

MODELAGEM DA CINÉTICA DE SECAGEM DE CAROÇOS MOÍDOS DE AÇAÍ VIA REDES NEURAIS ARTIFICIAIS, MODELOS EMPÍRICOS E FENOMENOLÓGICOMOHAMAD AL BANNOUD^{1*}, KACIANE ANDREOLA², TIAGO D. MARTINS³, CARLOS A. M. DA SILVA³, LUCIANE F. G. DE SOUZA², MATHEUS B. BRAGA³¹Universidade Estadual de Campinas, Faculdade de Engenharia Química²Instituto Mauá de Tecnologia, Departamento de Engenharia Química e de Alimentos³Universidade Federal de São Paulo, Departamento de Engenharia Química

*e-mail: m223369@dac.unicamp.br

RESUMO - O presente trabalho teve como objetivo desenvolver um sensor virtual via Redes Neurais Artificiais (RNAs) capaz de prever, com precisão, a cinética de secagem dos caroços moídos de açaí em um secador de leito fixo, além de comparar os resultados frente aos modelos empíricos e fenomenológico. Sete ensaios experimentais de secagem foram utilizados para treinar diversas estruturas de RNAs. As variáveis de entrada foram a temperatura de secagem, velocidade do ar e os valores do conteúdo de umidade (X) nos instantes $k-1$ e k . A saída consistiu no valor de X no instante $k+1$. Constatou-se que uma RNA com uma camada intermediária contendo 5 neurônios, treinada com funções de ativação lineares e com o algoritmo de treinamento Levenberg-Marquardt com Regularização Bayesiana apresentou o melhor desempenho. A partir da implementação do modelo fenomenológico, obteve-se valores do coeficiente de difusividade efetiva na ordem de 10^{-9} a 10^{-11} m²/s. O modelo de Midilli *et al.* (2002) foi o modelo empírico avaliado que mais se adequou aos dados experimentais. Todavia, a partir da análise dos parâmetros estatísticos, constatou-se que o modelo via RNA apresentou um desempenho superior aos demais modelos, com valores mais baixos de χ^2 e RMSE e mais alto de R².

INTRODUÇÃO

O açaí é um fruto composto majoritariamente pelo seu caroço, o qual representa cerca de 83 % da composição total do fruto (Rogez, 2000). A parte comestível (epicarpo e mesocarpo) representa aproximadamente 26,54 % do peso do fruto (Oliveira *et al.*, 2000). O caroço ainda não possui utilidade efetiva real no cotidiano, pois depois do despulpamento da fruta e a geração dos resíduos orgânicos, resulta em problemas ambientais para as cidades que processam o açaí (Rogez, 2000).

O caroço do açaí tem sido objeto de estudos em diversas áreas, com foco no desenvolvimento de tratamentos adequados para o seu descarte e/ou reutilização, o que geraria um impacto ambiental positivo (Cordeiro *et al.*, 2019). É importante destacar

que o caroço apresenta um potencial de aplicação como insumo em diversas indústrias como, por exemplo, na geração de bioenergia em olarias, sendo utilizado como fonte de biomassa para geração de energia por meio da gaseificação (Reis *et al.*, 2002; Silva *et al.*, 2018). Além do mais, pode ser reaproveitado como ração animal e fertilizante (Towsend *et al.*, 2001) e na fabricação de farinhas alimentícias.

Todavia, o caroço do açaí é altamente perecível, com umidade de aproximadamente 39,59 % em base úmida (Cordeiro *et al.*, 2017). Portanto, para o aproveitamento de suas propriedades e manutenção de sua vida útil, faz-se necessário a aplicação de métodos de conservação, dentre os quais destaca-se a secagem. O secador de bandejas é um equipamento empregado em indústrias de diversos seguimentos, destacando-se sua utilização para a secagem de alimentos e

fertilizantes (Avila, 2010). O secador de bandejas é denominado como um secador do tipo convectivo, o qual utiliza o ar como fluido na transferência simultânea de calor e massa (Towler e Sinnott, 2008).

As indústrias estão cada vez mais engajadas na busca por novas tecnologias que melhorem o desempenho das linhas de produção. Em processos industriais, o monitoramento em tempo real do conteúdo de umidade demanda um sensor *on-line* de alto custo e alto tempo de calibração e atraso na medida (Silva *et al.*, 2014). Além dessa variável, é necessário monitorar a temperatura média das partículas, a umidade do ar de entrada e saída do secador e a vazão de ar, que pode ser feito por meio de sensores *on-line* previamente inseridos no processo. A grande questão é que os instrumentos de medição *on-line* relativos à fase gasosa são muito mais baratos e de fácil instalação, quando comparados aos sensores para fase sólida. Face a estas dificuldades, geralmente a medição do conteúdo de umidade é realizada de forma *off-line*, retirando alíquotas do processo, que são levadas ao laboratório para uso de métodos termogravimétricos, por exemplo.

Diversos trabalhos foram desenvolvidos para modelagem de secadores convectivos. Para alguns, utilizou-se equações fenomenológicas (Benseddik *et al.*, 2020; Ruhanian e Movagharnejad, 2016; Dhurve *et al.*, 2022) e outros foram modelados de maneira empírica (Naderinezhad *et al.*, 2015; Ruhanian e Movagharnejad, 2016; Dhurve *et al.*, 2022). Devido à complexidade em se obter, utilizando modelos fenomenológicos, resultados próximos aos dados reais obtidos por medidores *off-line*, o cenário da pesquisa atual se voltou para a modelagem empírica, cabendo citar o uso de modelos caixa preta, tais como as Redes Neurais Artificiais (RNAs). Esse modelo pode ser utilizado como base para a obtenção de sensores virtuais (Sabanovic *et al.*, 2021).

Nas plantas de processos químicos, os sensores virtuais estão sendo amplamente utilizados para estimar de forma *on-line* uma variável de processo que é difícil medir. O sensor virtual é um modelo inferencial construído entre as variáveis que são fáceis de medir *on-line* (entradas) e uma ou mais variáveis que são difíceis de medir *on-line*

(saídas) (Choi e Yoon, 2020). Portanto, o uso de um sensor virtual para estimar uma variável da planta para a qual nenhum sensor é instalado fornece uma oportunidade para melhorar o desempenho de um processo.

As RNAs têm ganhado espaço em diversas áreas da engenharia e sendo empregadas no tratamento e descrição de diversos fenômenos envolvidos em processos industriais (Braga *et al.*, 2000; Dantas *et al.*, 2021, Leles *et al.*, 2021).

