

Uso de redes neurais artificiais para modelagem das propriedades de bolo sem glúten elaborado com farinha de arroz e farinha do resíduo agroindustrial de acerola

Use of artificial neural networks for modeling the properties of gluten-free cake made with rice flour and acerola agroindustrial waste flour

DOI:10.34117/bjdv9n3-123

Recebimento dos originais: 17/02/2023

Aceitação para publicação: 14/03/2023

Esther Emily Silva Freitas

Mestra em Ciências Farmacêuticas

Instituição: Universidade Estadual de Feira de Santana (UEFS)

Endereço: Av. Transnordestina, S/N, Feira de Santana – BA, CEP: 44036-900

E-mail: esther.silfre@hotmail.com

Laís Maciel Rodrigues

Mestra em Ciências Farmacêuticas

Instituição: Universidade Estadual de Feira de Santana (UEFS)

Endereço: Av. Transnordestina, S/N, Feira de Santana – BA, CEP: 44036-900

E-mail: sialmaciel@gmail.com

Célia Regina Bastos

Mestra em Ciências Farmacêuticas

Instituição: Universidade Estadual de Feira de Santana (UEFS)

Endereço: Av. Transnordestina, S/N, Feira de Santana – BA, CEP: 44036-900

E-mail: celinhabsts@gmail.com

Marcia Cristina Teixeira Ribeiro Vidigal

Doutora em Ciência e Tecnologia de Alimentos

Instituição: Universidade Federal de Viçosa (UFV)

Endereço: Av. Peter Henry Rolfs, S/N, Campus Universitário, CEP: 36570-000,
Viçosa - MG

E-mail: marciavidigal@ufv.br

Marília Lordêlo Cardoso Silva

Doutora em Biotecnologia

Instituição: Universidade Estadual de Feira de Santana (UEFS)

Endereço: Av. Transnordestina, S/N, Feira de Santana – BA, CEP: 44036-900

E-mail: mlcsilva@uefs.br

Renato Souza Cruz

Doutor em Ciência e Tecnologia de Alimentos

Instituição: Universidade Estadual de Feira de Santana (UEFS)

Endereço: Av. Transnordestina, S/N, Feira de Santana – BA, CEP: 44036-900

E-mail: cruz.rs@uefs.br

Geany Peruch Camilloto

Doutora em Ciência e Tecnologia de Alimentos

Instituição: Universidade Estadual de Feira de Santana (UEFS)

Endereço: Av. Transnordestina, S/N, Feira de Santana – BA, CEP: 44036-900

E-mail: geanyperuch@yahoo.com.br

RESUMO

O objetivo do trabalho foi modelar e prever as propriedades tecnológicas de bolo sem glúten a partir da mistura da farinha de arroz (FA) e da farinha do resíduo agroindustrial de acerola (FRAA) por meio da aplicação de redes neurais artificiais (RNAs). Quatro modelos de redes *perceptron* de múltiplas camadas com arquitetura *feedforward* foram obtidas utilizando o método de validação *k-fold*. Os modelos 1, 2, 3 e 4 para predição do volume, perfil de textura, cor da crosta e cor do miolo apresentaram melhores topologias contendo 10, 9, 9 e 15 neurônios na camada oculta, respectivamente. A escolha da melhor topologia foi feita com base no coeficiente de determinação (R^2) e nos menores valores de erro (RMSE). As RNAs obtidas demonstram ser capazes de prever com boa precisão as propriedades de bolo sem glúten adicionados de FRAA.

Palavras-chave: panificação, propriedades tecnológicas, textura.

ABSTRACT

The objective of this work was to model and predict the technological properties of gluten-free cake from the mixture of rice flour (RF) and acerola agro-industrial residue flour (AARF) through the application of artificial neural networks (ANNs). Four models of multilayer *perceptron* networks with *feedforward* architecture were obtained using the *k-fold* validation method. Models 1, 2, 3 and 4 for volume prediction, texture profile, crust color and crumb color showed better topologies containing 10, 9, 9 and 15 neurons in the hidden layer, respectively. The choice of the best topology was made based on the coefficient of determination (R^2) and the smallest error values (RMSE). The RNAs obtained demonstrate to be able to predict with good accuracy the properties of gluten-free cakes added with AARF.

Keywords: bakery, technological properties, texture.

1 INTRODUÇÃO

A procura por produtos de panificação sem glúten tem se intensificado, não apenas por indivíduos celíacos ou sensíveis ao glúten, como também por uma parcela da população que opta por introduzi-los na sua alimentação. Entre esses produtos, o bolo apresenta boa aceitação pelo mercado consumidor devido às suas características reológicas: produtos leves e facilmente mastigáveis, apresentando textura porosa que facilita a digestão e são normalmente muito saborosos (MOSCATTO et al., 2004). O bolo se destaca no que se refere ao consumo e comercialização no Brasil, principalmente devido às tecnologias que foram desenvolvidas ao longo dos anos, trazendo grandes

mudanças no setor de panificação e confeitaria que passaram para grande escala. Contudo, o principal ingrediente, responsável pela qualidade tecnológica e sensorial dos bolos tradicionais, é o glúten, uma proteína que proporciona coesão, manutenção do volume e textura de miolo desejável e a sua substituição é um dos desafios para a tecnologia de alimentos (SALEHI, 2019).

Diante disso, a farinha de arroz, por ser isenta de glúten, conter altos teores de carboidratos digeríveis e garantir boas características tecnológicas aos produtos, torna-se uma alternativa adequada para substituição da farinha de trigo. No entanto, apresenta baixas quantidades de gordura, sódio e fibra, que podem ser elevadas com a utilização de farinhas sucedâneas (SIVARAMAKRISHNAN et al., 2004; DEMIRKESEN et al., 2010).

A elaboração e aplicação de farinhas obtidas de fontes não convencionais, principalmente as resultantes do processamento de frutas e vegetais, com alto valor nutricional, pode contribuir com a diversificação dos produtos de panificação. Estes resíduos compreendem geralmente caules, casca, sementes, bagaços e possuem moléculas bioativas com potencial aplicação (BRITO et al., 2019). Essas farinhas são matérias-primas ricas em fibras que podem ser incluídos na dieta humana, e são consideradas uma alternativa viável de reaproveitamento, sendo utilizada como ingrediente alimentar na preparação de bolos, biscoitos, barras de cereais e pão (MARQUES et al., 2014; MONTEIRO et al., 2020).

A indústria brasileira de processamento de frutas ocupa posição de liderança global no setor de alimentos, tornando-se um país de cadeia produtiva bem estruturada (BELWAL et al., 2018), colocando o Brasil na posição de maior produtor de acerola do mundo, totalizando 60.966 toneladas/ano, com destaque para o Nordeste, que detém aproximadamente 75% da produção do país (IBGE, 2017). Segundo Borges et al. (2021), quase toda a produção de acerola é processada industrialmente, gerando uma grande quantidade de subprodutos, resultante da prensagem (bagaço) e decantação (sem bagaço). Baseado nesse contexto, grande quantidade de resíduos é gerada após o beneficiamento da fruta e pode corresponder a até 40% do volume total extraído (BORTOLOTTI et al., 2013; SILVA et al., 2022). O quantitativo desses resíduos gerados em seu processamento é significativo e passível de obtenção da sua farinha, pois pode ser caracterizado como uma fonte alternativa de nutrientes como fibra alimentar, vitaminas C e E, carotenóides e compostos fenólicos (INFANTE et al., 2013).

