

LAIS FERNANDA BATISTA

**MODELAGEM E PREDIÇÃO DAS PROPRIEDADES REOLÓGICAS E DO PERFIL
DE TEXTURA DE IOGURTE SEM GORDURA**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Ciência e Tecnologia de Alimentos, para obtenção do título de *Magister Scientiae*.

Orientadora: Márcia Cristina T.R. Vidigal

Coorientadores: Ana Clarissa dos Santos Pires
Luiz Antônio Minim

**VIÇOSA - MINAS GERAIS
2020**

RESUMO

BATISTA, Laís Fernanda, M.Sc., Universidade Federal de Viçosa, fevereiro de 2020.
Modelagem e predição das propriedades reológicas e do perfil de textura de iogurte sem gordura. Orientadora: Márcia Cristina Teixeira Ribeiro Vidigal.
Coorientadores: Ana Clarissa dos Santos Pires e Luis Antônio Minim.

O iogurte é um dos leites fermentados mais consumidos, podendo ser obtidos a partir de diferentes formas de processamento e tipos de ingredientes, o que torna difícil estabelecer a padronização da textura. Produtos mais consistentes e sem de gordura são um desafio para o setor, visto que esses apresentam uma textura mais frágil. Nesse sentido, a adição da enzima transglutaminase e de proteína e modificações no processo de fabricação podem ser utilizadas como alternativas para melhorar a textura desses produtos. No entanto, o estudo instrumental de textura por perfil de textura (TPA) ou reologia é uma limitação para a indústria de alimentos devido ao alto custo dos equipamentos. Assim, a aplicação de modelagem por redes neurais artificiais (RNA's) pode ser uma ferramenta utilizada na construção de modelos de predição dessas medidas. Este trabalho teve como objetivo modelar e otimizar a textura do iogurte sem gordura a partir de alterações na composição do produto e no processo, sendo dividido em duas partes. Na primeira parte, o efeito dos fatores proteína caseína (Cas), enzima transglutaminase (TgE) e velocidade de rotação no processo de centrifugação (CRS) no perfil de textura (firmeza, coesão, goma e adesividade) e nas medidas reológicas (rotacional e oscilatório) foi avaliada. Por fim, a função desejabilidade foi aplicada para obter a melhor combinação entre os fatores estudados que proporcionaria um produto com uma textura adequada. A concentração final de proteína do iogurte e o volume de soro retirado no processo de centrifugação se correlacionaram positivamente com firmeza, índice de consistência, viscosidade aparente e tixotropia ($p < 0,05$). A condição otimizada capaz de atender a todas as restrições aplicadas é obtida quando são utilizados 3,4% CAS, 1U TgE e 5500 rpm (CRS). Na segunda parte, as propriedades de textura instrumentais foram modeladas por RNA's e três modelos foram desenvolvidos. A melhor configuração encontrada para a predição das propriedades de textura obtidas no TPA (modelo 1), tixotropia (modelo 2) e viscosidade aparente (modelo 3) foram, respectivamente, 3-10-4, 4-5-1 e 4-45-1, em que a sequência apresentada representa o número de entradas, o número de neurônios na camada oculta e as saídas de cada modelo,

respectivamente. As RNA's foram capazes de prever tanto o TPA quanto as medidas reológicas com boa precisão e com desempenho superior aos modelos de regressão obtidos na primeira parte do trabalho. Portanto, o uso de ferramentas estatísticas pode auxiliar a indústria na definição de uma combinação adequada dos fatores em estudo para a obtenção de um produto final com características de textura desejáveis, e também na obtenção de modelos de previsão das propriedades de textura.

Palavras-chave: Modelagem. Iogurte. Transglutaminases. Reologia.

ABSTRACT

BATISTA, Laís Fernanda, M.Sc., Universidade Federal de Viçosa, February, 2020. **Modeling and prediction of rheological properties and texture profile of yogurt added nonfat.** Advisor: Márcia Cristina Teixeira Ribeiro Vidigal. Co-advisors: Ana Clarissa dos Santos Pires and Luis Antônio Minim.