Frente ao apresentado, o presente trabalho teve como objetivos desenvolver um sensor virtual via Redes Neurais Artificiais para prever, com precisão, a cinética de secagem dos caroços moídos de açaí em um secador de leito fixo e avaliar os parâmetros de desempenho das RNAs, confrontando os resultados obtidos com os resultados provenientes de modelos empíricos e fenomenológico.

MATERIAIS E MÉTODOS

Processo De Secagem Dos Caroços De Açaí

Cerca de 10 kg de caroços de açaí foram usados nos experimentos de secagem. Os caroços foram adquiridos em um comércio local na cidade de Belém do Pará. Os processos de secagem foram realizados em um secador de bandejas Armfield TM (modelo UOP8, Hampshire, Inglaterra). Para a realização dos ensaios da secagem, utilizou-se aproximadamente 150 gramas de caroços de açaí prensados e acomodados em cada bandeja do secador. O equipamento consiste em três seções básicas: controle de velocidade do ar, seção de aquecimento e câmara de secagem. O compartimento de secagem tem capacidade máxima de 3,0 kg de material úmido e que podem ser dispostos em 3 bandejas.

As bandejas foram pesadas por uma balança semianalítica (Mettler Toledo PB3002-S) que registrou as variações no peso das amostras durante os ensaios de secagem. Essa balança é conectada a um computador, e um aplicativo foi usado para registrar os valores de massa da amostra em tempo real (Camargo *et al.*, 2019).

Os experimentos de secagem foram realizados de acordo com um planejamento

fatorial completo 2^2 , com três repetições no ponto central. Avaliou-se a influência da temperatura do ar de secagem (80, 100 e 120 °C) e da velocidade do ar de entrada (0,5, 0,7 e 0,9 m/s). As condições de cada experimento, bem como a quantidade de pontos experimentais, são mostradas na Tabela 1. Desta forma, as curvas de secagem (adimensional de umidade em função do tempo), foram construídas para cada ensaio de secagem. Um oitavo experimento foi conduzido a 110 °C e 0,6 m/s, com o intuito de verificar a capacidade de generalização do modelo obtido via RNA.

Cinéticas De Secagem

A aquisição dos dados de massa-tempo foi realizada em intervalos de 10 segundos, até que o produto atingisse a umidade de equilíbrio. As curvas de secagem foram construídas a partir dos valores da umidade adimensional (θ), Equação 1, em função do tempo de processo.

$$\theta = \frac{X - X_{eq}}{X_0 - X_{eq}} \quad (1)$$

Modelagem Da Cinética De Secagem

As cinéticas de secagem experimentais foram ajustadas aos modelos empíricos de Lewis (1921), Page (1949) e Midilli *et al.* (2002), mostrados pelas Equações 2, 3 e 4, respectivamente. Os parâmetros dos modelos foram obtidos utilizando-se a ferramenta Solver do Excel®.

$$\theta = \exp(-k \cdot t) \quad (2)$$

$$\theta = \exp(-k \cdot t^n) \quad (3)$$

$$\theta = a \cdot \exp(-k \cdot t^n) + b \cdot t \quad (4)$$

A segunda lei de Fick truncada no nt-ésimo termo também foi empregada para interpretar os dados de secagem experimental, uma vez que a difusão interna de umidade é o principal fenômeno de transporte que descreve o período de taxa de secagem decrescente. Assumindo geometria de placa plana, movimento unidirecional da umidade, distribuição uniforme da umidade inicial, considerando que a umidade migrou somente por difusão e que a resistência à transferência

de massa por convecção e o encolhimento dos caroços foram desprezíveis, o modelo fenomenológico usado pode ser representado pela Equação 5.

$$\theta = \frac{8}{\pi} \sum_{n=0}^{nt} \frac{1}{(2n+1)^2} \exp \left[-\frac{(2n+1)^2 \cdot \pi^2 \cdot D_{ef} \cdot t}{4 \cdot L^2} \right] \quad (5)$$

Redes Neurais Artificiais

Os dados experimentais provenientes dos oito ensaios de secagem consistiram em séries temporais discretizadas em intervalos iguais de 10 segundos, totalizando 5854 pontos experimentais. Para se desenvolver um modelo de RNA aplicável, utilizaram-se parâmetros importantes associados ao processo de secagem como variáveis de entrada para prever o valor de θ . As três etapas principais da elaboração e validação do modelo são mostradas na Figura 1. Na primeira etapa (Figura 1 (I)) foi realizado o projeto da estrutura da RNA. Como entrada, foram empregados os valores de temperatura de secagem T (°C), velocidade do ar V (m/s) e os valores de conteúdo de umidade (X) (b.s.) nos instantes de tempo $k-1$ (anterior) e k (atual). A saída da RNA consistiu no valor de X em $k+1$ (posterior), que foi utilizado para obter o adimensional de umidade θ , por meio da Equação 1. Assim, por exemplo, utilizou-se os valores de $X(t=0 \text{ s})$ e $X(t=10 \text{ s})$ para prever o valor em $X(t=20 \text{ s})$ e, consequentemente, $\theta(t=20 \text{ s})$.

Para garantir a generalização das RNAs, realizou-se uma validação cruzada de 5 *fold*s. Os dados experimentais foram divididos aleatoriamente em 5 conjuntos, conforme mostrado na Figura 1 (II). Os dados dos Ensaios 1 até 7 foram separados aleatoriamente, na proporção de 80% para a etapa denominada de obtenção, que foram por sua vez divididos de forma aleatória em três conjuntos: treino (70%), validação (15%) e teste (15%). Essa divisão permitiu uma melhor eficiência durante o uso dos algoritmos de aprendizagem. Os 20% restante dos dados foram utilizados para a etapa de simulação. Além disso, o ensaio 8 foi utilizado separadamente, em condições de temperatura e velocidade diferentes das anteriores, de modo a averiguar o desempenho da RNA. Alterando-se de forma cíclica o conjunto de testes, 5 modelos (1 para cada *fold*) de RNAs foram ajustados para cada uma das

1960 estruturas testadas, onde todos os dados experimentais foram utilizados ao menos uma vez na etapa de treinamento e simulação. Desta forma, evitou-se um possível sobreajuste (*overfitting*) relacionado com a divisão dos dados.

Além da definição das variáveis de entrada e saída, foi necessário definir 5 hiperparâmetros: a quantidade de camadas ocultas, a quantidade de neurônios em cada camada oculta, a função objetivo a ser minimizada, as funções de ativação e o algoritmo de aprendizagem. Não existe regra prática para a seleção desses hiperparâmetros, fazendo-se necessário o treino e análise de resultados de diversas estruturas de RNAs via teste e erro.