Contudo, o uso de farinhas não-tradicionais, como as obtidas desses resíduos agroindustriais, é desafiador, uma vez que podem alterar as propriedades tecnológicas dos

produtos de panificação. A modelagem por meio da aplicação de Redes Neurais Artificiais (RNAs) auxiliam na otimização do uso dessas farinhas, pois permite a predição de propriedades destes produtos.

As RNAs são capazes de aprender por meio de exemplos e de generalizar a informação aprendida, gerando um modelo não-linear, refinando as relações complexas entre as variáveis de entrada e de saída, tornando sua aplicação bastante eficiente. As RNAs se baseiam no processamento de elementos (denominados de nós, nodos ou neurônios) interligados formando uma rede e ativados por funções.

As RNAs são aplicadas para resolver os problemas mais complexos na ciência e na engenharia de alimentos, devido sua capacidade de calcular problemas não lineares complexos, ser tolerantes a falhas, adaptáveis, robustas, flexíveis, capazes de mapear, generalizar, processar informações em alta velocidade, imunes a ruídos e não ser necessário conhecer a relação matemática entre as entradas e saídas. Assim, ao contrário da regressão linear múltipla, por exemplo, não é preciso propor uma função para o modelo, uma vez que algumas redes neurais são consideradas aproximadores universais de funções. (BHAGYA RAJ; DASH, 2020; GONÇALVES NETO et al., 2021; PENNA, 2004; SPÖRL et al., 2011).

A estrutura mais comumente utilizada na aplicação das RNAs é o *perceptron* multicamadas (MLP), onde neurônios são ordenados em camadas, ligados por conexões (pesos) e fluem os sinais da camada de entrada para uma (ou mais) camada(s) intermediária(s) (ou oculta) que fluem para uma camada de saída. Para que a rede neural realize com eficiência a previsibilidade das propriedades das variáveis, é necessário que a rede passe por duas fases de extrema importância. A primeira, é a fase de treinamento, onde parte dos dados fornecidos à rede são usados para treiná-la. Os pesos das conexões se modificam e se ajustam para que a rede apresente o maior coeficiente de variação (R^2) e a menor raiz quadrática do erro-médio (RMSE). O algoritmo comumente usado para a supervisão dessa fase é o *backpropagation* (retropopagação) (DELLA LUCIA; MINIM, 2010; GONÇALVES NETO et al., 2021).

A próxima fase é a validação, onde novos dados apresentados à rede são comparados (entre resultados esperados e dos resultados obtidos). A rede generaliza a informação fornecida, ajusta e modifica os pesos das conexões para garantir maior

eficiência nessa fase (maior R^2 e menor RMSE). O algoritmo aplicado para a supervisão dessa fase é o k-fold (BATISTA et al., 2021).

As diferentes aplicações das RNAs na modelagem e otimização de vários métodos de processamento de alimentos incluem extração, extrusão, secagem, filtração, enlatamento, fermentação, panificação, processamento de laticínios e avaliação de qualidade. Também foi usada para prever propriedades físicas, químicas, funcionais e sensoriais de vários produtos alimentícios durante o armazenamento (BHAGYA RAJ; DASH, 2020).

Neste contexto, este trabalho teve como objetivo modelar e prever as propriedades tecnológicas de bolo sem glúten elaborado com farinha de arroz e farinha do resíduo de acerola por meio da aplicação de RNAs.

2 MATERIAL E MÉTODOS

A pesquisa foi desenvolvida nos laboratórios de embalagem e de panificação da Universidade Estadual de Feira de Santana (DETEC/UEFS). Os ingredientes utilizados na produção dos bolos como a farinha de arroz, o açúcar, os ovos, o óleo vegetal, o leite e o fermento foram adquiridos em comércio local na cidade de Feira de Santana, Bahia.

Obtenção da Farinha do Resíduo Agroindustrial de Acerola (FRAA) - O resíduo de acerola (semente e casca), doado pela BRASFRUT Frutos do Brasil Ltda, foi desidratado em estufa de circulação de ar à 50 °C por 20 h. Após secagem, foi triturado em um moinho de facas (TECNAL,TE-651), acoplado a uma peneira (20 mesh).

Elaboração do bolo sem glúten - Os bolos sem glúten foram desenvolvidos de acordo com a metodologia descrita por Kirbas, Kumcuoglu, Tavman (2019), com modificações. As formulações foram preparadas utilizando planejamento experimental de misturas, com três repetições, para avaliar o efeito da substituição parcial da farinha de arroz (FA) (100%, 97,5%, 95%, 92,5% e 90%) pela FRAA (0%, 2,5%, 5%, 7,5% e 10%).

Tabela 1 - Formulação do bolo sem glúten com adição de 0, 2,5, 5, 7,5, 10 (%) de farinha do resíduo agroindustrial da acerola

Ingredientes	Formulações (%)*				
	F_0	F_2,5	F_5	F_7,5	F_10
Farinha de arroz (FA)	100,0	97,5	95,0	92,5	90,0
FRAA	0,0	2,5	5,0	7,5	10,0
Açúcar	70,0	70,0	70,0	70,0	70,0
Ovo	55,0	55,0	55,0	55,0	55,0

Óleo vegetal	45,0	45,0	45,0	45,0	45,0
Leite	27,5		27,5	27,5	27,5
Fermento	2,5	2,5	2,5	2,5	2,5

*As porcentagem dos demais ingredientes foram calculados em relação ao somatório das farinhas (FA e FRAA)

Características de cor, volume e análise perfil de textura (TPA) dos bolos - A análise física de volume do bolo foi realizada de acordo com método 10-90 descrito pela AACCC (1995) com o auxílio de um analisador de volume - Volscan Profiler (VSP300). A cor instrumental da crosta e do miolo dos bolos foi determinada com três medidas em cada replicata usando o colorímetro Konica Minolta (CR-400) com sistema de leitura CIE-Lab. Na TPA foram avaliados os parâmetros de dureza (N), elasticidade, coesividade e resiliência das amostras de 20 mm de altura e 37 mm de diâmetro, conforme descrito por Renzetti e Van der Sman (2022) utilizando um Texturômetro TA.XT Plus (probe de compressão de 70 mm de diâmetro).

Modelagem do volume, cor e perfil de textura - Utilizou-se uma rede do tipo *perceptron* de múltiplas camadas com arquitetura *feedforward*, apresentando uma camada oculta. O treinamento foi supervisionado, utilizando o algoritmo *backpropagation*. Foram obtidos quatro modelos com duas variáveis de entrada (concentrações de FA e FRAA) e as variáveis de saída foram: a) modelo 1: volume; b) modelo 2: dureza, elasticidade, coesividade e resiliência; c) modelo 3: as coordenadas L^* e b^* da crosta (a coordenada a^* não foi utilizada neste modelo pois não demonstrou diferença significativa com a variação da concentração da FRAA); e d) modelo 4: as coordenadas L^* , a^* e b^* do miolo. O algoritmo de validação utilizado foi o *k-fold* e a função de ativação tangente hiperbólica foi aplicada. O banco de dados foi de 30 elementos para volume e TPA e 45 elementos para cor da crosta e do miolo. A seleção da rede ótima foi determinada pela técnica de tentativa e erro, e escolheu-se topologias que apresentassem menores valores de erro (RMSE) e maior coeficiente de determinação (R^2).