Yogurt is one of the most consumed fermented milks and can be obtained from different forms of processing and types of ingredients, which makes it difficult to establish the standardization of texture. More consistent and fat-free products are a challenge for the sector, as they have a more fragile texture. In this sense, the addition of the transglutaminase enzyme and protein and modifications in the manufacturing process can be used as alternatives to improve the texture of these products. However, the instrumental study of texture by texture profile (TPA) or rheology is a limitation for the food industry due to the high cost of equipment. Thus, the application of modeling by artificial neural networks (ANNs) can be a tool used in the construction of prediction models for these measures. This work aimed to model and optimize the texture of fat-free yogurt from changes in the composition of the product and in the process, being divided into two parts. In the first part, the effect of the factors casein protein (Cas), transglutaminase enzyme (TgE) and speed of rotation in the centrifugation process (CRS) on the texture profile (firmness, cohesion, gum and adhesiveness) and on the rheological measures (rotational and oscillatory) was evaluated. Finally, the desirability function was applied to obtain the best combination of the studied factors that would provide a product with adequate texture. The final protein concentration of yogurt and the volume of serum removed in the centrifugation process was positively correlated with firmness, consistency index, apparent viscosity, and thixotropy ($p < 0.05$). The optimized condition capable of meeting all applied restrictions is obtained when 3.4% CAS, 1U TgE and 5500 rpm (CRS) are used. In the second part, the instrumental texture properties were modeled by RNA's and three models were developed. The best configuration found for the prediction of the texture properties obtained in TPA (model 1), thixotropy (model 2) and apparent viscosity (model 3) were, respectively, 3-10-4, 4-5-1 and 4-45-1, where the presented sequence represents the number of inputs, the number of neurons in the hidden layer and the outputs of each model, respectively. The ANN's were able to predict both TPA and rheological measurements with good precision and with superior performance to the regression models obtained

in the first part of the work. Therefore, the use of statistical tools can assist the industry in defining an appropriate combination of the factors under study to obtain a final product with desirable texture characteristics, and also in obtaining predictive models of texture properties.

Figure 3. Response surface of rheological properties: (a) firmness, (b) cohesiveness, (c) adhesiveness, and (d) gumminess in relation to the factors Cas, TgE and CRS. 25

Keywords: Modeling. Yogurt. Transglutaminases. Rheology. 27

Figure 3. Response surface of rheological properties: (a) Apparent viscosity and (b) Thixotropy in relation to the factors Cas, TgE and CRS. 29

Figure 4. Response surface of the Tan δ property in relation to the Cas, TgE and CRS factors. 31

Figure 5. Desirability response surfaces as a function of Cas, TgE and CRS, for optimization of the Thixotropic, apparent viscosity, Tan δ , firmness, adhesiveness, cohesiveness and gumminess variables. 33

Artigo 2.

Figura 1. Ilustração do processo de validação k-fold. Fonte: <http://sehn8181.github.io>. 43

Figura 2. a) Configuração de RNA escolhida; b) gráfico de barras mostrando a importância relativa percentual de cada variável de entrada (proteína, enzima e rotação) sobre o perfil de textura (TPA). 46

Figura 3. a) Configuração de RNA escolhida para o modelo 2; b) gráfico de barras mostrando a importância relativa percentual de cada variável de entrada (proteína, enzima, rotação e taxa de deformação) sobre a thixotropia. 47

Figura 4. a) Configuração de RNA escolhida para o modelo 3; b) gráfico de barras mostrando a importância relativa percentual de cada variável de entrada (proteína, enzima, rotação e taxa de deformação) viscosidade aparente. 49

Figure 5. Relação entre os valores preditos e os valores experimentais para o modelo 1 nas fases de a) treinamento (coluna da direita) e b) validação (coluna da esquerda) respectivamente (Modelo 1). 50

Figure 6. Relação entre os valores preditos e os valores experimentais para os modelos 2 e 3 nas fases de a) treinamento (coluna da esquerda) e b) validação (coluna da direita) respectivamente (Modelo 2 e modelo 3). 51