A etapa de treinamento teve por objetivo ajustar os valores dos pesos $W^{(1)}$ e $W^{(2)}$ e $b^{(1)}$ e $b^{(2)}$ da Equação 6, de modo a minimizar a função objetivo MSE, consistindo em uma relação entre os dados experimentais de saída e a saída obtida pelo modelo de RNA. Nesse

estudo, foram obtidas estruturas com combinações de diferentes hiperparâmetros: (a) estruturas com uma camada intermediária de neurônios; (b) quantidade de neurônios da camada intermediária entre 2 e 50 neurônios; (c) erro quadrático médio (*Mean Squared Error*, MSE) como função objetivo a ser minimizada; (d) funções de ativação consideradas: linear (*purelin*), saturada linear (*satlin*) e saturada linear simétrica (*satlins*), tangente hiperbólica (*tansig*), sigmoideal (*logsig*), de base radial (*radbas*) e base radial normalizada (*radbasn*); (e) algoritmos de aprendizado: Levenberg-Marquardt, *Resilient back-propagation*, Powell-Beale e Levenberg-Marquardt com Regularização Bayesiana. No total, 1960 estruturas de RNAs foram analisadas. A representação matemática da estrutura de uma RNA com uma camada é dada pela Equação 6.

$$\hat{y} = f_{(2)}[W^{(2)}f_{(1)}(W^{(1)}x + b^{(1)}) + b^{(2)}] \quad (6)$$

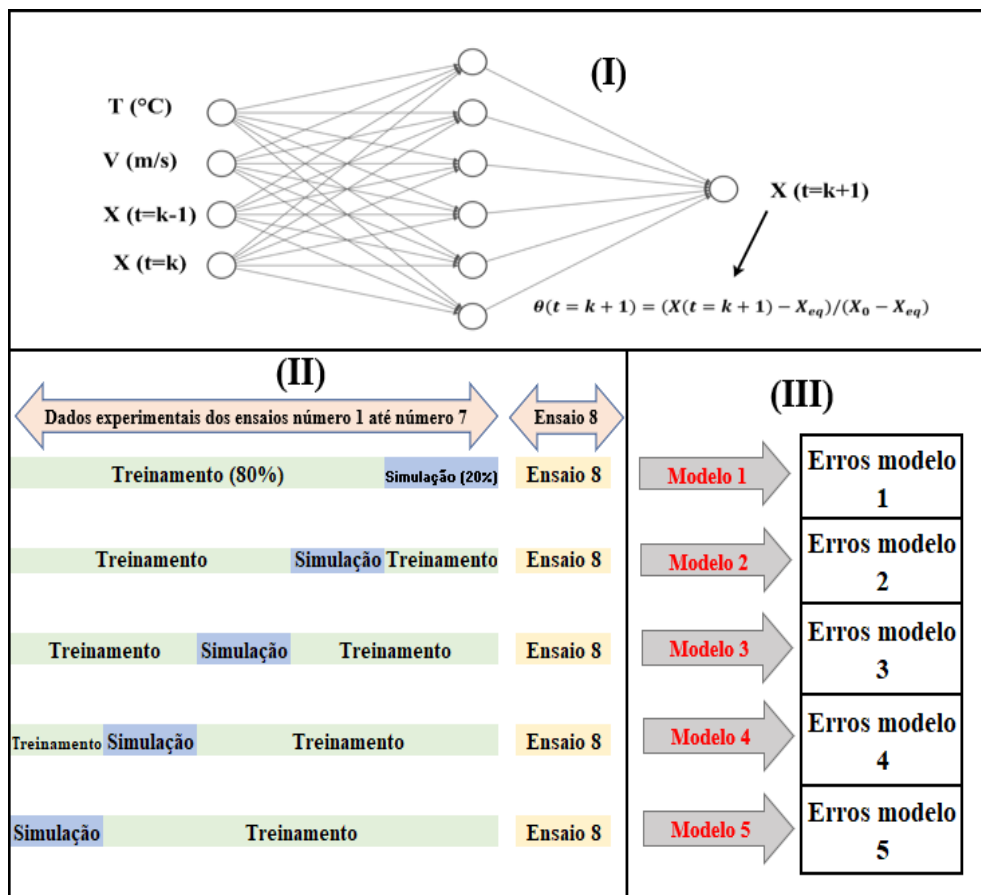


Figura 1: Representação esquemática da metodologia utilizada para a elaboração das RNAs (I) elaboração das estruturas de RNAs (II) separação dos dados experimentais utilizando a validação cruzada, e (III) avaliação de desempenho das RNAs via cálculo de parâmetros estatísticos e erros

As métricas de desempenho para cada modelo de RNA (Figura 1 (III)) foram o erro quadrático médio (Equação 7), a média do erro quadrático médio entre os cinco modelos (μ) e o desvio padrão do erro quadrático médio dos cinco modelos (σ). A melhor RNA selecionada foi aquela que apresentou os valores mais baixos de σ e μ . Esses critérios garantiram que somente as estruturas que apresentaram boa generalização, refletida pelo baixo valor de desvio padrão, e boa acurácia, devido ao baixo valor do MSE, fossem selecionadas como as melhores.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (7)$$

As curvas de secagem previstas pelo melhor modelo de RNA, para cada um dos oito ensaios de secagem foram construídas. Para o melhor modelo de RNA, é apresentada uma curva de regressão de dados experimentais versus dados previstos pela rede. Além do mais, para a melhor estrutura de RNA foi construído um gráfico de violino com uma distribuição Gaussiana com função Kernel Normal para os erros absolutos. Os valores de média e mediana do erro absoluto entre o valor experimental e o previsto pela RNA foram avaliados para cada modelo da validação cruzada. Também foi avaliado o desvio padrão residual representado pela Equação 8. Todos os cálculos foram realizados utilizando o *software* MATLAB.

$$RSD(\%) = 100 \left(\frac{\sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}}{\bar{y}_i} \right) \quad (8)$$

Comparação Estatística Entre Os Modelos

Para verificar a qualidade do ajuste de cada modelo (fenomenológico, empíricos e via RNA), aos dados experimentais, analisou-se o qui-quadrado reduzido (χ^2) (Equação 9), o coeficiente de determinação (R^2) (Equação 10) e o erro quadrático médio reduzido ($RMSE$) (Equação 11).