3 RESULTADOS E DISCUSSÃO

Foram desenvolvidos 4 modelos e seus coeficientes de variação (R^2) e RMSE foram avaliados. Para cada modelo, treze diferentes topologias foram testadas a fim de estabelecer uma relação entre as variáveis de entrada (concentração de farinha de arroz e farinha do resíduo agroindustrial da acerola) e as variáveis de saída (volume, perfil de textura e cor), o número de nodos na camada oculta foi encontrado por tentativa e erro. O coeficiente calculado por meio da Equação (1) foi utilizado para determinar a escolha da

melhor rede. Quanto maior o valor do coeficiente, melhor o modelo (BATISTA et al., 2021).

$$C = \frac{R_t^2 + R_v^2}{RMSE_t + RMSE_v}$$

Onde, C é coeficiente da relação entre os coeficientes de determinação e os valores de erro da rede neural; R_t^2 é coeficiente de correlação dos valores preditos na fase de treinamento; R_v^2 é coeficiente de correlação dos valores preditos na fase de validação; $RMSE_t$ é o erro da fase de treinamento; $RMSE_v$ é o erro da fase de validação.

A melhor rede nos modelos com duas ou mais variáveis de saída foi escolhida também pelo maior coeficiente (C), este obtido por meio da razão entre o R^2 geral fornecido pelo *software* pelo somatório dos erros dos parâmetros na fase de treinamento e validação, respectivamente.

A melhor arquitetura para o modelo 1, proposto para predição do volume, possui 10 neurônios na camada oculta, 5 folds, uma variável de saída (Figura 1), R^2 de 0,9342 e RMSE de 6,8717 para treinamento, R^2 de 0,9438 e RMSE de 5,7137 para validação, como pode ser observado na tabela 2. Na Figura 2 é demonstrada uma comparação gráfica entre os valores preditos dos valores experimentais (pontilhado) para predição do volume. É observado que nas duas fases (treinamento e validação) apesar do alto desvio-padrão entre os valores preditos dos experimentais, atribuído à sensibilidade da metodologia e do equipamento analisador de volume, a rede aplicada conseguiu generalizar a informação e minimizar o erro, predizendo uma modelagem para esse parâmetro com um alto coeficiente de variação.

Figura 1 - Estrutura obtida da melhor topologia para o volume

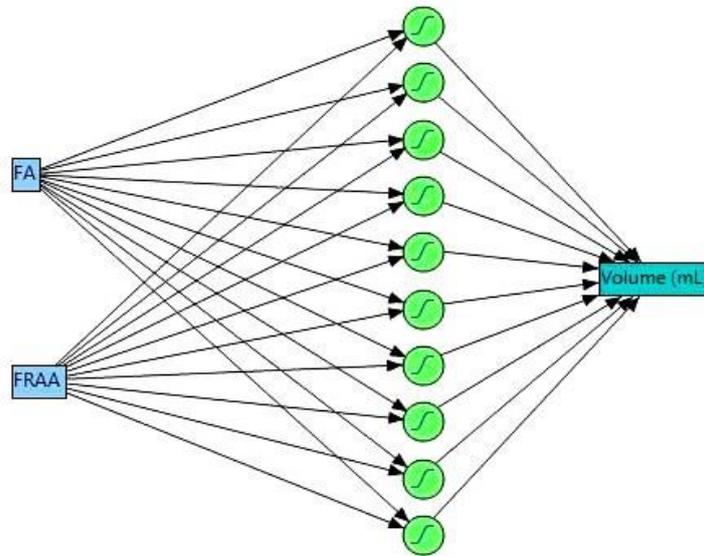
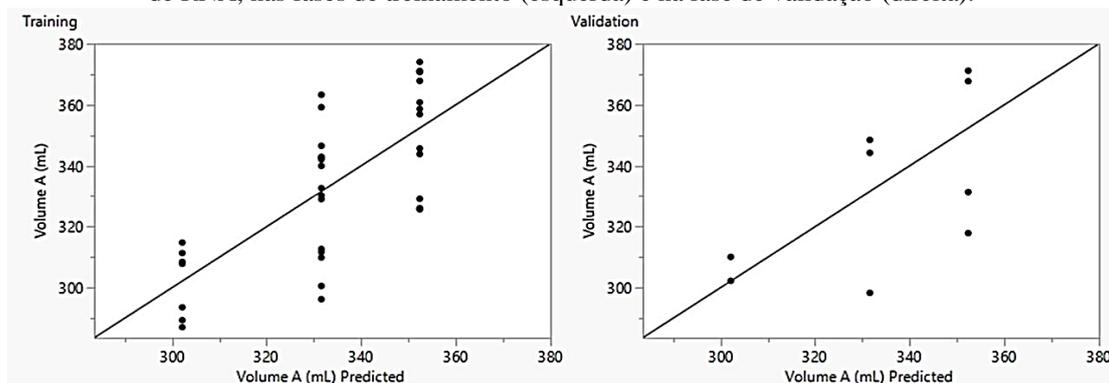


Tabela 2 – Resultados obtidos para modelagem do volume para o primeiro modelo

Volume					
Nº de nodos	Treinamento		Validação		
	R ²	RMSE	R ²	RMSE	Coefficiente
3	0,9393	6,5597	0,9222	7,0595	0,1367
5	0,9457	6,056	0,8999	8,7845	0,1244
8	0,9394	6,5511	0,9213	7,0994	0,1363
10	0,9342	6,8717	0,9438	5,7137	0,1492
12	0,9421	6,2586	0,9083	8,4111	0,1261
15	0,9451	6,0871	0,8989	8,8272	0,1236

Figura 2- Relação entre os valores preditos e os valores experimentais para volume dos bolos, por meio de RNA, nas fases de treinamento (esquerda) e na fase de validação (direita).



O modelo 2 obtido para prever o perfil de textura do bolo conta com 9 neurônios na camada oculta, 5 folds, 4 variáveis de saída (Figura 3), R² de 0,9997 e RMSE de 0,7990 para treinamento, R² de 1,0000 e RMSE de 0,4841 para validação, obtido conforme observado na tabela 3, onde a topologia com melhor desempenho foi escolhida, correlacionando o R², fornecido pelo programa com o somatório do erro de cada parâmetro analisado, tanto na etapa de treinamento, como na de validação.

Na Figura 4 é apresentado uma comparação gráfica entre os valores preditos dos valores experimentais para predição do TPA do bolo. Já nesse modelo a fase de treinamento apresentou maiores desvios dos valores experimentais em comparação a fase de validação (principalmente para dureza), isso pode ser explicado também pela sensibilidade da análise, já que em geral medidas de texturas apresentam altos desvios-padrão (BATISTA et al., 2021).

