

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

KEILA CRISTINA DA SILVA

**IMAGENS DIGITAIS E TÉRMICAS, ESPECTROSCOPIA NIR E
CALIBRAÇÃO MULTIVARIADA NA AVALIAÇÃO DE PARÂMETROS
DE TEXTURA DE FARINHAS**

CAMPO MOURÃO

2022

KEILA CRISTINA DA SILVA

**IMAGENS DIGITAIS E TÉRMICAS, ESPECTROSCOPIA NIR E
CALIBRAÇÃO MULTIVARIADA NA AVALIAÇÃO DE PARÂMETROS
DE TEXTURA DE FARINHAS**

**Digital and thermal images, NIR spectroscopy and multivariate calibration in
the evaluation of flour texture parameters**

Dissertação de Mestrado apresentada como requisito para obtenção do título de Mestre em Inovações Tecnológicas do Programa de Mestrado em Inovações Tecnológicas da Universidade Tecnológica Federal do Paraná (UTFPR).

Orientador(a): Profa. Dra. Patrícia Valderrama

CAMPO MOURÃO

2022



[4.0 Internacional](https://creativecommons.org/licenses/by-nc-sa/4.0/)

Esta licença permite remixe, adaptação e criação a partir do trabalho, para fins não comerciais, desde que sejam atribuídos créditos ao(s) autor(es) e que licenciem as novas criações sob termos idênticos.

Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.



KEILA CRISTINA DA SILVA

IMAGENS DIGITAIS E TÉRMICAS, ESPECTROSCÓPIA NIR E CALIBRAÇÃO MULTIVARIADA NA AVALIAÇÃO DE PARÂMETROS DE TEXTURA DE FARINHAS

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestra Em Inovações Tecnológicas da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Inovações Tecnológicas.

Data de aprovação: 09 de Junho de 2022

Dra. Patricia Valderrama, Doutorado - Universidade Tecnológica Federal do Paraná

Dra. Juliana Luna Bilheiro Peixoto, Doutorado - Centro Universitário Ingá

Dr. Wyrllen Everson De Souza, Doutorado - Universidade Tecnológica Federal do Paraná

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 09/06/2022.

“Dedico este trabalho ao meu querido pai Valdir (in memoriam), cujo empenho em me educar sempre veio em primeiro lugar. Aqui estão os resultados dos seus esforços. Com muito amor e gratidão.”

AGRADECIMENTOS

À Deus pelo dom da vida.

Ao meu marido e companheiro Bruno, meu amor, que me deu força e apoio, e com muita paciência compreendeu minhas dificuldades e nunca deixou de acreditar em mim. Obrigada por tudo!

Agradeço imensamente a minha orientadora, Prof^a Dr^a Patrícia Valderrama por ter confiado em mim para a execução dessa pesquisa, por todo suporte dado, pela paciência e disponibilidade, pela amizade adquirida e principalmente por nunca me deixar desmotivar. Muito obrigada professora, você é incrível!

Ao meu pai Valdir (in memoriam), tenho certeza que está muito orgulhoso de mim, sinto sua falta e te amo para sempre!

Ao meu porto seguro, minha mãe Dirce, agradeço pelo amor incondicional e torcer pelo meu sucesso.

Às minhas amigas que são uma enorme motivação para mim e a alegria dos meus dias.

Agradeço ao Programa de Pós-Graduação em Inovações Tecnológicas da Universidade Tecnológica Federal do Paraná (UTFPR) pela oportunidade. Agradeço aos colegas e aos professores por todo ensinamento, conselhos e experiências compartilhadas.

À banca examinadora pelas sugestões e atenção dedicadas a este estudo.

Enfim, a todos os que por algum motivo contribuíram para a realização desta pesquisa.

RESUMO

A farinha de trigo é um ingrediente predominante em vários produtos alimentícios e tem-se verificado uma inserção gradativa ao mercado consumidor de diversas farinhas e com parâmetros específicos de qualidade nutricional e tecnológico para a produção de alimentos, como farinhas de trigo integral, milho, milho branca, fécula de mandioca, aveia, centeio, arroz, arroz integral, linhaça marrom, linhaça dourada, soja, banana, batata doce, casca de maracujá, maracujá, berinjela, gengibre, yacon, amaranto, chia, coco, uva que podem substituir o trigo de forma parcial ou integral, assim garantindo uma vida mais saudável para população que necessitam de farinhas sem glúten, sendo que cada tipo de farinha tem particularidades específicas relativas à textura, fraturabilidade, dureza, adesividade, elasticidade, resiliência, coesividade, gomosidade e mastigabilidade. O objetivo deste trabalho foi utilizar parâmetros das imagens digitais, imagens térmicas, espectroscopia na região do infravermelho próximo (NIR) e utilizar a ferramenta da quimiometria, calibração multivariada (PLS) na investigação de correlação com parâmetros de textura analisados no texturômetro (TPA). No caso empregou-se diferentes tipos de farinhas em um mesmo modelo de calibração multivariado, considera-se multiproduto. Os modelos obtidos a partir das imagens digitais apresentaram resultados de ajuste mais elevados, os modelos gerados a partir das imagens térmicas e da espectroscopia NIR também apresentam resultados considerados satisfatórios. Os resultados de VIP scores permitem verificar que a dureza, a gomosidade e a coesão apresentam semelhança nas variáveis importantes para modelar esses parâmetros. Concluiu-se que o método proposto é uma alternativa ao método convencional por texturômetro para determinação dos parâmetros de textura em farinhas.

Palavras-chave: farinhas; quimiometria; texturômetro; *smartphone*; imagem digital.

ABSTRACT

Wheat flour is a predominant ingredient in several food products and there has been a gradual insertion into the consumer market of various flours and with specific parameters of nutritional and technological quality for food production, such as whole wheat flour, corn, corn white, cassava starch, oats, rye, rice, brown rice, brown linseed, golden linseed, soybeans, bananas, sweet potatoes, passion fruit peel, passion fruit, eggplant, ginger, yacon, amaranth, chia, coconut, grapes that can be substituted partial or whole wheat, thus ensuring a healthier life for the population that needs gluten-free flour, and each type of flour has specific particularities related to texture, fractureability, hardness, adhesiveness, elasticity, resilience, cohesiveness, gumminess and chewability. The objective of this work was to use parameters of digital images, thermal images, spectroscopy in the region of near infrared (NIR) and to use the chemometric tool, multivariate calibration (PLS) in the investigation of correlation with parameters of texture analyzed in the texturometer (TPA). In this case, different types of flour were used in the same multivariate calibration model, it is considered multiproduct. The models obtained from the digital images presented higher adjustment results, the models generated from the thermal images and from the NIR spectroscopy also present satisfactory results. The results of VIP scores allow us to verify that hardness, gumminess and cohesion are similar in the variables important to model these parameters. It was concluded that the proposed method is an alternative to the conventional texturometer method for determining texture parameters in flours.

Keywords: flours; chemometrics; texturometer; smartphone; digital imaging.

SUMÁRIO

1 INTRODUÇÃO.....	8
2 OBJETIVOS	14
2.1 Objetivo Geral	14
2.2 Objetivo Específico	14
3 METODOLOGIA	15
4 RESULTADOS E DISCUSSÃO	18
5 CONCLUSÃO	26
REFERÊNCIAS	27

1 INTRODUÇÃO

A farinha é um ingrediente predominante em vários produtos alimentícios, incluindo pão, bolos, biscoitos e macarrão. No caso dos produtos de panificação, a substituição da farinha de trigo ocorre parcialmente ou de forma total, dependendo do objetivo final, pois a escolha do tipo de farinha vai depender das características desejadas no alimento. Tem-se verificado uma inserção gradativa ao mercado consumidor de diversas farinhas com parâmetros específicos de qualidade nutricional e tecnológico para a produção de alimentos. Em produtos de panificação alguns tipos de farinhas comumente usadas são as de arroz, cevada, chia, farinha de coco, ervilha, banana, berinjela, entre outras (COSTA et al., 2007; PINELLI, 2018; OLIVEIRA et al., 2020).