$$\chi^2 = \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N - z} \quad (9)$$

$$R^2 = \frac{\sum_{i=1}^n (X_{RNA}^{t+1} - \bar{X}_{RNA}^{t+1})(X_{exp}^{t+1} - \bar{X}_{exp}^{t+1})}{\sqrt{\sum_{i=1}^n (X_{RNA}^{t+1} - \bar{X}_{RNA}^{t+1})^2} \cdot \sqrt{\sum_{i=1}^n (X_{exp}^{t+1} - \bar{X}_{exp}^{t+1})^2}} \quad (10)$$

$$RMSE = \left[\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \right]^{\frac{1}{2}} \quad (11)$$

RESULTADOS E DISCUSSÃO

Modelagem Das Cinéticas De Secagem

Na Figura 2 é possível observar os resultados experimentais da cinética de secagem dos caroços moídos de açaí, para os sete ensaios de secagem. Constatou-se que as curvas de secagem apresentaram, em sua totalidade, um perfil típico de curva de secagem de grãos, como apresentado em Lehn e Pinto (2004), para o arroz em casca.

Tabela 1: Parâmetros ajustados dos modelos empíricos para todos os Ensaios de secagem.

Ensaio (Pontos experimentais)	Ensaio						Midilli <i>et al.</i>		Lewis	Page		Lei de Fick
	T (°C)	V (m/s)	a	b	k	n	k	k	n	D _{ef} (m ² /s)		
1 (741)	80	0,9	0,97890	0,00004	0,01763	1,27184	0,04405	0,02050	1,23011	1,53898x10 ⁻⁹		
2 (1342)	80	0,5	1,00082	0,00003	0,01035	1,24476	0,02623	0,01072	1,23323	0,91530x10 ⁻⁹		
3 (516)	120	0,9	1,00299	0,00007	0,02303	1,32871	0,06080	0,02324	1,32206	2,12848x10 ⁻⁹		
4 (483)	120	0,5	0,97789	0,00008	0,02138	1,37444	0,06491	0,02590	1,31407	2,27076x10 ⁻⁹		
5 (828)	100	0,7	1,00964	0,00004	0,01819	1,24273	0,04072	0,01755	1,24817	1,42083x10 ⁻⁹		
6 (751)	100	0,7	0,98270	0,00004	0,01759	1,27247	0,04406	0,02048	1,23042	1,53939x10 ⁻⁹		
7 (823)	100	0,7	1,00912	0,00006	0,01867	1,27248	0,04490	0,01461	1,33225	1,56818x10 ⁻⁹		
8 (664)	110	0,6	0,98666	0,00000	0,01621	1,34578	0,05064	0,01701	1,33652	1,79177x10 ⁻⁹		

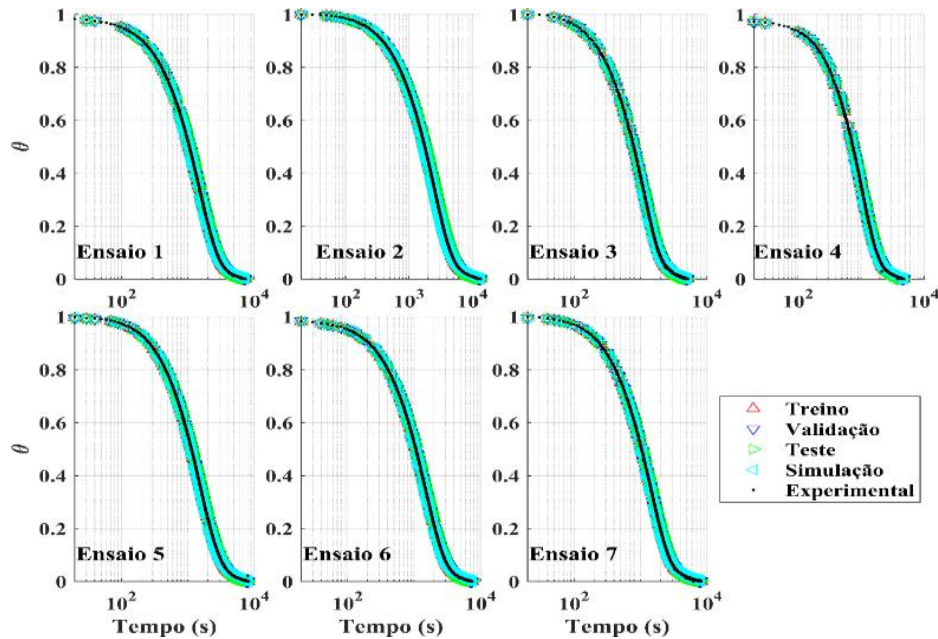


Figura 2: Saídas previstas da RNA em comparação com valores experimentais para os sete ciclos de secagem, utilizando o modelo 1 da estrutura 1541

A partir dos resultados experimentais, realizou-se a análise de regressão com o objetivo de ajustar os modelos matemáticos das curvas de secagem. A Tabela 1 apresenta os valores dos parâmetros dos modelos de Midilli *et al.* (2002), Page (1949), e Lewis (1921), para os sete ensaios de secagem, além do modelo fenomenológico, em que o coeficiente de difusividade efetiva (D_{ef}) foi estimado para cada ensaio de secagem.

Analisando os resultados da Tabela 1, observou-se que os valores de D_{ef} permaneceram na ordem de 10^{-9} a 10^{-11} m^2/s , típicos para alimentos (Rizvi, 2005). Os resultados são semelhantes aos obtidos por Kian-Pour e Karatas (2019), que estudaram a influência da geometria (quadrada, circular e triangular) e tamanho das amostras na cinética de secagem de maçãs e reportaram valores do coeficiente de difusividade entre $1,93 \times 10^{-9}$ e $2,85 \times 10^{-9}$ m^2/s .

Redes Neurais Artificiais

A partir da combinação de todos os valores possíveis para os hiperparâmetros selecionados, um total de 1960 estruturas foram treinadas e tiveram seus desempenhos avaliados. A Tabela 2 contém um resumo dos resultados das seis redes que apresentaram os melhores resultados. Essa tabela apresenta a

estrutura com as funções de ativação e quantidade de neurônios, o algoritmo de aprendizagem, e as médias e desvio padrão do MSE obtidos na validação cruzada, para os dados de treinamento, validação, teste e simulação.

