto dos componentes principais dados pelo método PCA. Então, uma análise de regressão PLS é realizada neste novo conjunto de variáveis predictoras  $x_p$  (OLIVIERI, 2018).

Vale destacar que ambos os algoritmos de PCR e PLS transformam o grande número das variáveis originais em um número reduzido de variáveis, denominadas como componentes principais, que são combinações lineares das variáveis originais. A grande diferença entre estes algoritmos é que o PCR aplica um PCA nos dados originais e em seguida, com as pontuações obtidas, cria um modelo de regressão linear múltipla. Já o PLS tenta explicar a variância

máxima entre as variáveis, mas ponderando a correlação entre cada variável original com a variável resposta (LÓPEZ-FERIA *et al.*, 2007).

➤ **Análise discriminante linear (LDA)**

O LDA é uma abordagem de classificação que utiliza a redução de dimensionalidade. Ele é frequentemente utilizado em conjunto de dados com muitas entradas, onde a redução do número de variáveis é necessária para obter uma classificação mais robusta (GAMBELLA; GHADDAR; NAOUM-SAWAYA, 2021). Assim, a técnica LDA reduz o número de variáveis do problema de classificação, o que reduz a dimensionalidade dos dados, garantindo assim a máxima separação da classe. Para isto, o LDA calcula a distância entre as médias de classes diferentes, para maximizar a variância entre as classes afim de que elas fiquem separadas e calcula a distância entre a média e as amostras de cada classe, a fim de minimizar as diferenças dentro da classe (THARWAT *et al.*, 2017). Maximizar a distância mínima entre cada amostra de classe e a média total da classe é uma forma de otimização da LDA (CHEN *et al.*, 2013).

Assim como no MLR, no LDA é necessário que o número de variáveis não seja maior que o número de amostras de calibração (SHARMA; PALIWAL, 2012). O LDA realiza a classificação utilizando todas as variáveis disponíveis. Como resultado, ele gera uma matriz binária, onde o valor 1 indica que a entrada pertence à classe classificada e o valor 0 indica que a entrada não pertence a classe classificada (THARWAT *et al.*, 2017).

➤ **Análise discriminante por quadrados mínimos parciais (PLS-DA)**

O PLS-DA é um método de classificação supervisionado que parte do pressuposto de que várias classes podem ser separadas pela rotação dos componentes principais de forma a obter uma separação máxima entre as classes (FIDELIS *et al.*, 2017; MARGRAF *et al.*, 2016). Assim, o PLS-DA é um método de classificação utilizado para criar modelos lineares discriminantes (INDAH; MARTENS; NAES, 2007; NOCAIRI *et al.*, 2005). Ele utiliza a regressão PLS, sendo capaz de reduzir a dimensionalidade dos dados, operando somente sobre seus componentes principais. No PLS-DA,  $x$  é uma matriz preditora e a variável de resposta  $y$  é binária. Ela assume o valor 1 quando uma determinada amostra pertence à classe estudada, e assume o valor 0 caso contrário (LENHARDT *et al.*, 2014). Quando a regressão PLS é desenvolvida, o valor de resposta  $y_{\text{pred}}$  é previsto para uma nova amostra. A decisão é baseada

na comparação dos  $y_{\text{pred}}$  com dados variáveis categóricas em  $y$ . A amostra é atribuída à classe, quando a variável  $y$  é a mais próxima de  $y_{\text{pred}}$  (FIDELIS *et al.*, 2017).

➤ **Regressão logística (LR)**

A LR é um método poderoso e bem estabelecido para classificação supervisionada. A LR ajuda a encontrar a probabilidade de que uma nova instância pertença a uma determinada classe. Como é uma probabilidade, o resultado fica entre 0 e 1 (UDDIN *et al.*, 2019). Portanto, na regressão logística a variável dependente é considerada binária. O valor predito por um modelo de LR sempre está entre 0 e 1 e pode ser interpretado como a probabilidade de uma amostra pertencer a uma determinada classe (BAUMANN; HOCHBAUM; YANG, 2019).

Para usar o LR como um classificador binário, um limite precisa ser atribuído para diferenciar as duas classes. Por exemplo, pode-se determinar um valor de probabilidade superior a 0,50 para uma instância de entrada para classificá-la como “classe A”; caso contrário, “classe B” (UDDIN *et al.*, 2019). Portanto, uma amostra é atribuída a classe A quando sua previsão é maior que o limite predefinido e a classe B quando a previsão é menor ou igual ao limite (BAUMANN; HOCHBAUM; YANG, 2019). Para ajustar o modelo de regressão logística e evitar *overfitting*, a seleção de variáveis pode ser realizada onde apenas os subconjuntos mais relevantes das variáveis  $x$  são mantidos no modelo (GAMBELLA; GHADDAR; NAOUM-SAWAYA, 2021).

➤ **Rede neural artificial (ANN)**

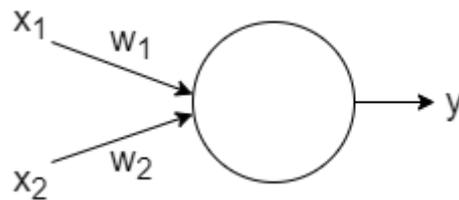
Uma ANN é um algoritmo inspirado nas redes neurais biológicas que constituem os cérebros dos seres humanos (BAO; LIANJU; YUE, 2019). O cérebro é composto por uma rede de células conectadas entre si, denominadas neurônios. Cada neurônio é uma unidade simples de processamento que recebe e combina sinais e informações recebidos de outros neurônios. Se o sinal combinado for forte o suficiente, ele ativa o neurônio, e gera uma resposta (saída) (MINIM, 2013; TAUD; MAS, 2017; YU; LOW; ZHOU, 2018). Em uma ANN, a informação é transferida na forma de sinais, da mesma forma que a informação percorre o cérebro. Cada neurônio é responsável por processar dados locais, sendo que o comportamento inteligente da rede vem das interações entre seus neurônios (HAYKIN, 2008; ROJAS, 2013).

O modelo computacional de neurônio mais utilizado é o apresentado por Rosenblatt (1958), denominado *Perceptron*. Ele é utilizado em detrimento do pioneiro modelo de neurônio

descrito por McCulloch e Pitts (1943), cujas saídas eram somente um único valor binário. Neste modelo, com a ajuda de diferentes funções de ativação, podemos ter como saída de cada neurônio um valor real, também entre 0 e 1 (ROJAS, 2013). Um simples *Perceptron* pode ser entendido como demonstrado pela Figura 5. Ela exibe um neurônio com duas variáveis de entrada ( $x_1$  e  $x_2$ ) e dois pesos ( $w_1$  e  $w_2$ ) e uma única saída ( $y$ ). Basicamente, este neurônio implementa a seguinte equação (2):

$$y = x_1 w_1 + x_2 w_2 \quad (2)$$

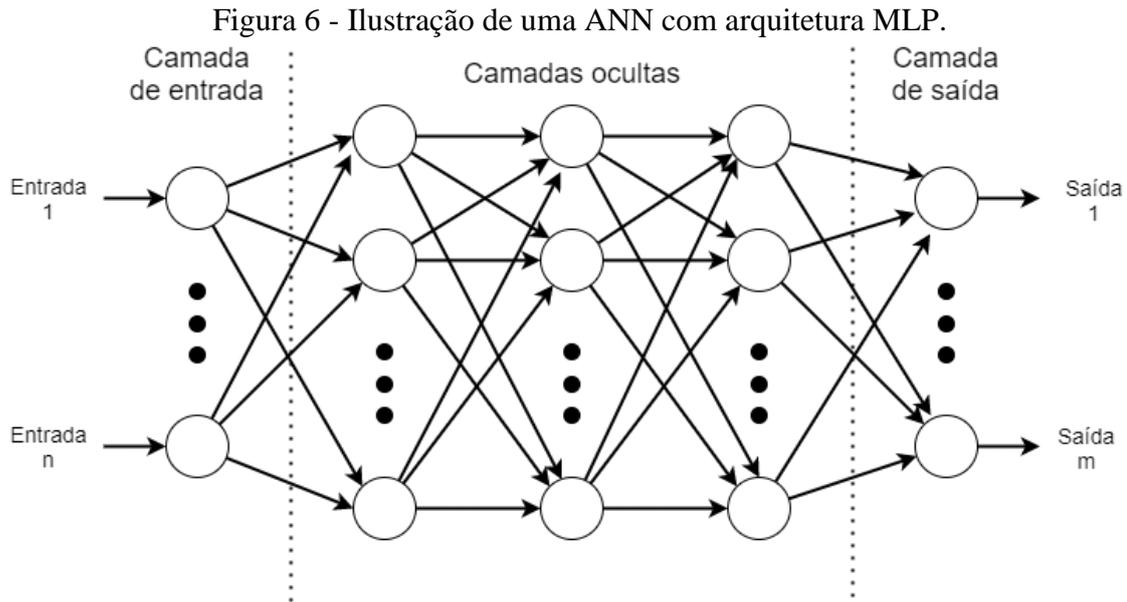
Figura 5 - Exemplo de um neurônio do tipo *Perceptron* com duas variáveis de entrada.



Fonte: Da autora (2021).

Uma rede neural pode ser formada por uma ou mais camadas de neurônios. A entrada para neurônios individuais é determinada pela soma das saídas dos neurônios na camada anterior, que por sua vez é afetada por pesos de conexões neurais individuais e vieses de neurônios anteriores. Os pesos de uma ANN representam como a informação é processada pela rede neural. A entrada de rede é então processada pela função de transferência de neurônios, e a informação, ou sinal, é passada para os neurônios na camada subsequente. Existem várias funções de transferência usadas na ANN, com as funções lineares e sigmoidais sendo as funções de transferência mais comumente utilizadas (YU; LOW; ZHOU, 2018).

Uma ANN consiste em um conjunto de *perceptrons* ou neurônios interconectados. Assim, cada neurônio é capaz de receber sinais de entrada e transformá-los em um sinal de saída usando uma função de transferência. Os neurônios são organizados em camadas e cada neurônio é conectado a todos os outros neurônios das camadas adjacentes (BAUMANN; HOCHBAUM.; YANG, 2019). As camadas de uma ANN geralmente podem ser divididas em camadas de entrada, saída e ocultas (BAUMANN; HOCHBAUM; YANG, 2019; LIU *et al.*, 2021; YU; LOW; ZHOU, 2018), como pode ser observado na Figura 6.



Fonte: Da autora (2021).

Redes *Multi-layer Perceptron* (MLP) são compostas por neurônios do tipo *Perceptron*, e são divididas em camadas, sendo uma camada de entrada, uma camada de saída e  $n$  camadas intermediárias ou camadas ocultas, sendo  $n > 0$ . Cada camada é conectada unicamente com sua camada anterior e sua camada posterior. Todo o processo de aprendizado de uma rede MLP é realizado em suas camadas intermediárias (DUDA; HART; STORK, 2012). A primeira camada é a camada de entrada, onde os valores das variáveis são alimentados na rede. A camada de entrada geralmente corresponde às variáveis independentes e seu tamanho é determinado pela dimensionalidade do conjunto de dados de entrada. A segunda camada é a camada oculta que é uma camada de neurônios entre as camadas de entrada e saída e que não tem interação direta com os dados de entrada e saída. Esta camada compreende a principal força motriz por trás da capacidade da ANN de resolver problemas não lineares complexos. A última camada é a camada de saída onde a previsão da rede realizada. Nesta camada gera-se a saída da ANN, que na maioria dos casos, é o valor previsto de uma variável dependente em uma regressão, ou rótulo de classificação (BAUMANN; HOCHBAUM.; YANG, 2019; YU; LOW; ZHOU, 2018).

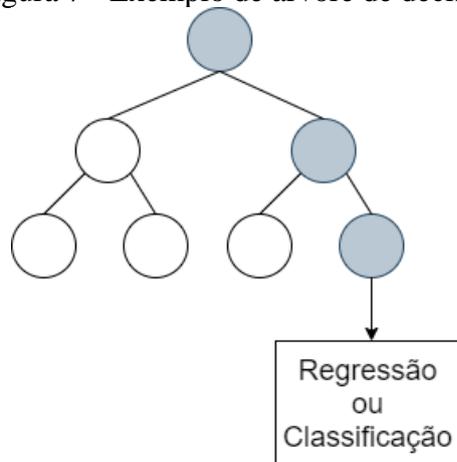
Uma ilustração de uma rede MLP é dada na Figura 6. Ela descreve uma rede MLP com as variáveis de entrada e os valores de saída, além dos neurônios artificiais divididos em três camadas intermediárias. É possível notar que a conexão entre neurônios só é realizada entre três camadas subsequentes. Nesta figura, cada *perceptron* representa um neurônio artificial e cada seta representa uma conexão da saída de um neurônio artificial para a entrada de outro. Desta forma, o modelo ANN começa passando as características de cada amostra para a camada

de entrada, e então processa essas características através das camadas ocultas, finalmente alcançando a camada de saída onde a resposta final será dada com base nos pesos. Esses pesos são atribuídos a cada recurso com base em sua importância relativa. O processo de ajuste de pesos, conhecido como treinamento, é repetido em vários loops, visando minimizar os erros entre a classe prevista e a classe verdadeira (BAO; LIANJU; YUE, 2019).

### ➤ **Árvore de decisão (DT)**

A DT prevê um valor ou rótulo para um novo objeto com base nos valores de suas entradas (BAUMANN; HOCHBAUM; YANG, 2019). Os resultados preditivos da DT podem ser representados como um grafo acíclico direcionado na forma de uma árvore (FIGURA 7), sendo assim facilmente compreendidos (BAO; LIANJU; YUE, 2019). Uma DT é definida como árvores de regressão quando a variável de destino é contínua e como árvores de classificação quando a variável de destino é discreta (BAUMANN; HOCHBAUM; YANG, 2019).

Figura 7 - Exemplo de árvore de decisão.



Fonte: Da autora (2021).

Uma árvore de classificação e regressão (CART) (BREIMAN *et al.*, 1984) é uma estrutura clássica usada em muitas técnicas de aprendizado de máquina. Como demonstrado na Figura 7, uma árvore de decisão é composta por nós internos, sendo que o primeiro nó é denominado como raiz e os nós da última camada são denominados como folhas. Desta forma, a estrutura se inicia com um nó (raiz), que contém todas as entradas do conjunto de dados. Em seguida, ele constrói partições binárias do conjunto de dados de forma que cada nó seja dividido em dois subnós. Este processo é iniciado no nó raiz e executado recursivamente. Os nós finais de um CART são chamados de folhas e podem conter uma única observação do conjunto de

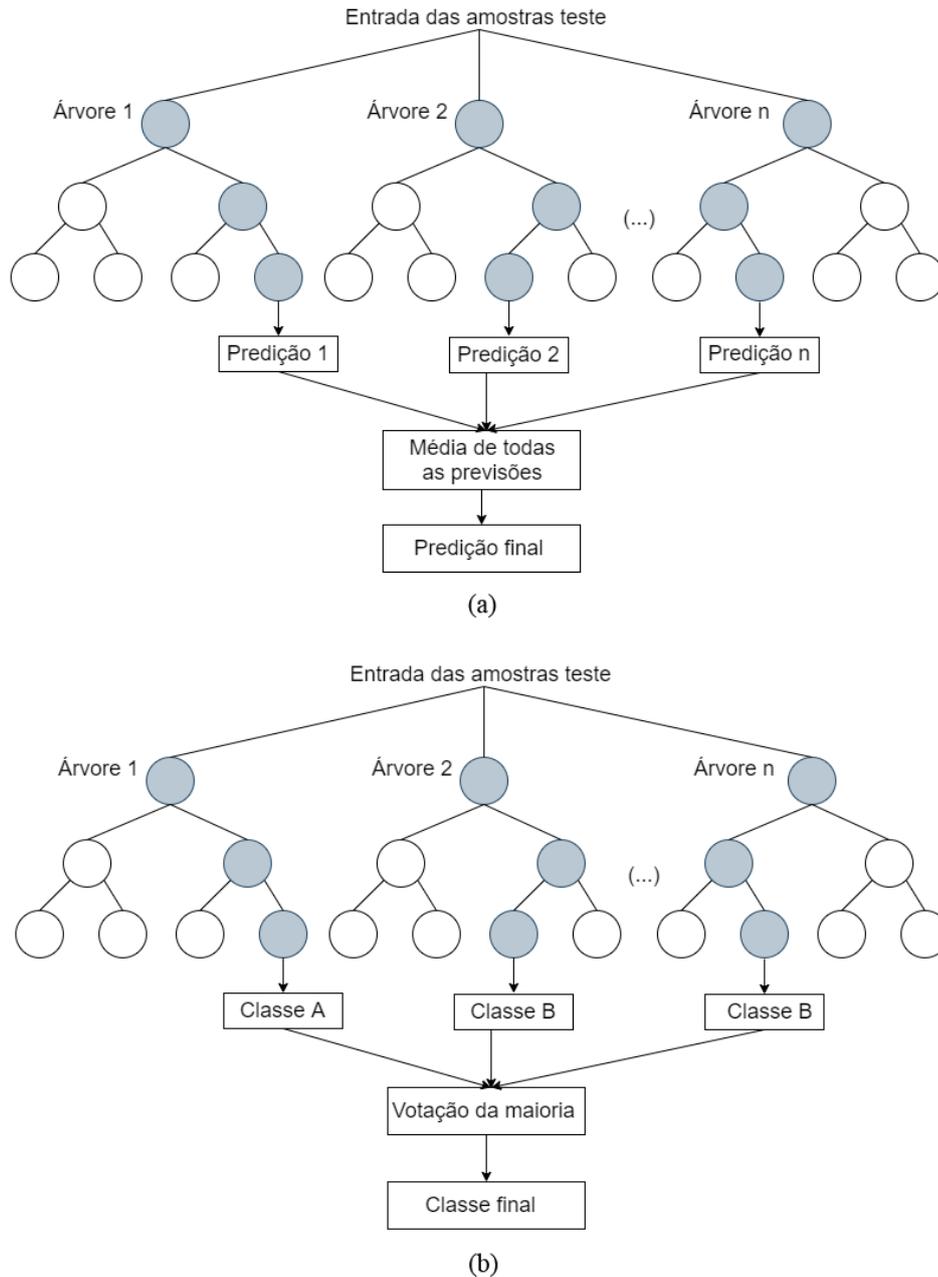
dados se a árvore estiver completamente construída. Assim, cada nó interno representa um teste em um recurso. Os arcos que saem de um nó interno são rotulados com uma faixa específica de valores possíveis. Cada nó folha representa um valor de predição ou um rótulo de classe. Dado um novo objeto, uma série de testes ao longo dos nós internos, começando pelo nó raiz, determinará um nó folha que prevê o valor previsto da variável ou a classe (BAO; LIANJU; YUE, 2019; BAUMANN; HOCHBAUM; YANG, 2019).

### ➤ Floresta aleatória (RF)

Floresta aleatória (RF) (BREIMAN, 2001) é um algoritmo de aprendizado de máquina versátil que pode ser usado tanto para tarefas de regressão como de classificação. Além disto, este algoritmo demonstra um desempenho robusto em uma gama de conjuntos de dados (SHAH *et al.*, 2020). Como um algoritmo de conjunto, ele pode alcançar o melhor desempenho da classe com baixo erro de generalização (WYNER *et al.*, 2017). Além disso, este algoritmo pode lidar com muitas variáveis de entrada e é capaz de selecionar as mais importantes variáveis para os modelos de regressão e de classificação (SHAH *et al.*, 2020), além de precisar de poucos parâmetros de ajuste (AHMAD; MOURSHED; REZGUI, 2017). Destaca-se que uma das grandes vantagens do RF é que seus modelos apresentam alta precisão mesmo com um pequeno conjunto de dados de treinamento (HAN *et al.*, 2017).

Em resumo, a RF (BREIMAN, 2001) é um conjunto de CARTs (FIGURA 8) e, portanto, enquadra-se na categoria de *ensembles* (máquinas de comitê). Cada CART dentro de um RF é construído aleatoriamente, usando dois processos de randomização. O primeiro é o bootstrap, que consiste em selecionar um subconjunto das entradas do conjunto de dados para construir cada CART. A segunda é a seleção de variável, que considera apenas um subconjunto das variáveis dependentes originais em cada árvore. Vale destacar que as árvores do RF não avaliam as mesmas variáveis, cada árvore avalia um subconjunto de variáveis e em diferente ordem, e o resultado é a média dos resultados de cada árvore. Em um RF, o resultado para cada entrada do conjunto de dados é calculado como a classe mais classificada (no caso de usar árvores de classificação) ou a média dos valores previstos para a variável dependente (no caso de usar árvores de regressão) (FIGURA 8). Desta forma, RF fornece uma precisão melhor do que um único CART, uma vez que a resposta final é calculada usando os valores de saída do conjunto de CART.

Figura 8 - Exemplo de floresta aleatória. (a) RF para regressão e predição de variável contínua. (b) RF para classificação e predição de variável discreta.



Fonte: Da autora (2021).

### ➤ K-Vizinhos mais próximos (KNN)

KNN é um dos algoritmos mais reconhecidos em identificação de padrões estatísticos (COVER; HART, 1967). A ideia principal por trás do modelo KNN é que ele prevê os rótulos das novas amostras de entrada de acordo com o conjunto mais próximo (ou k- vizinhos mais próximos) das amostras previamente rotuladas (BAO; LIANJU; YUE, 2019). Ou seja, ele encontra as observações mais semelhantes a observação que será prevista e então infere uma

possível resposta tirando a média dos valores vizinhos ou escolhendo a resposta mais frequente (MULLER; MASSARON, 2019). Assim, a predição do valor da saída é determinada pela posição de entrada usando o valor médio dos K pontos (LIU *et al.*, 2021).

Normalmente KNN calcula os vizinhos mais próximos de uma observação depois de usar uma medida de distância. A distância euclidiana é comumente usada em modelos KNN para medir a distância entre a nova amostra e as amostras de treinamento anteriores. Também pode usar a distância Manhattan, que funciona melhor quando existem muitas características redundantes nos dados. Vale lembrar que é necessário testar cada distância como uma hipótese distinta e verificar por validação cruzada, qual funciona melhor para o problema em questão (BAO; LIANJU; YUE, 2019; MULLER; MASSARON, 2019). A vantagem do KNN é que ele dispensa treinamento, ou seja, não há pesos/parâmetros a serem atualizados/ajustados.

#### ➤ **Máquina de vetores de suporte (SVM)**

O SVM é outro algoritmo de aprendizado de máquina supervisionado popular, proposto pela primeira vez por Cortes e Vapnik (1995). O SVM é utilizado tanto para a regressão como para classificação e se destaca em comparação a outros algoritmos por causa de suas soluções superiores de resolver o problema de esparsidade (BAO; LIANJU; YUE, 2019). Além disto, o SVM apresenta diversas qualidades que o tornam atraente para muitos problemas de dados, como o fato de ser utilizado para classificação binária e de várias classes, regressão e detecção de dados anômalos ou novos; por realizar tratamento robusto de dados ruidosos e sobreajuste; além de apresentar capacidade de tratar de soluções com muitas variáveis; e de realizar detecção automática de não linearidade nos dados (MULLER; MASSARON, 2019).

Dado um conjunto de exemplos de treinamento, cada um marcado como pertencente a uma das duas categorias, um algoritmo de treinamento SVM constrói um modelo que prevê se um novo exemplo se enquadra em uma categoria ou em outra. Basicamente, sua ideia principal é projetar os dados de entrada em um espaço de recursos de alta dimensão e então encontrar um hiperplano apoiado pelos vetores de suporte para separar as duas classes com uma margem máxima. Com base nos recursos dos vetores de suporte, o rótulo da nova amostra de entrada pode ser previsto (BAO; LIANJU; YUE, 2019).

Além de realizar a classificação linear, os SVMs podem realizar com eficiência uma classificação não linear usando o que é chamado SVM kernel (LIU *et al.*, 2021). O SVM linear usa funções lineares para expressar um conjunto de hiperplanos lineares e assim dividir o espaço de entrada em diferentes regiões de classe. Os coeficientes das funções lineares são

determinados maximizando a separação/margem dos pontos conhecidos mais próximos em ambos os lados do hiperplano (BURGES, 1998; LIU *et al.*, 2021). Já o SVM Kernel usa uma função kernel que descreve a correlação entre uma posição de entrada e os pontos conhecidos do conjunto de treinamento, ou seja, para os quais a classe é conhecida. Isso produz um conjunto de hiperplanos não lineares que podem ser usados para classificação (CRISTIANINI; SHAWE-TAYLOR, 2000; LIU *et al.*, 2021).

### **1.3.4 Validação dos modelos do aprendizado supervisionado**

A validação de modelos caracteriza a segunda etapa de um projeto de ML, e otimiza a relação no sentido de uma melhor descrição na resposta de interesse (FERREIRA, 1999), ou seja, a confiabilidade estatística dos modelos é numericamente testada em vários procedimentos (KIRALIJ; FERREIRA, 2009). Esta validação estatística é necessária para garantir a confiabilidade, qualidade e eficácia dos modelos de regressão e classificação, pois testa o modelo prevendo concentrações de amostras, de preferência não usadas na construção, para estabelecer se o modelo de fato irá refletir o comportamento da resposta de interesse (FERREIRA, 1999).