De acordo com o Regulamento da Anvisa – RDC 263/2005, a farinha é o produto obtido de partes comestíveis de uma ou mais espécies de cereais, leguminosas, frutos, sementes, tubérculos e rizomas por moagem e ou outros processos tecnológicos considerados seguros para produção de alimentos, devendo ser denominada de seguida do nome comum da espécie vegetal utilizada, por exemplo, "farinha de arroz", "farinha de mandioca", "farinha de batata doce" e "farinha de banana". Sua classificação varia de acordo com suas características físicas, químicas, enzimáticas e reológicas, podendo ser considerada uma farinha simples, no qual ocorre a moagem ou raladura de forma individual, ou farinha mista, obtida através de diferentes espécies vegetais (BRASIL, 2005).

Dentre as diversas farinhas inseridas no mercado, a que mais se destaca é a farinha de trigo, consumida em grande escala no Brasil, com inúmeras aplicações na indústria de alimentos. Entretanto, do ponto de vista teórico todo grão inteiro pode ser transformado em farinha através do processo de moagem (GRAÇA et al., 2017).

Considerando a demanda de mercado, ou a necessidade em atender um público específico, como por exemplo os portadores de doença celíaca, diversos trabalhos avaliaram a substituição parcial ou total da farinha de trigo em produtos de panificação (MARTINEZ et al., 2014; LEMOS et al., 2012; LACERDA et al., 2009; CÉSAR et al., 2006).

A busca pela melhoria na qualidade nutricional, associado à demanda de um público que busca cada vez mais produtos com atrativos saudáveis, fez surgir novas

demandas. A farinha de banana verde, por exemplo, tem sido utilizada em produtos cárneos reduzidos no teor de gordura. Dessa forma, considerando que redução do nível de gordura em produtos cárneos pode afetar diretamente na aceitabilidade do alimento e interferir nos aspectos tecnológicos do produto, estudos mostram a viabilidade da substituição da gordura pela farinha de banana verde com boa aceitabilidade sensorial e melhoria nas características tecnológicas e nutricionais (HARTMANN et al. 2020).

A farinha de banana verde também tem despertado interesse do mercado consumidor pelo seu valor nutricional, com quantidades consideráveis de vitaminas B e C, bem como sais minerais, como potássio e cálcio (LEONEL et al., 2011; ASMAR et al., 2013), destaca-se a presença de amido resistente (TRIBESS et al., 2009; ALKARKHI et al., 2011) que incluído na dieta humana tem sido associada à redução dos níveis de colesterol LDL. Além disso, a farinha de banana verde é rica em fitosteróis, compostos fenólicos (HASLINDA et al., 2009; BERTOLINI et al., 2010; VERNAZA et al., 2011; SARAWONG et al., 2014) e apresenta capacidade antioxidante (HASLINDA et al., 2009; CHOO & AZIZ, 2010; WANG et al., 2012; SARAWONG et al., 2014).

A farinha da casca do fruto maracujá vem sendo empregada em pesquisas associadas a estados patológicos caracterizados por alterações no metabolismo glicêmico e lipídêmico, bem como a fim de prevenir doenças. Desta forma, este recurso tem sido empregado no retardo no esvaziamento gástrico promovido pela pectina que reduz o pico glicêmico decorrente da ingestão elevada de carboidrato (SOUZA et al., 2008), reduzindo a absorção de glicídios. A pectina também favorece a formação de uma camada gelatinosa na mucosa intestinal, reduzindo a absorção de lipídeos (MEDEIROS et al., 2009). No intestino grosso, a pectina, após ser fermentada, origina ácidos graxos de cadeia curta. Além disso, estudos apontam a pectina com propriedades anticancerígenas e imunoestimulatórias (BRAGA et al., 2010).

Na América Latina a doença celíaca (DC) afeta 1 em cada 100 a 200 indivíduos. Esses portadores de DC quando expostos a um tratamento inadequado acabam apresentando o surgimento de outras doenças como a osteoporose e infertilidade, por exemplo (GREEN, 2003; KIM E SHIN, 2014). Segundo a Associação Portuguesa de Celíacos (APC), o tratamento para essa doença consiste em dieta a longo prazo com a promoção de uma alimentação rigorosa, saudável e equilibrada através da

substituição de alimentos com glúten por matérias-primas isentas para restabelecer a regeneração do intestino (LARROSA, 2013). Uma possível alternativa de ingrediente funcional e sem glúten é a farinha de coco, pois apresenta rica fonte de fibras alimentares, proteínas, lipídios, cinzas (ferro e cálcio) e carboidratos, além de conter baixa quantidade de gordura e triglicérido de cadeia média, que estão relacionados com a melhoria do funcionamento do intestino, redução dos níveis de colesterol ruim e controle da diabetes (TRINIDAD et al., 2004; QUEIROZ, 2017).

A sensibilidade ao glúten não celíaca (SGNC) é uma manifestação da má digestão do glúten com sintomas gastrointestinais semelhantes à DC, como inchaço abdominal, vômitos, diarreia e flatulências. Entretanto, diferente da DC, a SGNC demonstra não desencadear processo imunológico crônico e alterações nas vilosidades intestinais (TYE-DIN; GALIPEAU; AGARDH, 2018). Além disso, outra manifestação semelhante é a alergia ao trigo, causada por mecanismo imunológico desencadeado pela ingestão deste cereal. Neste caso, os sintomas se manifestam em poucas horas após a ingestão de alimentos que contenham trigo, sendo caracterizados por urticária, anafilaxia, náusea, vômitos e obstrução brônquica (BIESIEKIERSKI, 2017).

As farinhas de arroz e milho podem ser utilizadas na dieta celíaca e fornecem um sabor suave, levemente doce para produtos de panificação e massas, além de serem ricas em carboidratos e proteínas (KOIRALA, 2020; WANG; UPADHYAYA; DWEIKAT, 2016). Os alimentos vegetais são fontes ricas de minerais, os quais, geralmente, estão em déficit em pacientes celíacos (WALLACE et al., 2020). A batata-doce é bastante utilizada na produção de fécula de batata, com aplicações interessantes para a produção de base para produtos destinados a celíacos (TANUMIHARDJO et al., 2016). A farinha ou fécula de mandioca, denominada de tapioca, tem promissora aplicação na dieta celíaca (TANUMIHARDJO et al., 2016). Incluem-se também os pseudocereais livres de glúten, como por exemplo a farinha de amaranto, uma fonte rica em magnésio, cálcio, zinco, ferro, vitamina A, B12, B6 e ácido fólico (PIRZADAH et al., 2017).

As pesquisas enfatizando que as fibras apresentam efeito de proteção em relação às doenças cardiovasculares fez aumentar o consumo de farinha de trigo integral (JUSTO et al., 2007; SKRBIC & FILIPCEV, 2009).

Em virtude das propriedades viscoelásticas das massas de diferentes farinhas, que podem ser determinadas por características físico-químicas e reológicas, a

qualidade de produtos alimentícios obtidos com farinhas diferentes da farinha de trigo pode ser modificada (CHEN et al., 2017). Indo ao encontro disso, um parâmetro importante é a textura, que pode ser descrita como uma propriedade sensorial e funcional da estrutura da farinha, podendo ser avaliada a partir de instrumentos que realizam ensaios mecânicos ou por painéis sensoriais (LAWLESS; HEYMANN, 2010). Ainda, fatores como clima, solo, manejo, cultivo, colheita, secagem e armazenamento garantem particularidades específicas relativas à textura, adesividade, elasticidade, resiliência, coesão e viscosidade para cada tipo de farinha (GRAÇA et al., 2017).

A análise do perfil de textura (do inglês, *Texture Profile Analysis* - TPA) é uma técnica de dupla compressão de uso difundido no estudo quantitativo da textura dos alimentos. Nesta técnica, amostras de alimentos são comprimidas duas vezes, em um curto intervalo de tempo, analogamente ao processo de mastigação, sendo obtidos os parâmetros quanto a sua textura (TORMENA, 2016; PINELLI, 2018), cujas definições são descritas no Quadro 1.

Quadro 1. Definições dos parâmetros de textura – TPA.

Parâmetros	Definição
Fraturabilidade	É a força necessária para fraturar um produto.
Dureza	É a força necessária para produzir certa deformação.
Coesividade	É a extensão que um material pode ser deformado antes da ruptura.
Elasticidade ou Flexibilidade	É a velocidade na qual um material deformado volta à condição inicial, depois que a força de deformação é removida.
Adesividade	É a energia necessária para superar as forças atrativas entre a superfície de alimento e a de outros materiais com os quais o alimento está em contato.
Gomosidade	É a energia necessária para desintegrar um alimento até estar pronto para deglutição.
Mastigabilidade	É o trabalho necessário para mastigar um alimento sólido até a deglutição.
Resiliência	É a medida do esforço do produto para retornar a sua forma original, em termos de velocidade.