Figura 3- Estrutura obtida para melhor topologia para o perfil de textura

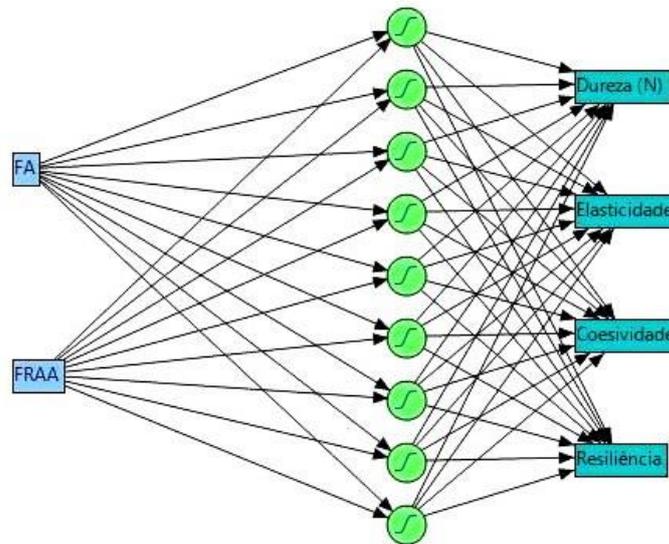
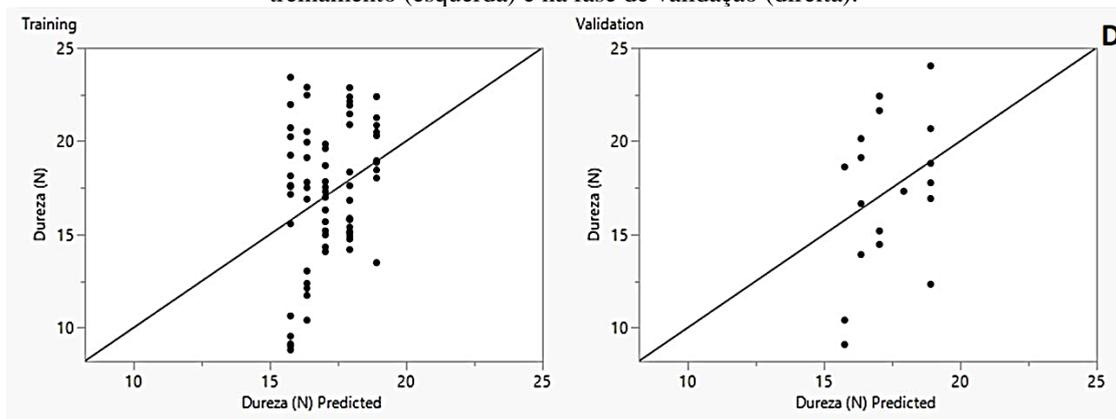
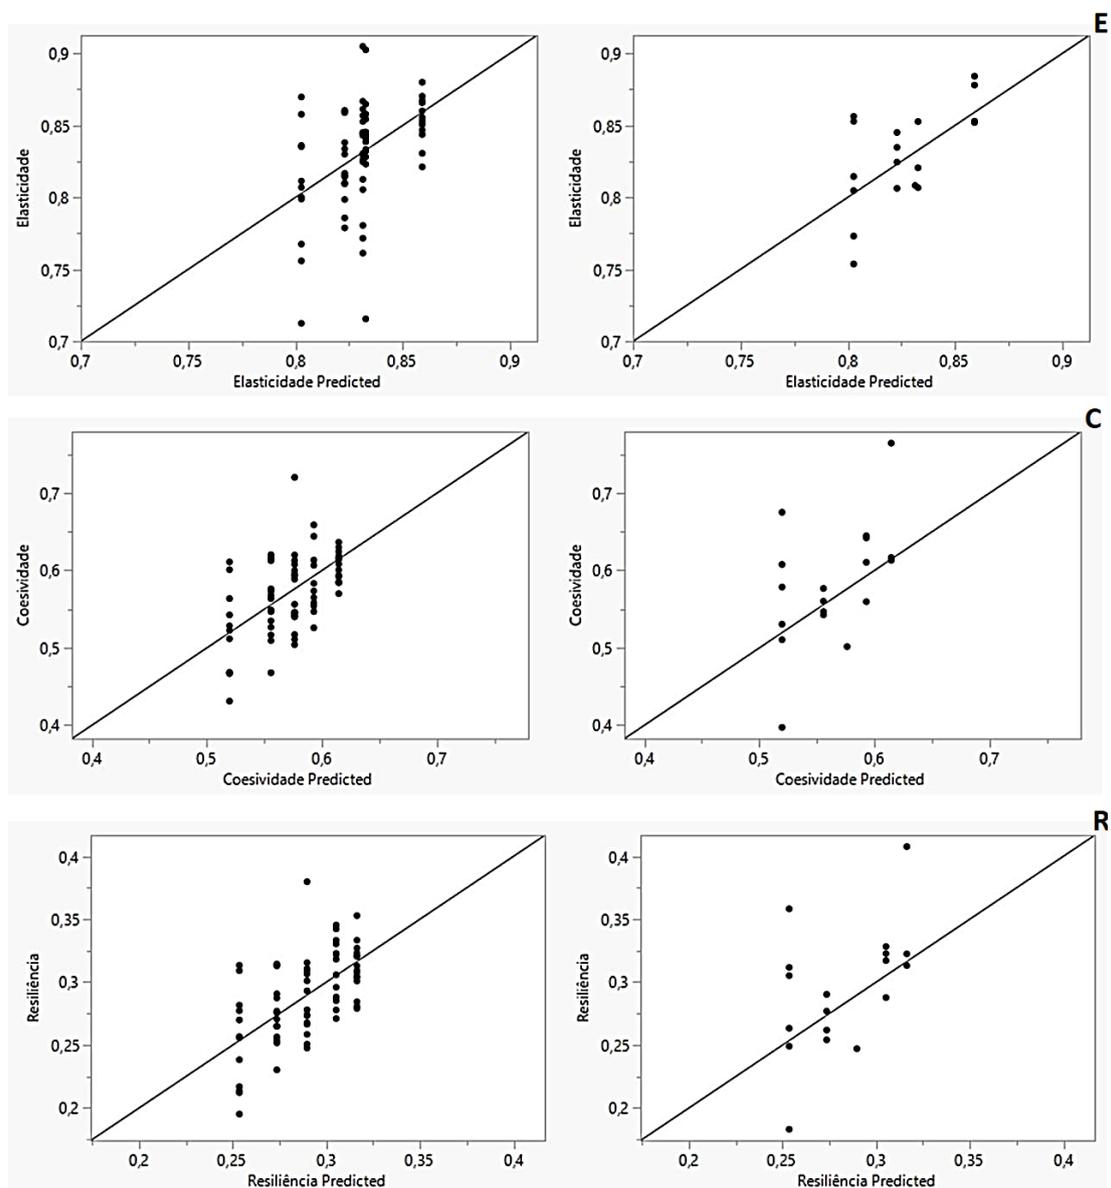


Figura 4- Relação entre os valores preditos e os valores experimentais para TPA da RNA nas fases de treinamento (esquerda) e na fase de validação (direita).



* Variáveis de saída para a TPA: D – Dureza, E – elasticidade, C- coesividade e R- resiliência.

Figura 4- Relação entre os valores preditos e os valores experimentais para TPA da RNA nas fases de



treinamento (esquerda) e na fase de validação (direita) (Continuação).

* Variáveis de saída das RNA para a TPA: D – Dureza, E – elasticidade, C- coesividade e R- resiliência.

Tabela 3 – Resultados obtidos para modelagem do perfil de textura do bolo.