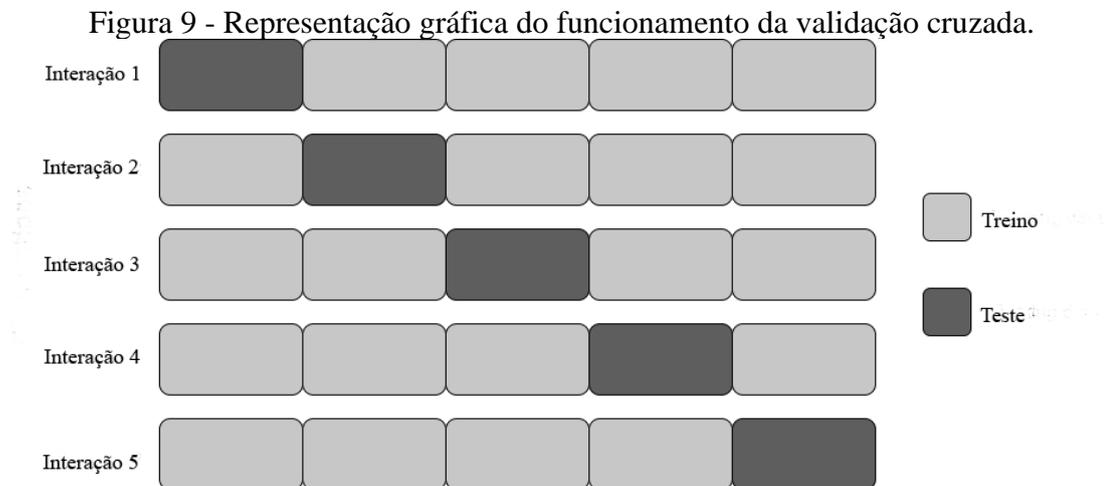
Na validação externa, um conjunto independente de dados, ou seja, um conjunto de dados que não participaram da construção do modelo, é deixado de fora do treinamento e é usado para testar o modelo de regressão/classificação. Se o conjunto de validação externa for bem ajustado pelo modelo, pode-se dizer com maior confiança que o modelo é representativo dos dados e não está super ajustado. Embora o erro do modelo estimado através do uso de um conjunto de validação externa seja de maior precisão em comparação com a validação cruzada, este método requer que o experimentador deixe de fora parte de todo o conjunto de dados (normalmente 20% dos dados gerais), o que pode resultar em perda substancial em termos de informações capturadas pelo modelo desenvolvido (FABER; RAJKO, 2007; RIEDL; ESSLINGER; FAUHL-HASSEK, 2015; YU; LOW; ZHOU, 2018). Assim, ao dividir o conjunto de dados em treinamento e teste, pode-se deixar de fora do treinamento alguns exemplos úteis. Além disto, quando não há muitos exemplos, esses problemas são acrescidos da instabilidade dos resultados da amostragem, além do risco de dividir os dados de modo desfavorável (MULLER; MASSARON, 2019).

A validação cruzada é um método para treinar um algoritmo de aprendizado de máquina e pode ser usada em tarefas de regressão e classificação. Neste método, as amostras são divididas repetidamente em um subconjunto de treinamento e avaliação, e vários modelos são

avaliados. Um dos métodos de validação cruzada mais comuns é o *k-fold*, onde *k* é um parâmetro definido pelo usuário que indica o número de dobras que o conjunto de dados será dividido.

Em resumo, na validação cruzada, a validação do modelo de regressão é dividida em várias rodadas, em que um número de observações é particionado para servir como o conjunto de dados de validação. Os dados restantes são usados para treinar o modelo de regressão, e o modelo desenvolvido é testado usando o conjunto de validação. Este processo é repetido várias vezes, com um conjunto diferente de observações ou dados sendo particionados em cada rodada, e o erro médio do conjunto de validação é usado como uma estimativa do erro do modelo de regressão geral (YU; LOW; ZHOU, 2018).

A Figura 9 dá um exemplo de como as amostras são particionadas usando um algoritmo de validação cruzada *k-fold*. Nesse caso, o algoritmo considera  $k = 5$ . A cada iteração, as amostras são divididas em cinco dobras, sendo uma dobra usada para treinamento e as demais para validação. Percebe-se que, em cada uma das *k* iterações do método, uma dobra diferente é utilizada para validação. O desempenho geral do modelo é dado pelo desempenho médio de cada iteração do algoritmo de validação cruzada *k-fold*.



Fonte: Da autora (2021).

Portanto, uma maneira de avaliar o sobreajuste de um modelo de regressão é realizar a validação do modelo com um conjunto de dados invisível, comumente conhecido como o conjunto de validação, e comparar o erro de validação ( $R^2$  e RMSE) com o do conjunto de dados de treinamento. O conjunto de validação pode ser derivado interna e externamente (FABER; RAJKO, 2007). Assim, o erro quadrático médio (RMSE) e o coeficiente de correlação

( $R^2$ ) são utilizados como parâmetros estatísticos para avaliar o desempenho do modelo (KIRALIJ; FERREIRA, 2009; MITRA; SAHA; ROY, 2010).

Pode-se medir a qualidade do modelo pelo seu coeficiente  $R^2$  da calibração, sendo que quanto mais próximo de 1, melhor é a qualidade do modelo. Alguns autores recomendam que, para um modelo ser considerado válido ele deve apresentar um  $R^2 > 0,8$  na fase de calibração e  $R^2 > 0,5$  nas fases de validação e teste. Além disto, ele deve também apresentar baixo valor de RMSE (KIRALIJ; FERREIRA, 2009; TROPSHA, 2010). Porém, Chirico e Gramatica (2011) recomendam valores de  $R^2 > 0,7$  para calibração e  $R^2 > 0,6$  para validação e testes.

#### **1.4 Aplicação do aprendizado de máquina às ciências sensoriais**

A ciência sensorial de alimentos é considerada com um processos-chave no desenvolvimento de novos produtos, além de ser essencial para fazer a ponte entre as características do produto e a percepção e aceitação do consumidor (YU; LOW; ZHOU, 2018). Além disto, a avaliação sensorial da qualidade dos alimentos usando uma abordagem de aprendizado de máquina fornece um meio de medir a qualidade dos produtos alimentícios. Assim, esse tipo de avaliação pode auxiliar na melhoria da composição dos alimentos e estimular o desenvolvimento de novos produtos alimentícios (LU *et al.*, 2020).

A maioria das aplicações de aprendizado de máquina para a ciência sensorial tem se concentrado no desenvolvimento de modelos de regressão e classificação a partir de dados da composição do produto. É possível encontrar na literatura alguns estudos que demonstram que as medidas físicas e físico-químicas se correlacionam bem com as medidas sensoriais. Entre os casos mais relevantes, destacam-se o estudo realizado por Yu, Low e Zhou (2018) que correlacionaram a satisfação do consumidor com medidas químicas de chá verde. Caballero *et al.* (2018) correlacionaram medidas físico-químicas com sensoriais de loim. Vigneau *et al.* (2018) correlacionaram compostos voláteis com respostas sensoriais em vinhos. Nunes *et al.* (2017) correlacionaram os dados físico-químicos com os dados sensoriais para prever a aceitação de alimentos termoprocessados (pão francês, pão de forma com farinha de resíduo da filetagem de peixe e café), por meio de modelos multivariados. Cadena *et al.* (2013) demonstraram que os dados sensoriais descritivos e físico-químicos do néctar de manga se correlacionaram com o teste de aceitação do consumidor. Piombino *et al.* (2013) correlacionaram voláteis e parâmetros físico-químicos com a aceitação de tomates. Por fim, modelos multivariados também foram utilizados para prever a aceitação sensorial dos

consumidores, com base nos parâmetros físico-químicos de diferentes frutas, como laranja, abacaxi e uva (CORRÊA *et al.*, 2014) e morango (RIBEIRO *et al.*, 2021).

Desta forma, o aprendizado de máquina tem sido frequentemente utilizado para classificação e regressão, e encontraram aplicações em diferentes produtos. Exemplos de estudos recentes utilizando ML para prever respostas sensoriais foram resumidos na Quadro 2.

Quadro 2 - Aplicações de aprendizado de máquina supervisionado em estudos sensoriais (Continua).

<b>Produto</b>	<b>Objetivo</b>	<b>Algoritmo</b>	<b>Referência</b>
Chá verde	Classificação das notas de sabor com base na satisfação do consumidor	ANN de retropropagação para classificação usando níveis de aceitação do consumidor	Kengpol e Wangkananon (2015)
Vinho	Predição dos atributos sensoriais das concentrações de compostos fenólicos	PLS para prever respostas de provadores treinados	Gao <i>et al.</i> (2015)
Carne	Predição da qualidade da carne a partir de dados do nariz eletrônico	SVM para prever a qualidade sensorial	Mohareb <i>et al.</i> (2016)
Leite	Predizer a aceitação do consumidor	PLS	Lawrence, Lopetcharat e Drake (2016)
Pão e café	Predizer a aceitação do consumidor a partir de parâmetros físico-químicos	MLR	Nunes <i>et al.</i> (2017)
Mamão	Predição do amadurecimento do mamão e classificação em três estágios de maturação	RF para prever o amadurecimento por meio de imagens digitais	Pereira <i>et al.</i> (2018)
Vinho	Predição das características olfativas dos vinhos a partir de seu teor de compostos orgânicos voláteis	RF para prever respostas sensoriais de provadores treinados	Vigneau <i>et al.</i> (2018)

Quadro 2 - Aplicações de aprendizado de máquina supervisionado em estudos sensoriais (Continua).

<b>Produto</b>	<b>Objetivo</b>	<b>Algoritmo</b>	<b>Referência</b>
Carne	Predição dos atributos sensoriais de lombo suíno a partir de dados de espectroscopia de infravermelho próximo	MLR para predizer respostas de provadores treinados	González-Mohino <i>et al.</i> (2018)
Azeite	Predição de características sensoriais a partir de parâmetros físico-químicos e químicos	MLR para predizer respostas de provadores treinados	Rodrigues <i>et al.</i> (2019)
Iogurte	Predição da aceitação de sabor do iogurte a partir de dados do nariz eletrônico	Rede neural e RF para classificar as amostras em satisfatório ou insatisfatório	Tian <i>et al.</i> (2020)
Queijo Minas Frescal	Predição da aceitação dos consumidores	RF, árvores impulsionadas por gradiente e máquina de aprendizado extremo	Rocha <i>et al.</i> (2020)
Aroma de peixe fermentado	Predição do perfil de aroma de peixe a partir dos compostos voláteis	PLS para predizer respostas de provadores treinados	Gao <i>et al.</i> (2020)
Vinho	Predição dos perfis sensoriais de vinho a partir de dados de espectroscopia de infravermelho próximo	ANN para predizer respostas sensoriais de provadores treinados	Fuentes <i>et al.</i> (2020)
Cerveja	Predição da aceitação com base nos dados do nariz eletrônico, espectroscopia de infravermelho próximo e parâmetros físico-químicos	ANN para predizer as respostas sensoriais de consumidores	Gonzalez Viejo e Fuentes (2020)
Presunto	Predição de parâmetros sensoriais a partir de dados de espectroscopia de infravermelho próximo	ANN para predizer respostas de provadores treinados	Hernandez-Ramos <i>et al.</i> (2020)

Quadro 2 - Aplicações de aprendizado de máquina supervisionado em estudos sensoriais (Conclusão).

<b>Produto</b>	<b>Objetivo</b>	<b>Algoritmo</b>	<b>Referência</b>
Queijo	Predição de atributos sensoriais a partir de dados de espectroscopia de infravermelho próximo	ANN para predizer respostas de provadores treinados	Curto <i>et al.</i> (2020)
Café	Predição de sabores de cafés especiais com base em espectroscopia de infravermelho próximo de café moído como entrada	<i>Deep learning</i> (DL), SVM e Rede neural convolucional profunda para predizer descrições sensoriais de provadores treinados	Chang <i>et al.</i> (2021)
Morango	Predição da aceitação, expectativa e ideal de doçura, suculência e acidez a partir de parâmetros físico-químicos	Floresta aleatória (RF) para predizer respostas sensoriais de consumidores	Ribeiro <i>et al.</i> (2021)
Morango	Classificação dos morangos em satisfeito ou não satisfeito e pagaria mais ou não pagaria mais	Floresta aleatória (RF) para predizer respostas sensoriais de consumidores	Ribeiro <i>et al.</i> (2021)
Espinafre	Classificação do frescor do espinafre a partir dos parâmetros de cor de imagens digitais	SVM para predizer respostas de provadores treinados	Koyama <i>et al.</i> (2021)
Iogurte de soja	Classificação e rastreabilidade dos iogurtes de soja com diferentes adoçantes (naturais e artificiais) a partir de parâmetros físico-químicos	LDA para predizer as respostas de provadores semi-treinados	Rana, Babor e Sabuz (2021)

Fonte: Da autora (2021).

## 2 CONSIDERAÇÕES FINAIS

Como abordado neste capítulo, o aprendizado de máquina tem sido frequentemente utilizado como estratégia para avaliar dados relacionados as ciências sensoriais dos alimentos. Vimos que o aprendizado de máquina pode fornecer de maneira eficiente previsões das respostas sensoriais em função da composição, imagens ou dados descritivos dos alimentos, e assim acelerar o desenvolvimento de novos produtos e garantir a qualidade dos alimentos.

Vimos também que existem diferentes algoritmos de ML e todos podem ser utilizados para dados sensoriais. A escolha do algoritmo dependerá do conjunto de dados e do objetivo. Observamos que o uso de algoritmos mais simples e menos complexos podem se ajustar bem aos dados sensoriais e responder ao objetivo proposto.

Embora o aprendizado de máquina tenha sido utilizado com sucesso na análise sensorial, deve-se estar atendo ao tamanho do conjunto de dados. Para uma resposta robusta e confiável é necessário que o conjunto de dados seja grande o suficiente para que os algoritmos possam realizar o reconhecimento de padrões. Alguns algoritmos geralmente produzem previsões insatisfatórias ao trabalhar com pequenos conjuntos de dados. Assim, o banco de dados sensoriais pode ser uma limitação ao aprendizado de máquina e um desafio para os pesquisadores.

## REFERÊNCIAS BIBLIOGRÁFICAS

- AHMAD, M. W.; MOURSHED, M.; REZGUI, Y. Trees vs neurons: Comparison between random forest and ann for high-resolution prediction of building energy consumption. **Energy and Buildings**, v. 147, p. 77–89, 2017.
- BAO, W.; LIANJU, N.; YUE, K. Integration of unsupervised and supervised machine learning algorithms for credit risk assessment. **Expert Systems with Applications**, v. 128, p. 301–315, 2019.
- BAUMANN, P.; HOCHBAUM, D. S.; YANG, Y. T. A comparative study of the leading machine learning techniques and two new optimization algorithms. **European journal of operational research**, v. 272, n. 3, p. 1041-1057, 2019.
- BAYANE, C. K.; KRAMER, R. Chemometric Techniques for Quantitative Analysis. **Technometrics**, v. 41, p. 173, 1999.
- BEEBE, K. R.; KOWALSKI, B. R. An introduction to multivariate calibration and analysis. **Analytical Chemistry**, v. 59, n. 17, p. 1007A–1017A, 1987.
- BREIMAN, L. Random forests. **Machine learning**, v. 45, p. 5-32, 2001.
- BREIMAN, L. *et al.* **Classification and Regression Trees**. Boca Raton: CRC Press, 1984.
- BURGES, C. J. A tutorial on support vector machines for pattern recognition. **Data Mining and Knowledge Discovery**, v. 2, n. 2, p. 121-167, 1998.
- CABALLERO, D. *et al.* Comparison of different image analysis algorithms on mri to predict physicochemical and sensory attributes of loin. **Chemometrics and Intelligent Laboratory Systems**, v. 180, p. 54–63, 2018.
- CADENA, R. S. *et al.* Sensory profile and physicochemical characteristics of mango nectar sweetened with high intensity sweeteners throughout storage time. **Food Research International**, v. 54, n. 2, p. 1670-1679, 2013.
- CHANG, Y. T. *et al.* Prediction of specialty coffee flavors based on near-infrared spectra using machine-and deep-learning methods. **Journal of the Science of Food and Agriculture**, v. 101, n. 11, p. 4705-4714, 2021.
- CHEN, X. *et al.* Complete large margin linear discriminant analysis using mathematical programming approach. **Pattern Recognition**, v. 46, n. 6, p. 1579-1594, 2013.
- CHIRICO, N.; GRAMATICA, P. Real external predictivity of qsar models: how to evaluate it? comparison of different validation criteria and proposal of using the concordance correlation coefficient. **Journal of Chemical Information and Modeling**, v. 51, n. 9, p. 2320–2335, 2011.
- CORREA, S. C. *et al.* Prediction of the sensory acceptance of fruits by physical and physical–chemical parameters using multivariate models. **LWT - Food Science and Technology**, v. 59, n. 2, p. 666–672, 2014.

CORTES, C.; VAPNIK, V. Support-vector networks. **Machine Learning**, v. 20, n. 3, p. 273–297, 1995.

COVER, T.; HART, P. Nearest neighbor pattern classification. **IEEE Transactions on Information Theory**, v. 13, n. 1, p. 21–27, 1967.

CRISTIANINI, N. *et al.* **An introduction to support vector machines and other kernel-based learning methods**. Cambridge: Cambridge University Press, 2000.

CURTO, B. *et al.* Accurate prediction of sensory attributes of cheese using near-infrared spectroscopy based on artificial neural network. **Sensors**, v. 20, n. 12, p. 3566, 2020.

DA SILVA COTRIM, W. *et al.* Development of a hybrid system based on convolutional neural networks and support vector machines for recognition and tracking color changes in food during thermal processing. **Chemical Engineering Science**, v. 240, p. 116679, 2021.

DA SILVA COTRIM, W. *et al.* Short convolutional neural networks applied to the recognition of the browning stages of bread crust. **Journal of Food Engineering**, v. 277, p. 109916, 2020.

DHANKHAD, S.; MOHAMMED, E.; FAR, B. **Supervised machine learning algorithms for credit card fraudulent transaction detection: a comparative study**. In: c p. 122–125, 2018. DOI: 10.1109/IRI.2018.00025

DOSHI-VELEZ, F.; KIM, B. **Towards a rigorous science of interpretable machine learning**. arXiv preprint arXiv:1702.08608, 2017.

DUDA, R. O.; HART, P. E.; STORK, D.G. **Pattern Classification**, 2nd ed, Hoboken: Wiley, 2012.

EL FIKY, H.; HUSSEIN, W.; EL GOHARY, R. **Literature review with study and analysis of the quality challenges of recommendation techniques and their application in movie ratings**. In: Hassanien A.E., Darwish A. (eds) *Machine Learning and Big Data Analytics Paradigms: Analysis, Applications and Challenges*. Springer, v. 77, p. 219–241, 2021.

FABER, N.; RAJKO, R. How to avoid over-fitting in multivariate calibration—the conventional validation approach and an alternative. **Analytica Chimica Acta**, v. 595, n. 1-2, p. 98–106, 2007.

FAGAN, C. C. *et al.* Application of mid-infrared spectroscopy to the prediction of maturity and sensory texture attributes of cheddar cheese. **Journal of Food Science**, v. 72, n. 3, p. E130–E137, 2007.

FATIMA, M. *et al.* Survey of machine learning algorithms for disease diagnostic. **Journal of Intelligent Learning Systems and Applications**, v. 9, n. 1, p. 1, 2017.

FERREIRA, M. *et al.* Quimiometria i: calibração multivariada, um tutorial. **Química Nova**, v. 22, n. 5, p. 724–731, 1999.

FIDELIS, M. *et al.* Authentication of juices from antioxidant and chemical perspectives: A feasibility quality control study using chemometrics. **Food Control**, v. 73, p. 796–805, 2017.

FUENTES, S. *et al.* Machine learning modeling of wine sensory profiles and color of vertical vintages of pinot noir based on chemical fingerprinting, weather and management data. **Sensors**, v. 20, n. 13, p. 3618, 2020.

GAMBELLA, C.; GHADDAR, B.; NAOUM-SAWAYA, J. Optimization problems for machine learning: A survey. **European Journal of Operational Research**, v. 290, n. 3, p. 807-828, 2021.

GAO, P. *et al.* Aroma profiles of commercial chinese traditional fermented fish (suan yu) in western hunan: Gc-ms, odor activity value and sensory evaluation by partial least squares regression. **International Journal of Food Properties**, v. 23, n. 1, p. 213–226, 2020.

GAO, Y. *et al.* Evolution of phenolic compounds and sensory in bottled red wines and their co-development. **Food Chemistry**, v. 172, p. 565–574, 2015.

GELADI, P.; KOWALSKI, B. R. Partial least-squares regression: a tutorial. **Analytica Chimica Acta**, v. 185, p. 1–17, 1986.

GONZALEZ VIEJO, C.; FUENTES, S. Low-cost methods to assess beer quality using artificial intelligence involving robotics, an electronic nose, and machine learning. **Fermentation**, v. 6, n. 4, p. 104, 2020.

GONZÁLEZ-MOHINO, A *et al.* Near-infrared spectroscopy-based analysis to study sensory parameters on pork loins as affected by cooking methods and conditions. **Journal of the Science of Food and Agriculture**, v. 98, n. 11, p. 4227–4236, 2018.

GOUSE, S.; HELINI, K. A comparative performance analysis of different unsupervised and reinforcement learning algorithms of machine learning using python. Algorithms. **International Journal of Scientific Research in Computer Science Applications and Management Studies**, v. 15, n. 16, p. 17, 2019.

GOYAL, K.; KUMAR, P.; VERMA, K. Food adulteration detection using artificial intelligence: A systematic review. **Archives of Computational Methods in Engineering**, p. 1–30, 2021.

HAN, T. *et al.* Comparison of random forest, artificial neural networks and support vector machine for intelligent diagnosis of rotating machinery. **Transactions of the Institute of Measurement and Control**, v. 40, n. 8, p. 2681–2693, 2018.

HAYKIN, S. **Neural Networks: a Comprehensive Foundation**. New Jersey: Prentice Hall, 2008.

HERNÁNDEZ-RAMOS, P. *et al.* Prediction of sensory parameters of cured ham: A study of the viability of the use of nir spectroscopy and artificial neural networks. **Sensors**, v. 20, n. 19, p. 5624, 2020.

INDAHL, U. G.; MARTENS, H.; NÆS, T. From dummy regression to prior probabilities in pls-da. **Journal of Chemometrics: A Journal of the Chemometrics Society**, v. 21, n. 12, p. 529–536, 2007.

JAIN, A. K.; MURTY, M. N.; FLYNN, P. J. Data clustering: a review. **ACM Computing Surveys**, v. 31, n. 3, p. 264-323, 1999.

- JIMÉNEZ-CARVELO, A. M *et al.* Alternative data mining/machine learning methods for the analytical evaluation of food quality and authenticity—a review. **Food Research International**, v. 122, p. 25–39, 2019.
- JORDAN, M. I.; MITCHELL, T. M. Machine learning: Trends, perspectives, and prospects. **Science**. v. 349, n. 6245, p. 255–260, 2015.
- KENGPOL, A.; WANGKANANON, W. **An assessment of customer contentment for ready-to-drink tea flavor notes using artificial neural networks**. In: Toward sustainable operations of supply chain and logistics systems. Springer, p. 421–434, 2015.
- KIRALJ, R.; FERREIRA, M. Basic validation procedures for regression models in qsar and qspr studies: theory and application. **Journal of the Brazilian Chemical Society**, v. 20, n. 4, p. 770–787, 2009.
- KOYAMA, K *et al.* Predicting sensory evaluation of spinach freshness using machine learning model and digital images. **Plos One**, v. 16, n. 3, p. e0248769, 2021.
- KUCUKYILMAZ, T *et al.* A machine learning approach for result caching in web search engines. **Information Processing & Management**, v. 53, n. 4, p. 834–850, 2017.
- LAWRENCE, S.; LOPETCHARAT, K.; DRAKE, M. Preference mapping of soymilk with different us consumers. **Journal of Food Science**, v. 81, n. 2, p. S463–S476, 2016.
- LENHARDT, L. *et al.* Determination of the botanical origin of honey by frontface synchronous fluorescence spectroscopy. **Applied Spectroscopy**, v. 68, n. 5, p. 557–563, 2014.
- LIN, Y. W. *et al.* The equivalence of partial least squares and principal component regression in the sufficient dimension reduction framework. **Chemometrics and Intelligent Laboratory Systems**, v. 150, p. 58–64, 2016.
- LIU, H. *et al.* Machine learning for glass science and engineering: A review. **Journal of Non-Crystalline Solids**, v. 557, p. 119419, 2021.
- LÓPEZ-FERIA, S. *et al.* Quantification of the intensity of virgin olive oil sensory attributes by direct coupling headspace-mass spectrometry and multivariate calibration techniques. **Journal of Chromatography A**, v. 1147, n. 2, p. 144–152, 2007.
- LU, N. V. *et al.* Incorporating active learning into machine learning techniques for sensory evaluation of food. **International Journal of Computational Intelligence Systems**, v. 13, n. 1, p. 655–662, 2020.
- MARGRAF, T. *et al.* Effects of geographical origin, variety and farming system on the chemical markers and in vitro antioxidant capacity of brazilian purple grape juices. **Food Research International**, v. 82, p. 145–155, 2016.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of Mathematical Biophysics**, v. 5, n. 4, p. 115–133, 1943.
- MEHINAGIC, E. *et al.* Prediction of the sensory quality of apples by physical measurements. **Postharvest Biology and Technology**, v. 34, n. 3, p. 257–269, 2004.