Fonte: PINELLI (2018); SZCZESNIAK et al. (2002).

Apesar da TPA poder ser realizada através de ensaios mecânicos instrumentais em substituição às análises sensoriais (CHEN et al., 2013), ainda assim deve-se levar em consideração etapas que envolvem o preparo da amostra e custo relativamente mais elevado do texturômetro, equipamento utilizado nas medidas.

Dessa forma, a busca pelo desenvolvimento de métodos alternativos vem aumentando, e levando em consideração a possibilidade do emprego de um instrumental de menor custo como a espectroscopia na região do infravermelho próximo (do inglês, *Near InfraRed* - NIR) e as imagens digitais.

A espectroscopia NIR foi empregada para determinar teores de cinzas, proteínas, pH e umidade em farinhas de soja (BRÁS et al., 2005) e de inhame (LEBOT et al., 2009) através de calibração multivariada por mínimos quadrados parciais (do inglês, *Partial Least Squares* – PLS). Esta técnica instrumental também foi empregada na classificação de diferentes tipos de farinha de trigo por categoria de qualidade a partir dos parâmetros proteínas e fibras (COCCHI et al., 2005), nesse caso a ferramenta quimiométrica empregada foi a análise de componentes principais (PCA). No trabalho de Chen et al., (2017) foi utilizado a espectroscopia NIR com regressão por PLS na determinação da proteína total e do glúten úmido. Por outro lado, parâmetros físico-químicos e reológicos foram avaliados em farinhas de trigo empregando imagens digitais e calibração multivariada com PLS (CORDEIRO; VALDERRAMA, 2021), e na avaliação da estrutura dos poros em alimentos assados (RAHIMI et al., 2020).

Métodos analíticos para a análise de alimentos por imagens digitais têm ganhado grande destaque na literatura e o número de publicações tem aumentado consideravelmente nos últimos anos. Isto ocorre devido à facilidade de uso de imagens digitais como uma nova ferramenta de obtenção de dados analíticos, utilizando *scanners* (BELTRAME et al., 2019; GONÇALVES et al., 2020), *webcams* (BASSETTI, 2019), câmeras digitais e telefones celulares (CAPITÁN-VALLVEY et al., 2015; GRUDPAN et al., 2015; CORDEIRO, 2020). Além disso, as imagens térmicas também vêm ganhando espaço no desenvolvimento de métodos para análise de alimentos (VADIVAMBAL & JAYAS, 2010; GOWEN et al., 2010; GHOSH et al., 2016; FERREIRA, D.S., 2020).

Apesar da espectroscopia NIR e as imagens térmicas e digitais apresentarem grande potencial no desenvolvimento de métodos analíticos alternativos, essas

técnicas necessitam conjuntamente do emprego da quimiometria, através de suas ferramentas (como o PLS, por exemplo).

A quimiometria têm por finalidade desenvolver modelos com base em medições e contribuir para a interpretabilidade dos dados instrumentais (ALMEIDA, 2009). Considerando o exposto, este trabalho busca desenvolver métodos analíticos alternativos através da espectroscopia NIR, das imagens digitais e das imagens térmicas na determinação dos parâmetros de textura de farinhas.

2 OBJETIVOS

2.1 Geral

Utilizar parâmetros das imagens digitais, imagens térmicas, espectroscopia na região do infravermelho próximo (NIR) e calibração multivariada na investigação de correlação com parâmetros de textura.

2.2 Específicos

- Utilizar aplicativo para *smartphone Photometrix* para adquirir as imagens digitais das farinhas.
- Utilizar o aplicativo para *smartphone night vision* para adquirir as imagens digitais das farinhas.
- Adquirir espectros NIR das farinhas.
- Obter parâmetros de textura - dureza, coesividade, elasticidade ou flexibilidade, adesividade, gomosidade, mastigabilidade e resiliência – das farinhas.
- Utilizar calibração multivariada por mínimos quadrados parciais (PLS) para buscar correlações entre os parâmetros de textura e as imagens e espectros NIR.

3 METODOLOGIA

Foram consideradas um total de 138 amostras de farinhas de diferentes composições, sendo 6 amostras de cada tipo de farinha com diferentes marcas e/ou lotes. Os tipos de farinha utilizados foram: trigo, trigo integral, milho, milho branca, fécula de mandioca, aveia, centeio, arroz, arroz integral, linhaça marrom, linhaça dourada, soja, banana, batata doce, casca de maracujá, maracujá, berinjela, gengibre, yacon, amaranto, chia, coco, uva. Todas as amostras comerciais foram adquiridas no estado do Paraná – Brasil.

Para a aquisição das imagens digitais e dos espectros NIR, as amostras tiveram a granulometria padronizada em 80 mesh.

Uma porção de 5 g de farinha foi disposta em placa de petri com 5 cm de diâmetro. Um *smartphone iPhone XR* foi posicionado a uma distância fixa de 20 cm em relação às amostras (Figura 1) e as imagens foram capturadas a partir do aplicativo *Photometrix* (HELFER et al., 2017) e *Night Vision*. Todas as imagens foram adquiridas no mesmo dia e sob a mesma condição de luminosidade.

Figura 1. Esquema para aquisição das imagens digitais das farinhas



Fonte: Autoria própria (2022).

Os histogramas de cor capturados pelo aplicativo *Photometrix* foram importados para o software Matlab R2007b. As imagens obtidas pelo aplicativo *Night Vision* foram transformadas em histogramas de cor através do software Matlab R2007b.

As medidas espectrais na região do infravermelho próximo (906 – 1600 nm) foram realizadas em equipamento microNIR da marca JDSU, empregando um

acessório para medida de amostras sólidas. As medidas foram realizadas em temperatura ambiente e modo de leitura em reflectância.

Os parâmetros de dureza, coesividade, elasticidade ou flexibilidade, adesividade, gomosidade, mastigabilidade e resiliência foram obtidos a partir de um texturômetro modelo TA-XT Express (*Stable Micro Systems*). Na análise por texturômetro, uma quantidade de 10 g de amostra foi misturada a 10 mL de água destilada em corpos de prova e foi utilizado um probe cilíndrico de 5 cm de diâmetro. Os dados adquiridos no texturômetro foram processados em *software Exponent Lite Express*. A análise foi realizada à temperatura ambiente.

A calibração multivariada foi realizada empregando a regressão por PLS. Para tanto, a matriz X (espectros NIR, histogramas de cor) foram então correlacionadas a um vetor y que continha os valores dos parâmetros de textura determinados pelo método convencional.

As etapas de pré-processamentos e transformações foram realizadas no *software* MATLAB R2007B (*The MathWorks Inc., Natick, USA*). Os espectros NIR passaram pela correção do espalhamento multiplicativo (ISAKSSON; NAES, 1988). Todos os modelos foram construídos com os dados centrados na média e o conjunto de dados foi separado em conjuntos de calibração (3/4 das amostras) e validação (1/4 das amostras) a partir do algoritmo *Kennard-Stone*. Este algoritmo seleciona as amostras com base na distância. A primeira amostra selecionada é a que apresenta a maior distância em relação à amostra média. A segunda amostra a ser selecionada será a que apresentar maior distância em relação à primeira amostra selecionada e assim, sucessivamente, até atingir a quantidade de amostras desejadas (KENNARD; STONE, 1969).

O número de variáveis latentes (VLs) foi escolhido baseado no menor valor encontrado para o erro da validação cruzada (RMSECV), realizada em blocos contínuos de 10 amostras. Além disso, a percentagem de variância explicada pelo vetor y também foi considerada na escolha do número de VLs.

A otimização dos conjuntos de calibração e validação, pela eliminação das amostras anômalas, foi realizada de acordo com a norma da ASTM E1655-15 (Annual Book of ASTM Standards, 2015). Nesta otimização são avaliadas as amostras anômalas com relação ao *leverage*, ao resíduo espectral e o resíduo na variável dependente.