Observou-se que as RNAs apresentaram erros na ordem de 10^{-7} . A estrutura 1541, em negrito (Tabela 2), utilizando 5 neurônios na camada intermediária e funções de ativação do tipo linear saturada (entrada) e linear (saída), foi a que apresentou o menor desvio de valores de MSE para todos os dados, em todos os modelos, além das menores médias de MSE. Essa rede foi selecionada como a melhor, e os resultados obtidos com esta estrutura são mostrados na sequência.

A Figura 2 ilustra o desempenho da RNA para o primeiro modelo da estrutura 1541. O desempenho da predição da RNA dos outros quatro modelos dessa estrutura foram muito semelhantes. Constatou-se que, para todos os dados de entrada (treino, validação, teste e simulação), os resultados previstos pela RNA se aproximaram dos valores experimentais, para todos os sete ensaios. A eficiência é comprovada pela Figura 3, na qual é possível observar um ajuste preciso entre a curva gerada pela RNA e os valores experimentais.

Tabela 2: Resumo das melhores RNAs encontradas.

ID	Funções de ativação (neurônios)	Algoritmo	Treino $\mu \pm \sigma$	validação $\mu \pm \sigma$	Teste $\mu \pm \sigma$	Simulação $\mu \pm \sigma$	Total $\mu \pm \sigma$
1541	Satlin-purelin (4-5-1)	Bayesian	$8,03 \times 10^{-7} \pm 1,17 \times 10^{-7}$	$8,3 \times 10^{-7} \pm 3,41 \times 10^{-7}$	$8,24 \times 10^{-7} \pm 2,62 \times 10^{-7}$	$8,24 \times 10^{-7} \pm 2,24 \times 10^{-7}$	$8,2 \times 10^{-7} \pm 1,16 \times 10^{-8}$
354	Radbas-purelin (4-20-1)	Levenberg Marquardt	$7,42 \times 10^{-7} \pm 7,32 \times 10^{-8}$	$6,03 \times 10^{-7} \pm 1,25 \times 10^{-7}$	$5,45 \times 10^{-7} \pm 3,45 \times 10^{-8}$	$8,42 \times 10^{-7} \pm 1,91 \times 10^{-7}$	$6,83 \times 10^{-7} \pm 1,34 \times 10^{-7}$
304	Logsig-satlins (4-20-1)	Levenberg Marquardt	$6,35 \times 10^{-7} \pm 6,44 \times 10^{-8}$	$8,19 \times 10^{-7} \pm 3,77 \times 10^{-7}$	$8,42 \times 10^{-7} \pm 4,11 \times 10^{-7}$	$7,8 \times 10^{-7} \pm 2,23 \times 10^{-7}$	$7,69 \times 10^{-7} \pm 9,29 \times 10^{-8}$
445	Radbas-satlins (4-25-1)	Levenberg Marquardt	$7,29 \times 10^{-7} \pm 9,52 \times 10^{-8}$	$5,46 \times 10^{-7} \pm 4,93 \times 10^{-8}$	$7,51 \times 10^{-7} \pm 2,75 \times 10^{-7}$	$8,12 \times 10^{-7} \pm 2,15 \times 10^{-7}$	$7,1 \times 10^{-7} \pm 1,15 \times 10^{-7}$
353	Radbas-purelin (4-15-1)	Levenberg Marquardt	$7,34 \times 10^{-7} \pm 8,8 \times 10^{-8}$	$8,73 \times 10^{-7} \pm 4,4 \times 10^{-7}$	$5,38 \times 10^{-7} \pm 5,37 \times 10^{-8}$	$7,95 \times 10^{-7} \pm 2,29 \times 10^{-7}$	$7,35 \times 10^{-7} \pm 1,43 \times 10^{-7}$
233	Tansig-satlins (4-15-1)	Levenberg Marquardt	$6,65 \times 10^{-7} \pm 1,05 \times 10^{-7}$	$7,84 \times 10^{-7} \pm 2,22 \times 10^{-7}$	$7,68 \times 10^{-7} \pm 2,4 \times 10^{-7}$	$7,46 \times 10^{-7} \pm 2,2 \times 10^{-7}$	$7,41 \times 10^{-7} \pm 5,31 \times 10^{-8}$

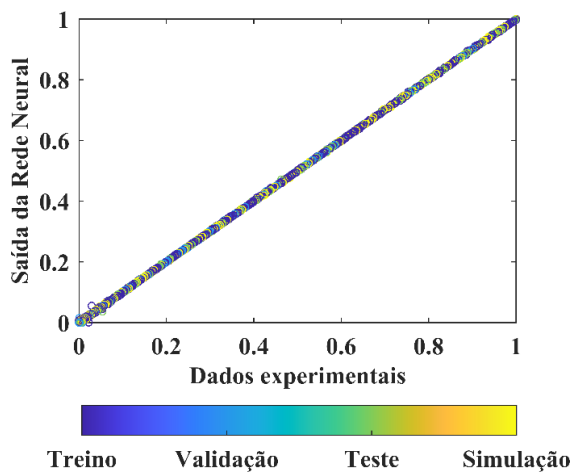


Figura 3: Curva de regressão entre a saída da RNA e os valores experimentais de θ , para o modelo 1 da estrutura 1541

A Figura 4 mostra o gráfico tipo violino para os erros absolutos entre a predição da RNA e o valor experimental de θ , para os cinco modelos obtidos na validação cruzada. Mais de 90% das predições apresentaram erros absolutos menores que 1×10^{-3} . Independente do modelo, os valores de RSD, média e mediana do erro absoluto foram baixos e próximos, indicando que o ajuste da cinética de secagem por meio de um modelo de RNA possui uma alta capacidade de generalização e adaptação,

possuindo boa precisão para a estimativa de novos valores de θ em condições de temperatura entre 80 e 120 °C e velocidade entre 0,5 m/s e 0,9 m/s.

Um ensaio experimental extra (ensaio 8) foi realizado a uma temperatura do ar de 110 °C e velocidade de 0,6 m/s. Esses valores são diferentes daqueles utilizados nos sete ensaios anteriores. Neste caso, objetivou-se determinar o desempenho da RNA previamente treinada a partir dessa nova condição operacional e além disto, pôde-se avaliar a performance em condições experimentais intermediárias à faixa de aplicação da RNA treinada. A Figura 5 ilustra a simulação da melhor RNA treinada para o ensaio 8. Como se pode observar, semelhantemente aos outros 7 ensaios, os valores previstos de θ se aproximaram aos dados experimentais satisfatoriamente. A Figura 6 apresenta a curva de regressão obtida para o Ensaio 8, com um coeficiente de correlação de 0,99999. Para este ensaio, a média do erro absoluto foi $7,72 \times 10^{-4}$, mediana igual a $5,44 \times 10^{-4}$ e RSD igual a 0,2899. Já para as métricas de erro absoluto dos outros 7 ensaios, a média, mediana e RSD foram iguais a $8,22 \times 10^{-4}$, $5,70 \times 10^{-4}$ e 0,7494, respectivamente.