- MINIM, V. P. R. **Análise sensorial: estudos com consumidores**. 3 ed. Viçosa: UFV, 2013.
- 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, n. 13, p. 1067–1079, 2010.
- MOHAREB, F. *et al.* Ensemble-based support vector machine classifiers as an efficient tool for quality assessment of beef fillets from electronic nose data. **Analytical Methods**, v. 8, n. 18, p. 3711–3721, 2016.
- MUELLER, J. P.; MASSARON, L. **Aprendizado de máquina para leigos**. Rio de Janeiro: Alta Books, 2019.
- NOBLE, A.; EBELER, S. Use of multivariate statistics in understanding wine flavor. **Food Reviews International**, v. 18, n. 1, p. 1–20, 2002.
- NOCAIRI, H. *et al.* D. Discrimination on latent components with respect to patterns. application to multicollinear data. **Computational Statistics & Data Analysis**, v. 48, n. 1, p. 139–147, 2005.
- NUNES, C. A. *et al.* Prediction of consumer acceptance in some thermoprocessed food by physical measurements and multivariate modeling. **Journal of Food Processing and Preservation**, v. 41, n. 5, p. e13178, 2017.
- OLIVIERI, A. C. **Principal Component Regression**. Introduction to Multivariate Calibration. p. 73-86: Springer Nature Swizerland, 2018.
- PEREIRA, L. F. S. *et al.* Predicting the ripening of papaya fruit with digital imaging and random forests. **Computers and Electronics in Agriculture**, v. 145, p. 76–82, 2018.
- PERROT, N. *et al.* Fuzzy concepts applied to food product quality control: A review. **Fuzzy Sets and Systems**, v. 157, n. 9, p. 1145–1154, 2006.
- PIOMBINO, P. *et al.* Investigating physicochemical, volatile and sensory parameters playing a positive or a negative role on tomato liking. **Food Research International**, v. 50, n. 1, p. 409–419, 2013.
- RANA, M. R.; BABOR, M.; SABUZ, A. A. Traceability of sweeteners in soy yogurt using linear discriminant analysis of physicochemical and sensory parameters. **Journal of Agriculture and Food Research**, v. 5, p. 100155, 2021.
- RIBEIRO, M. N. *et al.* Quality control of fresh strawberries by a random forest model. **Journal of the Science of Food and Agriculture**, v. 101, n. 11, p. 4514-4522, 2021.
- RIBEIRO, M. N. *et al.* Optimising a stevia mix by mixture design and napping: A case study with high protein plain yoghurt. **International Dairy Journal**, v. 110, p. 104802, 2020.
- RIEDL, J.; ESSLINGER, S.; FAUHL-HASSEK, C. Review of validation and reporting of non-targeted fingerprinting approaches for food authentication. **Analytica Chimica Acta**, v. 885, p. 17–32, 2015.

- ROCHA, R. S. *et al.* Consumer acceptance and sensory drivers of liking of minas frescal minas cheese manufactured using milk subjected to ohmic heating: Performance of machine learning methods. **LWT - Food Science and Technology**, v. 126, p. 109342, 2020.
- RODRIGUES, N. *et al.* Application of an electronic tongue as a single-run tool for olive oils' physicochemical and sensory simultaneous assessment. **Talanta**, v. 197, p. 363–373, 2019.
- ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review**, v. 65, n. 6, p. 386, 1958.
- Rosipal, R.; Krämer, N. **Overview and recent advances in partial least squares**. Saunders, C.; Grobelnik, M.; Gunn, S.; Shawe Taylor, J. (Eds.), Subspace, latent structure and feature selection, Springer Berlin Heidelberg, v.3940, p. 34-51, 2006.
- RUSSELL, S.; NORVIG, P. **Artificial intelligence: A modern approach**. 3 ed. Hoboken: Prentice Hall, 2010.
- SAMUEL, A. L. Some studies in machine learning using the game of checkers. **IBM Journal of Research and Development**, v. 3, n. 3, p. 210–229, 1959.
- SANTOS, M. F.; VICTORINO, A. C. **Autonomous vehicle navigation based in a hybrid methodology: model based and machine learning based**. In: . c2021. p. 1–6. DOI: 10.1109/ICM46511.2021.9385629
- SARKER, I. H. Machine learning: Algorithms, real-world applications and research directions. **SN Computer Science**, v. 2, n. 3, p. 1–21, 2021.
- SHAH, K. *et al.* A comparative analysis of logistic regression, random forest and knn models for the text classification. **Augmented Human Research**, v. 5, n. 1, p. 1–16, 2020.
- SHARIF, O. *et al.* Detecting suspicious texts using machine learning techniques. **Applied Sciences**, v. 10, n. 18, p. 6527, 2020.
- SHARMA, A.; PALIWAL, K. K. A new perspective to null linear discriminant analysis method and its fast implementation using random matrix multiplication with scatter matrices. **Pattern Recognition**, v. 45, n. 6, p. 2205–2213, 2012.
- SIMEONE, O. A very brief introduction to machine learning with applications to communication systems. **IEEE Transactions on Cognitive Communications and Networking**, v. 4, n. 4, p. 648–664, 2018.
- SINDHU, V.; NIVEDHA, S.; PRAKASH, M. An empirical science research on bioinformatics in machine learning. **Journal of Mechanics of Continua and Mathematical Sciences**, n. 7, p. 86-94, 2020.
- SOLOMONOFF, R. J. **An inductive inference machine**. In: . c1957. v. 2. p. 56–62.
- SOOD, S.; SINGH, H. Computer vision and machine learning based approaches for food security: A review. **Multimedia Tools and Applications**, v. 80, p. 27973–27999, 2021.

TARLEY, C. R. T. *et al.* Chemometric tools in electroanalytical chemistry: methods for optimization based on factorial design and response surface methodology. **Microchemical Journal**, v. 92, n. 1, p. 58–67, 2009.

TAUD, H.; MAS, J. **Multilayer perceptron (mlp)**. In: *Geomatic Approaches for Modeling Land Change Scenarios*. Springer, 2018. p. 451–455.

THARWAT, A.; GABER, T.; IBRAHIM, A.; HASSANIEN, A. E. Linear discriminant analysis: A detailed tutorial. **AI Communications**, v. 30, n. 2, p. 169–190, 2017.

TIAN, H. *et al.* Combined application of electronic nose analysis and back-propagation neural network and random forest models for assessing yogurt flavor acceptability. **Journal of Food Measurement and Characterization**, v. 14, n. 1, p. 573–583, 2020.

TROPSHA, A. Best practices for qsar model development, validation, and exploitation. **Molecular Informatics**, v. 29, n. 6-7, p. 476–488, 2010.

UDDIN, S. *et al.* Comparing different supervised machine learning algorithms for disease prediction. **BMC Medical Informatics and Decision Making**, v. 19, n. 1, p. 1–16, 2019.

VIGNEAU, E. *et al.* Random forests: A machine learning methodology to highlight the volatile organic compounds involved in olfactory perception. **Food Quality and Preference**, v. 68, p. 135–145, 2018.

WOLD, S.; SJÖSTRÖM, M.; ERIKSSON, L. Pls-regression: a basic tool of chemometrics. **Chemometrics and Intelligent Laboratory Systems**, v. 58, n. 2, p. 109–130, 2001.

WU, S.; YAU, W.-C.; ONG, T.-S.; CHONG, S.-C. Integrated churn prediction and customer segmentation framework for telco business. **IEEE Access**, v. 9, p. 62118–62136, 2021.

WYNER, A. J. *et al.* Explaining the success of adaboost and random forests as interpolating classifiers. **The Journal of Machine Learning Research**, v. 18, n. 1, p. 1558–1590, 2017.

XIONG, J. *et al.* A review of plant phenotypic image recognition technology based on deep learning. **Electronics**, v. 10, n. 1, p. 81, 2021.

YING, X. An overview of overfitting and its solutions. **Journal of Physics: Conference Series**, v. 1168, n.2, p. p. 022022, 2019.

YU, P. *et al.* Design of experiments and regression modelling in food flavour and sensory analysis: A review. **Trends in Food Science & Technology**, v. 71, p. 202–215, 2018.

ZIELINSKI, A. A. *et al.* Chemical composition, sensory properties, provenance, and bioactivity of fruit juices as assessed by chemometrics: a critical review and guideline. **Comprehensive Reviews in Food Science and Food Safety**, v. 13, n. 3, p. 300–316, 2014.

**TERCEIRA PARTE - ARTIGOS****ARTIGO 1 - QUALITY CONTROL OF FRESH STRAWBERRIES BY A RANDOM FOREST MODEL**

Artigo publicado na Revista Journal of the Science of Food and Agriculture

Doi: <https://doi.org/10.1002/jsfa.11092>

**Michele Nayara RIBEIRO<sup>1</sup>, Iago Augusto de CARVALHO<sup>2</sup>, Gabriel Aparecido FONSECA<sup>3</sup>, Rafael Carvalho do LAGO<sup>1</sup>, Lenízy Cristina Reis ROCHA<sup>1</sup>, Danton Diego FERREIRA<sup>4</sup>, Eduardo Valério Barros VILAS BOAS<sup>1</sup>, Ana Carla Marques PINHEIRO<sup>1</sup>**

<sup>1</sup>Departamento de Ciência dos Alimentos, Universidade Federal de Lavras – UFLA, Lavras, MG, Brasil

<sup>2</sup>Departamento de Computação, Universidade Estadual de Campinas – UNICAMP, Campinas, SP, Brasil

<sup>3</sup> Departamento de Engenharia, Universidade Federal de Lavras – UFLA, Lavras, MG, Brasil

<sup>4</sup> Departamento de Automática, Universidade Federal de Lavras – UFLA, Lavras, MG, Brasil

## ABSTRACT

**BACKGROUND:** Strawberry quality is one of the most important factors that guarantees consistent commercialization of the fruit and ensures the consumer's satisfaction. This work makes innovative use of Random Forest (RF) to predict sensory measures of strawberries and to classify them in “satisfied” or “not satisfied” and “would pay more” or “wouldn’t pay more” using physical and physical-chemical variables. The RF-based model predicts the acceptance, expectation, ideal of sweetness, ideal of acidity, and the ideal of succulence based on the physical and physical-chemical data, which are used as input for the RF-based classification model.

**RESULTS:** The RF achieved a coefficient of determination  $R^2 > 0.72$  and a root-mean-squared error (RMSE) smaller than 0.17 for the prediction task, which indicates that one can estimate the sensory measures of strawberries using physical and physical-chemical data. Furthermore, the RF was able to correctly classify 87.95% of the strawberry samples in the classes “satisfied” and “not satisfied” and 78.99% in the classes “would pay more” or “wouldn’t pay more”. Additionally, a two-step RF model, which employed both physical and physical-chemical data to classify strawberry samples regarding the consumer’s response, correctly classified 100% and 90.32% of the samples with respect to the consumer's satisfaction and its willingness to pay more, respectively.

**CONCLUSION:** The results indicate that the developed models can be used in the quality control of strawberries, supporting the establishment of quality standards that consider the consumer’s response. Additionally, the proposed methodology can be extended to control the sensory quality of other fruits.

**Keywords:** strawberry; sensory response; regression; classification; random forests; machine learning

## 1. INTRODUCTION

Strawberry is a highly appreciated fruit by consumers. The taste and the subsequent consumer’s acceptance of strawberry, as for other food products, rely on intrinsic and extrinsic factors. The extrinsic factors, such as price, nutritional facts, the credibility of the seller’s brand, among others, do not affect the sensory characteristics of the product<sup>1,2</sup>. On the other hand, the intrinsic factors are associated with chemical, physical, physical-chemical, and sensory

characteristics of the food, such as their sensory profile <sup>2</sup>, the volatile profile <sup>3</sup>, and the physical appearance <sup>4</sup>. Therefore, the quality of a strawberry is directly correlated with sensory attributes such as appearance, aroma, flavor, and texture. These are perceived by human senses and influenced by the physical and physical-chemical characteristics of the fruit <sup>5</sup>.

Strawberries are generally commercialized without any quality control of their intrinsic qualities, *i.e.*, without taking into consideration their physical, physical-chemical, and sensory attributes <sup>6</sup>. This lack of quality control leads to the commercialization of fruits only based on their visual aspect, such as size and coloring, in such a way that the pricing of the product is established without taking into consideration its perceived quality. This can influence the consumer to buy a product with low quality, which leads to dissatisfaction and frustration <sup>6</sup>.

It is impracticable to monitor the sensory response of consumers, as sensory tests demand a great number of consumers and require a large amount of time and resources <sup>7</sup>. However, as the sensory properties of the food are affected by its chemical compounds, it is possible to correlate the chemical profile of the strawberry with its sensory profile, and with the general acceptance of the fruit <sup>2</sup>. Thus, mathematical models can be used to infer the consumer's sensory response using fast, cheap, and easy-to-obtain physical and physical-chemical analysis, therefore ensuring the commercialization of the strawberry takes into consideration the quality variability of the product <sup>6</sup>.

Recently, several studies demonstrated that the physical and physical-chemical data can be correlated with the sensory response of consumers <sup>6, 7, 8, 9, 10, 11, 12</sup>. These studies used prediction models to comprehend the food system through regression analysis, correlating the physical and physical-chemical properties of food with their sensory responses. Most of them are machine learning-based models, which have the powerful capacity of finding hidden linear and non-linear variable relations. From such variable relations, simple and useful regression models may be built.

Random Forests (RF) <sup>13</sup> is a versatile machine learning algorithm that can be used for both regression and classification tasks that demonstrated a robust performance across a range of data sets <sup>14</sup>. As an ensemble algorithm, it can achieve best-in-class performance with low generalization error <sup>15</sup>. Furthermore, this algorithm can handle many input variables and is able to rank the most important ones to the regression/classification models <sup>14</sup>. Additionally, it requires few tuning parameters <sup>16</sup>.

This work makes innovative use of RF to estimate consumer's sensory responses from physical and physical-chemical of strawberries and to classify them according to the consumer's satisfaction and willingness to pay more. Therefore, one can estimate the sensory quality of strawberries based on simple, fast, and cheap analysis. Hence, the aim of this work comprises two folds: *(i)* to identify the most relevant physical and physical-chemical variables that describes the sensory responses of strawberries; and *(ii)* to infer the sensory quality and the consumer's response during strawberries tasting using both physical and physical-chemical data. For doing so, regression and classification models based on RF are exploited.

RF models achieves high accuracy even with a small training data set, which is the case of this study <sup>17</sup>. This algorithm was previously used by Vigneau et al. <sup>10</sup> to build predictive models which correlate volatile compounds with the olfactory perception of wines. Furthermore, Pereira et al. <sup>18</sup> employed this algorithm to classify papayas in different maturation stages, while Qiu & Wang <sup>19</sup> used RF to construct regression models to estimates the amount of food additives in fruit juices using an electronic nose.

The contributions of the work for the food science are: *(i)* to show that it is possible to predict the consumer's satisfaction and willingness to pay more for strawberries using only physical and physical-chemical data; and *(ii)* to propose a robust methodology for developing regression and classification models to the sensory sciences and sensometrics communities. The latter is highly important as several recent works still employed lesser effective methodologies

based on linear equations <sup>2</sup>, such as Multiple Linear Regression <sup>6, 7</sup> or Partial Least Squares <sup>20, 21</sup>.

## **2. MATERIALS AND METHODS**

### **2.1 Materials**

*Fragaria x ananassa* Duch strawberries were bought in a local market in Lavras town, Brazil. A total of 30 samples, each containing 4 Kg of strawberries, were acquired. Each sample was obtained from a different region or farmer, thus ensuring the collection of strawberries with quality variability.

### **2.2 Strawberries manipulation**

Sample preparation and pre-processing followed the methodology employed by Côrrea et al. <sup>6</sup>. After the acquisition, the strawberries were transported to the Post-Harvest Laboratory at the Universidade Federal de Lavras, Brazil. All selected fruits were visibly healthy and did not present any physical injury. Strawberries were washed in running water to remove any possible small particles of dust or dirt and sanitized with a solution of sodium hypochlorite (100 ppm) by immersion for 15 minutes. Then, to standardize the samples, the strawberries were sliced perpendicularly to their main axis, in four equal parts, and the ends were removed. Finally, the strawberries were separated into two groups, one group was subjected to the physical and physical-chemical analysis and the other one was used for the sensory analysis. The physical, physical-chemical, and the sensory analyses were immediately performed after these steps.

### **2.3 Physical and physical-chemical analysis**

The physical and physical-chemical analysis were realized in six repetitions for every strawberry sample. The titratable acidity (TA), soluble solids (SSC), and the SSC/TA ratio were computed following the AOAC <sup>22</sup> guidelines. The color of the strawberry was determined in three distinct points of the fruit surface using a Minolta colorimeter, model CR-400, with illuminator D65 and color systems CIE L\*, a\*, and b\*, previously calibrated. To measure the color of the juice, 20 ml of the liquid was put into a Petri plate and the color readings were realized in the inferior surface of the plate containing the juice. The firmness of the whole fruit was measured by a puncture test in two points in the equatorial region of the fruit using a Magness-Taylor penetrometer, with a 5mm probe, being the results expressed in Newtons (N). The height and diameter of the fruits were determined using a digital pachymeter 150mm/6” CSX-B Mitutoyo<sup>®</sup> and the results were expressed in millimeters. The juice yield was computed after the weighting of the fruit (without its calyx) in a semi-analytical balance and processing in a juicer extractor Cadence juicer plus model JCE400 60 Hz 700W, and it was computed as

$$\text{Juice yield (\%)} = (\text{juice volume (ml)} \times 100) / \text{weight of the strawberries (g)} \quad (1)$$

## 2.4 Sensory analysis

The sensory analysis was carried out by recruited consumers that consume strawberry frequently, that highly appreciate the fruit, and that were interested in participating of this study. The analysis was carried out by a total of 715 consumers, whereas 98.9% of them aged between 18 and 15 years. Furthermore, 60.6% were female and 39.4% were male. This study was revised and approved by the Ethics Committee for Research with Humans of the Universidade Federal de Lavras, under the code CAAE 12112113.8.0000.5148.

The sensory analysis was carried out in the Laboratory of Sensory Analysis of the Universidade Federal de Lavras, MG, Brazil. They were performed under ideal conditions, under white light, controlled temperature of 25 °C, and in individual cabins. The analysis was

carried out in six sessions. Every test session was performed using a complete balanced block design in which a consumer evaluated five different strawberry samples. Water was served along with the strawberry samples to clean the palate between the evaluation of samples. The strawberry samples were codified using 3-digit random numbers and presented in monadic and balanced order, following the sensory methodology proposed by Walkeling & Macfie <sup>23</sup>. The samples were presented into dispensable plastic cups of 50 mL, each containing a piece of strawberry of approximately 20 g. Table 1 presents the summary of the test sessions. One can see that 115 out of the 715 consumers participated in the first session (being a total of six sessions as stated before) and 600 consumers participated in the remaining sessions. The last five sessions received 120 consumers each one.

Table 1: Number of consumers and samples in each sensory session.

	<b>Session</b>	<b>Session</b>	<b>Session</b>	<b>Session</b>	<b>Session</b>	<b>Session</b>	<b>Total</b>
	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>	
Samples	5	5	5	5	5	5	<b>30</b>
Consumers	115	120	120	120	120	120	<b>715</b>

#### **2.4.1 Sensory tests**

Consumers were asked to evaluate how much they liked or disliked the strawberry samples. For this, the consumers took into consideration the global impression of the fruit, evaluating the sensory aspects of color, aroma, texture, and flavor. Using these aspects, the consumers evaluated the acceptance of different samples using a numeric 9 cm unstructured scale whose left extreme point was anchored with the term “extremely disliked”, the center with the term “neither liked or disliked”, and the right extreme point with the term “extremely liked”.

Next, the consumers evaluated the samples taking into consideration their expectation regarding its quality. This evaluation was performed using a numeric 9 cm unstructured scale whose left extreme point was anchored with the term “far below my expectation”, the center with the term “reached my expectation”, and the right extreme point with the term “way above my expectation”.

Additionally, the consumers evaluated the samples and determined how ideal was the sweetness, the succulence, and the acidity of the strawberries. These evaluations were performed using three numeric 9 cm unstructured scale whose left extreme points were respectively anchored with the term “extremely less sweet than ideal”, “extremely less succulent than ideal”, and “extremely less acid than ideal” expectation”, the center with the terms “ideal sweetness”, “ideal succulence”, and “ideal acidity”, and the right extreme point with the terms “extremely more sweet than ideal”, “extremely more succulent than ideal”, and “extremely more acid than ideal”.

Finally, the consumers stated if they were satisfied or not and whether they were willing to pay more or not for the evaluated sample.

## **2.5 Regression and classification models**

Regression models were built to estimate the acceptance, the expectation, the ideal acidity, the ideal sweetness, and the ideal succulence of strawberries using physical and physical-chemical analysis. Furthermore, classification models were developed to classify strawberry samples into four categories: “satisfied” or “not satisfied” and “willing to pay more” or “not willing to pay more”. Both regression and classification models were built using the Random Forest algorithm freely available in the Python package scikit-learn <sup>24</sup>.

### **2.5.1 Regression models**

A Random Forest <sup>13</sup> is an ensemble of Classification and Regression Trees (CARTs) <sup>25</sup>. Each CART within RF is constructed randomly, using two randomization processes. The first one is the *bootstrap*, which consists in selecting a subset of the entries of the dataset to construct each CART. The second is the variable selection, which considers only a subset of the original dependent variables in each tree. In a RF, the result for each entry of the dataset is computed as the average of the predicted values for the dependent variable (in the case of using regression trees) or the most classified class (in the case of using classification trees). In general, RF provides a better accuracy than a single CART, since the final response is computed using output values of the set of CART.

Five regression models were developed using RF. They considered 17 input physical and physical-chemical variables, as listed in Session 2.3, and the objective of each model was to predict one different sensory parameter. The first model was used to predict the acceptance of the strawberries, while the second model tried to predict their expectation. The three remaining models were respectively used to predict the ideal sweetness, the ideal juiciness, and the ideal acidity.

The regression models implemented in this work were composed by four different phases, which are summarized in Figure 1. The first phase consisted of the samples' pre-processing. Since only 30 physical and physical-chemical data were available, we oversampled the data with a factor of 3 to increase the number of available samples. Next, the samples were randomly split into two subsets: the training subset and the validation subset. The developed RF model considered 80% of the data for the training subset and 20% for the validation subset.