A validação dos modelos PLS foi realizada através do cálculo de parâmetros de mérito como: exatidão, linearidade, inverso da sensibilidade analítica, ajuste, limites de detecção e quantificação. Os cálculos foram realizados com base nas equações apresentadas na Quadro 2 (VALDERRAMA; BRAGA; POPPI, 2009; BASSETTI, 2019).

Quadro 2. Equações para calcular os parâmetros de mérito.

Parâmetros de mérito	Equação
Exatidão	$RMSEP = \sqrt{\frac{\sum_{i=1}^{nv} (y_i - \hat{y}_i)^2}{nv}}$
	$RMSEC = \sqrt{\frac{\sum_{i=1}^{nc} (y_i - \hat{y}_i)^2}{nc - nVL + 1}}$
Sensibilidade	$Sensibilidade = \frac{1}{\ \mathbf{b}\ }$
Sensibilidade Analítica	$Sensibilidade Analítica = \frac{Sensibilidade}{\ \delta x\ }$
Sensibilidade Analítica ⁻¹	$Sensibilidade Analítica^{-1} = \frac{1}{Sensibilidade Analítica}$
Limite de detecção	$\text{Limite de detecção} = 3.3 \delta x \ \mathbf{b}\ = 3.3 \delta x \frac{1}{Sensibilidade}$
Limite de quantificação	$\text{Limite de quantificação} = 10 \delta x \ \mathbf{b}\ = 10 \delta x \frac{1}{Sensibilidade}$

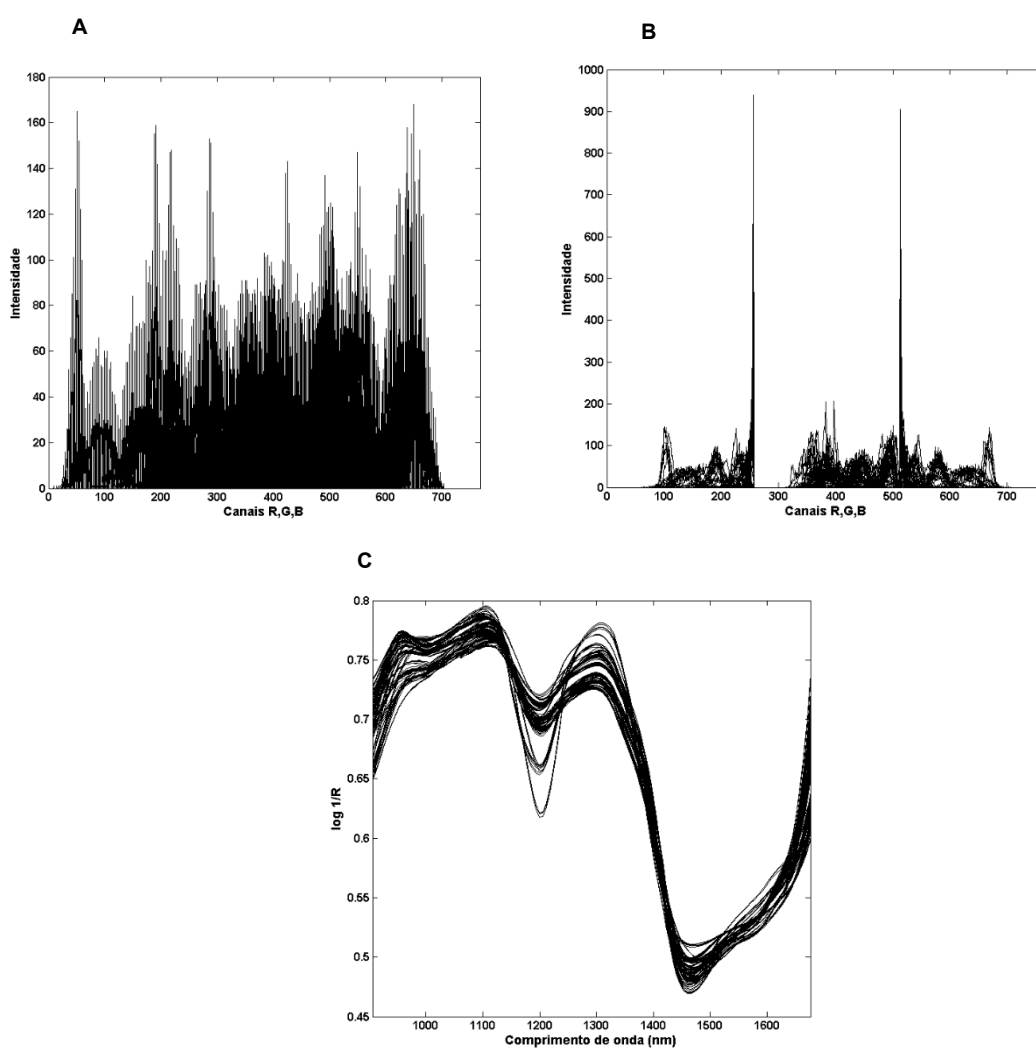
nv é o número de amostras no conjunto de validação, *y_i* é o valor de referência da amostra *i* e *ŷ_i* é o valor previsto da amostra *i*, *nc* é o número de amostras no conjunto de calibração, *nVL* é o número de Variáveis Latentes, *RMSECV* é o Erro Quadrado Médio da Raiz para Validação Cruzada, *b* é o vetor dos coeficientes de regressão, *δx* é uma estimativa para o ruído instrumental. Na equação do RMSEC, o "+1" é adicionado quando os dados são centrados na média.

Fonte: adaptado de VALDERRAMA; BRAGA; POPPI (2009); BASSETTI (2019).

4 RESULTADOS E DISCUSSÃO

A Figura 2 apresenta os canais R, G e B obtidos a partir do aplicativo Photometrix (Figura 2A – imagens digitais), e do aplicativo *night vision* (Figura 2B – imagens térmicas digitais) para 120 amostras, bem como os espectros NIR para 138 amostras de diferentes farinhas (Figura 2C). Em todos os casos, os dados foram importados para o ambiente Matlab, e utilizados no desenvolvimento dos modelos PLS.

Figura 2. Histogramas de cor das imagens digitais (A), Histogramas de cor das imagens térmicas (B), Espectros NIR (C)




Fonte: Autoria própria (2022).

Tabela 1. Resultados para os modelos PLS.

Parâmetros de Validação		Dureza (Hardness)	Adesividade (Adhesiveness)	Elasticidade (Springiness)	Mastigabilidade (Chewiness)	Gomosidade (Gumminess)	Coesão (Cohesiveness)	Resiliência (Resilience)
Imagens digitais / PLS								
Faixa modelada		0.0252 - 22.0613	(-10.5440) – (-0.0004)	0.1500 – 1.000	5.0000-287.0000	5.7300 - 451.5200	0.1300 - 0.7400	0.0100 - 0.1300
Exatidão	RMSEC ^a	1.2575	0.4135	0.1409	20.6533	23.7867	0.0382	0.0118
	RMSEP ^a	1.4167	0.3612	0.1252	18.9088	30.2218	0.0338	0.0109
Linearidade	JBSTAT	0.5137	3.3278	1.0944	3.7353	1.2832	2.7395	0.6051
	CRITVAL	4.4039	4.4039	4.2602	4.4039	4.1494	4.1494	4.4039
R ²		0.9391	0.9002	0.8497	0.8952	0.9231	0.9622	0.8085
VLs		6	7	5	8	5	6	5
Outliers		0	6	10	0	11	11	0
Sensibilidade analítica ¹		0.7412	-0.4480	0.0508	10.9738	17.7057	0.0259	0.0040
Limite de detecção		2.4459	-1.4783	0.1677	36.2136	58.2136	0.0854	0.0133
Limite de quantificação		7.4117	-4.4796	0.5083	109.7382	177.0575	0.2587	0.0404
Imagens térmicas / PLS								
Faixa modelada		0.0252-20.2488	(-11.9370) – (-0.0004)	0.1500 – 1.0000	5.0000 - 256.2600	5.5800-513.0700	0.1300 - 0.7400	0.0100 - 0.1300
Exatidão	RMSEC ^a	1.9295	0.8672	0.1777	21.0261	54.1399	0.0996	0.0143
	RMSEP ^a	1.7544	0.7453	0.1812	21.1321	50.2776	0.0624	0.0122
Linearidade	JBSTAT	0.6415	1.2821	1.2457	1.3651	0.8923	0.8302	0.2140
	CRITVAL	4.0239	4.2602	3.8011	3.8011	3.7156	4.1494	3.8806
R ²		0.8433	0.7357	0.7559	0.8162	0.7719	0.7116	0.7518
VLs		7	10	9	8	7	7	9
Outliers		16	8	20	15	18	16	9
Sensibilidade analítica ¹		0.5782	-0.5361	0.0790	8.7274	15.7803	0.0279	0.0059
Limite de detecção		1.9081	-1.7692	0.2608	28.8003	52.0751	0.0919	0.0194
Limite de quantificação		5.7821	-5.3613	0.7902	87.2736	157.8032	0.2785	0.0588
Espectroscopia NIR / PLS								
Faixa modelada		0.0254 - 20.2488	(-1.7296) – (-0.0002)	0.1500 - 1.2300	5 - 136.22	2.0500 - 423.8300	0.1000 - 0.7400	0.0100 - 0.1300
Exatidão	RMSEC ^a	2.2759	0.3534	0.1949	17.4119	52.3102	0.0841	0.0108
	RMSEP ^a	2.3483	0.4466	0.2230	12.1371	55.0346	0.0772	0.0112
Linearidade	JBSTAT	1.2560	3.3873	1.5328	2.6672	3.4767	0.9283	2.1688
	CRITVAL	4.4039	4.3108	4.5259	4.4467	5.3963	4.1494	4.4039
R ²		0.7955	0.7963	0.7391	0.7489	0.7937	0.7618	0.8199
VLs		8	20	20	9	9	19	14
Outliers		15	11	11	19	13	21	13
Sensibilidade analítica ¹		0.5888	0.1221	0.0497	2.3782	12.1628	0.0227	0.0022
Limite de detecção		1.9429	- 0.4028	0.1640	7.8479	40.1372	0.0749	0.0072
Limite de quantificação		5.8876	- 1.2207	0.4970	23.7815	121.6278	0.2271	0.0219