Dureza					
Treinamento			Validação		
Nº de nodos	R ²	RMSE	R ²	RMSE	Coeficiente
3	0,8457	0,7879	0,7911	1,2214	0,8146
5	0,7702	0,9614	0,8207	1,1315	0,7602
7	0,8107	0,9558	0,9198	0,5662	1,1370
9	0,9482	0,7732	0,5235	0,4523	1,2009
12	0,8521	0,8530	0,6868	1,0566	0,8059
15	0,8159	0,9426	0,9212	0,5611	1,1552
Elasticidade					
Treinamento			Validação		
Nº de nodos	R ²	RMSE	R ²	RMSE	Coeficiente
3	0,8142	0,0107	0,9392	0,0050	111,4474

5	0,8132	0,1007	0,9435	0,0049	16,6386
7	0,8817	0,0070	0,7324	0,0182	64,0192
9	0,8801	0,0070	0,7640	0,0171	68,0636
12	0,8501	0,0097	0,7102	0,0107	76,5581
15	0,8774	0,0071	0,7449	0,0178	65,1233
Coesividade					
Treinamento			Validação		
Nº de nodos	R²	RMSE	R²	RMSE	Coeficiente
3	0,8968	0,0101	0,7974	0,0122	75,9191
5	0,9016	0,0098	0,7966	0,0123	76,8315
7	0,8612	0,1070	0,9342	0,0099	130,3922
9	0,8549	0,0109	0,9512	0,0085	92,8365
12	0,9290	0,0089	0,3961	0,0155	54,3951
15	0,8609	0,0107	0,9380	0,0096	88,5769
Resiliência					
Treinamento			Validação		
Nº de nodos	R²	RMSE	R²	RMSE	Coeficiente
3	0,9407	0,0070	0,9113	0,0084	120,2350
5	0,9416	0,0070	0,8817	0,0097	109,5590
7	0,9237	0,0076	0,9598	0,0066	133,1162
9	0,9203	0,0078	0,9646	0,0062	135,5107
12	0,9262	0,0082	0,9494	0,0051	141,7100
15	0,9254	0,0075	0,9518	0,0072	127,8338
Perfil de Textura (Total)					
Nº de nodos	Treinamento		Validação		
	R²	RMSE	R²	RMSE	Coeficiente
					e
3	0,9998	0,8157	0,9998	1,2471	0,9694
5	0,9998	1,0789	0,9998	1,1583	0,8938
7	0,9998	1,0774	0,9999	0,6009	1,1916
9	0,9997	0,7990	1,0000	0,4841	1,5586
12	0,9999	0,8797	0,9972	1,0879	1,0150
15	0,9998	0,9679	0,9999	0,5957	1,2789

O modelo 3 obteve uma RNA capaz de prever a cor da crosta contendo 9 neurônios na camada oculta, 5 folds, 2 variáveis de saída (Figura 5), R² de 0,9941 e RMSE de 3,1009 para treinamento, R² de 0,9964 e RMSE de 2,3958 para validação, conforme observado na tabela 4, onde a estrutura que melhor representou o desempenho do perfil de textura do bolo foi escolhida, por meio da correlação do R², fornecido pelo programa, pelo somatório do erro dos parâmetros analisados, tanto na etapa de treinamento, como na de validação.

Na Figura 6 é apresentado uma comparação gráfica entre os valores preditos e os valores experimentais (pontilhado) para predição da cor da crosta do bolo. Os valores experimentais mesmo com diferentes concentrações da FRAA apresentaram para as coordenadas L^* e b^* comportamento pontual e altos desvios-padrões nas duas fases. Isso pode ser justificado pela reação de Maillard e de caramelização que ocorrem na etapa de assamento do bolo, responsáveis por proporcionar cor e aroma característicos que são dependentes do conteúdo de açúcares e aminoácidos presentes nos ingredientes da formulação e apresentam diferentes tonalidades na superfície do bolo (FIB, 2015).

Figura 5- Estrutura obtida para melhor topologia para predição da cor da crosta

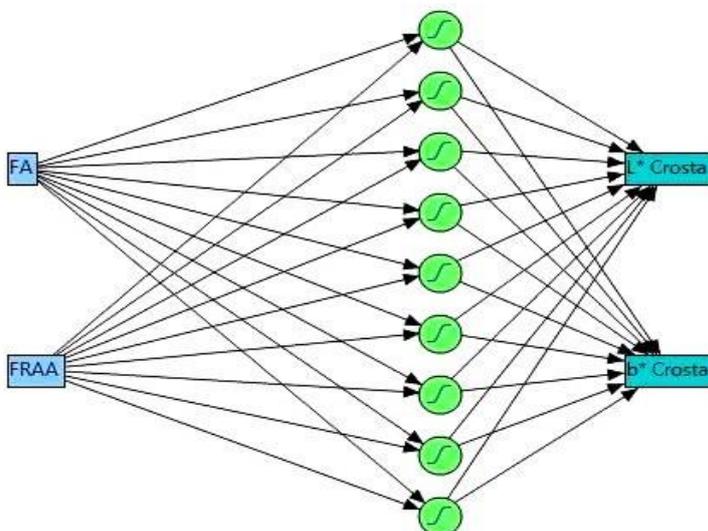
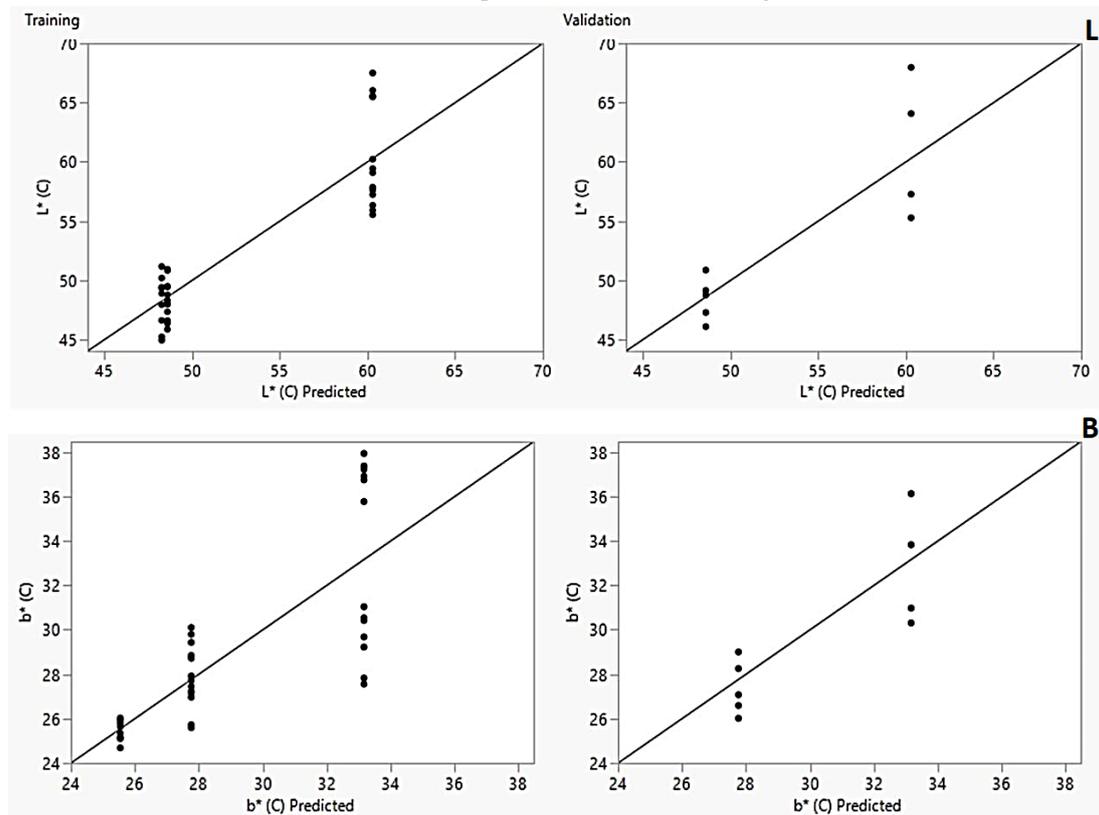


Figura 6- Relação entre os valores preditos e os valores experimentais para cor da crosta da RNA nas fases de treinamento (esquerda) e na fase de validação (direita).