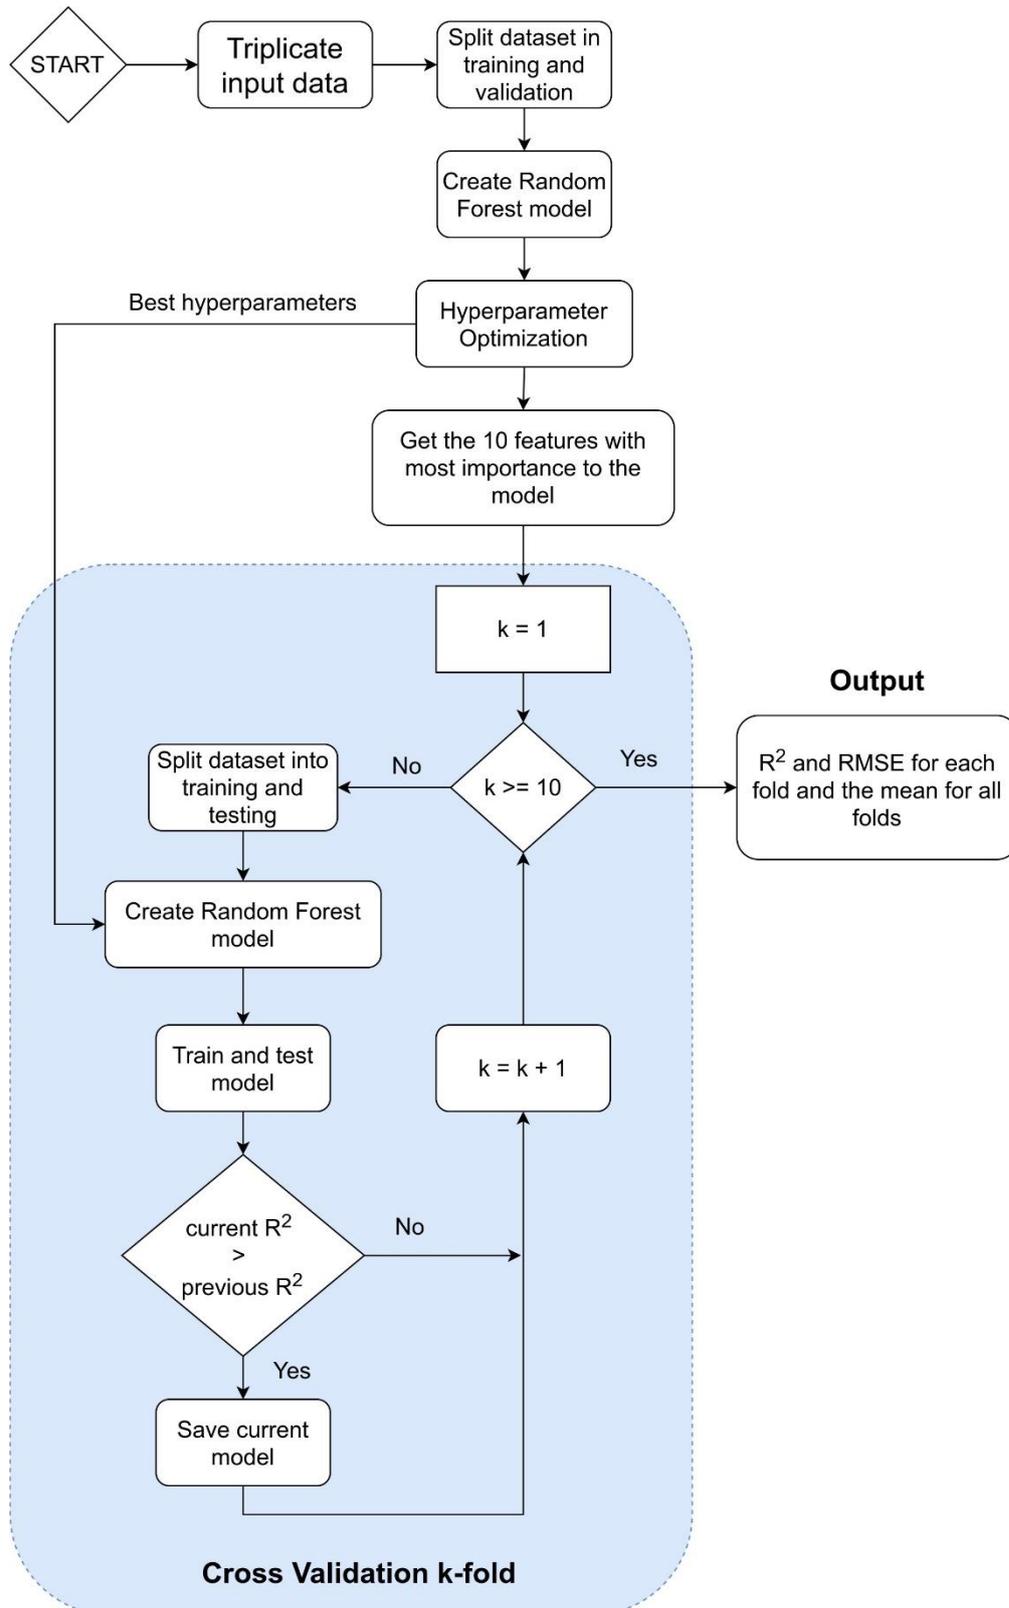


Figure 1: Scheme for creating regression models

The second phase was the optimization of the parameters of the RF. The implemented RF had 6 parameters: the number of CARTs used ( $n_{estimators}$ ), the maximum depth of each

CART (*max\_depth*), the maximum number of features used to split a node (*max\_features*), the min number of data points placed in a node before the node is split (*min\_samples\_split*), the minimum number of samples in a leaf node (*min\_samples\_leaf*), and the method used for sampling, which can be with or without replacement. The objective of this phase was to choose the values that lead to a better performance of the regression model. This process was performed using *Random Search*, *i.e.*, by randomly selecting the values of the parameters of the RF and training the model. This random search process was performed 100 times and the values that lead to the best results were stored and used in the RF models. Additionally, we also applied a feature reduction technique using the mean decrease impurity (MDI) mechanism<sup>26</sup> in order to remove the input variables that were not relevant to the RF models. As a result, *n\_estimators* variable was set to 10, *max\_depth* was set to 20, and *max\_features* variable was equal to the square root value of the total number of input variables. Additionally, the parameters *min\_samples\_split* and *min\_samples\_leaf* were set to 2, while replacement was set to false.

The third phase comprised the training of the RF regression models and corresponds to the gray-colored area in Figure 1. This phase used a k-fold cross validation algorithm<sup>27</sup> with the samples on the training subset chosen in the first phase.

The fourth and last phase consisted in evaluating the trained model using the validation subset of samples, as chosen in the first phase. This phase generated the values of the coefficient of determination ( $R^2$ ) and the root-mean-square error (RMSE), which are used to evaluate the quality of the models.

### **2.5.2 Classification models**

The RF employed in the classification model differs from those of the regression models in the type of the CART: the classification model used an ensemble of classification trees, while the regression models used ensembles of regression trees. Two classification models were built. Both models considered five input variables, namely the acceptance, the expectation, the ideal

sweetness, the ideal juiciness, and the ideal acidity. The first was responsible by classifying the samples in “satisfied” or “not satisfied”, while the second classified the samples in “would pay more” or “wouldn’t pay more”.

The classification models implemented in this work were composed by four different phases, which are summarized in Figure 2. The first was the samples’ pre-processing. Initially, an undersampling method was performed to ensure the same number of samples for each class, making the classification problem balanced. Despite reducing the number of samples with this approach, an enough number of samples were kept for training and evaluating the model. Next, the samples were randomly split into two subsets: the training subset and the validation subset. The implemented classification models considered 70% of the data for the training subset and 30% for the validation subset. As in this case there were more samples it was possible to consider less for training and more for validation.

The second phase was the RF parameters optimization, which was performed exactly as the second phase of the regression models (as described in Section 2.5.2) and separately for each model. For the consumers’ satisfaction model, the optimal parameters achieved were  $n\_estimators = 10$ ,  $max\_depth = 10$ ,  $max\_features = sqrt$ ,  $min\_samples\_split = 50$ ,  $min\_samples\_leaf = 6$ , and  $replacement = false$ . Furthermore, for the consumers’ willingness to pay more model, the optimal parameter values were  $n\_estimators = 103$ ,  $max\_depth = 50$ ,  $max\_features = automatic$ ,  $min\_samples\_split = 30$ ,  $min\_samples\_leaf = 10$ , and  $replacement = true$ .

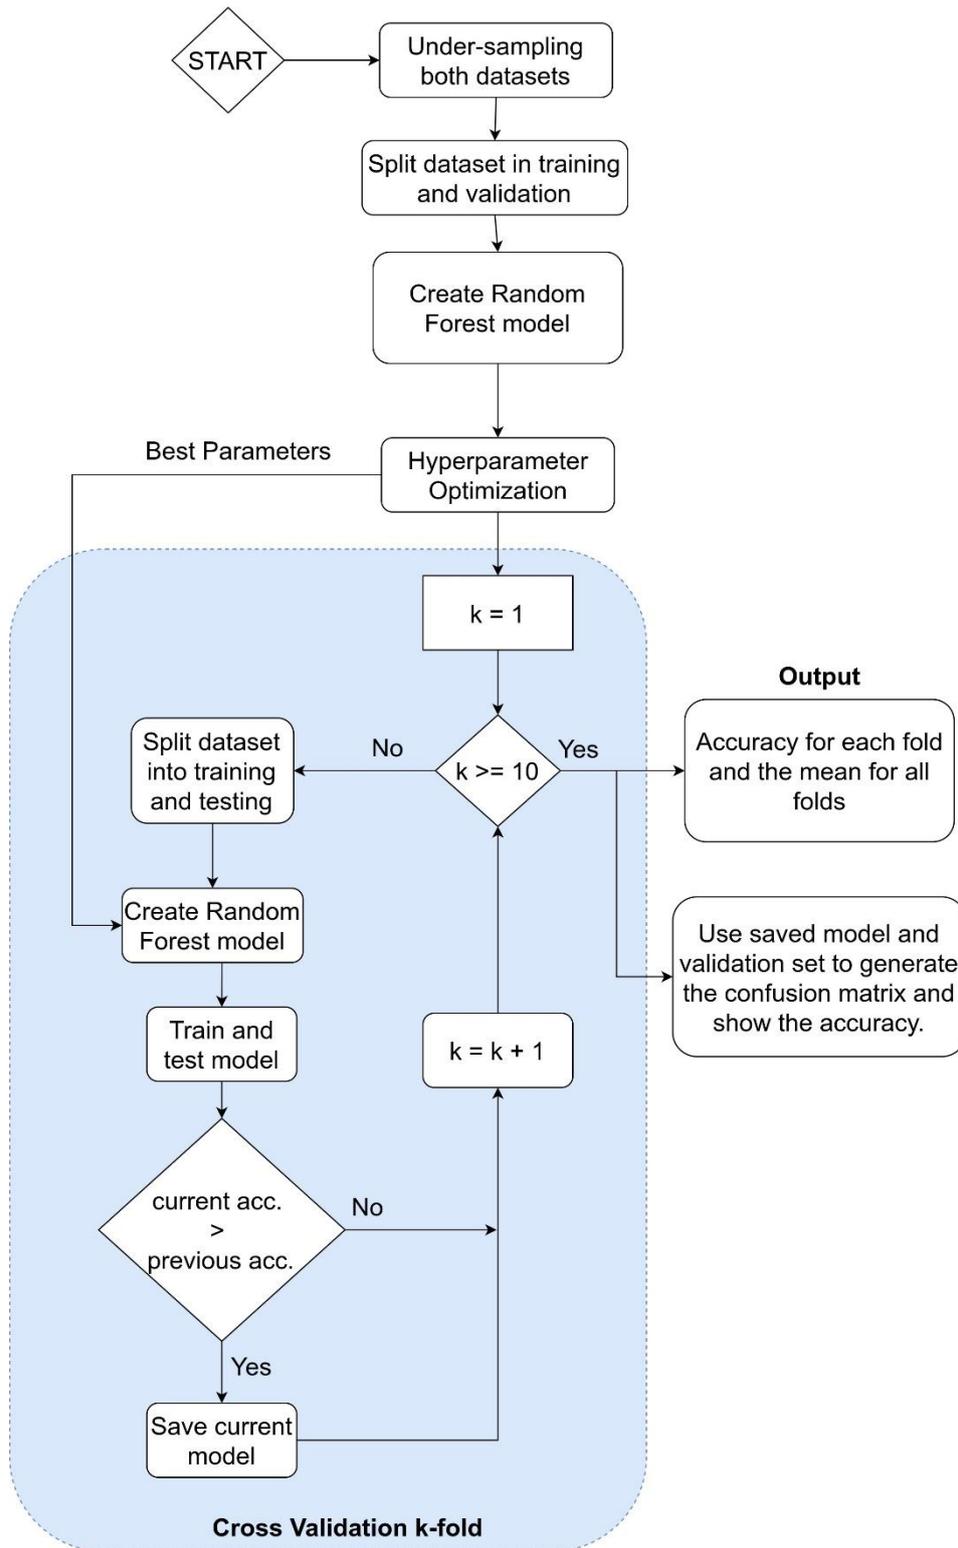


Figure 2: Scheme for creating classification models

The third phase comprised the training of the classification models and corresponds to the gray-colored area on Figure 2. This phase used a k-fold cross validation algorithm with the

samples on the training subset chosen in the first phase, in a similar way as performed in the third phase of the regression models.

The fourth and last phase consisted in evaluating the trained model using the validation subset of samples, as chosen in the first phase. This phase generated the accuracy of the models.

#### **2.5.4 Two-step classification models**

Two-step learning models were built to classify strawberry samples in the classes “satisfied” or “not satisfied”, and in the classes “would pay more” or “wouldn’t pay more”. These models took as input the physical and physical-chemical data of the strawberries, which were used to generate the acceptance, the expectancy, the ideal sweetness, the ideal succulence, and the ideal acidity values following the methodology described in Section 2.5.1. Next, the generated values were used as input for two classification models. The first classified the data between the classes “satisfied” and “not satisfied”, while the second classified the data in the classes “would pay more” or “wouldn’t pay more”. These classification models were constructed following the methodology presented in Section 2.5.2.

These models used as data the 30 strawberry samples originated from different regions or farmers. Two labels (“satisfied” or “not satisfied” and “would pay more” or “wouldn’t pay more”) were associated with each sample according to the most common response of the consumers in the sensory tests. These labels are used to assess the accuracy of the developed two-step classification models.

### **3. RESULTS AND DISCUSSION**

#### **3.1 Regression**

##### **3.1.1 Selection of variables**

The average values for the physical and physical-chemical data (X) were used to predict the average scores of the consumer's sensory responses (Y): acceptance, expectancy, ideal sweetness, ideal succulence, and ideal acidity. A variable selection phase was carried out to build a subset of the physical and physical-chemical variables that most contribute with the machine learning models. The goal of this phase is to reduce the input data dimension for the models by eliminating redundant information. The selected variables are shown in Table 2 in order of relevance for the developed models. These variables were used as input (dependent variables) for the regression models based on RF.

Table 2: Independent (X) and dependent (Y) variables for each prediction model. The independent variables are shown in order of relevance

X	Y
pH, C <sup>a</sup> _fruit, height, a* <sub>fruit</sub> , L* <sub>juice</sub> , diameter, SS <sup>b</sup> , °h <sub>juice</sub> , TA <sup>c</sup> , L* <sub>fruit</sub>	Acceptance
L* <sub>fruit</sub> , pH, juice yield, C <sup>a</sup> _fruit, heigh, °h <sub>juice</sub> , SS <sup>b</sup> , b* <sub>juice</sub> , a* <sub>fruit</sub> , SS/TA	Expectancy
C <sup>a</sup> _fruit, a* <sub>fruit</sub> , SS <sup>b</sup> , L* <sub>fruit</sub> , firmness, TA <sup>c</sup> , pH, C <sup>a</sup> _juice, a* <sub>juice</sub> , b* <sub>juice</sub>	Ideal sweetness
firmness, L* <sub>fruit</sub> , pH, b* <sub>juice</sub> , juice yield, °h <sub>fruit</sub> , a* <sub>fruit</sub> , diameter, SS <sup>b</sup> , C <sup>a</sup> _juice	Ideal succulence
SS <sup>b</sup> , C <sup>a</sup> _fruit, °h <sub>juice</sub> , a* <sub>juice</sub> , C <sup>a</sup> _juice, SS/TA, b* <sub>juice</sub> , firmness, pH, b* <sub>fruit</sub>	Ideal acidity

<sup>a</sup> Chroma

<sup>b</sup> Soluble solids

<sup>c</sup> Titratable acidity

### 3.1.2 Regression models

Several studies in the literature reported a satisfactory correlation between the consumer's acceptance and the physical and physical-chemical variables of food products <sup>6, 7, 11, 12</sup>. These studies demonstrated that multivariate learning algorithms can generate valid and robust models to correlate the studied variables.

Hence, the hypothesis of inferring the consumer's acceptance and expectancy, the ideal of sweetness, succulence, and acidity, using physical and physical-chemical variables, was first evaluated. The multivariate models were computed using the RF algorithm based on the independent variables presented in Table 2. The performance of the regression models was

evaluated using the root mean square error (RMSE) and the squared correlation coefficient ( $R^2$ ) in both training and validation phases, as shown in Table 3. In this table, the first column gives the predicted consumer's response. The second and third columns report the results for the training phase, whereas the second column gives the average  $R^2$  value across the 10 folds and the third column presents the average RMSE value for these same 10 folds. The fourth and fifth columns give the results for the validation phase and presents the  $R^2$  and the RMSE values, respectively.

Table 3:  $R^2$  and RMSE achieved by RF in the training and validation phase for all regression models

	Training phase regression		Validation phase regression	
	$R^2$	RMSE	$R^2$	RMSE
Acceptance	0.89	0.15	0.96	0.14
Expectancy	0.84	0.16	0.95	0.14
Ideal Sweetness	0.86	0.16	0.89	0.17
Ideal Juiciness	0.85	0.15	0.91	0.13
Ideal Acidity	0.72	0.09	0.92	0.06

The quality of regression models can be measured using the  $R^2$  value, such that the closer is  $R^2$  to 1, the better is the quality of the model. Tables 3 shows that the mean  $R^2$  values in the training phase was higher than 0.8 for 4 out of the 5 computed models and higher than 0.7 for all of them. Moreover, the  $R^2$  of the validation phase was higher than 0.9 in 4 out of the 5 computed models and equal to 0.89 in the other one. The maximum RMSE value was 0.16 in the training phase and 0.17 in the validation phase. It implies that the RMSE has little to no effect in the model, since its very small compared to the magnitude of the predicted variables (they range from 1 to 9 due to the numeric limits of the unstructured scales, as presented in Section 2.4.1). Therefore, the obtained results indicate that the developed models may accurately predict the acceptance, the expectation, the ideal sweetness, the ideal succulence, and the ideal acidity of strawberries using their physical and physical-chemical variables.

Few studies in the literature also used machine learning algorithms to correlate physical and physical-chemical measures with the consumer's acceptance of fruits. Lópes et al. <sup>28</sup> correlated the physical-chemical data of apples with the consumer's acceptance using a Partial Least Squares algorithm and found a  $R^2$  of 0.74. Corrêa et al. <sup>6</sup> demonstrated that it is possible to use a Multiple Linear Regression algorithm to predict the consumer's acceptance for oranges, pineapples, and grapes only using the physical and physical-chemical data of these fruits, achieving  $R^2$  values higher than 0.7 for both the training and validation phases. In our study, RF achieved  $R^2$  values higher than 0.89 for predicting the consumers acceptance for strawberry in both training and validation phases. Furthermore, we also successfully predicted the expectation, ideal sweetness, the ideal juiciness, and the ideal acidity. Hence, these works indicate that consumer's acceptance and other sensory indicators in fruits can be efficiently predicted by machine learning algorithms using physical and physical-chemical data.

The RF algorithm was previously used by Vigneau et al. <sup>10</sup> to predict the aroma of wines. The authors concluded that RF was better than the Partial Least Squares algorithm for this task, presenting higher  $R^2$  values and smaller errors. The work of Vigneau et al. <sup>10</sup>, along with the results found by our work, indicates that RF is efficient in predicting the sensory characteristics of different food products.

In this study, it was possible to observe that the models obtained through RF were effectively built and validated. For a better visualization of the ability of the models to predict the consumer's sensory response, Table 4 shows the real average sensory responses given by consumers and the values predicted by the proposed RF-based models. In general, the scores generated by the RF were very close to those of the real data. One can observe that the maximum difference between the acceptance, expectancy, ideal sweetness, ideal succulence, and ideal acidity scores were respectively 0.39, 0.38, 0.44, 0.34, and 0.12, which demonstrates the utility of the proposed model.

Table 4: Real data collected in the sensory analysis and the data generated by the validation phase of the RF algorithm

		Sample Validation																	
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
Acceptance	True Values	5.35	5.28	6.07	5.73	5.99	6.52	5.26	5.28	6.18	6.01	5.47	3.92	4.78	4.78	5.46	6.48	4.56	3.92
	Predicted Values	5.35	5.32	6.11	5.73	5.99	6.52	5.26	5.32	6.18	6.01	5.47	4.31	4.61	4.61	5.46	6.38	4.56	4.31
	Diff	0.00	-0.04	-0.04	0.00	0.00	0.00	0.00	0.00	-0.04	0.00	0.00	0.00	-0.39	0.17	0.17	0.00	0.10	0.00
Expectancy	True Values	4.32	4.49	4.98	5.15	4.98	5.21	4.37	4.49	5.09	5.27	4.76	3.45	3.77	3.77	4.64	5.46	3.99	3.45
	Predicted Values	4.32	4.63	4.98	5.15	4.97	5.11	4.37	4.63	5.09	5.27	4.76	3.83	3.80	3.80	4.64	5.46	3.99	3.83
	Diff	0.00	-0.14	0.00	0.00	0.01	0.10	0.00	-0.14	0.00	0.00	0.00	-0.38	-0.03	-0.03	0.00	0.00	0.00	-0.38
Ideal Sweetness	True Values	3.74	3.66	4.24	3.83	4.24	4.62	3.81	3.66	4.37	4.37	3.81	3.32	2.84	2.84	3.57	4.33	3.12	3.32
	Predicted Values	3.74	3.72	4.24	3.83	4.24	4.56	3.81	3.72	4.37	4.37	3.81	3.58	3.28	3.28	3.57	4.33	3.12	3.58
	Diff	0.00	-0.06	0.00	0.00	0.01	0.06	0.00	-0.06	0.00	0.00	0.00	-0.26	-0.44	-0.44	0.00	0.00	0.00	-0.26
Ideal Juiciness	True Values	4.08	4.41	5.02	4.35	4.93	4.85	4.63	4.41	5.11	4.79	4.74	4.39	3.61	3.61	4.49	4.92	3.73	4.39
	Predicted Values	4.08	4.56	5.02	4.35	4.88	4.88	4.63	4.56	5.11	4.79	4.74	4.53	3.95	3.95	4.49	4.92	3.73	4.53
	Diff	0.00	-0.15	0.00	0.00	0.05	-0.03	0.00	-0.15	0.00	0.00	0.00	-0.14	-0.34	-0.34	0.00	0.00	0.00	-0.14
Ideal Acidity	True Values	4.72	4.96	4.93	4.89	5.22	4.56	4.99	4.96	5.33	5.04	4.78	4.84	5.17	5.17	5.23	4.84	5.01	4.84
	Predicted Values	4.72	4.84	4.88	4.89	5.22	4.56	4.99	4.84	5.33	5.04	4.78	4.95	5.14	5.14	5.23	4.82	5.01	4.95
	Diff	0.00	0.12	0.05	0.00	0.00	0.00	0.00	0.12	0.00	0.00	0.00	-0.11	0.03	0.03	0.00	0.02	0.00	-0.11

### 3.2 Classification models

In this study, RF was also used to classify the strawberry samples according to the consumer's satisfaction and willingness to pay more. The classification model labels a strawberry sample instead of estimating a value. In this case, the dependent variable is a class and not a quantitative variable.

Table 5 gives the accuracy achieved for the 10 folds in the training phase of the classification models along with the mean and the standard deviation of the accuracy across all folds. The second column reports the accuracy for classifying the strawberry samples in the classes "satisfied" and "not satisfied", while the third column shows the accuracy for classifying the strawberry samples in the classes "would pay more" and "wouldn't pay more". It shows that the classification models constructed through the RF algorithm were able to correctly classify 88.33% samples according to the consumer's satisfaction. Additionally, the RF models correctly classified 79.41% according to the consumer's willingness to pay more or not.

Table 5: Classification accuracy of the constructed models (training phase)

	Cross-validation – accuracy in each fold (%)	
	Classification in "satisfied" and "not satisfied"	Classification in "would pay more" and "wouldn't pay more"
Fold 1	91.67	79.18
Fold 2	87.22	80.00
Fold 3	92.22	78.37
Fold 4	86.11	82.38
Fold 5	89.44	74.59
Fold 6	88.89	79.10
Fold 7	89.44	81.56
Fold 8	85.00	79.10
Fold 9	83.89	82.79
Fold 10	89.44	77.05
Mean accuracy of all folds	<b>88.33</b>	<b>79.41</b>
SD of all folds	<b>2.59</b>	<b>2.35</b>

Figure 3 presents the confusion matrix for the classification results considering the validation dataset. It is possible to observe that the RF model reached an accuracy of 87.95% in

classifying samples in “satisfied” and “not satisfied”. Additionally, one can observe that the model had a larger type-2 error than a type-1 error, which means that the model overestimated the consumer satisfaction for strawberries.