Fonte: Autoria própria.

Figura 3. VIP-Scores das Imagens digitais – (A) Dureza, (B) Adesividade, (C) Elasticidade, (D) Mastigabilidade, (E) Gomosidade, (F) Coesão, (G) Resiliência



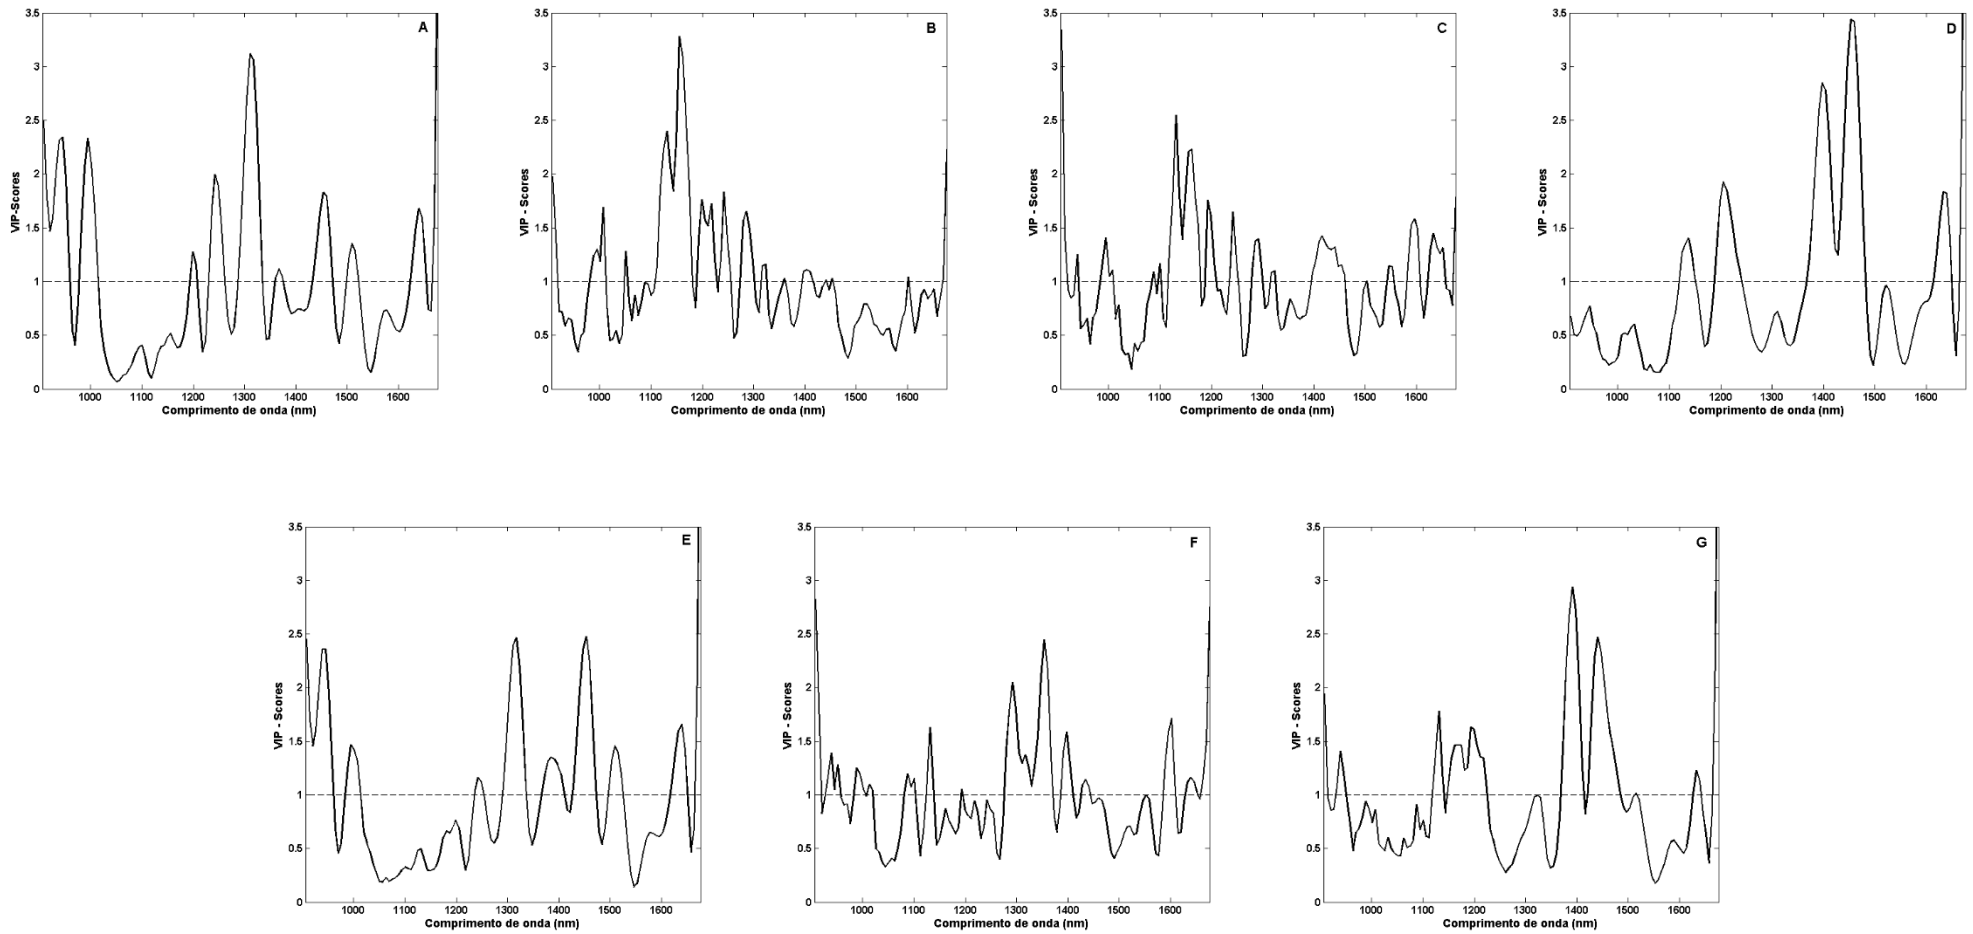
Fonte: Autoria própria (2022).