* Variáveis de saída das RNA para a cor da crosta: L – Luminosidade e B – coordenada b*.

Tabela 4 – Resultados obtidos para modelagem da cor da crosta do bolo

L*crosta					
Treinamento			Validação		
Nº de nodos	R²	RMSE	R²	RMSE	Coeficiente
3	0,8992	2,0978	0,9102	2,0270	0,4387
5	0,9002	2,1266	0,9089	1,8857	0,4509
7	0,9204	1,8906	0,8248	2,6679	0,3829
9	0,8985	2,1446	0,9085	1,6177	0,4803
12	0,9012	2,1150	0,9084	1,8910	0,4517
15	0,9008	2,1195	0,9088	1,8870	0,4517
b*crosta					
Treinamento			Validação		
Nº de nodos	R²	RMSE	R²	RMSE	Coeficiente
3	0,9408	0,9699	0,9623	0,7437	1,1106
5	0,9412	0,9660	0,9626	0,7557	1,1057
7	0,9437	0,9212	0,9520	0,9318	1,0231
9	0,9424	0,9564	0,9603	0,7781	1,0970
12	0,9412	0,9662	0,9638	0,7431	1,1145
15	0,9408	0,9695	0,9639	0,7424	1,1125
Cor da crosta (Total)					
Treinamento			Validação		
Nº de nodos	R²	RMSE	R²	RMSE	Coeficiente
3	0,9940	3,0677	0,9966	2,7707	0,3409
5	0,9941	3,0926	0,9966	2,6414	0,3472
7	0,9955	2,8119	0,9966	3,5997	0,3107

9	0,9941	3,1009	0,9964	2,3958	0,3621
12	0,9942	3,0812	0,9967	2,6340	0,3483
15	0,9941	3,0890	0,9967	2,6294	0,3481

A topologia com o melhor desempenho para predição da cor do miolo possui 15 neurônios na camada oculta, 5 folds, 3 variáveis de saída (Figura 7), R^2 de 1,0000 e RMSE de 1,8811 para treinamento, R^2 de 1,0000 e RMSE de 1,5021 para validação, obtido conforme observado na tabela 5, onde foi escolhida por meio da correlação do R^2 , fornecido pelo programa com o somatório do erro de cada variável analisada, tanto na etapa de treinamento, como na de validação. Na Figura 8 é apresentado uma comparação gráfica entre os valores preditos dos valores experimentais (o pontilhado) para predição da cor do miolo do bolo. Nesse modelo, na etapa de treinamento há comportamento semelhante ao relatado na crosta. Já na fase de validação o desvio entre os valores preditos dos experimentais é menor, isso porque o miolo do bolo não alcança temperatura suficiente para ocorrer reações de caramelização, que favorecem as disparidades entre os dados.

Figura 7- Estrutura obtida para melhor topologia para predição da cor do miolo

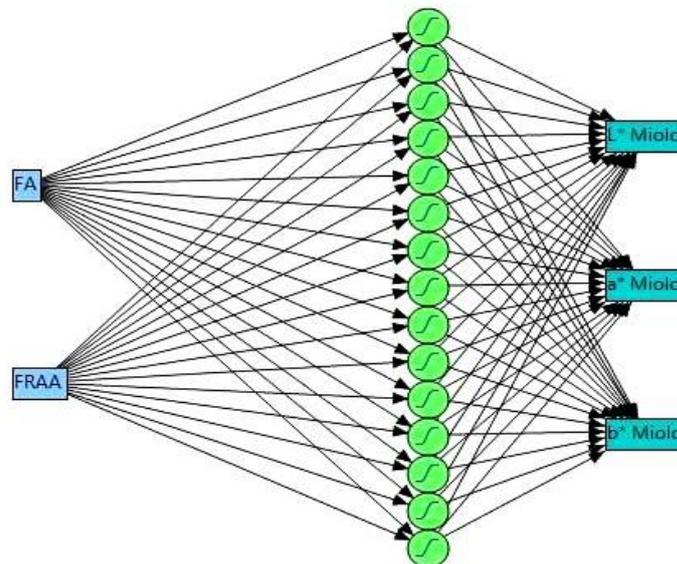
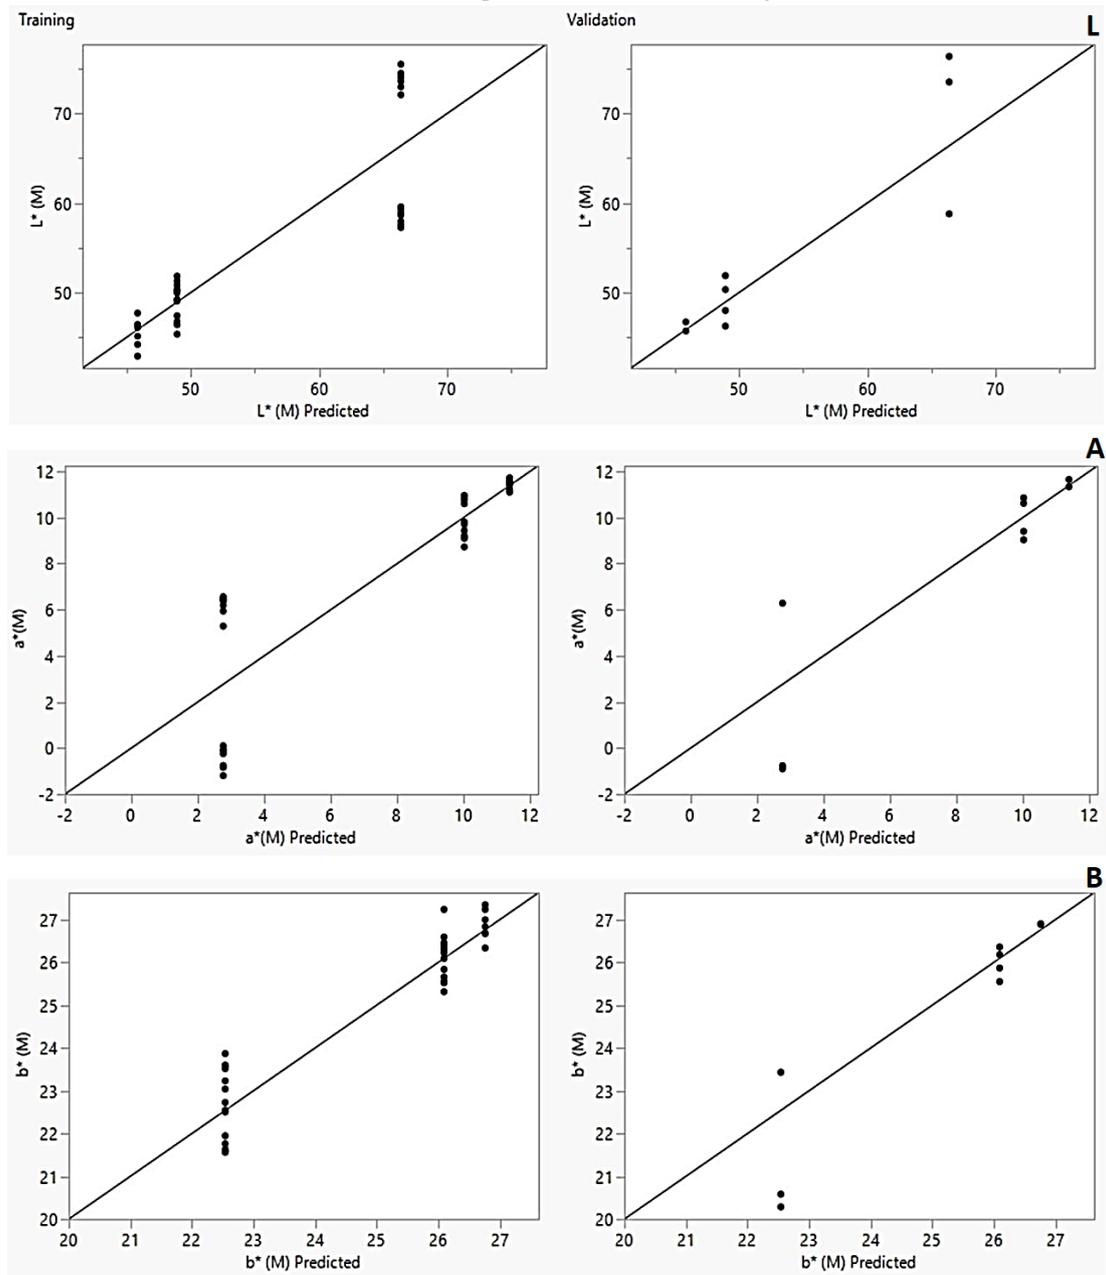