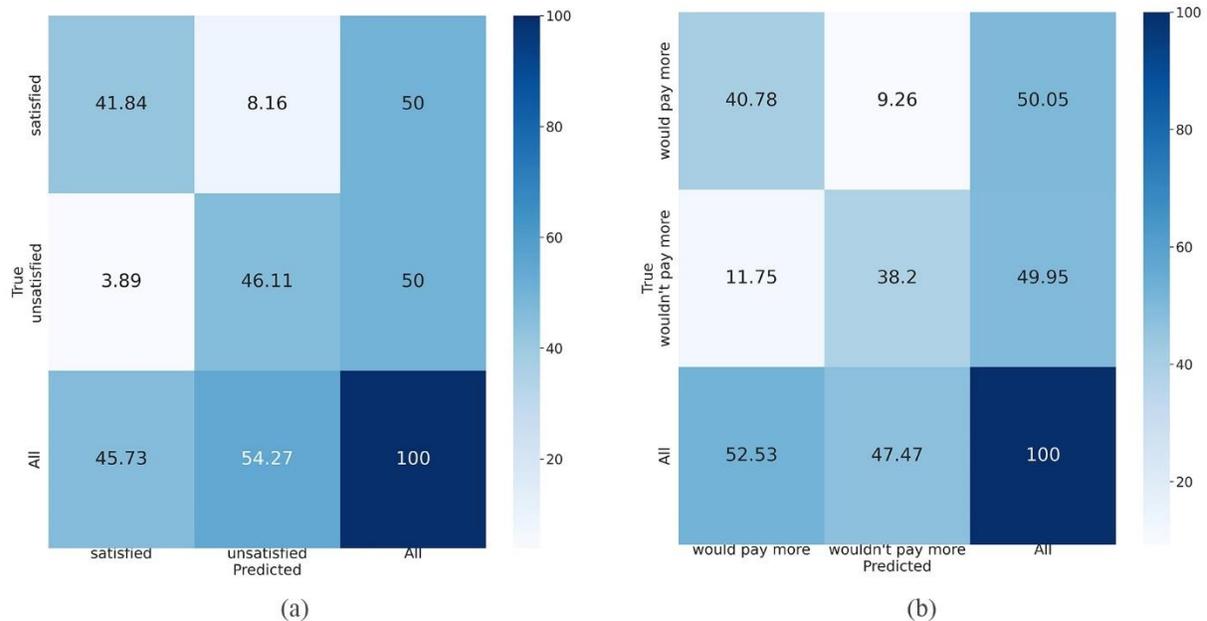


Figure 3: (a) Confusion matrix for classification regarding the consumer's satisfaction; (b): Confusion matrix for classification regarding the consumer's willingness to pay more

Figure 3 (b) shows that the RF achieved 78.99% of accuracy for the classification in “would pay more” and “wouldn't pay more” (for validation data). Unlike the previous model (see Figure 3 (a)), this model presented an error type-2 smaller than type-1. Thus, one can say that it has a slightly tendency in underestimating the willingness of the consumer to pay more for a high-quality strawberry sample.

Pereira et al. <sup>18</sup> classified papayas into three maturation stages using photos of the fruits through the RF algorithm. Their model achieved an accuracy of 94.3% in the training phase and 93.3% in the validation phase. Furthermore, D'Archivio et al. <sup>20</sup> used a Partial Least Squares

algorithm to identify the region of origin of 144 samples of saffron using their chemical data and obtained an accuracy of 88%.

It is important to highlight that the strawberry sample was very heterogeneous, and that the consumer's response is based on their own personal criteria. Despite these facts, the results obtained by the validation phase show the efficacy and robustness of the RF in classifying the strawberry samples according to the consumer's responses using the given sensory data.

### **3.3 Two-step learning model**

Figure 4 (a) shows the results for the classification in "satisfied" and "not satisfied", while Figure 4 (b) gives the results for the classification in "would pay more" and "wouldn't pay more" for the two-step learning model. It is possible to observe that the two-step learning model achieved 100% of accuracy for classifying the strawberry samples according to the consumer's satisfaction. This accuracy is higher than that of the classification model shown in Figure 3 (a). This increased accuracy was achieved because the two-step learning model considered the mode of the consumers satisfaction, thus being able to overpass the personal preference of the consumers. Therefore, these results indicate that the two-steps model is a robust mechanism to classify strawberries according to the satisfaction of the consumers.

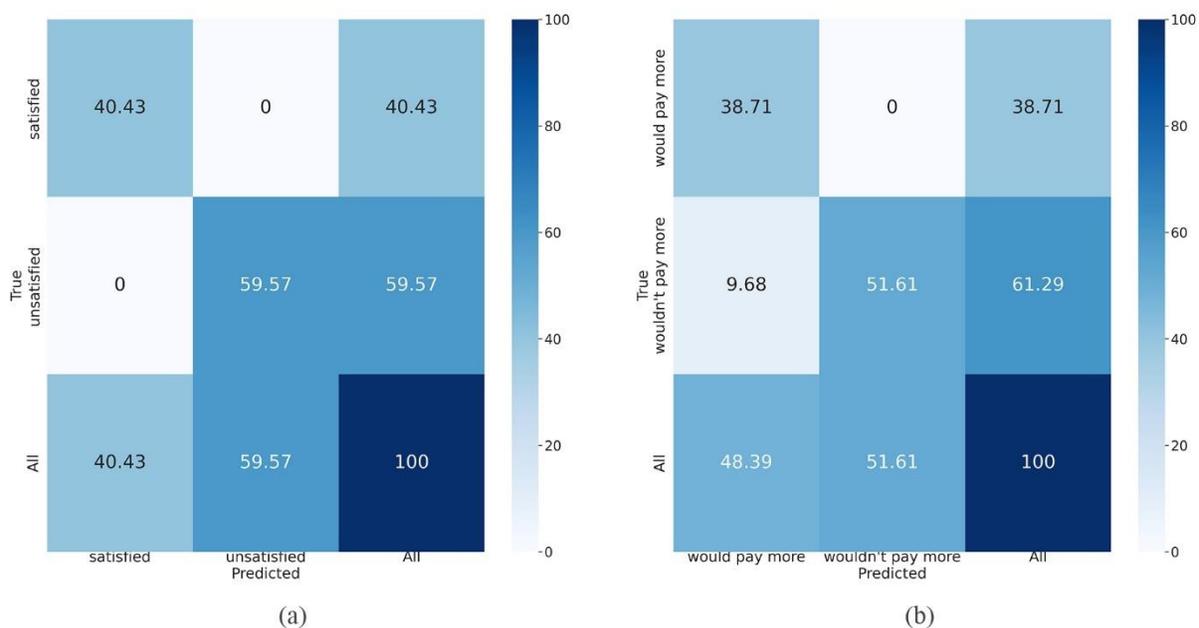


Figure 4: (a) Confusion matrix for classification regarding the consumer's satisfaction; (b) Confusion matrix for classification regarding the consumer's willingness to pay more

Similar results are found for the two-step learning model for the classification of strawberry samples in the classes “would pay more” and “wouldn't pay more”, as shown in the confusion matrix in Figure 4 (b). This model achieved an accuracy of 90.32%, which is much higher than that of the classification model shown in Figure 3 (b). It also can be explained by the fact that the two-step learning model considered the most frequent response of the consumers regarding their willingness to pay more, thus removing the personal criteria of each consumers from the model.

#### 4. CONCLUSIONS

It was possible to identify the physical and physical-chemical variables that significantly contributed to the construction of the models. The RF algorithm was able to predict the acceptance, expectation, ideal sweetness, ideal succulence, and ideal acidity of strawberries using simple and fast physical and physical-chemical data. Furthermore, the RF algorithm was also able to classify strawberry samples according to the consumer's satisfaction and their willingness to pay more.

The experiments also demonstrated that it was possible to classify the strawberries into these classes using only their physical and physical-chemical data through a two-step learning model. This successful result corroborates with the fact that it is possible to obtain a correlation between the sensory variables (acceptance, expectation, ideal of sweetness, ideal of succulence, and ideal of acidity) with the consumer's satisfaction and willingness to pay more. It also suggests that the generated RF-based models can be used in the quality control of strawberries and to establish the correct price of the fruit considering its sensory quality, thus ensuring consumer's satisfaction.

Therefore, one can conclude that the generated models can be efficiently used to predict the consumer's sensory response, which guarantees the consumer's satisfaction. Future works may extend the proposed methodology for assuring the consumer's satisfaction of other fruits.

## **ACKNOWLEDGEMENTS**

This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Finance Code 001, the Conselho Nacional de Desenvolvimento Científico e Tecnológico - Brasil (CNPq), the Fundação de Amparo à Pesquisa do Estado de São Paulo – Brasil (FAPESP), and the Fundação de Amparo à Pesquisa de Minas Gerais - Brasil (FAPEMIG).

Declarations of interest: none

## **REFERENCES**

1 Bae YW, Lee SM, Kim KO. Age and gender differences in the influence of extrinsic product information on acceptability for RTD green tea beverages. *Journal of the Science of Food and Agriculture*. 2016 Mar;96(4):1362-72.

- 2 Yu P, Low MY, Zhou W. Design of experiments and regression modelling in food flavour and sensory analysis: A review. *Trends in Food Science & Technology*. 2018 Jan 1;71:202-15.
- 3 Yu P, Yeo AS, Low MY, Zhou W. Identifying key non-volatile compounds in ready-to-drink green tea and their impact on taste profile. *Food chemistry*. 2014 Jul 15;155:9-16.
- 4 Hurling R, Shepherd R. Eating with your eyes: effect of appearance on expectations of liking. *Appetite*. 2003 Oct 1;41(2):167-74.
- 5 Chitarra MI, Chitarra AB. *Pós-Colheita de Frutas e Hortaliças: Fisiologia e Manuseio*. 2nd edn (Lavras: UFLA).
- 6 Corrêa, S. C., Pinheiro, A. C. M., Siqueira, H. E., Carvalho, E. M., Nunes, C. A., & Boas, E. V. D. B. V. (2014). Prediction of the sensory acceptance of fruits by physical and physical–chemical parameters using multivariate models. *LWT-Food Science and Technology*, 59(2), 666-672.
- 7 Nunes CA, Souza VR, Rodrigues JF, Pinheiro AC, Freitas MP, Bastos SC. Prediction of consumer acceptance in some thermoprocessed food by physical measurements and multivariate modeling. *Journal of Food Processing and Preservation*. 2017 Oct;41(5):e13178.
- 8 Yu P, Low MY, Zhou W. Development of a partial least squares-artificial neural network (PLS-ANN) hybrid model for the prediction of consumer liking scores of ready-to-drink green tea beverages. *Food Research International*. 2018 Jan 1;103:68-75.
- 9 Caballero D, Caro A, Dahl AB, Ersbøll BK, Amigo JM, Pérez-Palacios T, Antequera T. Comparison of different image analysis algorithms on MRI to predict physico-chemical and sensory attributes of loin. *Chemometrics and intelligent laboratory systems*. 2018 Sep 15;180:54-63.
- 10 Vigneau E, Courcoux P, Symoneaux R, Guérin L, Villière A. Random forests: A machine learning methodology to highlight the volatile organic compounds involved in olfactory perception. *Food Quality and Preference*. 2018 Sep 1;68:135-45.
- 11 Cadena RS, Cruz AG, Netto RR, Castro WF, Faria JD, Bolini HM. Sensory profile and physicochemical characteristics of mango nectar sweetened with high intensity sweeteners throughout storage time. *Food Research International*. 2013 Dec 1;54(2):1670-9.
- 12 Piombino P, Sinesio F, Moneta E, Cammareri M, Genovese A, Lisanti MT, Mogno MR, Peparaio M, Termolino P, Moio L, Grandillo S. Investigating physicochemical, volatile and sensory parameters playing a positive or a negative role on tomato liking. *Food Research International*. 2013 Jan 1;50(1):409-19.
- 13 Breiman L. Random forests. *Machine learning*. 2001 Oct 1;45(1):5-32.
- 14 Shah K, Patel H, Sanghvi D, Shah M. A comparative analysis of logistic regression, random Forest and KNN models for the text classification. *Augmented Human Research*. 2020 Dec;5(1):1-6.

- 15 Wyner AJ, Olson M, Bleich J, Mease D. Explaining the success of adaboost and random forests as interpolating classifiers. *The Journal of Machine Learning Research*. 2017 Jan 1;18(1):1558-90.
- 16 Ahmad MW, Mourshed M, Rezgui Y. Trees vs Neurons: Comparison between random forest and ANN for high-resolution prediction of building energy consumption. *Energy and Buildings*. 2017 Jul 15;147:77-89.
- 17 Han T, Jiang D, Zhao Q, Wang L, Yin K. Comparison of random forest, artificial neural networks and support vector machine for intelligent diagnosis of rotating machinery. *Transactions of the Institute of Measurement and Control*. 2018 May;40(8):2681-93.
- 18 Pereira LF, Barbon Jr S, Valous NA, Barbin DF. Predicting the ripening of papaya fruit with digital imaging and random forests. *Computers and Electronics in Agriculture*. 2018 Feb 1;145:76-82.
- 19 Qiu S, Wang J. The prediction of food additives in the fruit juice based on electronic nose with chemometrics. *Food chemistry*. 2017 Sep 1;230:208-14.
- 20 D'Archivio AA, Giannitto A, Maggi MA, Ruggieri F. Geographical classification of Italian saffron (*Crocus sativus* L.) based on chemical constituents determined by high-performance liquid-chromatography and by using linear discriminant analysis. *Food chemistry*. 2016 Dec 1;212:110-6.
- 21 Gao P, Jiang Q, Xu Y, Yang F, Yu P, Xia W. Aroma profiles of commercial Chinese traditional fermented fish (Suan yu) in Western Hunan: GC-MS, odor activity value and sensory evaluation by partial least squares regression. *International Journal of Food Properties*. 2020 Jan 1;23(1):213-26.
- 22 Official Methods of Analysis of AOAC INTERNATIONAL. 21st ed. Rockville: AOAC International; 2019
- 23 Wakeling IN, MacFie HJ. 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 Quality and Preference*. 1995 Jan 1;6(4):299-308.
- 24 Pedregosa F, Varoquaux G, Gramfort A, Michel V, Thirion B, Grisel O, Blondel M, Prettenhofer P, Weiss R, Dubourg V, Vanderplas J. Scikit-learn: Machine learning in Python. *the Journal of machine Learning research*. 2011 Nov 1;12:2825-30.
- 25 Breiman L, Friedman J, Stone CJ, Olshen RA. *Classification and regression trees*. CRC press; 1984.
- 26 Louppe G, Wehenkel L, Sutter A, Geurts P. Understanding variable importances in forests of randomized trees. In *Advances in neural information processing systems 2013* (pp. 431-439).
- 27 Fushiki T. Estimation of prediction error by using K-fold cross-validation. *Statistics and Computing*. 2011 Apr 1;21(2):137-46.

28 López ML, Villatoro C, Fuentes T, Graell J, Lara I, Echeverría G. Volatile compounds, quality parameters and consumer acceptance of 'Pink Lady®' apples stored in different conditions. *Postharvest Biology and Technology*. 2007 Jan 1;43(1):55-66.

**ARTIGO 2 - A COMPARISON OF MACHINE LEARNING ALGORITHMS FOR  
PREDICTING CONSUMER RESPONSES BASED ON PHYSICAL, CHEMICAL, AND  
PHYSICAL-CHEMICAL DATA OF FRUITS**

Normas da Revista Científica: Scientia Horticulturae

ISSN: 0304-4238

(versão preliminar)

## ABSTRACT

Machine learning algorithms are widely used for predicting the consumer response to several food products. Recent studies in the literature demonstrated that it is possible to predict the consumer response to fruits using the physical, chemical, and physical-chemical data of fruits as input for the machine learning algorithms. However, a myriad of machine learning algorithms exists, and there is no consensus on which algorithm is the best for this task. This work evaluates and compares the results of six machine learning algorithms in predicting the consumers' acceptance, expectation, and their ideal of sweetness, succulency, and acidity for three different fruits. The results demonstrated that, indeed, there is no algorithm that outperforms all others for this task. Each one has its advantages and disadvantages and performs differently according to the fruit and corresponding dataset. Therefore, it highlights the importance of carefully selecting, optimizing, and comparing several algorithms when one is interested in predicting the consumer response to fruits.

**Keywords:** Machine learning; experimental analysis; consumer response; sensory analysis; physical-chemical data; fruits

## 1. INTRODUCTION

The taste and consumer acceptance for fruits rely on the quality of the fruits. In general, the fruit's quality includes a number of extrinsic (such as price, nutritional facts, credibility of the sellers brand, among others) and intrinsic (such as physical appearance, chemical, physical-chemical, and sensory characteristics) factors. Therefore, the consumer response to fruits is directly correlated to the combination of the intrinsic characteristics of the fruits but is also influenced by their extrinsic attributes (Musacchi & Serra, 2018).

Consumers are used to choose and buy fruits based on their visual appearance, taking into consideration their color and size (Kyriacou & Rouphael, 2018). However, these attributes, if unaccompanied, are not good indicators of the fruits' quality (Corrêa et al., 2014). Therefore, this visual-based selection can potentially lead to consumer's dissatisfaction as the chosen fruit may not be as good as it looks (Ribeiro et al., 2021; Yu et al., 2018).

One can correlate the physical, chemical, and physical-chemical parameters of fruits with consumer acceptance and expectation by employing machine learning algorithms (Kyriacou & Rouphael, 2018). Using such algorithms, it is possible to predict the consumer responses accurately. Thus, consumers can be aware of the fruit quality beforehand, which narrows their expectations and probably diminishes their dissatisfaction (Correa et al., 2014; Ribeiro et al., 2021; Yu et al., 2018).

The recent review presented by Yu et al. (2018) pointed out that many machine learning algorithms were used for correlating physical, chemical, and physical-chemical parameters of food products with their sensory parameters and consumer's response. Furthermore, the authors identified the advantages and disadvantages of many of these algorithms. However, their analysis was only theoretical and no experimental data to compare these algorithms was shown.

In this research we evaluated six of the most employed machine learning algorithms in the literature and contrasted their results when predicting the consumers' acceptance, expectation, and their ideal of sweetness, succulency, and acidity for three different fruits.

## **2. MATERIALS AND METHODS**

### **2.1 Materials**

A total of 31 samples of orange (*Citrus Sinensis x Rutaceae*), 24 samples of tangor (*C. reticulata* × *C. sinensis*; mandarin × orange hybrid), and 22 samples of grape (*Vitis vinífera x Vitaceae*) were bought from several local markets in the city of Lavras, Minas Gerais, Brazil. Each acquired sample was produced by a different producer/farmer. Additionally, there was a temporal gap between the purchase of a set of samples and another. Therefore, it was possible to obtain fruits with varied quality. Every sample contained approximately 4 kg of fruits, thus being sufficient for both the sensorial study and the physical, chemical, and physical-chemical analysis.

### **2.2 Fruits manipulation**

Sample preparation and pre-processing followed the methodology employed by Côrrea et al. (2014) and Ribeiro et al. (2021). Initially, the fruits were hand-picked to discard those which had visible physical damage. Next, they were washed into running water and, then, submersed into a sanitizing solution for 15 minutes. The tangors and the oranges were sanitized with a sodium hypochlorite solution (200 ppm), while the grapes were sanitized with a sodium hypochlorite solution (100 ppm). Thereafter, the fruits were standardized: the oranges were peeled and perpendicularly cut into four equal pieces following its center line; the tangors were peeled and their segments pulled apart; and the grapes had their whole berries removed from the cluster.

The standardized fruits were separated for both the sensory and the physical, chemical, and physical-chemical analysis. The physical, chemical, and physical-chemical analysis were carried out immediately after the fruits standardization, while the sensory analysis were performed through the day. All fruits were kept refrigerated at 14 °C during the sensory analysis.

### **2.3 Physical and physical-chemical analysis**

The physical and physical-chemical analysis were performed in six repetitions for every fruit sample, strictly following the methodology presented by Ribeiro et al. (2021). The titratable acidity (TA), soluble solids (SSC), and the SSC/TA ratio were computed following the AOAC (2019) guidelines. The color of the fruits was determined in three distinct points of the fruit surface using a Minolta colorimeter, model CR-400, with illuminator D65 and color systems CIE L\*, a\*, and b\*, previously calibrated. To measure the color of the juice, 20 ml of the liquid was put into a Petri plate and the color readings were performed in the inferior surface of the plate containing the juice. The firmness of the whole fruit was measured by a puncture test in two points in the equatorial region of the fruit using a Magness-Taylor penetrometer, with a 5mm probe, being the

results expressed in Newtons (N). The height and diameter of the fruits were determined using a digital pachymeter 150mm/6" CSX-B Mitutoyo® and the results were expressed in millimeters. The juice yield was computed after the weighting of the fruits (without their calyx) in a semi-analytical balance and processing in a juicer extractor Cadence juicer plus model JCE400 60 Hz 700W.

## 2.4 Sensory analysis

The sensory analysis was carried out by consumers that appreciate and frequently consume the studied fruits. Furthermore, they affirmed that were interested in participating in this study. Table 1 shows the delineation of the sensory analysis. It shows, for every fruit, the number of sensory analysis sessions that were performed, the number of fruit samples within each session, and the number of consumers that participated in each session. All consumers were 18 years of age or older at the time of sensory analysis, and 98.6% of them were under 45 years old. Men accounted for 35.2%, 42.5%, and 41.7% of the consumers that analyzed the orange, tangor, and grape samples, respectively. Each sensory session was carried out on a different day so that a consumer only evaluated a single fruit (orange, tangor, or grape) in each sensory analysis session. Furthermore, each session was performed using a balanced complete block design.

Table 1: Number of consumers and samples in each sensory session.

		Session 1	Session 2	Session 3	Session 4	Session 5	Session 6	Total
Orange	Samples	4	4	6	5	6	6	<b>31</b>
	Consumers	108	120	118	120	120	119	<b>705</b>
Tangor	Samples	3	4	4	5	4	4	<b>24</b>
	Consumers	97	118	93	100	111	105	<b>624</b>
Grape	Samples	6	6	5	5	-	-	<b>22</b>
	Consumers	120	120	120	117	-	-	<b>477</b>

The sensory analysis extended strictly following the methodology employed by Ribeiro et al. (2021). We evaluated the acceptance, expectation, ideal of sweetness, ideal of succulence, and the ideal of acidity of each fruit. Consumers were presented with pieces of approximately 20g of tangor and orange or a grape berry, along with a glass of water. All fruit samples were codified using 3-digit random numbers and presented in monadic and balanced order, following the sensory

methodology proposed by Walkeling & Macfie (1995). This study was reviewed and approved by the Ethics Committee for Research with Humans of the Universidade Federal de Lavras, under the code CAAE 12112113.8.0000.5148.

## 2.5 Machine learning models design

Six machine learning models Random Forest (RF), Decision Tree (TREE), a Support Vector Machine (SVM), Multilayer Perceptron neural network (MLP), K-Nearest Neighbors (KNN), and Multivariate Linear Regression (MLR) were designed for predicting the consumer responses to each fruit. All algorithms were developed via MatLab software.

To compare the performances of the different predictive models proposed we used the Cross-validation. Due to the small databases available for this work as one can see in Table 1 (31 samples of orange, 24 samples of tangor, and 22 samples of grape), we chose the leave-one-out cross-validation procedure (Kohavi, 1995).

Firstly, a relevance analysis was carried out, in which input variables with linear correlation lower than  $|0.2|$  in relation to the target variable were discarded. Those input variables with linear correlation higher than  $|0.7|$  each other were also discarded.

The development of the models can be divided into four phases, as follows. In the first phase, we randomly split the dataset into two parts: 80% of the data was used for training, while the remaining 20% were kept for the validation. The second phase was the tuning process of the algorithm. In this phase, a total of 100 random search processes were employed to perform the hyperparameter optimization of the algorithms using the training dataset. In the third phase, the algorithms were trained using the leave-one-out cross validation procedure. Each iteration of the leave-one-out was performed 20 times, and the best model was selected. The fourth and last phase was the validation of the algorithm. This validation was carried out using the 20% of the samples that were not used to train the algorithms. In this last phase, we recorded the coefficient of determination ( $R^2$ ) and the root mean squared error (RMSE) of each model. As the leave-one-out cross validation was applied, we found a predictive model for each fold of the leave-one-out procedure and, therefore, we computed the average values of  $R^2$  and RMSE achieved for the validation dataset.

For the KNN algorithm, we used the Euclidean distance as metric, and we considered  $K = 1, 3, 5$  and  $7$ . We found that  $K = 5$  led to better results. For the MLR model the least-squares algorithm was used as fitting function. The linear function was used as Kernel to compute the elements of the Gram matrix in the SVM model. For the TREE algorithm, we used the mean squared error (MSE) as split criterion. The Least-Squares Boosting algorithm was used for the RF model. For the MLP model, a hidden layer was used in which the number of neurons was varied from 2 to 10. The chosen number of neurons was 5. The hyperbolic tangent was used as activation function in the hidden layer and the linear function was used in output layer, which comprises only one neuron. The Levenberg-Marquardt algorithm was used for training.

## 3. RESULTS AND DISCUSSION

### 3.1 Selection of variables

Table 2 shows the variables employed in each machine learning model. The first column shows the fruit name, while the second column presents the selected variables, also called as independent variables of the machine learning models. Besides that, the third column gives the name of the parameter that was predicted, which is known as the dependent variable of the machine learning models. These variables were used in the remaining tests.