Figura 4: Plotagem de violino para os erros absolutos obtidos em cada subconjunto da validação cruzada

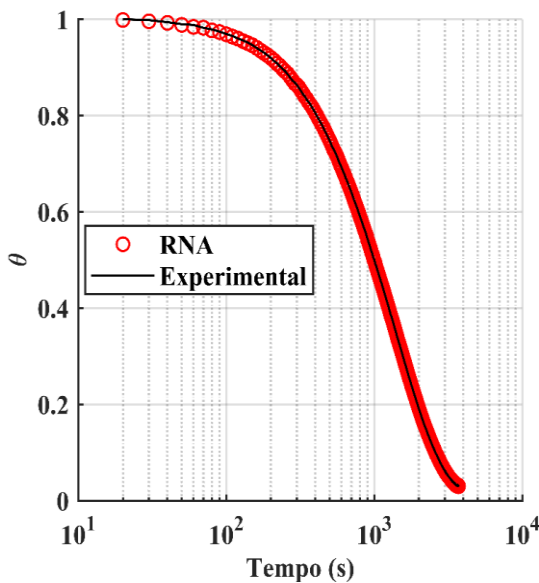


Figura 5: evolução temporal de θ para o oitavo ensaio, na condição de temperatura de 110 °C e velocidade de 0,6 m/s

RNA treinada apresentou elevado desempenho e capacidade de generalização, além de robustez para realizar previsões em condições de temperatura na faixa entre 80 °C e 120 °C e velocidade na faixa entre 0,5 m/s e 0,9 m/s.

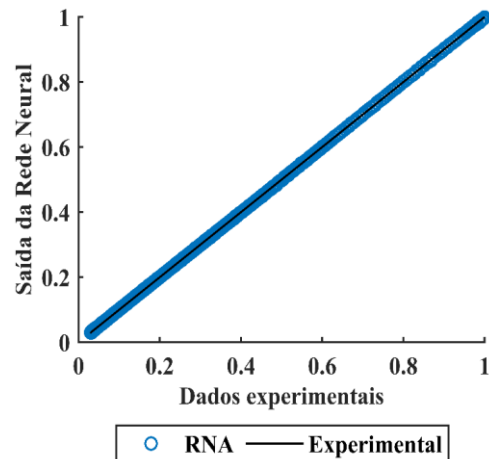


Figura 6: curva de regressão para o ensaio 8

Embora a previsão da RNA tenha sido avaliada a partir de uma condição de temperatura e velocidade que não foi utilizada na etapa de obtenção e validação cruzada, os erros absolutos foram menores no ensaio 8 em comparação com as métricas obtidas dos ensaios 1 a 7. A Figura 7 ilustra a comparação dos erros absolutos para todos os ensaios. Com essas observações, pode-se considerar que a

Comparação Estatística Entre Os Modelos

As Tabelas 3 e 4 apresentam os valores dos coeficientes de determinação (R^2), qui-quadrado reduzido χ^2 e erro quadrático médio (RMSE) para cada um dos ensaios. A Tabela 3 apresenta os valores para os modelos empíricos obtidos da literatura, e a Tabela 4 contém os valores para o modelo fenomenológico e o modelo de RNA.




Figura 7: Erros absolutos obtidos pela predição com RNA para os sete ensaios utilizados no treinamento e o oitavo ensaio de validação em novas condições experimentais

Tabela 3: Resultados estatísticos obtidos para os modelos empíricos.

N	Ensaio			Midilli <i>et al.</i>			Lewis			Page	
	T (°C)	V (m/s)	RMSE ($\times 10^3$)	R ²	χ^2 ($\times 10^5$)	RMSE ($\times 10^2$)	R ²	χ^2 ($\times 10^4$)	RMSE ($\times 10^3$)	R ²	χ^2 ($\times 10^5$)
1	80	0,9	3,2277	0,99985	1,0474	2,6639	0,98966	7,1057	4,4371	0,99971	1,9740
2	80	0,5	3,6851	0,99980	1,3621	2,6170	0,98970	6,8535	5,0861	0,99961	2,5907
3	120	0,9	4,8001	0,99939	2,3225	3,6250	0,96500	13,1661	5,8327	0,99909	3,4152
4	120	0,5	4,4547	0,99973	2,0009	3,5261	0,98318	12,4589	6,6988	0,99945	4,1114
5	100	0,7	3,0997	0,99986	0,9654	2,8199	0,98852	7,9614	4,7840	0,99967	2,2943
6	100	0,7	2,9550	0,99987	0,8779	2,6668	0,98964	7,1211	4,4133	0,99972	1,9529
7	100	0,7	4,6464	0,99967	2,1694	4,1629	0,98673	8,6860	10,1189	0,99843	10,2640
8	110	0,6	8,6376	0,99918	1,5685	4,8394	0,97425	4,8455	8,76237	0,99915	1,5885

Tabela 4: Resultados estatísticos obtidos para os modelos fenomenológico e RNA.

N	Ensaio			Fenomenológico			Redes Neurais Artificiais		
	T (°C)	V (m/s)	RMSE ($\times 10^2$)	R ²	χ^2 ($\times 10^3$)	RMSE ($\times 10^3$)	R ²	χ^2 ($\times 10^6$)	
1	80	0,9	5,8295	0,95048	3,4073	1,0161	0,99999	1,0759	
2	80	0,5	5,7458	0,95035	3,3064	0,6466	1,00000	0,4276	
3	120	0,9	6,9069	0,93647	4,7890	1,9510	0,99997	4,0413	
4	120	0,5	6,7200	0,93892	4,5346	2,0188	0,99997	4,3454	
5	100	0,7	6,0484	0,94718	3,6671	1,2283	0,99999	1,5653	
6	100	0,7	5,8302	0,95047	3,4082	0,9471	0,99999	0,9343	
7	100	0,7	5,9973	0,94499	3,6056	1,5192	0,99998	2,3954	
8	110	0,6	8,9424	0,91213	8,0392	0,9486	1,00000	0,9792	

Verificou-se que o modelo de Midilli *et al.* (2002) foi o modelo empírico que mais se adequou às curvas de secagem obtidas experimentalmente para os caroços moídos de açaí, apresentando resultados mais próximos de zero para o erro médio e para o chi-quadrado e, mais próximos de um para o R^2 . Este mesmo modelo também foi considerado o modelo mais adequado por Costa (2018) para a secagem em estufa dos resíduos inteiros de açaí e por Kian-Pour e Karatas (2019) para a secagem de pedaços de maçãs.