Figura 4. VIP-Scores das imagens térmicas – (A) Dureza, (B) Adesividade, (C) Elasticidade, (D) Mastigabilidade, (E) Gomosidade, (F) Coesão, (G) Resiliência



Fonte: Autoria própria (2022).

Figura 5. VIP-Scores da Espectroscopia NIR – (A) Dureza, (B) Adesividade, (C) Elasticidade, (D) Mastigabilidade, (E) Gomosidade, (F) Coesão, (G) Resiliência



Fonte: Autoria própria (2022).

Os modelos foram centrados na média e o número de variáveis latentes (VLs) para cada modelo de calibração multivariada desenvolvido foi determinado atendendo aos resultados da raiz quadrada do erro médio quadrático de validação cruzada (RMSECV) para as amostras de calibração, obtido pelo método de blocos contínuos de 10 amostras. Além disso, a percentagem de variância capturada por cada parâmetro de textura (bloco y) também foi considerada na escolha do número de VLs.

A Tabela 1 apresenta os resultados para os valores de erro médio quadrático da calibração (RMSEC) e validação (RMSEP) do modelo otimizado. Esses valores são considerados como um dos indicadores de exatidão do modelo multivariado (VALDERRAMA; BRAGA; POPPI, 2009; CORDEIRO, 2020) e indicam que o número de variáveis latentes utilizado foi escolhido de forma adequada, não havendo sobre ajuste ou falta de ajuste. Além disso, um outro indicador de exatidão é a regressão entre os valores de referência e os valores estimados pelo modelo (ajuste), cujos coeficientes de determinação são também apresentados na Tabela 1.

Os modelos obtidos a partir das imagens digitais apresentaram resultados de ajuste mais elevados. Entretanto, os modelos gerados a partir das imagens térmicas e da espectroscopia NIR também apresentam resultados considerados satisfatórios. Resultados de coeficiente de determinação similares aos encontrados para esses modelos já foram reportados antes na literatura empregando modelos de calibração multivariada por PLS (VALDERRAMA et al., 2007; FERREIRA et al., 2013; SANTOS et al., 2015; SANTOS et al., 2018; CORDEIRO, 2020; SANTOS et al., 2020;). Além disso, neste caso empregou-se diferentes tipos de farinhas em um mesmo modelo multivariado. Portanto, considera-se que se trata de um modelo de calibração multivariada multiproduto, cujos coeficientes de determinação para o ajuste, nestes tipos de modelos, já foram reportados na ordem de 0,7 para a quantificação de parâmetros de qualidade em sucos (SANTOS et al., 2015; SANTOS et al., 2016; SANTOS et al., 2018; SANTOS et al., 2019).

O teste estatístico Jarque-Bera foi empregado para confirmação da distribuição aleatória dos resíduos. Neste teste, quando JBSTAT é menor do que o CRITIVAL a hipótese nula (resíduos são normalmente distribuídos com média e desvio padrão não específicos) pode ser aceita no nível de 95% de significância. Conforme apresentado na Tabela 1, em todos os modelos o resultado para JBSTAT é menor do que o valor para CRITIVAL, portanto, confirma-se que os resíduos se distribuem aleatoriamente.

O inverso da sensibilidade analítica (sensibilidade analítica⁻¹) permite estabelecer a menor diferença para o parâmetro analisado que pode ser distinguida entre as amostras (VALDERRAMA; BRAGA; POPPI, 2009). Sendo assim, é possível, por exemplo, fazer a distinção de amostras com diferença de dureza da ordem de 0,7 com o modelo PLS a partir das imagens digitais, e da ordem de 0,5 com os modelos PLS a partir das imagens térmicas e da espectroscopia NIR.

O limite de detecção representa a menor quantidade que pode ser detectada, mas não necessariamente quantificada. Por outro lado, o limite de quantificação apresenta a menor quantidade que pode ser medida com exatidão adequada (VALDERRAMA; BRAGA; POPPI, 2009). Dessa forma, o modelo proposto a partir das imagens digitais para o parâmetro dureza, por exemplo, consegue detectar esse parâmetro com valores de 2.4459 e é capaz de quantificar com exatidão amostras de farinhas com dureza superiores a 7.4117.

Para identificar as variáveis que contribuem com os modelos, a importância da variável na projeção (do inglês, *Variable Importance in Projection* - VIP) (WOLD et al., 1993; VITALE et al., 2013) foi considerada e os resultados são apresentados nas Figuras 3 a 5. VIP, também conhecido como *VIP scores*, é um índice que contabiliza a contribuição de variáveis experimentais individuais para o modelo bilinear, e é dimensionado de tal forma que índices com uma pontuação VIP superior a 1 são considerados significativos (BAQUETA et al., 2020).

Os resultados de *VIP scores* permitem verificar que a dureza, a gomosidade e a coesão apresentam semelhança nas variáveis importantes para modelar esses parâmetros. A dureza representa a força máxima determinada na primeira compressão (mordida). A coesão representa o grau em que a amostra poderia ser deformada antes da ruptura, ou tendência à estrutura manter-se unida. Já a força necessária para desintegrar a massa do alimento semi-sólido durante a mastigação até que atinja o ponto de engolir representa a gomosidade. Dessa forma é coerente que as variáveis importantes na modelagem desses três parâmetros sejam similares. (TEXTURE TECHNOLOGIES, 2022).

A adesividade é o trabalho requerido para remover o material que adere a boca (ou do probe) durante o processo normal de comer. A elasticidade é a capacidade da amostra para recuperar seu formato original depois de sofrer uma força de deformação (TEXTURE TECHNOLOGIES, 2022). Esses parâmetros mostraram

similaridade nas variáveis importantes (VIP scores) na modelagem e, de fato, tem relação entre si.

A mastigabilidade e a resiliência apresentam variáveis semelhantes na modelagem de ambos os parâmetros. A mastigabilidade é o trabalho requerido para mastigar o alimento sólido, enquanto a resiliência é o quanto, em termos de energia, o produto “luta” para recuperar sua forma original. (TEXTURE TECHNOLOGIES, 2022).

5 CONCLUSÃO

Os resultados obtidos mostraram a possibilidade de utilização de imagens digitais e térmicas, bem como da espectroscopia NIR aliada à calibração multivariada por PLS na determinação de parâmetros de textura em amostras de diferentes farinhas. Os modelos são considerados como multiproduto por incluírem diferentes tipos de amostras em um mesmo modelo de calibração multivariada.

O método proposto é uma alternativa ao método convencional por texturômetro para determinação dos parâmetros de textura em farinhas, destacando-se as vantagens de apresentar menor custo, maior rapidez nas determinações, não necessitando de preparo de amostra.

REFERÊNCIAS

- ALKARKHI, A.F. et al. Comparing physicochemical properties of banana pulp and peel flour prepared from green and ripe fruits. **Food Chemistry**, v.129, p. 312-318, 2011.
- ALMEIDA, N.M.F. **Espectroscopia de Infravermelho Próximo com Transformada de Fourier (FT-NIR) na Caracterização de Farinhas para Alimentação Pueril**. 2009. Dissertação (Mestrado em Engenharia Biológica) – Universidade Técnica de Lisboa, Lisboa, 2009.
- ASMAR, S. A. et al. Changes in leaf anatomy and photosynthesis of micropropagated banana plantlets under silicon sources. **Scientia Horticulturae**, v. 161, p. 328-332, 2013.
- BAQUETA, M.R., COQUEIRO, A., MARÇO, P.H., VALDERRAMA, P. Quality control parameters in the roasted coffee industry: A proposal by using MicroNIR spectroscopy and multivariate calibration. **Food Analytical Methods**, v.13, p. 50–60, 2020.
- BASSETTI, B.D. **Desenvolvimento de método alternativo para quantificação de clorofilas em indústria de óleo de soja utilizando imagens digitais**. 2019. Dissertação (Mestrado em Inovações Tecnológicas) - Universidade Tecnológica Federal do Paraná, Campo Mourão, 2019.
- BELTRAME, K., GONÇALVES, T., MARÇO, P., GOMES, S., MATSUSHITA, M. E VALDERRAMA, P. Aplicação de imagens digitais e calibração multivariada para quantificação de antocianina e atividade antioxidante no suco de uva. **Australian Journal of Grape and Wine Research**, v. 25, p.156-160, 2019.
- BERTOLINI, A.C. et al. Rheological and functional properties of flours from banana pulp and peel. **Starch/Starke**, v. 62, p. 277-284, 2010.
- BIESIEKIERSKI, Jessica R. What is gluten? **Journal of Gastroenterology and Hepatology**, v. 32, p. 78–81, 2017.
- BRAGA, A. et al., Investigação da atividade antihiperlicemiante da farinha da casca de *Passiflora edulis* Sims, Passifloraceae, em ratos diabéticos induzido por aloxano. **Revista Brasileira de Farmacognosia**. v. 20, n. 2, p. 186-191, 2010.
- BRASIL. MINISTÉRIO DA SAÚDE. AGÊNCIA NACIONAL DE VIGILÂNCIA SANITÁRIA. Comissão Nacional de Normas e Padrões para Alimentos. **Resolução nº 263**, de 2005. Normas Técnicas Especiais. Diário Oficial da União, Brasília, DF, 22 de setembro de 2005. Disponível em: https://bvsms.saude.gov.br/bvs/saudelegis/anvisa/2005/rdc0263_22_09_2005.html. Acesso em: 11 de mai. de 2022.