Table 2: Independent and dependent variables for each prediction model of each fruit

Fruits	Independent	Dependent
Orange	height, C <sup>a</sup> _peel, °h_ peel, L*_pulp, a*_juice, C <sup>a</sup> _juice, juice yield, pH, SS <sup>b</sup>	Acceptance
	height, a*_ peel, C <sup>a</sup> _ peel, °h_ peel, L*_pulp, a*_juice, C <sup>a</sup> _juice, juice yield, pH, SS <sup>b</sup>	Expectancy
	height, firmness, b*_ peel, C <sup>a</sup> _ peel, °h_ peel, L*_pulp, a*_juice, C <sup>a</sup> _juice, juice yield, pH, SS <sup>b</sup> , SS/TA	Ideal sweetness
	height, C <sup>a</sup> _ peel, °h_ peel, L*_pulp, a*_juice, C <sup>a</sup> _juice, juice yield, pH, SS <sup>b</sup>	Ideal succulence
	height, L*_ peel, a*_ peel, °h_ peel, L*_pulp, a*_juice, C <sup>a</sup> _juice, juice yield, pH, SS <sup>b</sup>	Ideal acidity
Tangor	height, firmness, L*_juice, juice yield, pH, SS <sup>b</sup> , TA <sup>c</sup>	Acceptance
	firmness, a*_ peel, b*_ peel, °h_juice, juice yield, pH, SS <sup>b</sup> , SS/TA	Expectancy
	diameter, height, firmness, L*_ peel, C <sup>a</sup> _ peel, juice yield, pH, SS <sup>b</sup> , TA <sup>c</sup>	Ideal sweetness
	diameter, C <sup>a</sup> _ peel, °h_juice, juice yield, pH, SS <sup>b</sup> , TA <sup>c</sup>	Ideal succulence
	diameter, °h_ peel, °h_juice, juice yield, pH, SS <sup>b</sup> , TA <sup>c</sup>	Ideal acidity
Grape	firmness, a*_fruit, °h_fruit, a*_juice, C <sup>a</sup> _juice, SS <sup>b</sup> , TA <sup>c</sup> , SS/TA	Acceptance
	firmness, L*_fruit, a*_fruit, C <sup>a</sup> _fruit, a*_juice, C <sup>a</sup> _juice, juice yield, SS <sup>b</sup>	Expectancy
	firmness, a*_fruit, C <sup>a</sup> _fruit, a*_juice, C <sup>a</sup> _juice, juice yield	Ideal sweetness
	firmness, a*_fruit, C <sup>a</sup> _fruit, a*_juice, C <sup>a</sup> _juice, juice yield, SS <sup>b</sup>	Ideal succulence
	diameter, firmness, b*_fruit, °h_fruit, a*_juice, C <sup>a</sup> _juice, juice yield o, SS <sup>b</sup>	Ideal acidity

<sup>a</sup> Chroma

<sup>b</sup> Soluble solids

<sup>c</sup> Titratable acidity

### 3.2 Regression models

The results of the six machine learning algorithms are displayed in Table 3. The first column of this table presents the fruit name, while the second column gives the consumer response that was predicted. Additionally, the third column shows which parameters of the algorithm are displayed, *i.e.*, the coefficient of determination ( $R^2$ ) or the root mean squared error (RMSE). Then, each subsequent column presents the results for a different algorithm, showing the average and the standard deviation values of the evaluated parameter ( $R^2$  or RMSE). One may remember that the higher is the  $R^2$  value, the more accurate is the algorithm in predicting the consumer response. Furthermore, as lower is the RMSE value, the smaller is the average error of the algorithm. We highlighted in bold the results that were able to successfully predict each consumer response, *i.e.*,

those algorithms that achieved an average  $R^2$  value greater than 0.7 and an average RMSE value smaller than 10% (0.9) of the size of the employed scale.

One can see that the results of an algorithm greatly vary depending on the evaluated fruit and of the predicted consumer response. Despite that, one or two algorithms were able to achieve good results for every fruit and for each one of the evaluated consumer responses. This result indicates that, regardless of the evaluated fruit or the predicted consumer response, we were always able to develop a successful machine learning model. Conversely, four or five algorithms were not able to successfully predict each consumer response. Thus, it suggests that most of the proposed machine learning models were unsuccessful in predicting the consumer responses to the evaluated fruits, which may have been caused by the small database used for training the algorithms.

A series of statistical analyses were performed to investigate if there exists an algorithm that outperforms the others in predicting the consumer responses. To do so, we ranked the data presented in Table 3 using the ranking methodology proposed by Carvalho (2019). For every fruit and each consumer response, the results of the algorithms were ranked lexicographically, whereas the  $R^2$  value had a greater importance than the RMSE value. Therefore, despite the results of each algorithm being presented as two values ( $R^2$  and RMSE), it was possible to devise a single ranking.

The resulting rank was used as input to nine different paired Friedman's tests, whereas each test evaluated a different subset of entries. The first Friedman's test used all available ranked data. The second, third, and fourth Friedman's tests used as input the data of a single fruit, *i.e.*, the second test evaluated the results for the tangor, the third test assessed the results for the orange, and the fourth test appraised the results for the grape. Each one of the remaining Friedman's tests used as input the data of a consumer response for all three fruits. Thus, the fifth test evaluated the data for the consumer acceptance for orange, tangor, and grapes, the sixth test appraised the data for the consumers expectancy of these same fruits, and so on.

No one of the Friedman's tests was able to reject the null hypothesis at a 5% significance level, *i.e.*, the  $p$ -value returned by the tests were always greater than 0.05. Therefore, it is possible to affirm that no algorithm outperformed another in predicting the consumer responses to orange, tangor, or grape using their physical, chemical, and physical-chemical data as predictors.

Table 3: R<sup>2</sup> and RMSE achieved by the algorithms in the validation phase for all constructed models

			RF	TREE	SVM	MLP	KNN	MLR	
Orange	Acceptance	R <sup>2</sup>	0.55 ± 0.22	<b>0.89 ± 0.08</b>	0.52 ± 0.03	0.51 ± 0.24	0.63 ± 0.09	0.51 ± 0.05	
		RMSE	0.56 ± 0.23	<b>0.27 ± 0.04</b>	0.83 ± 0.06	0.72 ± 0.25	0.40 ± 0.04	0.82 ± 0.05	
	Expectancy	R <sup>2</sup>	0.42 ± 0.07	0.09 ± 0.06	<b>0.72 ± 0.11</b>	0.38 ± 0.27	0.43 ± 0.11	0.69 ± 0.06	
		RMSE	0.64 ± 0.08	0.73 ± 0.06	<b>0.37 ± 0.06</b>	0.80 ± 0.32	0.57 ± 0.03	0.39 ± 0.04	
	Ideal sweetness	R <sup>2</sup>	<b>0.71 ± 0.11</b>	0.47 ± 0.17	0.59 ± 0.04	0.25 ± 0.23	0.66 ± 0.17	0.50 ± 0.02	
		RMSE	<b>0.34 ± 0.08</b>	0.43 ± 0.09	0.43 ± 0.08	0.62 ± 0.18	0.34 ± 0.07	0.43 ± 0.04	
	Ideal succulence	R <sup>2</sup>	<b>0.77 ± 0.08</b>	0.68 ± 0.08	<b>0.82 ± 0.02</b>	<b>0.71 ± 0.17</b>	<b>0.81 ± 0.02</b>	<b>0.81 ± 0.01</b>	
		RMSE	<b>0.61 ± 0.11</b>	0.47 ± 0.04	<b>0.49 ± 0.08</b>	<b>0.63 ± 0.26</b>	<b>0.32 ± 0.10</b>	<b>0.60 ± 0.04</b>	
	Ideal acidity	R <sup>2</sup>	<b>0.78 ± 0.09</b>	0.44 ± 0.12	<b>0.77 ± 0.06</b>	0.44 ± 0.27	0.52 ± 0.09	0.66 ± 0.07	
		RMSE	<b>0.19 ± 0.03</b>	0.29 ± 0.03	<b>0.26 ± 0.02</b>	0.32 ± 0.09	0.27 ± 0.01	0.25 ± 0.01	
	Tangor	Acceptance	R <sup>2</sup>	<b>0.77 ± 0.21</b>	<b>0.74 ± 0.08</b>	0.55 ± 0.14	0.56 ± 0.30	0.24 ± 0.25	0.47 ± 0.09
			RMSE	<b>0.58 ± 0.09</b>	<b>0.51 ± 0.13</b>	0.56 ± 0.14	0.68 ± 0.22	0.66 ± 0.16	0.59 ± 0.14
		Expectancy	R <sup>2</sup>	0.25 ± 0.20	0.27 ± 0.19	0.20 ± 0.33	0.27 ± 0.27	<b>0.70 ± 0.06</b>	0.15 ± 0.28
			RMSE	0.57 ± 0.12	0.59 ± 0.12	0.53 ± 0.09	0.72 ± 0.29	<b>0.61 ± 0.03</b>	0.52 ± 0.08
Ideal sweetness		R <sup>2</sup>	0.61 ± 0.28	<b>0.71 ± 0.32</b>	0.57 ± 0.14	0.43 ± 0.31	0.35 ± 0.20	0.64 ± 0.08	
		RMSE	0.34 ± 0.06	<b>0.30 ± 0.13</b>	0.66 ± 0.13	0.51 ± 0.23	0.39 ± 0.05	0.72 ± 0.17	
Ideal succulence		R <sup>2</sup>	0.31 ± 0.33	0.37 ± 0.41	<b>0.71 ± 0.07</b>	0.48 ± 0.30	0.38 ± 0.28	<b>0.70 ± 0.07</b>	
		RMSE	0.27 ± 0.19	0.21 ± 0.15	<b>0.18 ± 0.15</b>	0.26 ± 0.21	0.17 ± 0.07	<b>0.20 ± 0.21</b>	
Ideal acidity		R <sup>2</sup>	0.66 ± 0.26	<b>0.79 ± 0.21</b>	0.52 ± 0.15	0.39 ± 0.28	0.66 ± 0.19	0.44 ± 0.12	
		RMSE	0.37 ± 0.09	<b>0.26 ± 0.12</b>	0.31 ± 0.08	0.33 ± 0.13	0.26 ± 0.06	0.46 ± 0.14	
Grape		Acceptance	R <sup>2</sup>	<b>0.83 ± 0.10</b>	<b>0.86 ± 0.01</b>	0.59 ± 0.11	0.66 ± 0.26	0.53 ± 0.16	0.35 ± 0.17
			RMSE	<b>0.38 ± 0.17</b>	<b>0.32 ± 0.04</b>	0.68 ± 0.21	0.52 ± 0.30	0.34 ± 0.03	0.46 ± 0.07
		Expectancy	R <sup>2</sup>	0.61 ± 0.25	<b>0.73 ± 0.27</b>	0.43 ± 0.13	0.42 ± 0.35	0.60 ± 0.36	0.55 ± 0.11
			RMSE	0.50 ± 0.13	<b>0.51 ± 0.14</b>	0.56 ± 0.10	0.74 ± 0.21	0.51 ± 0.11	0.56 ± 0.08
	Ideal sweetness	R <sup>2</sup>	0.46 ± 0.32	0.53 ± 0.32	0.34 ± 0.27	0.48 ± 0.26	<b>0.82 ± 0.11</b>	0.30 ± 0.16	
		RMSE	0.85 ± 0.18	0.78 ± 0.16	0.68 ± 0.06	0.81 ± 0.24	<b>0.58 ± 0.07</b>	0.65 ± 0.10	
	Ideal succulence	R <sup>2</sup>	0.54 ± 0.32	0.43 ± 0.10	0.18 ± 0.20	0.43 ± 0.26	<b>0.71 ± 0.26</b>	0.30 ± 0.12	
		RMSE	0.33 ± 0.11	0.42 ± 0.06	0.42 ± 0.05	0.44 ± 0.17	<b>0.45 ± 0.08</b>	0.37 ± 0.06	
	Ideal acidity	R <sup>2</sup>	0.47 ± 0.23	0.12 ± 0.15	<b>0.84 ± 0.01</b>	0.54 ± 0.29	0.20 ± 0.27	<b>0.85 ± 0.01</b>	
		RMSE	0.49 ± 0.06	0.56 ± 0.03	<b>0.18 ± 0.16</b>	0.57 ± 0.14	0.45 ± 0.04	<b>0.13 ± 0.14</b>	

#### 4. CONCLUSIONS

This research investigated the use of six machine learning algorithms to predict the consumer responses to three fruits: tangor, orange, and grape. The algorithms aimed at predicting the consumer acceptance, expectancy, ideal of sweetness, ideal of succulency, and ideal of acidity of these fruits using their physical, chemical, and physical-chemical data as input. The results, expressed in terms of the coefficient of determination ( $R^2$ ) and root mean squared error (RMSE) of the algorithm, indicated that we were always able to devise a machine learning algorithm that successfully predicts these consumer responses for every fruit. However, the successful algorithm varies among the evaluated consumer responses. In fact, Friedman's tests carried out on the generated results pointed out that does not exist a silver bullet for this task, i.e., there does not exist a single algorithm that outperforms all others in predicting the consumer's response for the evaluated fruits using their physical, chemical, and physical-chemical parameters. Therefore, it indicated the need of carefully selecting, optimizing, and comparing different machine learning algorithms to build a successful model to predict the consumer response to fruits. To overcome the small dataset limitation, one recommends using few shot learning techniques (Fei-Fei; Fergus & Perona, 2006) which we intend to exploit in future works.

#### REFERENCES

- Carvalho, I. A. (2019). On the statistical evaluation of algorithmic's computational experimentation with infeasible solutions. *Information Processing Letters*, 143, 24-27.
- Corrêa, S. C., Pinheiro, A. C. M., Siqueira, H. E., Carvalho, E. M., Nunes, C. A., & Boas, E. V. D. B. V. (2014). Prediction of the sensory acceptance of fruits by physical and physical-chemical parameters using multivariate models. *LWT-Food Science and Technology*, 59(2), 666-672.
- Fei-Fei, L.; Fergus, R.; Perona, P. (2006). One-shot learning of object categories. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 28(4), 594-611.
- Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. *In International joint Conference on artificial intelligence*, 14(2), 1137-1145.
- Kyriacou, M. C., & Roupheal, Y. (2018). Towards a new definition of quality for fresh fruits and vegetables. *Scientia Horticulturae*, 234, 463-469.
- Latimer, G. W. (2019). Association of Official Analytical Chemists International, Official Methods of Analysis of AOAC International, 21st edn. AOAC International, Rockville.
- Musacchi, S., & Serra, S. (2018). Apple fruit quality: Overview on pre-harvest factors. *Scientia Horticulturae*, 234, 409-430.
- Ribeiro, M. N., Carvalho, I. A., Fonseca, G. A., Lago, R. C., Rocha, L. C., Ferreira, D. D., ... & Pinheiro, A. C. (2021). Quality control of fresh strawberries by a random forest model. *Journal of the Science of Food and Agriculture*.
- Wakeling, I. N., & MacFie, H. J. (1995). 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 Quality and Preference*, 6(4), 299-308.
- Yu, P., Low, M. Y., & Zhou, W. (2018). Design of experiments and regression modelling in food flavour and sensory analysis: A review. *Trends in Food Science & Technology*, 71, 202-215.

**ARTIGO 3 - ENTENDENDO A PERCEPÇÃO DOS CONSUMIDORES POR MEIO DE DIFERENTES ESCALAS AFETIVAS E SUAS INTERAÇÕES: UM ESTUDO DE CASO COM MORANGOS**

Normas da Revista Científica: Food Quality and Preference

ISSN: 0950-3293

(versão preliminar)

## RESUMO

As escalas afetivas são capazes de medir com precisão as respostas sensoriais e de atitude dos consumidores, sendo extremamente importantes para determinar a qualidade final dos produtos. Existem diferentes escalas afetivas que fornecem respostas diversas como aceitabilidade, percepção do ideal de um determinado atributo, intenção de compra, expectativa e satisfação do consumidor. O objetivo deste trabalho foi avaliar o comportamento dos consumidores em relação a morangos, por meio da relação/interação entre diferentes escalas e medidas afetivas. Trinta amostras diferentes de morangos foram avaliadas por 715 consumidores. As escalas lineares de 9 cm quantificaram o nível de gostar dos morangos e as expectativas dos consumidores, enquanto as escalas do ideal determinaram o ideal de doçura, ideal de suculência e ideal de acidez. Além disso, aferiu-se a satisfação e intenção de pagar mais ou não pelo produto. Como esperado, os atributos de doçura, suculência e acidez influenciaram diretamente na aceitação e expectativa dos consumidores e conseqüentemente na satisfação e intenção de compra. Os índices de aceitação e expectativas foram maximizados com ideal de doçura a 5.08, suculência a 5.58 e acidez a 4.9. Esses índices permitem aferir as percepções dos consumidores e conseqüentemente a qualidade dos morangos. Além disso, foi possível concluir que a correlação de diferentes escalas afetivas pode oferecer um panorama melhor de como o consumidor realmente percebe o produto. Este trabalho demonstrou a importância da interação das escalas para quantificar as respostas sensoriais dos consumidores, além de fornecer subsídios para a aplicação de diferentes escalas para avaliar diferentes produtos.

**Palavras-chave:** Escala hedônica; Escala do ideal; Comportamento do consumidor; Aceitação; Expectativa; Satisfação; Análise sensorial

## 1. INTRODUÇÃO

Na comercialização de alimentos in natura ou mesmo durante seu processo de desenvolvimento e aprimoramento, a indústria e os pesquisadores devem se esforçar para entender os desejos e as necessidades dos consumidores. Além disso, também é necessário se empenhar para entender a percepção dos clientes em relação ao produto final, a fim de garantir a satisfação do consumidor (Varela, Ares, Gimenez, & Gambaro, 2010; Cruz et al., 2013). Desta forma, deve-se compreender como os consumidores percebem os alimentos, como eles fazem suas escolhas e o que afeta a sua tomada de decisão (Cruz et al., 2013). Os estudos com consumidores podem ser utilizados para caracterizar o perfil sensorial dos alimentos, determinando as suas características como doçura, acidez, mastigabilidade, dentre outros. Ademais, podem quantificar a aceitação ou preferência de consumidores utilizando testes afetivos (Yu, Low, & Zhou, 2018).

Diferentes escalas podem ser utilizadas para quantificar as respostas afetivas dos consumidores (Yeung et al., 2021). Dentre elas, destaca-se a escala hedônica de 9 pontos (Lawless et al., 2010), um dos métodos mais comumente utilizados para medir com precisão a aceitação ou o gostar do consumidor (Kim, Hout, & Lee, 2018). Outra opção é a escala do ideal (*Just About Right*), que tem como objetivo definir a intensidade de um determinado atributo, como por exemplo doçura, considerado como ideal pelos consumidores (Ribeiro et al., 2020). E também tem a escala de atitude, que quantifica o grau de aceitação dos produtos com base na atitude dos consumidores, ou seja, o quanto eles estariam dispostos a consumir ou a pagar mais pelo produto (Drake, 2007).

Como demonstrado, existem diferentes escalas afetivas que podem ser utilizadas para entender o comportamento do consumidor. Porém, cada uma delas afere as respostas sensoriais dos consumidores de uma forma diferente, o que pode levar a diferentes resultados. Escolher entre as diversas escalas afetivas pode ser um desafio para os pesquisadores. Por isso, a seleção e uso das escalas afetivas para medir a resposta do consumidor é uma área ativa de investigação e discussão na comunidade das ciências sensoriais (Yeung et al., 2021). Existem diversos trabalhos na literatura que comparam a eficácia dessas escalas e comparam com os resultados dos dados sensoriais coletados (Lawless, Sinopoli, & Chapman, 2010; Kalva et al., 2014; Kershaw & Running, 2019; Yeung et al., 2021). Porém, ainda é necessário aprofundar mais e entender qual é o desempenho dessas escalas, qual é a relação com o comportamento do consumidor, e principalmente, entender a interação e a relação entre essas escalas de forma a otimizar as respostas dos consumidores.

Neste trabalho propomos avaliar a qualidade de morangos utilizando escalas afetivas. A qualidade de um morango está diretamente correlacionada com atributos sensoriais como aparência, aroma, sabor e textura (Ribeiro et al., 2021). A qualidade sensorial dos frutos, como o morango, é um dos principais impulsionadores do gostar e da decisão de compra do

consumidor (Colquhoun et al., 2012). Porém, até o momento, não existe uma escala preferida para avaliar o gostar de frutos vermelhos. Na verdade, existem poucos relatos sobre a preferência ou estudos hedônicos em frutos não processados, possivelmente devido a perecibilidade e fragilidade dos frutos (Yeung et al., 2021). Algumas escalas foram utilizadas para avaliar as respostas sensoriais dos consumidores de morangos, como a escala de 9 pontos (Filho et al., 2018) e escalas de intensidade hedônica global (Oliver et al., 2018; Schwieterman et al., 2014). Ainda assim, são necessários mais estudos sobre as escalas afetivas para compreender o potencial de mercado dos morangos e os fatores que influenciam a aceitação do produto pelos consumidores.

Este trabalho tem como objetivo compreender a relação/interação de diferentes escalas e medidas na avaliação das respostas sensoriais e de atitude de consumidores de morangos. Neste contexto, o planejamento experimental foi definido com o propósito de avaliar o efeito e a relação entre as respostas de consumidores obtidas com cinco diferentes escalas afetivas na avaliação de morangos, aplicada aos atributos sensoriais suculência, doçura e acidez e perspectivas de aceitação e expectativa, referindo-se as características hedônicas e de qualidade que despertam o interesse do consumidor para compra e aquisição dos frutos.

## **2. MATERIAIS E MÉTODOS**

### **2.1 Materiais**

Os morangos (*Fragaria* × *ananassa* Duch) utilizados neste trabalho foram adquiridos em um comércio local da cidade de Lavras, estado de Minas Gerais, Brasil. O morango foi escolhido por ser um fruto muito consumido no mundo. No total foram adquiridas 30 amostras de morango da mesma variedade. Porém, cada amostra era proveniente de uma região ou agricultor diferente. Dessa forma, foi possível obter amostras diferentes, garantindo a

variabilidade da qualidade dos morangos. Cada amostra continha aproximadamente 4kg de morango.

## **2.2 Manipulação dos frutos**

A preparação e pré-processamento das amostras seguiram a metodologia proposta por Côrrea et al. (2014) e Ribeiro et al. (2021). As amostras passaram por um processo de seleção onde retirou-se os morangos com injúrias. As amostras selecionadas eram de tamanhos, formas e cores semelhantes, respeitando as características das amostras obtidas dos diferentes produtores. Antes da realização das análises, os morangos foram lavados em água corrente e sanitizados por imersão em solução de hipoclorito de sódio (100 ppm), por 15 min. Em seguida, os morangos foram fatiados perpendicularmente ao seu eixo principal, em quatro partes iguais e as pontas foram retiradas, a fim de padronizar o tamanho das amostras. Por fim, as amostras foram encaminhadas para a análise sensorial, que ocorreu imediatamente após a manipulação dos morangos.

## **2.3 Análise Sensorial**

Os experimentos foram realizados em condições ideais, sob luz branca, temperatura controlada de 25 °C e em cabines individuais. Este estudo foi revisado e aprovado pelo Comitê de Ética em Pesquisa com Seres Humanos da Universidade Federal de Lavras, sob o código CAAE 12112113.8.0000.5148.

As análises sensoriais seguiram a metodologia proposta por Ribeiro et al. (2021). Como demonstrado na Tabela 1, a análise sensorial foi realizada em 6 sessões, ou seja, em seis dias distintos e foi realizada por um total de 715 consumidores, dos quais 98,9% tinham entre 18 e 45 anos. Além disso, 60,6% eram do sexo feminino. Todos os participantes deste estudo eram consumidores frequentes de morango, apreciavam muito o fruto e tinham interesse em participar da pesquisa.

Tabela 1: Número de consumidores e amostras em cada sessão sensorial.

	Sessão 1	Sessão 2	Sessão 3	Sessão 4	Sessão 5	Sessão 6	Total
Amostras	5	5	5	5	5	5	<b>30</b>
Consumidores	115	120	120	120	120	120	<b>715</b>

Para avaliar as respostas dos consumidores em relação às amostras de morangos, foram utilizadas 5 escalas não estruturadas de 9 cm para quantificar a percepção dos consumidores. Na Figura 1 apresentam-se os modelos das escalas utilizadas neste estudo. Os consumidores avaliaram o quanto gostaram ou não gostaram das amostras de morango [Figura 1 (a)], assim como avaliaram a sua expectativa em relação a qualidade dos frutos [Figura 1 (b)]. Além disso, os consumidores também avaliaram o ideal de doçura, ideal de suculência e ideal de acidez, utilizando as escalas não estruturadas de 9 cm [Figura 1 (c); (d); (e)]. Por fim, os consumidores declararam se estavam satisfeitos ou não e se estavam dispostos a pagar mais ou não pela amostra avaliada.