Comparando os modelos empíricos e fenomenológico com o modelo via RNA, a partir dos parâmetros estatísticos, observou-se que a RNA apresentou um desempenho superior aos demais modelos.

Sharabiani *et al.* (2021) utilizaram RNAs para modelar a secagem convectiva de maçãs, obtendo valores de R^2 igual a 0,9993 para a etapa de treino e 0,9994 para a etapa de teste. O melhor modelo empírico obtido foi de Midilli *et al.* (2002), com R^2 na faixa de 0,9998-0,9999. Sarkar *et al.* (2020) utilizaram as RNAs para a modelagem da cinética de secagem de abacaxis em secador convectivo, obtendo R^2 igual a 0,99936. Onwude *et al.* (2016) encontraram um valor de R^2 igual a 0,902 com o uso de RNAs para a modelagem de cinética de secagem de abóbora. Kirbas *et al.* (2019) obtiveram valores de R^2 na faixa de 0,99656-0,99948, modelando a cinética de secagem convectiva de pomelo com RNAs. A fins de comparação, em nosso trabalho, obtiveram-se valores de R^2 na faixa de 0,99997-1,00000 com o uso de RNAs.

CONCLUSÕES

Neste estudo, avaliou-se o desempenho de Redes Neurais Artificiais na obtenção de um sensor virtual neural capaz de prever a cinética de secagem de caroços moídos de açaí em leito fixo. A partir dos dados experimentais de sete ensaios de secagem, um total de 1960 estruturas foram treinadas, validadas e testadas. Constatou-se que uma RNA com uma camada intermediária, 5 neurônios na camada intermediária, treinada com as funções de ativação *satlin* e *purelin* e com o algoritmo de treinamento Levenberg-Marquardt com regularização Bayesiana apresentou os melhores resultados de desempenho.

Foi encontrado um excelente desempenho da RNA ao simular a cinética de secagem do ensaio em condições não treinadas, mas dentro da faixa de condições operacionais usadas nesta etapa. Portanto, a RNA apresentou uma elevada capacidade de generalização, além de robustez para realizar previsões em condições de temperatura na faixa entre 80 °C e 120 °C e velocidade na faixa entre 0,5 m/s e 0,9 m/s.

Avaliando-se os resultados dos parâmetros estatísticos (coeficientes de determinação, qui-quadrado reduzido e erro quadrático médio), para os modelos empíricos e fenomenológico e a RNA, constatou-se que o modelo via RNA apresentou um desempenho superior aos demais modelos, confirmando a eficiência de utilização deste tipo de modelagem quando os modelos tradicionais não apresentam um bom desempenho.

NOMENCLATURA

a	Constante do modelo de Midilli <i>et al.</i>	(-)
b	Constante do modelo de Midilli <i>et al.</i>	(-)
$b^{(1)}$	Vetor de bias para os neurônios da camada intermediária	(-)
$b^{(2)}$	Vetor de bias para a camada de saída	(-)
D_{ef}	Coefficiente de difusividade	(m ² /s)
$f_{(1)}$	Função de ativação para os neurônios da camada intermediária	(-)
$f_{(2)}$	Função de ativação para a camada de saída	(-)
k	Constante dos modelos empíricos	(-)
L	Semi espessura da placa	(m)
MSE	Erro quadrático médio-função objetivo	(-)
n	Constante dos modelos de Page e Midilli <i>et al.</i>	(-)
N	Quantidade de pontos experimentais.	(-)
RMSE	Erro quadrático médio reduzido	(-)
RSD	Desvio padrão residual	(-)
R^2	Coefficiente de determinação	(-)
t	Tempo	(s)
T	Temperatura do ar	(°C)
V	Velocidade do ar	(m/s)

$W^{(1)}$	Matriz de pesos entre a entrada e a camada intermediária	(-)
$W^{(2)}$	Matriz de pesos entre a camada intermediária e a saída	(-)
x	Vetor entrada na RNA	(-)
X	Umidade em base seca	(kg/kg)
X_{eq}	Umidade de equilíbrio	(kg/kg)
X_o	Umidade inicial em base seca	(kg/kg)
χ^2	Qui-quadrado reduzido	(-)
y	Valor experimental	(-)
\hat{y}	Saída predita pela RNA	(-)
\bar{y}	Média dos valores experimentais	(-)
z	Quantidade de constantes no modelo	(-)
θ	Adimensional de umidade	(-)
μ	Média da função objetivo entre os modelos	(-)
σ	Desvio padrão da função objetivo entre os modelos	(-)