- BRÁS, P.B., BERNARDINO S.A., LOPES, J.A., MENEZES, J.C. Multiblock PLS as an approach to compare and combine NIR and MIR spectra in calibrations of soybean flour. **Chemometrics and Intelligent Laboratory Systems**, v. 75, p. 91-99, 2005.
- CAPITÁN-VALLVEY, L. F.; LÓPEZ-RUIZ, N.; MATÍNEZ-OLMOS, A; ERENAS, M; PALMA, A. Recent developments in computer vision-based analytical chemistry: A tutorial review. **Analytica Chimica Acta**, v. 899, p. 23-56, 2015.
- CÉSAR, A. S.; GOMES, J. C.; STALIANO, C. D.; FANNI, M. L.; BORGES, M. C. Elaboração de pão sem glúten. **Revista Ceres, Viçosa**, v. 53, n. 306, p. 150-155, 2006.
- CHEN, L.; OPARA, U. L. Approaches to analysis and modeling texture in fresh and processed foods – A review. **Journal of Food Engineering**, v. 119, p. 497-507, 2013.
- CHEN, J.; ZHU, S.; ZHAO, G. Rapid determination of total protein and wet gluten in commercial wheat flour using siSVR-NIR. **Food Chemistry**, v. 221, p.1939-1943, 2017.
- CHOO, C.L.; AZIZ, N.A.A. Effects of banana flour and β -glucan on the nutritional and sensory evaluation of noodles. **Food Chemistry**, v.119, p. 34-40, 2010.
- COCCHI, M.; CORBELLINI, M.; FOCA, G.; LUCISANO, M.; PAGANI, A.; TASSI, L.; ULRICI, A. Classification of bread wheat flours in different quality categories by a wavelet-based feature selection/classification algorithm on NIR spectra. **Analytica Chimica Acta**, v. 544, p.100–107, 2005.
- CORDEIRO, L., D. **Calibração multivariada e imagens digitais no controle de qualidade de farinha de trigo**. 2020. Dissertação (Mestrado em Inovações Tecnológicas) - Universidade Tecnológica Federal do Paraná, Campo Mourão, 2020.
- CORDEIRO, L. D.; VALDERRAMA, P. Digital images and multivariate calibration in the determination of rheological and quality parameters of wheat flour. **Brazilian Journal of Analytical Chemistry**, v. 8, n. 32, p. 62-77, 2021.
- COSTA, G. M.; SOUZA, L. E.; STAMFORD, M. L. T., ANDRADE, C.A. Technological quality of national and imported wheat grain and wheat flours. **Ciência e Tecnologia de Alimentos**, v. 39, n. 7, p. 452-461, 2007.
- FERREIRA, D. S.; PALLONE, J. A. L.; POPPI, R. J. Fourier transform near-infrared spectroscopy (FT-NIRS) application to estimate Brazilian soybean [Glycine max (L.) Merrill] composition. **Food Research International**, v. 51, n. 1, p. 53-58, 2013.
- GONÇALVES, T.R.; ROSA, L. N.; MARÇO, P.H.; SILVA, L.F.O.; GOMES, S.T.M., MAKOTO, M.; VALDERRAMA, P. Evaluation of brazilian monovarietal extra virgin olive oils using digital images and independent component analysis. **Journal of the Brazilian Chemical Society**, v. 31, n. 9, p. 1955-1963, 2020.

GRAÇA, C. S.; BARBOSA, J. B.; SOUZA, M. Z.; MOREIRA, A. S.; LUVIELMO, M. M.; MELLADO, M. L. M. S. Addition of collagen to gluten-free bread made from rice flour. **Brazilian Journal of Food Technology**, v. 20, p. 1-10, 2017.

GREEN, P.H.R et al. Risk of malignancy in patients with celiac disease. **American Journal of Medicine**, v. 115, p. 191-195, 2003.

GRUDPAN, K.; KOLEV, S.; LAPANANTNOPAKHUN, S.; McKELVIE, I.; WONGWILAI, W. Applications of everyday IT and communications devices in modern analytical chemistry: A review. **Talanta**, v. 136, p. 84-94, 2015.

HARTMANN, G.; TEIXEIRA, F.; SOARES, J. M.; SILVA, K. A.; SCHWARZ, K.; SCHIESSEL, D. L.; NOVELLO, D. Effect of fat replacement by fructooligosaccharide in hamburger: physicochemical, technological and sensorial analysis. **International Journal for Innovation Education and Research**, v. 8, n. 3, p. 15-25, 2020.

HASLINDA, W.H. et al. Chemical composition and physicochemical properties of green banana (*Musa acuminata* x *Balbisianacolla* cv. 'Awak') flour. **International Journal of Food Sciences and Nutrition**, v. 60, n. 4, p. 232-239, 2009.

HELPER, G.; MAGNUS, V. S.; BÖCK, F.; TEICHMANN, A.; FERRÃO, M.; COSTA, A. PhotoMetrix: An application for univariate calibration and principal components analysis using colorimetry on mobile devices. **Journal of the Brazilian Chemical Society**, v. 28, p. 328-335, 2017.

ISAKSSON, T.; NAES, T. Effect of multiplicative scatter correction (MSC) and linearity improvement in NIR spectroscopy. **Applied Spectroscopy**, v. 42, n. 7, p. 1273-1284, 1988.

JUSTO, M.B.; ALFARO, A.D.C.; AGUILAR, E.C.; WROBEL, K.; WROBEL, K.; GUZMÁN, G.A.; SIERRA, Z.G.; ZANELLA, V.M. Desarrollo de pan integral con soya, chía, linaza y ácido fólico como alimento funcional para la mujer. **Archivos Latinoamericanos de Nutrición**, v. 57, n.1, p. 78-84, 2007.

KENNARD, R. W.; STONE, L. A. Computer aided design of experiments. **Technometrics**, v.11, n. 1, p.137-148, 1969.

KIM, J. M.; SHIN.M. Effects of particle size distributions of rice flour on the quality of glutenfree rice cupcakes **LWT - Food Science and Technology**, v. 59, n. 1, p. 526-532, 2014.

KOIRALA, U. Health and nutritional aspect of underutilized high-value food grain of high hills and mountains of Nepal. In: **Nutritional and Health Aspects of Food in South Asian Countries**. Elsevier, p. 195-209, 2020.

LACERDA, D. B. C. L.; SOARES, J. M. S.; BASSINELLO, P. Z.; SIQUEIRA, B. S.; KOAKUZU, S. N. Quality of biscuits made with extruded rice bran in substitution of wheat flour and cassava starch. **Archivos Latinoamericanos de Nutricion - Organo Oficial de la Sociedad Latinoamericana de Nutrición**, v. 59, n. 2, p. 199-205, 2009.

LAWLESS, H. T.; HEYMANN, H. **Sensory evaluation of food – principles and practices**. USA: Springer, 2010. 596 p.

LEBOT, V. et al. NIR determination of major constituents in tropical root and tuber crop flours. **Journal Agricultural and Food Chemistry**, n.57, v.22, p.10539-10547, 2009.

LEMOS, A. R.; CAPRILES, V. D.; PINTO E SILVA, M. E. M.; ARÊAS, J. A. G. Effect of incorporation of amaranth on the physical properties and nutritional value of cheese bread. **Ciência e Tecnologia de Alimentos**, v. 32, n. 3, p. 427-431, 2012.