Figura 8- Relação entre os valores preditos e os valores experimentais para cor do miolo da RNA nas fases de treinamento (esquerda) e na fase de validação (direita).



* Variáveis de saída das RNA para a cor do miolo: L – Luminosidade, A – coordenada a* e B – coordenada b*.

Tabela 5 – Resultados obtidos para modelagem da cor do miolo

L*miolo					
Treinamento			Validação		
Nº de nodos	R ²	RMSE	R ²	RMSE	Coeficiente
3	0,9910	0,9776	0,9852	1,3961	0,8326
5	0,9898	1,0979	0,9892	0,9229	0,9793
7	0,9886	1,1177	0,9941	0,8333	1,0163
9	0,9899	1,0967	0,9874	0,9999	0,9431
12	0,9882	1,1342	0,9942	0,8279	1,0104
15	0,9896	1,1103	0,9902	0,8785	0,9955

a*miolo					
Treinamento			Validação		
Nº de nodos	R ²	RMSE	R ²	RMSE	Coeficiente
3	0,9927	0,3692	0,9980	0,2081	3,4482
5	0,9954	0,3078	0,9869	0,4307	2,6841
7	0,9934	0,3550	0,9970	0,2466	3,3083
9	0,9953	0,3099	0,9871	0,4275	2,6885
12	0,9937	0,3478	0,9969	0,2488	3,3364
15	0,9955	0,3038	0,9868	0,4323	2,6931
b*miolo					
Treinamento			Validação		
Nº de nodos	R ²	RMSE	R ²	RMSE	Coeficiente
3	0,9633	0,3854	0,9317	0,5861	1,9506
5	0,9523	0,4662	0,9853	0,2095	2,8673
7	0,9584	0,4067	0,9501	0,5167	2,0667
9	0,9513	0,4711	0,9857	0,2071	2,8560
12	0,9569	0,4139	0,9562	0,4842	2,1302
15	0,9521	0,4671	0,9878	0,1912	2,9467
Cor do miolo (Total)					
	Treinamento	Validação			
Nº de nodos	R ²	RMSE	R ²	RMSE	Coeficiente
3	1,0000	1,7322	1,0000	2,1902	0,5099
5	1,0000	1,8719	1,0000	1,5632	0,5822
7	1,0000	1,8794	1,0000	1,5967	0,5754
9	1,0000	1,8777	1,0000	1,6344	0,5695
12	1,0000	1,8959	1,0000	1,5609	0,5786
15	1,0000	1,8812	1,0000	1,5021	0,5912

Segundo Alves et al. (2022), os valores dos parâmetros estatísticos das etapas de treinamento e validação indicam a capacidade das RNAs de aprender e generalizar o comportamento do sistema sob investigação. A análise gráfica de todos modelos indica que há um desvio mais acentuado de vários pontos da fase de treinamento mas comprova a capacidade de predição das características analisadas. Foi demonstrado que com uma variação de até 10 % de farinha do resíduo agroindustrial da acerola foi possível prever as características do volume, da cor e do perfil de textura de um bolo sem glúten com significativos coeficientes de variação e menores erros.

As topologias foram descritas com número de até 15 neurônios, demonstrando que os dados apresentados foram eficientes para predição das propriedades analisadas. Em geral, redes neurais com poucos neurônios escondidos são preferidas, visto que elas tendem a possuir um melhor poder de generalização, reduzindo o problema de sobreajuste (*overfitting*) (PEREIRA, 1999).

Para avaliar a capacidade preditiva da rede para predição da vida útil de bolos macios armazenados a 10 °C, foi aplicado uma RNA *feedforward* com cinco neurônios

na camada de entrada e um neurônio na camada de saída. As características físico-químicas do bolo mole, ou seja, teor de umidade, acidez titulável, ácidos graxos livres, valor de peróxido e tirosina foram considerados como o neurônio de entrada, e a pontuação geral de aceitabilidade foi o único parâmetro de saída. A vida útil prevista pelo modelo de rede neural simulada foi de 20,57 dias, enquanto a vida útil experimental foi de 21 dias (GOYAL; GOYAL, 2011). Apontando que as redes neurais são uma excelente ferramenta na previsão da vida de prateleira de bolos moles.

Desta forma, por meio da aplicação das redes neurais artificiais, as características de volume, TPA e cor dos bolos, assim como a previsibilidade da vida de prateleira podem ser obtidas com uso de variáveis simples, como composição e parâmetros de qualidade.

4 CONCLUSÃO

As RNAs obtidas foram capazes de predizer, com boa precisão, as propriedades tecnológicas, volume, perfil de textura e cor, de bolo sem glúten a partir da variação da composição do produto (concentrações de farinha de arroz e farinha do resíduo agroindustrial de acerola).

REFERÊNCIAS

AACC - AMERICAN ASSOCIATION OF CEREAL CHEMISTS. **Approved methods of the American Association of Cereal Chemists**. 9 ed. Saint Paul: AACC, 1995.

ALVES, R. O. R.; TOMÉ, O. C.; PEREIRA, P. C.; VILLANOEVA, C. N. B. C.; SILVA, V. M. Artificial neural networks in the prediction of fraud in integral milk powder by adding whey power. **Ciência Rural**, v. 52, n. 4, e20210109, 2022. <https://doi.org/10.1590/0103-8478cr20210109>.

BHAGYA RAJ, G. V. S.; DASH, K. K. Comprehensive study on applications of artificial neural network in food process modeling. **Critical Reviews in Food Science and Nutrition**, 2020. <https://doi.org/10.1080/10408398.2020.1858398>.

BATISTA, L.F.; MARQUES, C.S.; PIRES, A.C.S.; MINIM, L.A.; SOARES, N.F.F.; VIDIGAL, M.C.T.R.. Artificial neural networks modeling of non-fat yogurt texture properties: effect of process conditions and food composition. **Food and Bioprocess Technology**, v.126, p.164-174, 2021.

BELWAL, T.; DEVKOTA, H. P.; HASSAN, H. A.; AHLUWALIA, S.; RAMADAN, M. F.; MOCAN, A.; ATANASOV, A. G. Phytopharmacology of Acerola (Malpighia spp.) and its potential as functional food. **Trends in food science & technology**, v. 74, p. 99-106, 2018. <https://doi.org/10.1016/j.tifs.2018.01.014>.