REFERÊNCIAS

- AVILA, J. F. G. (2010), Manual do secador de bandejas, Acesso em: 30/06/2022, Disponível em: <www.ebah.com.br>.
- BENSEDDIK, A.; AZZI, A.; DJEMOUI, L.; BENSABA, H.; ZIDOUNE, M.; ALLAF, K. (2020), Empirical Mathematical Model to Evaluate the Effective Diffusivity of Pumpkin Slice During Forced Air Convection Dryer, Anais do 1st International Conference on Renewable Energy and Energy Conversion, Orão, Argélia.
- BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. (2000), Redes Neurais Artificiais: Teoria e Aplicações, LTC – Livros Técnicos e Científicos, Rio de Janeiro, RJ.
- CAMARGO, L. L. D. D.; SOUZA, L. F. G. D.; NITZ, M. (2019), Study of Tray and Pulsed Fluidized Bed Drying of Brewer's Spent Grain, Chemical Industry and Chemical Engineering Quarterly, Vol. 25, p. 229-237.
- CHOI, Y.; YOON, S. (2020), Virtual sensor-assisted in situ sensor calibration in operational HVAC systems, Building and Environment, Vol. 181.
- CORDEIRO, M. A.; ALMEIDA, O.; RODRIGUES, E. M. S. R.; NETO, A. M. J.; MACHADO, N. T. (2019), Produção de Etanol Através da Hidrólise Enzimática do Caroço de Açaí (*Euterpe oleracea* Mart), Revista Brasileira de Energias Renováveis, Vol. 8, p. 122- 152.
- CORDEIRO, T. E. A.; ALMEIDA PAULA, C. C.; SOUSA, D. R.; AMORIM, M. S. (2017), Aproveitamento do caroço do açaí como fonte de energia térmica para as olarias do município de Bragança Pará, Anais do VIII Congresso Brasileiro de Gestão Ambiental, p. 1-8, Campo Grande, MS.
- COSTA, R. L. T.; NASCIMENTO, R. A.; ARAÚJO, R. C. S.; SANTANA, E. B.; AZEVEDO, C. A.; ANDRADE, E. L.; FARIA, L. J. G. (2018), Influência da Umidade no Poder Calorífico de Caroscos de Açaí, Anais do 58º Congresso Brasileiro de Química, São Luís, MA.
- DANTAS, G. G.; FUJITA, F. M.; BRAGA, M. B.; MARTINS, T. D. (2021), Aspectos energéticos do processo de secagem da mistura de leite concentrado com polpa de amora preta em *spray dryer*: predição via redes neurais artificiais, Anais do I Web Encontro Nacional de Engenharia Química-WENDEQ, p. 1-8, *online*.
- DHURVE, P.; ARORA, V. K.; YADAV, D. K.; MALAKAR, S. (2022), Drying kinetics, mass transfer parameters, and specific energy consumption analysis of watermelon seeds dried using the convective dryer, Materials Today: Proceedings, Vol. 59, p. 926-932.
- KIAN-POUR, N.; KARATAS, S. (2019), Impact of Different Geometric Shapes on Drying Kinetics and Textural Characteristics of Apples at Temperatures Above 100 °C, Heat and Mass Transfer, Vol. 55, p. 3721-3732.
- KIRBAS, I.; TUNCER, A. D.; SIRIN, C.; USTA, H. (2019), Modeling and developing a smart interface for various drying methods of pomelo fruit (*Citrus maxima*) peel using machine learning approaches, Computers and Electronics in Agriculture, Vol. 165.
- LEHN, D. N.; PINTO, L. A. A. (2004), Isotermas de Equilíbrio e Curvas de Secagem para o Arroz em Casca em Silos

- e Armazenagem, Engenharia da Agricultura, Vol. 12, p. 177-191.
- LELES, M. G.; MARTINS, T. D.; SILVA, C. A. M. (2021), Otimização de redes neurais artificiais para modelagem de processos de umedecimento e secagem em leite fluidizado, Anais do I Web Encontro Nacional de Engenharia Química.
- LEWIS, W. K. (1921), The Rate of Drying of Solid Materials, The Journal of Industrial and Engineering Chemistry, Vol. 13, p. 427-432.
- MIDILLI, A.; KUCUK, H.; YAPAAR, Z. A. (2002), A New Model for Single-Layer Drying, Drying Technology, Vol. 20, p. 1503-1513.
- NADERINEZHAD, S.; ETESAMI, N.; NAJAFABADY, A. P.; FALAVARJANI, M. G. (2015), Mathematical modeling of drying of potato slices in a forced convective dryer based on important parameters, Food Science & Nutrition, Vol. 4, p. 110-118.
- OLIVEIRA, M. D. S. P.; CARVALHO, J. E. U.; NASCIMENTO, W. M. O. (2000), Açai (*Euterpe oleracea* Mart.), Ministério da Agricultura, Pecuária e Abastecimento, Circular Técnica, p. 1-19.
- ONWUDE, D. I.; HASHIM, N.; JANIUS, R. B.; NAWI, N.; ABDAN, K. (2016), Modelling the convective drying process of pumpkin (*Cucurbita moschata*) using an artificial neural network, International Food Research Journal, Vol. 23, p. 237-243.
- PAGE, G. E. (1949), Factors Influencing the Maximum Rates of Air-Drying Shelled Corn in Thin Layers, Purdue University - West Lafayette, (Thesis M. Sc.).
- REIS, B. O.; SILVA, I. T.; SILVA, I. M. O. (2002), Produção de briquetes energéticos a partir de caroços de açaí, Anais do 4º ENCONTRO DE ENERGIA NO MEIO RURAL, Campinas, SP.
- RIZVI, S. S. H. (2005), Thermodynamic Properties of Foods in Dehydration, In: RAO, M. A.; RIZVI, S. S. H.; DATTA, A. K.: Engineering Properties of Foods, Taylor and Francis Group, Boca Raton.
- ROGEZ, H. (2000), Açai: Preparo, Composição e Melhoramento da Conservação, Editora Universidade Federal do Pará, Belém.
- RUHANIAN, S.; MOVAGHARNEJAD, K. (2016), Mathematical modeling and experimental analysis of potato thin-layer drying in an infrared-convective dryer, Engineering in Agriculture, Environment and Food, Vol. 9, p. 84-91.
- SABANOVIC, E.; KOJIS, P.; SUKEVICIUS, S.; SHYROKAU, B.; IVANOV, V.; DHAENS, M.; SKRICKIJ, V. (2021), Feasibility of a Neural Network-Based Virtual Sensor for Vehicle Unsprung Mass Relative Velocity Estimation, Sensors, Vol. 21, 7139.
- SARKAR, T.; SALAUDDIN, M.; HAZRA, S. K.; CHAKRABORTY, R. (2020), Artificial neural network modelling approach of drying kinetics evolution for hot air oven, microwave, microwave convective and freeze-dried pineapple, SN Applied Sciences, Vol. 2.
- SHARABIANI, V. R.; KAVEH, M.; ABDI R.; SZYMANEK M., TANAS, W. (2021), Estimation of moisture ratio for apple drying by convective and microwave methods using artificial neural network modeling, Scientific reports, Vol. 11.
- SILVA, C. A. M.; BUTZGE, J. J.; NITZ, M.; TARANTO, O. P. (2014), Monitoring and Control of Coating and Granulation Processes in Fluidized Beds – A review. Advanced Powder Technology, Vol. 25, p. 195-210.
- SILVA, L. T. A. D.; PANTOJA, C. L. G.; OLIVEIRA, D. E. C. M.; HOFSTATTER, G. A.; SANTOS, A. P. S. (2018), Caroço de açaí como fonte alternativa de energia e redução de impactos ambientais no Pará, Anais do XVI ENEEAMB & IV FLAES, Palmas, TO.
- TOWLER, G.; SINNOTT, R. (2008), Chemical Engineering Design: Principles, Practice and Economics of Plant and Process Design, Burlington.
- TOWNSEND, C. R.; COSTA, N. L.; PEREIRA, R. G. A.; SENGER, C. C. D. (2001), Características Químico-Bromatológica do Caroço de Açai, Embrapa, Comunicado Técnico n. 193, p. 1-6.