LEONEL, M. et al. Extração e caracterização do amido de diferentes genótipos de bananeira. **Revista Brasileira de Fruticultura**, v.33, p.599-605, 2011.

MARTINEZ, C. S.; RIBOTTA, P. D.; AÑÓN, M. C.; LEÓN, A. E. Effect of amaranth flour (*Amaranthus mantegazzianus*) on the technological and sensory quality of bread wheat pasta. **Food Science & Technology International**, v. 20, n. 2, p. 127-135, 2014.

MEDEIROS, J.S. et al. Ensaio toxicológicos clínicos da casca do maracujá-amarelo (*Passiflora edulis*, f.flavicarpa), como alimento com propriedade de saúde. **Brazilian Journal of Pharmacognosy**. v.19, n.2, p. 394-399, 2009.

OLIVEIRA, I. M.; MELO, F. S. N.; SOUSA, M. M.; MENEZES, M. S.; PAZ, E. O.; CAVALCANTI, M. S. Use of alternative flours in bakery products: a literary review. **Research, Society and Development**, v. 9, n. 9, e441996228, 2020.

PINELLI, L.C.D.F. **Análise de dados multi-tabelas (Comdim) para a avaliação de farinhas comestíveis por espectroscopia NIR e texturômetro**. 2018. Dissertação (Mestrado em Inovações Tecnológicas) - Universidade Tecnológica Federal do Paraná, Campo Mourão, 2018.

PIRZADAH, T. B. et al. Metabolite profiling of tartary buckwheat-an underutilized nutraceutical crop of Kashmir Himalaya. **Journal of Phytology**, v. 8, p. 49, 2017.

QUEIROZ, A. M. et al. Elaboração e caracterização de cookies sem glúten enriquecidos com farinha de coco: uma alternativa para celíacos. **Brazilian Journal of Food Technology**, v. 20, 2017.

RAHIMI, J.; BAUR, J.; SINGH, A. Digital imaging as a tool to study the structure of porous baked foods, **Journal of Cereal Science**, V.95, 2020.

SANTOS, D. A.; LIMA, K. P.; MARÇO, P. H. Espectroscopia UV e calibração multivariada multiproduto na determinação da acidez total em néctar de frutas. **Revista Brasileira de Pesquisa de Alimentos**, v. 6, n. 1, p. 1-8, 2015.

SANTOS, D. A. D. et al. Vitamin C determination by ultraviolet spectroscopy and multiproduct calibration. **Journal of the Brazilian Chemical Society**, v. 27, n. 10, p. 1912-1917, 2016.

SANTOS, D. A.; LIMA, K. P.; CAVALCANTE, V.; COQUEIRO, A.; CONSOLIN, M. F. B.; CONSOLIN FILHO, N.; MARÇO, P. H.; VALDERRAMA, P. Multiproduct, multicomponent and multivariate calibration: A case study by using Vis-NIR spectroscopy. **Food Analytical Methods**, v. 11, p. 1915-1919, 2018.

SANTOS, D. A.; LIMA, K. P.; CAVALCANTE, V.; COQUEIRO, A.; CONSOLIN, M. F. B.; CONSOLIN FILHO, N.; MARÇO, P. H.; VALDERRAMA, P. Multi-product multivariate calibration: determination of quality parameters in soybean industrialized juices. **Acta Scientiarum Technology**, v. 41, e37382, 2019.

SANTOS, D. A.; COQUEIRO, A.; GONÇALVES, T.; CARVALHO, J.; BEZERRA JUNIOR, J.; MATSUSHITA, M.; OLIVEIRA, C. A. L.; MARÇO, P. H.; VALDERRAMA, P.; RIBEIRO, R. Omega-3 and ômega-6 determination in Nile tilapia's fillet based on MicroNIR spectroscopy and multivariate calibration. **Journal of the Brazilian Chemical Society**, v. 31, n. 9, p. 1883-1890, 2020.

SARAWONG, C. et al. Effect of extrusion cooking on the physicochemical properties, resistant starch, phenolic content and antioxidant capacities of green banana flour. **Food Chemistry**, v.143, p.33-39, 2014.

ŠKRBIĆ, B.; MILOVAC, S.; CODIG, D.; FILIPČEV, B. Effects of hull-less barley flour and flakes on bread nutritional composition and sensory properties. **Food Chemistry**, v.115, n.3, p.982-988, 2009.

SOUZA, M.M. et al., Cytogenetic studies in some species of Passiflora L. (Passifloraceae): a review emphasizing Brazilian species. **Brazilian Archives of Biology and Technology**, v.51, n.2, p. 247-258, 2008.

SZCZESNIAK, A.S. Texture is a sensory property. **Food Quality and Preference**, v. 13, p. 215- 225, 2002.

TANUMIHARDJO, S. A. et al. Vegetables of temperate climates: Carrot, parsnip, and beetroot. In: **Encyclopedia of Food and Health**. Elsevier, p. 387–392, 2016.

TEXTURE TECHNOLOGIES. **Texture technologies: Overview of texture profile analysis (TPA)**, c2022. Página inicial. Disponível em: <https://texturetechnologies.com/resources/texture-profile-analysis>. Acesso em: 11 de mai. de 2022.

TORMENA, L.M.M., **Desenvolvimento de formulação para bolo contendo farinha de maca e Yacon**. 2016. Dissertação (Mestrado em Tecnologia de alimentos) - Universidade Tecnológica Federal do Paraná, Campo Mourão, 2016.

TRIBESS, T.B. et al. Thermal proprieties and resistant starch content of green banana flour (*Musa cavendishii*) produced at different drying conditions. **LWT- Food Science and Technology**, v.42, p.1022-1025, 2009.

TRINIDAD, T. P.; MALLILLIN, A. C.; VALDEZ, D. H.; LOYOLA, A. S.; MERCADO, F. C. A.; CASTILHO, J. C.; ENCABO, R. R.; MASA, D. B.; MAGLAYA, A. S.; CHUA, M.

T. Dietary fiber from coconut flour: a functional food. **Innovative Food Science and Emerging Technologies**, v. 7, n. 4, p. 309-317, 2004.

TYE-DIN, Jason A.; GALIPEAU, Heather J.; AGARDH, Daniel. Celiac disease: A review of current concepts in pathogenesis, prevention, and novel therapies. **Frontiers in Pediatrics**, v. 6, n. 11, p. 1–19, 2018.

VALDERRAMA, P.; BRAGA, J. W. B.; POPPI, R. J. Validation of multivariate calibration models in the determination of sugar cane quality parameters by near infrared spectroscopy. **Journal of the Brazilian Chemical Society**, v. 18, n. 2, p. 259-266, 2007.

VALDERRAMA, P.; BRAGA, J.W.B.; POPPI, R.J. Estado da Arte de figuras de mérito em calibração multivariada. **Química Nova**, v. 32, n. 5, p. 1278-1287, 2009.

VERNAZA, G.V. et al. Addition of green banana flour to instant noodles: Rheological and technological properties. **Ciências e Agrotecnologia**, v.35, n.6, p.1157-1165, 2011.

VITALE, R.; BEVILACQUA, M.; BUCCI, R.; MAGRI, A.D.; MAGRI, A.L.; MARINI, F. A rapid and non-invasive method for authenticating the origin of pistachio samples by NIR spectroscopy and chemometrics. **Chemometrics and Intelligent Laboratory System**, v.121, p.90–99, 2013.

WALLACE, Taylor C. et al. Fruits, vegetables, and health: A comprehensive narrative, umbrella review of the science and recommendations for enhanced public policy to improve intake. **Critical Reviews in Food Science and Nutrition**, v. 60, n. 13, p. 2174–2211, 2020.

WANG, Y. et al. Influence of green banana flour substitution for cassava starch on the nutrition color, texture and sensory quality in two types of snacks. **LWT-Food Science and Technology**, v.47, p.175-182, 2012.

WANG, Y.; UPADHYAYA, H. D.; DWEIKAT, I. Sorghum. In: **Genetic and Genomic Resources for Grain Cereals Improvement**. Elsevier, p. 227–251, 2016.

WOLD, S.; JOHANSSON, E.; COCCHI, M.; 3D QSAR in Drug design: theory, methods and applications. **ESCOM, Leiden, Holland** p. 523–550, 1993.