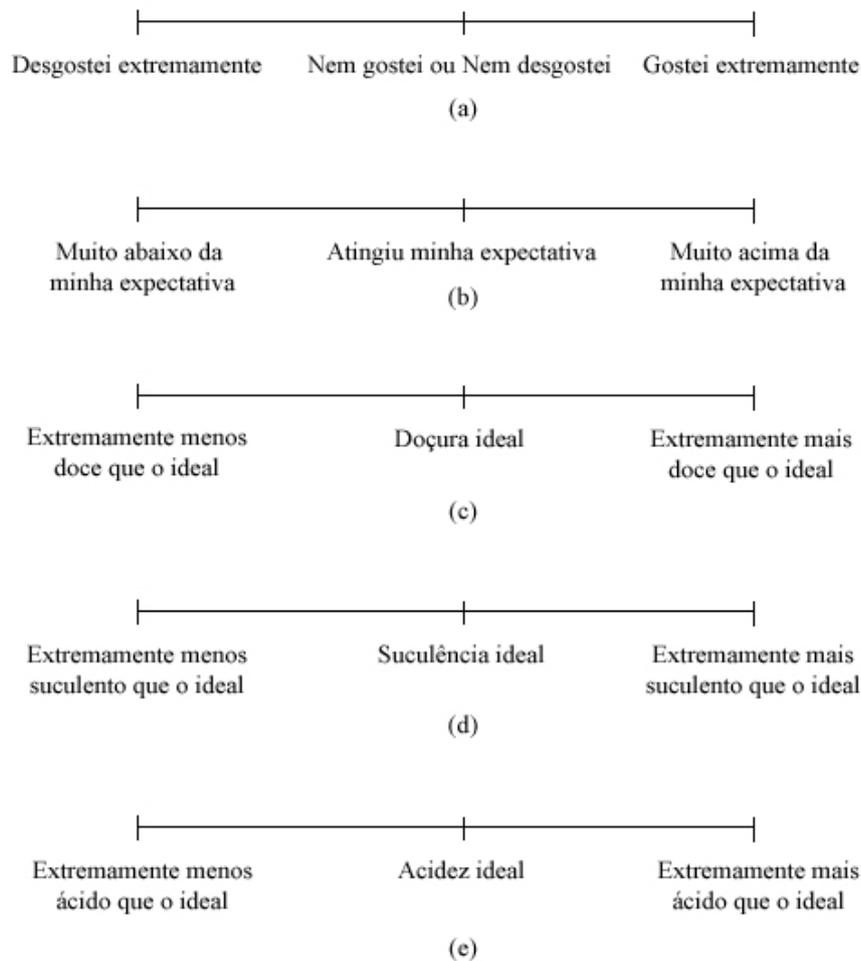


Figura 1: Modelo das escalas não estruturadas de 9 cm. (a): Gostou ou não gostou das amostras de morangos; (b): Expectativa quanto a qualidade das amostras de morangos; (c): Doçura ideal dos morangos; (d): Suculência ideal dos morangos; (e): Acidez ideal dos morangos.

Cada sessão de teste foi realizada usando um desenho de bloco balanceado completo no qual um consumidor avaliou cinco amostras diferentes de morango. Foram servidos em torno de 20g de cada amostra, juntamente com um copo de água. As amostras foram codificadas em números aleatórios de 3 dígitos e apresentadas em ordem monádica e balanceada, seguindo a metodologia sensorial proposta por Walkeling & Macfie (1995).

## 2.5 Análises estatísticas

### 2.5.1 Análise das percepções de consumo dada a relação das escalas binária e contínua em relação à aceitação e à expectativa dos consumidores.

A análise das percepções dos consumidores foi realizada a partir dos dados obtidos das escalas hedônicas de 9 pontos e de escala binária atribuída às questões referentes à satisfação (Sim=1/Não=0) e disposição em pagar mais pelo produto (Sim=1/Não=0).

As percepções relacionadas ao comportamento dos consumidores, foram representadas na forma de construtos, corroborando a definição de construto dada por Arsendorpf (2004), como um conceito teórico não observável, porém, no âmbito científico, deverá ser especificado por um embasamento empírico. Em consonância com essa definição, mantendo a codificação binária atribuída às variáveis (Tabela 2), foi sugerida a nomeação dos construtos como percepções dos consumidores classificadas em positivas e negativas.

Tabela 2 – Codificação das variáveis binárias para definição dos construtos relacionados ao comportamento dos consumidores

Codificação (S,P)*	Status	Combinação para definição do construto (S,P) e nomeação
1	Satisfeito	(S=1,P=1) – Percepções positivas
1	Pagar mais	
0	Insatisfeito	(S=0,P=0) – Percepções negativas
0	Não Pagar mais	

\*S = satisfeito e não satisfeito; P = pagaria mais e não pagaria mais

A discriminação da presença e ausência das percepções foi especificada ao considerar o efeito aditivo (S=1, P=1) + (S=0, P=0) e a diferença (S=1, P=1) – (S=0, P=0), respectivamente, proporcionando uma situação favorável para construção dos biplots que contemplam estes efeitos de forma independente utilizando a técnica de decomposição de valores singulares proposta por Greenacre (2003).

Para a execução desta técnica, foi necessário a organização dos dados em uma estrutura hierárquica, seguindo uma tabela de frequência com três entradas. A primeira entrada foi composta pelos atributos sensoriais na escala contínua categorizada em duas classes, definidas por notas maiores ou iguais a 4.5 e notas inferiores a 4.5, dispostas nas “colunas”. Convém ressaltar que esta nota de corte, é justificada por ser o valor médio das escalas contínuas e por

ser caracterizado pelos termos “Nem gostei ou Nem desgostei”; “Atingiu minha expectativa”; “Doçura ideal”; “Suculência ideal”; “Acidez ideal”.

Após a definição dos construtos, procedeu-se com a obtenção das frequências para as variáveis expectativa e aceitação, compondo a segunda entrada, sendo esta, distribuída no sentido “linha” e por fim, a terceira entrada foi definida pela repetição destas variáveis para cada construto. Com este arranjo, tornou-se perceptível uma estrutura hierárquica, observada pelo cruzamento das variáveis discretizadas pelos atributos sensoriais com as variáveis de aceitação e expectativa dentro de cada construto definido.

Em termos matriciais, nesta estrutura a decomposição de valores singulares proposta por Greenacre (2003), contextualizada neste trabalho pelo bloco de variáveis que compõe a terceira entrada, isto é, os construtos, representados pelas percepções positivas (S=1, P=1) e negativas (S=0, P=0) é aplicada inicialmente a especificação de uma matriz bloco M definida em (1).

$$M = \begin{bmatrix} (S=1, P=1) & (S=0, P=0) \\ (S=0, P=0) & (S=1, P=1) \end{bmatrix}. \quad (1)$$

Os biplots obtidos são resultantes da influência conjunta das variáveis (S=1, P=1) + (S=0, P=0) e suas diferenças (S=1, P=1) – (S=0, P=0), seguindo a decomposição resultante dada em (2),

$$\begin{aligned} (S=1, P=1) + (S=0, P=0) &= \mathbf{U}\mathbf{D}_\alpha\mathbf{V}^T \\ (S=1, P=1) - (S=0, P=0) &= \mathbf{X}\mathbf{D}_\beta\mathbf{Y}^T \end{aligned} \quad (2)$$

**em que**  $\mathbf{U}$  e  $\mathbf{X}$  são matrizes de vetores singulares à esquerda e  $\mathbf{V}$  e  $\mathbf{Y}$  são matrizes de vetores singulares à direita, cada um com  $k$  colunas ortonormais,  $\mathbf{D}_\alpha$  e  $\mathbf{D}_\beta$  representam as matrizes diagonais de valores singulares positivos  $\gamma$ , em ordem decrescente de grandeza.

Em síntese, a matriz M particionada resultante da decomposição é descrita por

$$\begin{bmatrix} (S=1,P=1) & (S=0,P=0) \\ (S=0,P=0) & (S=1,P=1) \end{bmatrix} = \frac{1}{\sqrt{2}} \begin{bmatrix} U & X \\ U & -X \end{bmatrix} \begin{bmatrix} D_\alpha & 0 \\ 0 & D_\beta \end{bmatrix} \frac{1}{\sqrt{2}} \begin{bmatrix} V & Y \\ V & -Y \end{bmatrix}^T. \quad (3)$$

A presença do fator  $1/\sqrt{2}$  multiplicando os vetores singulares à esquerda e à direita assegura a normalização correta, ou seja,  $\frac{1}{\sqrt{2}} \begin{bmatrix} U \\ U \end{bmatrix}^T \frac{1}{\sqrt{2}} \begin{bmatrix} U \\ U \end{bmatrix} = \frac{1}{2} U^T U + \frac{1}{2} U^T U = I$ . Assim, os vetores singulares à esquerda e à direita da equação (3) são ortonormais, isto é,  $U^T U = V^T V = I$  e  $X^T X = Y^T Y = I$ ,

Com a obtenção dos valores singulares e respectivos autovetores, os componentes foram determinados para geração dos gráficos biplots que explicam a relação dos atributos sensoriais com as variáveis de aceitação e expectativa, especificamente na situação correspondente à presença e à ausência de percepções. As operações matriciais necessárias, a obtenção dos componentes e a construção dos biplots foram feitas por meio de um script elaborado na linguagem R (R Core Team, 2020).

### **2.5.2 Otimização de respostas simultâneas em modelos de Superfícies de Respostas aplicados na maximização da aceitação e expectativa em função de atributos sensoriais.**

Os modelos de superfície de resposta foram aplicados com propósito de pesquisar a melhor combinação de notas, dadas pelos atributos sensoriais Doçura (A), Suculência (B) e Acidez (C) que proporcionasse a resposta máxima de Aceitação (Ac) e Expectativa (Ex). Inicialmente, considerou-se o ajuste dos modelos, para cada variável resposta específica, ou seja, as atitudes comportamentais Aceitação (Ac) e Expectativa (Ex), conforme as Eq (4) e (5). Dessa forma, considerou-se os ajustes dos modelos quadráticos com os parâmetros correspondentes aos efeitos lineares e quadráticos, dados por

$$Ac_i = \beta_0 + \beta_1 A_i + \beta_2 B_i + \beta_3 C_i + \beta_{11} A_i^2 + \beta_{22} B_i^2 + \beta_{33} C_i^2 + \xi_i, \quad (4)$$

$$Ex_i = \beta_0 + \beta_1 A_i + \beta_2 B_i + \beta_3 C_i + \beta_{11} A_i^2 + \beta_{22} B_i^2 + \beta_{33} C_i^2 + \xi_i, \quad (5)$$

sendo  $i=1, \dots, n = 715$  consumidores, as respostas relacionadas as avaliações dos atributos (A) doçura; (B) suculência e (C) acidez e  $\xi_i$  o erro experimental distribuído pela normal com média 0 e variância constante  $\sigma^2$ , ou seja,  $\xi_i \sim N(0, \sigma^2)$ .

Após os ajustes dos modelos e suas validações pelo coeficiente de determinação  $R^2$ , as curvas de contorno foram geradas, considerando os valores preditos por cada modelo (4) e (5) em função da combinação dos atributos sensoriais. Com esse enfoque, de forma exploratória, interpretações fundamentadas em faixas de notas foram discutidas e posteriormente validadas pela técnica de otimização de respostas simultâneas (Derringer & Suich, 1980).

Seguindo essa abordagem, determinou-se a combinação ótima dos atributos sensoriais por meio de uma estatística que evidencia a adequacidade desta combinação, de forma a satisfazer conjuntamente as respostas de Aceitação (Ac) e Expectativa (Ex). Dessa forma, enunciando os objetivos em maximizar ambas as respostas, considerou-se a função de desirability, descrita na Eq.(6).

$$D = \left( \prod_{j=1}^p d_j \right)^{1/p} \quad \text{sendo } d_j \text{ em que,} \quad (6)$$

$d_j$  ( $j=1, \dots, p$ ) refere-se a função de desejabilidade para cada variável resposta (Eq. 7), sendo  $p=2$  o número de variáveis dependentes, em particular para um problema de maximização .

$$d_j = \begin{cases} 0 & \text{para } \hat{y}_j < y_{jL} \\ \left( \frac{\hat{y}_j - y_{jL}}{y_{jT} - y_{jL}} \right)^s & \text{para } y_{jL} < \hat{y}_j < y_{jU} \\ 1 & \hat{y}_j > y_{jU} \end{cases} \quad (7)$$

$\hat{y}$  correspondeu ao valor predito das respostas Ac e Ex;  $y_{jL}$  e  $y_{jU}$ , respectivamente referiu-se aos limites inferiores e superiores, atribuídos pelo pesquisador, de modo que, a resposta da combinação máxima das notas de doçura, suculência e acidez seja possível de ser determinada.

### **3. RESULTADOS E DISCUSSÃO**

#### **3.1 Biplots obtidos por meio da técnica de decomposição de valores singulares para análise da ausência e da presença das percepções de consumo.**

Os resultados da metodologia estatística proposta na seção 2.5.1, para avaliar as atitudes comportamentais dos provadores são apresentados na Tabela 3. Eles referem-se ao cruzamento das variáveis aceitação e expectativa nas escalas contínuas, em diferentes classes dos atributos sensoriais, Doçura (A), Suculência (B) e Acidez (C). A primeira coluna exibe os dois construtos analisados para a descrição das percepções dos consumidores, sendo a percepção negativa denotado como S=0, P=0 e a percepção positiva representada como S=1, P=1. A segunda coluna mostra os intervalos dos valores de aceitação (Ac) e expectativa (Ex) avaliados, sendo exibidos os resultados separadamente para valores baixos ( $< 4.5$ ) e altos ( $\geq 4.5$ ) desses dois atributos. As colunas restantes exibem o número de vezes que os atributos sensoriais doçura, suculência e acidez foram citados, sendo que a terceira, quarta e quinta colunas mostram o número de vezes que cada atributo sensorial foi citado com uma nota baixa ( $< 4.5$ ), e as últimas três colunas exibem o número de vezes que os atributos foram citados com uma nota alta ( $\geq 4.5$ ).

Tabela 3: Discriminação das avaliações da aceitação e expectativa nas escalas contínuas com os atributos sensoriais classificadas pelas definições dos construtos (S=0,P=0) e (S=1,P=1), nomeados respectivamente por Percepções negativas e positivas.

Construtos	Aceitação/ Expectativa	Categorias de notas para os atributos sensoriais					
		A < 4.5	B < 4.5	C < 4.5	A ≥ 4.5	B ≥ 4.5	C ≥ 4.5
S=0, P=0	Ac < 4.5	262	202	93	34	94	203
	Ac ≥ 4.5	438	247	249	457	648	646
	Ex < 4.5	432	306	164	59	185	327
	Ex ≥ 4.5	268	143	178	432	557	522
S=1, P=1	Ac < 4.5	443	312	200	64	195	307
	Ac ≥ 4.5	564	330	318	579	813	825
	Ex < 4.5	671	444	287	102	329	486
	Ex ≥ 4.5	336	198	231	541	679	646

Dois biplots foram obtidos para investigar a percepção dos consumidores. No primeiro biplot (Figura 2 (a)) avalia-se a influência das percepções de consumo, com a soma das percepções negativas e as percepções positivas. Enquanto no segundo biplot (Figura 2 (b)) tem-se a ausência das percepções de consumo, que é representado pela diferença das percepções negativas e percepções positivas.

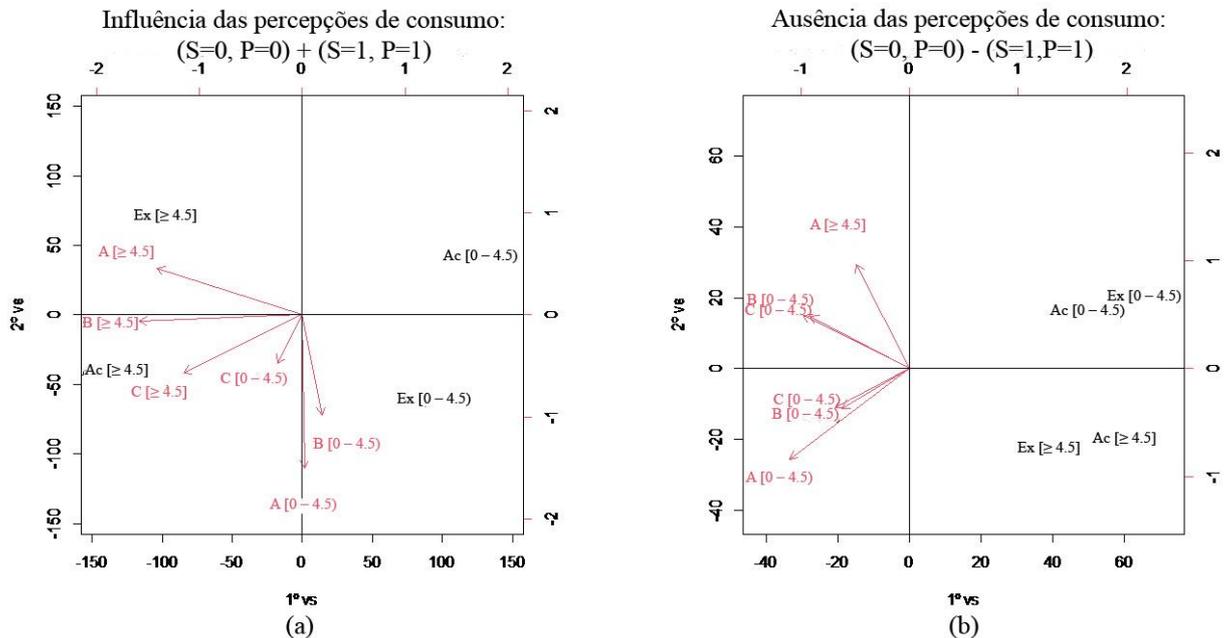


Figura 2: Resultados da análise da percepção dos consumidores: (a) em relação a influência das percepções; (b) em relação a ausência das percepções.

Os biplots apresentados na Figura 2 foram obtidos pelos dois primeiros valores singulares (vs) gerados, considerando o grupo de variáveis caracterizado pelas combinações (S=0, P=0) + (S=1, P=1), referentes aos construtos percepções negativas e positivas de consumo, respectivamente. Evidencia-se que existe a influência dessas percepções em relação a aceitação e expectativa dos consumidores. É possível observar que valores para ideais maiores ou iguais a 4.5 (ideal ou mais que o ideal) direcionam as maiores notas de aceitação e expectativa. A doçura maior ou igual a 4.5 tem uma relação mais forte com maiores notas de expectativas. Enquanto a acidez e suculência maiores ou iguais a 4.5 apresentam-se mais intimamente relacionado a aceitação. Já a baixa suculência e doçura (< 4.5) estão associados a uma baixa expectativa dos consumidores (< 4.5). Em relação a ausência das percepções de consumo (S=0, P=0) - (S=1, P=1), evidencia-se a não existência de uma relação das avaliações dos atributos com as classes de notas limitadas pelo ponto de corte 4.5. Observa-se que nenhum atributo avaliado pela escala do ideal foi relacionado à aceitação ou expectativa.

A questão da análise das percepções foi caracterizada pela validação das respostas contínuas dadas nas escalas de 9 cm, atribuídas à aceitação e à expectativa, em conjunto com a escala binária, definida em “Sim” e “Não”, referentes a questões de satisfação e disposição em pagar mais. Mediante o exposto, tornou-se compreensível a definição de construtos que representam as atitudes comportamentais de consumo a serem comparados com as variáveis mensuradas nas escalas contínuas. Observando a Figura 2 (a) vimos que as notas de ideal de doçura, suculência e acidez tem uma forte relação com a aceitação e expectativa dos consumidores. Entretanto, o biplot, que é uma análise exploratória, só nos oferece uma visão geral, e não oferece a análise individual das associações das variáveis. Ou seja, não é possível saber qual a nota necessária de ideal de doçura, suculência e acidez para atingir os valores maiores ou iguais a 4.5 da aceitação e expectativa. Diante disso, utilizamos a metodologia de

superfície de resposta como uma análise complementar para entendermos a interação das variáveis com a aceitação e expectativa.

### 3.2 Otimização de respostas simultâneas aplicadas à maximização das respostas de aceitação e expectativa

Dois modelos quadráticos foram gerados para estimar a aceitação e expectativa do consumidor, com base nas respostas sensoriais do ideal de doçura, suculência e acidez. As estimativas dos parâmetros dos modelos quadráticos de superfície de resposta, conforme descritos nas equações (1) e (2), estão apresentadas na Tabela 4. Além disso, são apresentados os níveis de significância e os coeficientes de determinação ( $R^2$ ).

Tabela 4 – Estimativas dos parâmetros considerando as respostas Aceitação (Ac) e Expectativa (Ex)

Parâmetros	Ac ( $R^2=79.02\%$ )		Ex ( $R^2=81.51\%$ )	
	Coef	p-value	Coef	p-value
$\beta_0$	-0.4633	0.980	-3.93379	0.780
$\beta_1$	3.0887	0.186	1.25379	0.474
$\beta_2$	-3.0915	0.308	-1.66919	0.467
$\beta_3$	1.7182	0.811	2.96385	0.589
$\beta_{11}$	-0.2468	0.379	-0.05077	0.811
$\beta_{22}$	0.3334	0.294	0.19536	0.417
$\beta_{33}$	-0.1468	0.841	-0.26935	0.629

Observando a Tabela 4, é possível constatar que o modelo correspondente a aceitação obteve  $R^2$  de 79.02%. Para a expectativa foi determinado um  $R^2$  de 81.51%. Os valores de  $R^2$  indicam a qualidade e o ajuste total dos modelos. Ambos os modelos apresentaram coeficientes de determinação com valores superiores a 0.7, indicando que são adequados para fins de predição (Henika, 1982). Foi observado nos dois modelos, valores não significativos ( $p > 0.05$ ) para as variáveis independentes. Isto significa que nenhuma variável foi mais importante do que a outra, ou seja, nenhuma variável teve maior efeito no poder preditivo dos modelos.

A partir dos modelos preditos e das estimativas para aceitação e expectativa, foram obtidas curvas de contorno para visualizar as regiões com maiores notas de aceitação e

expectativa em função das notas obtidas do ideal de doçura, ideal de suculência e ideal de acidez (Figura 3). As curvas de contorno foram geradas utilizando a combinação de 2 variáveis independentes (B x A), (C x A) e (B x C) em função das respostas sensoriais da aceitação e expectativa dos consumidores.

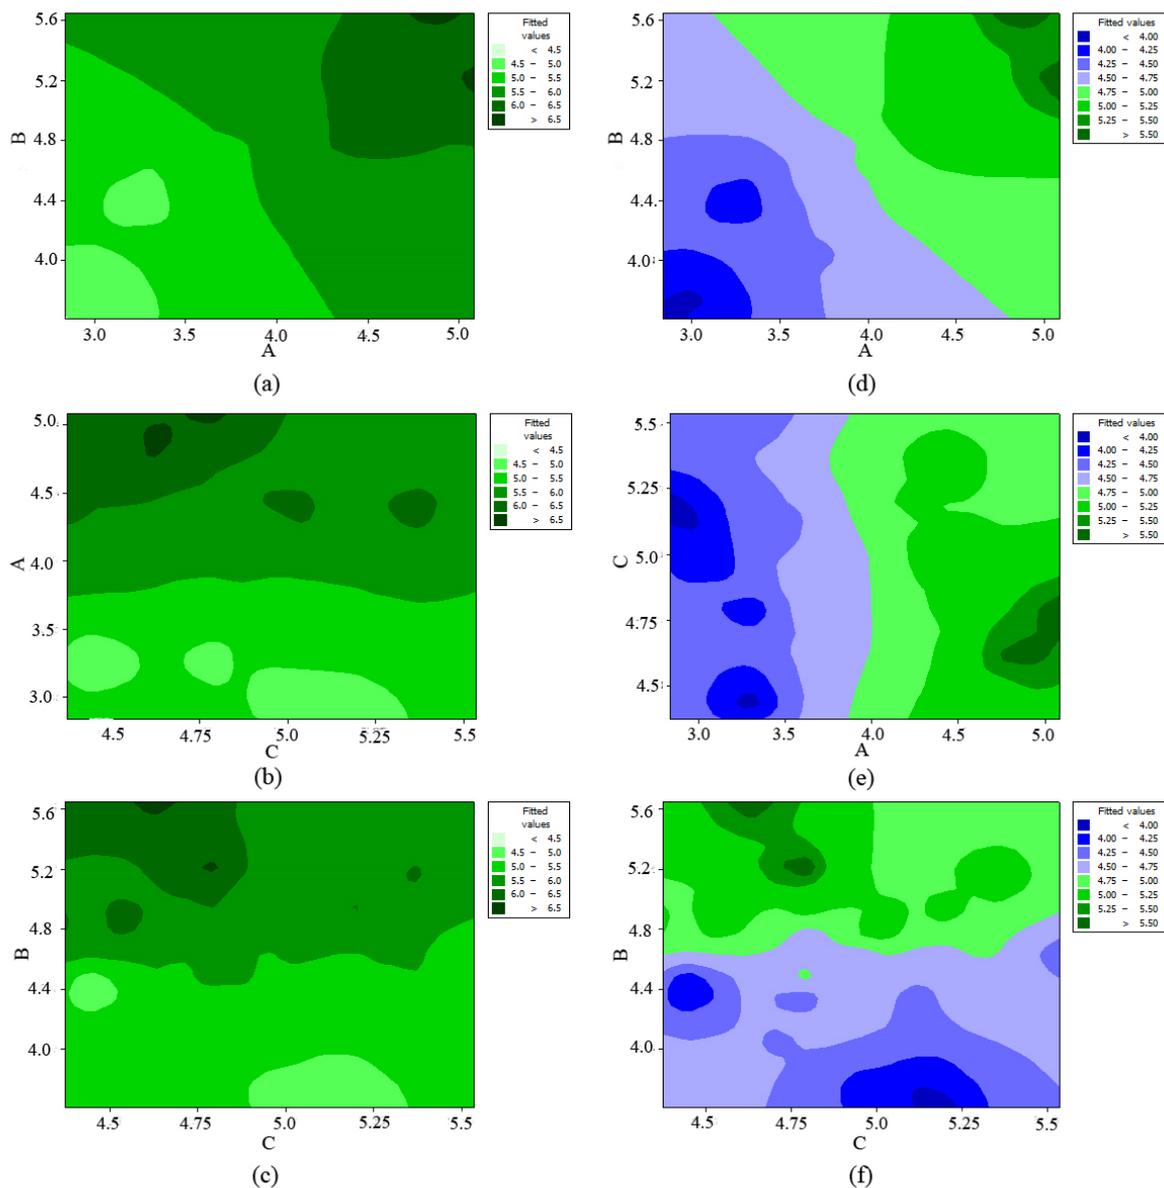


Figura 3: Gráficos de contorno das superfícies do modelo quadrático para em função de dois fatores e valores preditos para a resposta Aceitação e Expectativa: doçura (A), suculência (B) e acidez (C).