BORGES, O. M. A.; CESCO, K.; AREND, G. D.; ALVAREZ-RIVERA, G.; CIFUENTES, A.; ZIELINSKI, A. A. F.; POLETTO, P. Integrated green-based methods to recover bioactive compounds from by-product of acerola processing. **LWT**, v. 151, p. 112104, 2021. <https://doi.org/10.1016/j.lwt.2021.112104>.

BORTOLOTTI, C. T.; SANTOS, K. G.; FRANCISQUETTI, M. C.; DUARTE, C. R.; BARROZO, M. A. Hydrodynamic study of a mixture of West Indian cherry residue and soybean grains in a spouted bed. **The Canadian Journal of Chemical Engineering**, v. 91, n. 11, p. 1871-1880, 2013.

BRITO, T.B.; CARRANJOLA, J.F.; GONÇALVES, E. C. B. A.; MARTELLI-TOSI, M. FERREIRA, M. S. L. Fruit and vegetable residues flours with different granulometry range as raw material for pectin-enriched biodegradable film preparation. **Food Research International**, v. 121, p. 412-421, 2019. <https://doi.org/10.1016/j.foodres.2019.03.058>.

COSTA, M.G., SOUZA, E. L., STAMFORD, T. L. M., ANDRADE, S. A. C. Qualidade tecnológica de grãos e farinhas de trigo nacionais e importados. **Ciência e Tecnologia de Alimentos**, v. 28, n. 1, p. 220-225, 2008. <https://doi.org/10.1590/S0101-20612008000100031>.

DELLA LUCIA, S. M.; MINIM, L. A. Redes Neurais Artificiais: Fundamentos e Aplicações. In: MINIM, V. P. R. (Ed.). **Análise sensorial: estudos com consumidores**. Viçosa: Editora. UFV, 2010. Cap. 9, p.258-279.

DEMIRKESEN, I.; MERT, B.; SUMNU, G.; SAHIN, S. Utilization of chestnut flour in gluten-free bread formulations. **Journal of food engineering**, v. 101, n. 3, p. 329-336, 2010. <https://doi.org/10.1016/j.jfoodeng.2010.07.017>.

FIB. FOOD INGREDIENTS BRASIL. Funcionalidades do Açúcar em bolos. **Revista Fi**, n. 35, 2015.

GOYAL, S.; GOYAL, G.K. Simulated Neural Network Intelligent Computing Models for Predicting Shelf Life of Soft Cakes. **Global Journal of Computer Science and Technology**, v.11, n. 14, 2011.

GONÇALVES NETO, J.; VIDAL OZORIO, L.; CAMPOS DE ABREU, T.C.; FERREIRA DOS SANTOS, B., PRADELLE, F. Modeling of biogas production from food, fruits and vegetables wastes using artificial neural network (ANN), **Fuel**, v. 285, 2021. <https://doi.org/10.1016/j.fuel.2020.119081>.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA, 2017. **Censo Agropecuário 2017**.

INFANTE, J.; SELANI, M. M.; TOLEDO, N. D.; Silveira, M. F.; ALENCAR, S. D.; SPOTO, M. H. F. Atividade antioxidante de resíduos. **Alim. Nutr. Braz. J. Food Nutr.**, Araraquara, v. 24, n. 1, p. 87-91, jan./mar. 2013.

KIRBAS, Z; KUMCUOGLU, S.; TAVMAN, S. Effects of apple, orange and carrot pomace powders on gluten-free batter rheology and cake properties. **Journal Food Science Technology**, v. 56, n. 2, p. 914-926. <https://doi.org/10.1007/s13197-018-03554-z>.

MARQUES, T. R.; CORRÊA, A. D.; DE CARVALHO ALVES, A. P.; SIMÃO, A. A.; PINHEIRO, A. C. M.; OLIVEIRA RAMOS, V. Cereal bars enriched with antioxidant substances and rich in fiber, prepared with flours of acerola residues. **Journal of food science and technology**, v. 52, n. 8, p. 5084-5092, 2015. <https://doi.org/10.1007/s13197-014-1585-2>.

MONTEIRO, S. A.; BARBOSA, M. M; DA SILVA, F. F. M.; BEZERRA, R. F.; SILVA MAIA, K. Preparation, phytochemical and bromatological evaluation of flour obtained from the acerola (*Malpighia puniceifolia*) agroindustrial residue with potential use as fiber source. **LWT**, v. 134, p. 110142, 2020. <https://doi.org/10.1016/j.lwt.2020.110142>.

MOSCATTO, J. A.; PRUDÊNCIO-FERREIRA, S.H.; HAULY, M. C.O. Farinha de yacon e inulina como ingredientes na formulação de bolo de chocolate. *Food Science and Technology*, v. 24, p. 634-640, 2004. <https://doi.org/10.1590/S0101-20612004000400026>.

PENNA, M. L. F. Rede neural artificial para detecção de sobremortalidade atribuível à cólera no Ceará. **Revista Saúde Pública**, v. 38, n. 3, 2004.

PEREIRA BB., Introduction to Neural Networks in Statistics, Center of Multivariate Analysis, Technical Report; Penn. State University; 1999.

RENZETTI, S.; VAN DER SMAN, R.G.M. Food texture design in sugar reduced cakes: Predicting batters rheology and physical properties of cakes from physicochemical principles. **Food Hydrocolloids**, v. 131, 2022. <https://doi.org/10.1016/j.foodhyd.2022.107795>.

SALEHI, F. Improvement of gluten-free bread and cake properties using natural hydrocolloids: A review. **Food Science & Nutrition**, v. 7, n. 11, p. 3391-3402, 2019. <https://doi.org/10.1002/fsn3.1245>.

SILVA, J. D. O.; WISNIEWSKI JR, A.; CARREGOSA, I. S. C.; SILVA, W. R.; SOUZA ABUD, A. K.; OLIVEIRA JÚNIOR, A. M. Thermovalorization of acerola industrial waste by pyrolysis in a continuous rotary kiln reactor. **Journal of Analytical and Applied Pyrolysis**, v. 161, p. 105373, 2022. <https://doi.org/10.1016/j.jaap.2021.105373>.

SIVARAMAKRISHNAN, H. P.; SENGE, B.; CHATTOPADHYAY, P. K. Rheological properties of rice dough for making rice bread. **Journal of Food Engineering**, Essex, v. 62, n. 1, p. 37-45, 2004. [http://dx.doi.org/10.1016/S0260-8774\(03\)00169-9](http://dx.doi.org/10.1016/S0260-8774(03)00169-9).

SPÖRL, C.; CASTRO, E. G.; LUCHIARI, A. Aplicação de Redes Neurais Artificiais na construção de modelos de fragilidade ambiental. **Revista do Departamento de Geografia**, v. 21, n.1, p. 113-135, 2011. <https://doi.org/10.7154/RDG.2011.0021.0006>.

SANTOS, F. G.; AGUIAR, E. V.; CAPRILES, V. D. Analysis of ingredient and nutritional labeling of commercially available gluten-free bread in Brazil. **International Journal of Food Sciences and Nutrition**, v. 70, n. 5, p. 562-569, 2019. <https://doi.org/10.1080/09637486.2018.1551336>.

XU, J.; ZHANG, Y.; WANG, W.; LI, Y. Advanced properties of gluten-free cookies, cakes, and crackers: A review. **Trends in Food Science & Technology**, v. 103, p. 200–213, 2020. <https://doi.org/10.1016/j.tifs.2020.07.017>.