De acordo com a Figura 3, é possível perceber a influência e a interação das notas do ideal de suculência, doçura e acidez sobre a aceitação e expectativa. Observando as curvas de contorno para as variáveis independentes suculência e doçura (B x A), é possível constatar que quanto maior a nota de ideal de suculência e doçura do morango, maior a aceitação [Figura 3 (a)] e expectativa [Figura 3 (d)] do consumidor. Observa-se que notas de ideal de doçura maiores que 4.3 e notas de suculência maiores que 4.7, geram as maiores notas de aceitação para o morango, sendo essas notas de 6.0 a 6.5. Enquanto notas de ideal de doçura maiores que 4.5 e notas de suculência maiores que 4.9 geram as maiores notas de expectativas para o morango, sendo essas notas de 5.25 a 5.5.

Nota-se que para uma maior aceitação e expectativa do consumidor, notas de doçura e suculência devem estar com valores próximos e/ou maiores que o ideal (valores de 4.5 de acordo com a escala utilizada). Também se observa notas maiores de aceitação e expectativa para valores de ideal de doçura e suculência acima do ideal considerado pelos consumidores, de acordo com suas experiências vivenciadas para morangos. O fato de considerar “mais doce e suculento que o ideal” não penalizam a aceitação e expectativa, e sim favorecem maiores notas de aceitação e expectativa.

Já as notas de doçura inferiores a 3.5 e suculência inferiores a 4.4, que são valores abaixo do ideal (notas abaixo de 4.5 de acordo com a escala avaliada), geram uma menor aceitação. Enquanto notas de doçura menores que 3.3 e suculência menores que 4.1, que são valores abaixo do ideal (<4.5) não atingem a expectativa dos consumidores. Com essa análise validamos a relação de percepção de ideal em relação a aceitação e expectativa, mostrando que, notas próximas ao ideal ou maiores de suculência e doçura, ditam maiores notas de aceitação e expectativa. Enquanto notas abaixo do ideal ditam menores notas de aceitação e expectativa.

Quando se avalia a interação da doçura e acidez (A x C) sobre as respostas de aceitação [Figura 3 (b)], observa-se que é possível obter uma nota de aceitação entre 6.0 e 6.5 (valor

próximo do termo “gostei extremamente” na escala utilizada), quando as notas do ideal de doçura são maiores que 4.3 e a acidez abaixo de 5.0. Por outro lado, notas de ideal de doçura maiores que 4.6 e acidez menores que 4.8, geram notas de expectativa de 5.25 a 5.5 [Figura 3 (e)]. Se observarmos essas faixas, verifica-se que notas de acidez menores ou iguais a 5.0, ou seja, próximo ao ideal (4.5 de acordo com a escala), ou notas consideradas “menos ácido que o ideal” ( $< 4.5$ ) favorecem a aceitação e a expectativa dos consumidores. O fato de considerar “menos ácido que o ideal” não penaliza a aceitação e expectativa.

É possível observar que a acidez maior que o ideal, diferentemente da doçura e suculência, não favorece as maiores notas de aceitação e de expectativa. Desta forma, para que se obtenha uma boa aceitação e o morango atinja as expectativas dos consumidores, é necessário que as notas de ideal de acidez sejam notas próximas ou inferiores a nota de acidez ideal, enquanto as notas de ideal de doçura e suculência devem ser iguais ou maiores que a nota ideal. Outro fator interessante é que valor de ideal baixo de doçura ( $< 3.5$  e  $< 3.6$ ) afeta negativamente na aceitação e expectativa, respectivamente. Neste caso, também é possível constatar que a doçura está mais relacionada com a expectativa pois, independente da faixa de acidez, se a nota de ideal de doçura estiver baixa, a expectativa não será atingida.

O mesmo comportamento da acidez acontece quando se observa o gráfico que avalia a interação de suculência e acidez (B x C). Observa-se que a nota de ideal de acidez abaixo de 4.9 e suculência acima 4.8, resultam em uma nota de aceitação sensorial entre 6.0 e 6.5 [Figura 3 (c)]. Já na avaliação da expectativa [Figura 3 (f)], quando a nota de ideal de acidez é menor que 4.9 e a suculência é maior que 5.1, os valores de expectativa variam de 5.25 a 5.5. Semelhante a interação doçura e acidez, observa-se que nota de acidez igual ou menor que o ideal e suculência maior que o ideal, geram maiores notas de aceitação e expectativa. Neste caso, também se observa que a suculência está mais relacionada com a expectativa, pois

independente da faixa de acidez, se a suculência for inferior a 4.5, a expectativa do consumidor não será atingida.

Outro fator interessante é que observamos uma diferença entre a nota máxima da aceitação (6.0 – 6.5) e a nota máxima da expectativa (5.25 – 5.5). Isso demonstra que há uma diferença entre o gostar e o esperar, ou seja, o que o consumidor espera ao consumir a fruta. Avaliando o comportamento das variáveis do ideal de doçura, suculência e acidez, observa-se que estas variáveis se comportam de maneira semelhante para a aceitação quanto para a expectativa, representando a mesma percepção, entretanto, quando se avalia o valor nominal observa-se uma diferença entre a aceitação e expectativa. Ou seja, a percepção observada pelos consumidores de morangos não levou a uma mesma expressão quando pensamos em aceitação a expectativa.

Conforme demonstrado na Figura 3, valores próximos ao ideal ou maiores que o ideal de doçura e suculência e valores próximo ao ideal ou menores que o ideal de acidez tem um efeito positivo na aceitação e expectativa dos consumidores. Entretanto, as avaliações das curvas de contorno relacionadas a aceitação e expectativa, foram realizadas de forma individual para estas variáveis dependentes. Para entender melhor o comportamento das variáveis independentes e confirmar as respostas máximas, foi utilizado a técnica de otimização de respostas simultâneas. A otimização dos modelos é realizada de forma a atender os objetivos relacionados à obtenção da resposta máxima para aceitação e expectativa. Com isto, o objetivo foi estimar nas curvas de contorno a melhor combinação entre doçura, suculência e acidez que maximize simultaneamente a aceitação e a expectativa, em função da especificação de restrições para ambas as variáveis. Na Tabela 5 temos os valores que validam a otimização. Assim, o foco foi maximizar a aceitação e expectativa considerando as restrições em ambas as variáveis definidas por notas entre 4.5 e 7.0. Vale destacar que, quanto mais próximo de 1 for o valor da Estatística

D, melhor a recomendação da combinação de valores de doçura, suculência e acidez que maximizam as respostas para aceitação e expectativa (Cirillo, 2015).

Tabela 5: Estatísticas associadas aos valores de ideal de doçura, suculência e acidez que maximizam a aceitação e a expectativa considerando as restrições em ambas as variáveis definidas pelos limites de especificação utilizados no procedimento de otimização simultânea das variáveis

Variável dependente	Limites		Estatísticas que validam a otimização	
	Mínimo ( $y_{1L}$ )	Máximo ( $y_{1U}$ )	d (individual)	D (Global)
Aceitação (Ac)	4.5	7.0	0.99836	0.786
Expectativa (Ex)	4.5	7.0	0.61882	
Combinação que maximiza simultaneamente as respostas de Aceitação e Expectativa				
Doçura	5.08			
Suculência	5.58			
Acidez	4.9			

Com os resultados obtidos pela otimização, pode-se estabelecer valores ótimos para a doçura, suculência e acidez, garantindo a melhor combinação entre estas variáveis. Assim foram determinados os valores de 5.08 para doçura, 5.58 para suculência e 4.9 para acidez. Com essa combinação das notas obtidas pela escala do ideal, é possível maximizar simultaneamente a aceitação e expectativa dos consumidores. Dessa forma, a partir dos coeficientes obtidos e dos valores otimizados de doçura, suculência e acidez, obtemos a aceitação máxima de 6.88 e expectativa máxima de 5.95. Esses resultados validam o uso das escalas contínuas em confirmação com as escalas binárias.

Este estudo demonstra o uso de diferentes escalas afetivas para estimar a aceitação sensorial e expectativa dos consumidores, além de entender as influências dessas escalas na percepção sensorial, avaliando a satisfação e intenção de pagar mais por morangos. É inegável a importância de se entender por completo os desejos e as necessidades dos consumidores, bem

como sua percepção sobre os alimentos, a fim de garantir o sucesso dos produtos. Um melhor entendimento das necessidades dos consumidores provavelmente resultará em produtos bem-sucedidos no mercado (Varela et al., 2010).

Neste contexto, a ciência sensorial de alimentos é essencial para compreender os consumidores, fazendo a ponte entre as características dos alimentos e a percepção e aceitação do consumidor (Yu et al., 2018). Assim, várias metodologias foram desenvolvidas nos últimos anos para determinar a reação afetiva dos consumidores e para investigar sua percepção sobre as características sensoriais. A escala hedônica de 9 pontos é uma das escalas mais utilizadas para quantificar as respostas afetivas dos consumidores (Kim, Hout, & Lee, 2018). Porém entender todo o contexto das respostas afetivas e determinar os parâmetros de qualidade dos alimentos utilizando apenas uma escala hedônica pode ser ineficiente para compreender todo o panorama das reações afetivas e o que interfere na percepção dos consumidores.

A literatura mostrou que ao avaliar o desempenho das escalas afetivas construídas de forma diferente, pode-se chegar à conclusão de que não há uma vantagem muito clara para o uso de uma ou outra escala (da Silva et al., 2013; Lawless et., 2010; Yeung et al., 2021). Porém, o uso de diferentes escalas afetivas pode nos oferecer informações valiosas a respeito dos fatores que influenciam as preferências dos consumidores e que podem afetar diretamente na expectativa, satisfação, até a intenção de compra do produto. Entender estes parâmetros e a influência que eles têm no comportamento dos consumidores pode ser um importante critério para avaliar a qualidade dos produtos e assim garantir a satisfação do consumidor.

Sabe-se que a qualidade das frutas está ligada diretamente a fatores intrínsecos, que são associados a fatores químicos, físicos, físico-químicos e características sensoriais dos alimentos, como aparência, aroma, textura e sabor (Ribeiro et al., 2021). A qualidade sensorial de frutas como o morango, é um fator chave para entender os aspectos que levam o consumidor a gostar e a comprar a fruta (Colquhoun et al., 2012). Como Yeung et al. (2021) destacaram,

não há uma escala preferida para avaliar o gostar dos consumidores em relação as frutas vermelhas. Porém, neste trabalho observou-se que utilizar diferentes escalas afetivas para quantificar as características intrínsecas dos morangos, pode ser uma boa alternativa para entender o que leva a aceitação do consumidor e definir a qualidade da fruta.

Neste trabalho observamos que só utilizar a escala hedônica pode não ser suficiente para compreender o comportamento do consumidor e o que verdadeiramente o induz a comprar o produto avaliado. Como destacado por Ares et al. (2009), um dos principais problemas para determinar os limites de aceitação e a percepção dos consumidores, é determinar quais são os critérios que devem ser utilizados para definir se o morango é aceitável ou não. Os autores ainda destacaram que normalmente, os limites de aceitação são selecionados arbitrariamente e que faltam informações sobre a implicação desses limites para compreendermos o que afeta os consumidores.

Neste caso, avaliamos alguns limites para entender a percepção do consumidor e estabelecer a qualidade de morangos e foi possível observar uma clara influência da doçura, suculência e acidez na aceitação e expectativa dos consumidores. Observamos que valores próximos ao ideal ou maiores que o ideal ( $\geq 4.5$ ) para doçura e suculência, enquanto valores próximos ao ideal ou menores que o ideal de acidez estão relacionados a uma boa aceitação, e ao fato de o morango atingir as expectativas dos consumidores. As expectativas podem ser consideradas como crenças pré-julgamento sobre os produtos, afetando as reações de decisões cotidianas das pessoas, tanto consciente quanto subconscientemente. As expectativas sensoriais estão relacionadas às crenças dos consumidores sobre as características sensoriais do produto, enquanto as expectativas hedônicas referem-se a quanto o produto será apreciado ou rejeitado (Varela et al., 2010).

O fato de os morangos serem suculentos, mais doces e com acidez ideal pode significar a superação das expectativas dos consumidores, gerando uma maior aceitação da fruta e assim,

influenciar positivamente na satisfação e intenção de compra. Quanto mais alta ou baixa a expectativa do consumidor, mais alto ou baixo o julgamento das satisfações (Farias; Santos, 2000). Dessa forma, ao atingir a expectativa, provavelmente o morango será apreciado pelos consumidores e caso a expectativa não seja atingida, o morango será rejeitado.

Assim, para aceitar um morango para sua comercialização e garantir que a expectativa do consumidor seja atingida, a fruta deve apresentar um escore de ideal de doçura superior a 4.3, suculência superior a 4.7 e acidez menor que 5.0. Dessa forma, é possível determinar se o morango será aceito ou rejeitado usando escores de atributos desejáveis. Neste trabalho, observamos que a suculência e a doçura foram atributos importantes para a aceitação dos morangos. Vários trabalhos na literatura observaram características sensoriais que levam a uma melhor qualidade dos morangos (Ares et al., 2009; Lado et. al., 2010; Vicente et al., 2013; Wendin et al., 2019). Alguns deles destacam que a doçura é um dos principais atributos para influenciar a preferência e aceitação dos morangos pelos consumidores (Lado et. al., 2010; Wendin et al., 2019). Fato que vai ao encontro aos resultados obtidos neste trabalho.

Uma vez que estes limites levam em consideração as percepções do consumidor sobre o produto, eles consistem em uma melhoria nos critérios mais arbitrários usados por outros autores para estimar a qualidade de morangos (Ares et al., 2009). Ademais, esses limites podem ser utilizados para estimar a aceitação e expectativas dos consumidores de morangos, além de entender os fatores que levam à satisfação e à intenção de compra dessa fruta. Dessa forma, é possível garantir a qualidade dos morangos, pois esses limites são baseados na percepção dos consumidores.

Em relação aos resultados obtidos para os biplots gerados na ausência de percepções, entendem-se que as emoções percebidas pelo consumidor são identificadas a um conjunto de respostas hedônicas que surgem durante a realização do experimento (Makarem & Jae, 2016). Mediante o exposto, por não avaliar expressões faciais ou opiniões que retratam sentimentos,

supostamente pode explicar os resultados que não associam os atributos sensoriais a aceitação e expectativa.

Outra evidência, pode ser explicada pela teoria da equidade (Gashgari, 2016) que menciona que aceitação individual pode ser influenciada de forma proporcional a aceitação de um grupo de consumidores, ou seja, devido ao planejamento do experimento não há características da formação de grupos ou nichos de consumidores em relação a preferência de uma ou outra amostra.

#### **4. CONCLUSÃO**

No presente trabalho, o uso das diferentes escalas foi fundamental para entender o comportamento do consumidor e determinar parâmetros de qualidade dos morangos. Com elas foi possível compreender de maneira mais aprofundada o que leva os consumidores a aceitarem os morangos e quais são as suas expectativas. Utilizando apenas a escala da aceitação não seria possível entender por completo o que leva os consumidores a gostarem do morango. Este estudo apresentou dados relevantes para os pesquisadores das ciências sensoriais, que geralmente conduzem muitos estudos afetivos em diferentes produtos.

No caso dos morangos, observou-se que a doçura, suculência e acidez tiveram efeitos importantes para caracterizar a aceitação e expectativa dos consumidores e conseqüentemente a satisfação dos clientes. Os valores determinados para estes atributos podem ser utilizados para estimar a qualidade sensorial dos morangos, sendo úteis em estudos de controle de qualidade da fruta, a fim de minimizar a rejeição dos consumidores. A metodologia aplicada neste estudo pode ser utilizada em estudos com outros produtos, nos quais se avaliam as percepções dos consumidores e se identificam os fatores que levam a uma aceitação e expectativa dos consumidores.

#### **AGRADECIMENTOS**

Este estudo foi parcialmente financiado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código Financeiro 001, pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico - Brasil (CNPq) e pela Fundação de Amparo à Pesquisa de Minas Gerais - Brasil (FAPEMIG).

Declarações de interesse: nenhuma

## REFERÊNCIAS

- Ares, G., Barrios, S., Lareo, C., & Lema, P. (2009). Development of a sensory quality index for strawberries based on correlation between sensory data and consumer perception. *Postharvest biology and technology*, 52(1), 97-102.
- Cirillo, M. A. (2015). Otimização na Experimentação – Aplicação nas Engenharias e Ciências Agrárias. Editora UFLA, 226p.
- Colquhoun, T. A., Levin, L. A., Moskowitz, H. R., Whitaker, V. M., Clark, D. G., & Folta, K. M. (2012). Framing the perfect strawberry: an exercise in consumer-assisted selection of fruit crops. *Journal of Berry Research*, 2(1), 45-61.
- Correa, S. C., Pinheiro, A. C. M., Siqueira, H. E., Carvalho, E. M., Nunes, C. A., & Boas, E. V. D. B. V. (2014). Prediction of the sensory acceptance of fruits by physical and physical-chemical parameters using multivariate models. *LWT-Food Science and Technology*, 59(2), 666-672.
- Cruz, A. G., Cadena, R. S., Castro, W. F., Esmerino, E. A., Rodrigues, J. B., Gaze, L., ... & Bolini, H. M. A. (2013). Consumer perception of probiotic yogurt: Performance of check all that apply (CATA), projective mapping, sorting and intensity scale. *Food Research International*, 54(1), 601-610.
- da Silva, A. N., dos Santos Navarro, R. D. C., Ferreira, M. A. M., Minim, V. P. R., da Costa, T. D. M. T., & Perez, R. (2013). Performance of hedonic scales in sensory acceptability of strawberry yogurt. *Food quality and preference*, 30(1), 9-21.
- de Jesus Filho, M., Scolforo, C. Z., Saraiva, S. H., Pinheiro, C. J. G., Silva, P. I., & Della Lucia, S. M. (2018). Physicochemical, microbiological and sensory acceptance alterations of strawberries caused by gamma radiation and storage time. *Scientia Horticulturae*, 238, 187-194.
- Derringer, G., & Suich, R. (1980). Simultaneous optimization of several response variables. *Journal of quality technology*, 12(4), 214-219.
- Drake, M. A. (2007). Invited review: Sensory analysis of dairy foods. *Journal of dairy science*, 90(11), 4925-4937.

- Farias, S. A. D., & Santos, R. D. C. (2000). Modelagem de equações estruturais e satisfação do consumidor: uma investigação teórica e prática. *Revista de Administração Contemporânea*, 4, 107-132.
- Gashgari, S. (2016). Equity Theory and Its Effect on Performance Outcome. *International Journal of Scientific & Engineering Research*, v.7, n.4, p.517-520.
- Greenacre, M. (2003). Singular value decomposition of matched matrices. *Journal of applied statistics*, 30(10), 1101-1113.
- Henika, R. G. (1982). Use of response surface methodology in sensory evaluation. *Food Technol.*, 36(11), 96-101.
- Kalva, J. J., Sims, C. A., Puentes, L. A., Snyder, D. J., & Bartoshuk, L. M. (2014). Comparison of the hedonic general labeled magnitude scale with the hedonic 9-point scale. *Journal of Food Science*, 79(2), S238-S245.
- Kershaw, J. C., & Running, C. A. (2019). Data approximation strategies between generalized line scales and the influence of labels and spacing. *Journal of Sensory Studies*, 34(4), e12507.
- Kim, M. A., van Hout, D., & Lee, H. S. (2018). Degree of satisfaction-difference (DOSD) method for measuring consumer acceptance: Comparative and absolute measures of satisfaction based on signal detection theory. *Food Quality and Preference*, 68, 167-172.
- Lado, J., Vicente, E., Manzoni, A., & Ares, G. (2010). Application of a check-all-that-apply question for the evaluation of strawberry cultivars from a breeding program. *Journal of the Science of Food and Agriculture*, 90(13), 2268-2275.
- Lahne, J., & Zellner, D. A. (2015). The great is the enemy of the good: Hedonic contrast in a coursed meal. *Food Quality and Preference*, 45, 70-74.
- Lawless, H. T., Popper, R., & Kroll, B. J. (2010). A comparison of the labeled magnitude (LAM) scale, an 11-point category scale and the traditional 9-point hedonic scale. *Food Quality and Preference*, 21(1), 4-12.
- Lawless, H. T., Sinopoli, D., & Chapman, K. W. (2010). A comparison of the labeled affective magnitude scale and the 9-point hedonic scale and examination of categorical behavior. *Journal of Sensory Studies*, 25, 54-66.
- Lim, J. (2011). Hedonic scaling: A review of methods and theory. *Food quality and preference*, 22(8), 733-747.
- Makarem, S.C.; Jae, H. (2016). Consumer boycott behavior: an exploratory analysis of twitter feeds. *Journal of Consumer Affairs*, v.50, n.1, p.193-223.
- Oliver, P., Cicerale, S., Pang, E., & Keast, R. (2018). Check-all-that-applies as an alternative for descriptive analysis to establish flavors driving liking in strawberries. *Journal of sensory studies*, 33(2), e12316.
- R Core Team (2020). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL. <https://www.R-project.org/>.

- Ribeiro, M. N., Carvalho, I. A., Fonseca, G. A., Lago, R. C., Rocha, L. C., Ferreira, D. D., ... & Pinheiro, A. C. (2021). Quality control of fresh strawberries by a random forest model. *Journal of the Science of Food and Agriculture*, 101(11), 4514-4522.
- Ribeiro, M. N., Rodrigues, D. M., Rocha, R. A. R., Silveira, L. R., Condino, J. P. F., Júnior, A. C., ... & Pinheiro, A. C. M. (2020). Optimising a stevia mix by mixture design and napping: A case study with high protein plain yoghurt. *International Dairy Journal*, 110, 104802.
- Schwieterman, M. L., Colquhoun, T. A., Jaworski, E. A., Bartoshuk, L. M., Gilbert, J. L., Tieman, D. M., ... & Clark, D. G. (2014). Strawberry flavor: diverse chemical compositions, a seasonal influence, and effects on sensory perception. *PloS one*, 9(2), e88446.
- Varela, P., Ares, G., Giménez, A., & Gámbaro, A. (2010). Influence of brand information on consumers' expectations and liking of powdered drinks in central location tests. *Food Quality and Preference*, 21(7), 873-880.
- Vicente, E., Varela, P., de Saldamando, L., & Ares, G. (2014). Evaluation of the sensory characteristics of strawberry cultivars throughout the harvest season using projective mapping. *Journal of the Science of Food and Agriculture*, 94(3), 591-599.
- Wakeling, I. N., & MacFie, H. J. (1995). 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 Quality and Preference*, 6(4), 299-308.
- Wendin, K., Egan, P. A., Olsson, V., Forsberg, S., Nilsson, A., & Stenberg, J. A. (2019). Is there a best woodland strawberry? A consumer survey of preferred sensory properties and cultivation characteristics. *International Journal of Gastronomy and Food Science*, 16, 100151.
- Yeung, H. F., Homwongpanich, K., Michniuk, E., Rovai, D., Migliore, M., Lammert, A., & Lahne, J. (2021). A tale of 3 scales: How do the 9-pt, Labeled Affective Magnitude, and unstructured Visual Analog scales differentiate real product sets of fresh berries?. *Food Quality and Preference*, 88, 104109.
- Yu, P., Low, M. Y., & Zhou, W. (2018). Design of experiments and regression modelling in food flavour and sensory analysis: A review. *Trends in Food Science & Technology*, 71, 202-215