UNIVERSIDADE ESTADUAL PAULISTA "JÚLIO DE MESQUITA FILHO"

INSTITUTO DE QUÍMICA – UNESP ARARAQUARA

BEATRIZ HADDAD REGONHA

UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA ESTUDAR O PROCESSO DE SECAGEM DE BANANA E ABACATE

ARARAQUARA

2021

BEATRIZ HADDAD REGONHA

UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA ESTUDAR O PROCESSO DE SECAGEM DE BANANA E ABACATE

Trabalho de conclusão de curso de graduação apresentado ao Instituto de Química da Universidade Estadual Paulista "Júlio De Mesquita Filho" como parte dos requisitos para obtenção do grau de Bacharel em Engenharia Química.

Orientadora: Prof.ª Dr. ª Érica Regina Filletti Nascimento

ARARAQUARA

2021

BEATRIZ HADDAD REGONHA

UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA ESTUDAR O PROCESSO DE SECAGEM DE BANANA E ABACATE

Trabalho de conclusão de curso de graduação apresentado ao Instituto de Química da Universidade Estadual Paulista "Júlio De Mesquita Filho" como parte dos requisitos para obtenção do grau de Bacharel em Engenharia Química.

Aprovado em: 03/03/2021

BANCA EXAMINADORA

Érica Filletti

Profa. Dra. Érica Regina Filletti Nascimento

Instituto de Química – UNESP, Araraquara

Lorena Oliveira Pires

Profa. Dra. Lorena Oliveira Pires

Instituto de Química – UNESP, Araraquara

Gustavo N. Alves Vieira

Prof. Dr. Gustavo Nakamura Alves Vieira

Instituto de Química – UNESP, Araraquara

AGRADECIMENTOS

Em primeiro lugar agradeço à minha família, que sempre me apoiou ao longo de todos esses anos. Agradeço em especial aos meus pais Jussara e Robson por todo amor incondicional e incentivo, que serviram de alicerce para as minhas realizações.

Agradeço aos amigos que fiz durante os anos de graduação, que sempre estiveram ao meu lado e que me proporcionaram tantos momentos memoráveis ao longo desses anos.

Agradeço também a todos os professores que contribuíram com a minha formação acadêmica e profissional durante a minha vida. Em especial, à minha orientadora do Trabalho de Conclusão de Curso, Professora Dra. Érica Regina Filletti Nascimento cuja dedicação e paciência fizeram grande diferença no resultado final deste trabalho, e à Professora Dra. Lorena Oliveira Pires, por toda ajuda e atenção que foram essenciais para a realização desse projeto.

Por último, agradeço ao Instituto de Química – UNESP Araraquara pela infraestrutura e elevada qualidade do ensino oferecido e à Reitoria da UNESP pela bolsa de iniciação científica recebida durante o desenvolvimento desse trabalho.

RESUMO

Uma rede neural artificial (RNA) pode ser definida como um conjunto de funções matemáticas com uma estrutura de processamento que consistem em uma série de técnicas computacionais que apresentam um comportamento específico de entrada/saída e que podem ser implementadas em dispositivos eletrônicos. A capacidade dessa ferramenta de reconhecer padrões através de um determinado conjunto de dados permitiu sua utilização no estudo do processo de secagem de frutas partindo de dados coletados experimentalmente. Os gráficos gerados comparando os valores estimados pelas redes neurais e os valores esperados apresentaram coeficientes de correlação na faixa de 0,9 a 1. Os erros relativos médios variaram entre 0,20% e 1,5% para a umidade e a massa, enquanto para o fluxo mássico apresentaram valores maiores, entre 2% e 45% (45% no caso do abacate). Esses valores altos para os erros do fluxo mássico podem ser explicados pelos baixos valores de fluxo, principalmente no final do ensaio, fazendo com que os valores encontrados pela rede, mesmo que com uma pequena diferença absoluta, apresentassem erros relativos altos. Com isso, os resultados adquiridos no presente trabalho foram satisfatórios, principalmente no caso da banana, indicando que essa técnica pode ser utilizada para prever resultados do processo de secagem em diversas condições.

Palavras-chave: Redes neurais artificiais, processo de secagem, umidade.

ABSTRACT

An artificial neural network (ANN) can be defined as a set of mathematical functions with a processing structure that consists of a series of computational techniques that exhibit specific input / output behavior and that can be implemented in electronic devices. The ability of this tool to recognize patterns through a given set of data uses its use in the study of the drying process of fruits based on data collected experimentally. The graphs generated comparing the values estimated by the neural networks and the expected values of correlation coefficients in the range of 0.9 to 1. The average relative errors vary between 0.20% and 1.5% for humidity and mass, while for the mass flow higher values, between 2% and 45% (45% in the case of avocado). These high values for the mass flow errors can be explained by the low flow values, mainly at the end of the test, making the values found by the network, even with a small absolute difference, present high relative errors. Thus, the results obtained in the present work were satisfactory, especially in the case of bananas, indicating that this technique can be used to predict the result of the drying process under different conditions.

Keywords: Artificial neural network, drying process, moisture.

LISTA DE ILUSTRAÇÕES

Figura 1 - Modelo de processamento proposto por McCulloch e Pitts 12
Figura 2 - Modelo de neurônio não linear.....13
Figura 3 - Representação de função linear, degrau e sigmoide, respectivamente.....15
Figura 4 - Exemplo de arquitetura de rede neural de camada única (esquerda) e de múltiplas camadas (direita).....16
Figura 5 - Exemplo de conexão do tipo feedback 17
Figura 6 - Amostra de banana no final do experimento.....21
Figura 7 - Amostra de abacate no final do experimento.....21
Figura 8 – Curvas de secagem das amostras de banana em diferentes temperaturas 22
Figura 9 - Curvas de secagem das amostras de abacate em diferentes temperaturas 23
Figura 10 - Moisture ratio das amostras de banana em função do tempo para o ensaio à 50ºC 24
Figura 11 - Moisture ratio das amostras de banana em função do tempo para o ensaio à 60ºC 24
Figura 12 - Moisture ratio das amostras de banana em função do tempo para o ensaio à 70ºC 24
Figura 13 - Moisture ratio das amostras de abacate em função do tempo para o ensaio à 50ºC 25
Figura 14 - Moisture ratio das amostras de abacate em função do tempo para o ensaio à 60ºC 25
Figura 15 - Moisture ratio das amostras de abacate em função do tempo para o ensaio à 70ºC 25
Figura 16 - Valores de umidade obtidos pela rede em relação aos valores esperados para as amostras de treinamento, no caso da banana. 28
Figura 17 - Valores de fluxo mássico obtidos pela rede em relação aos valores esperados para as amostras de treinamento, no caso da banana.....29
Figura 18 - Valores de umidade obtidos pela rede em relação aos valores esperados para as amostras de validação, no caso da banana. 30
Figura 19 - Valores de fluxo mássico obtidos pela rede em relação aos valores esperados para as amostras de validação, no caso da banana.....30

Figura 20 - Valores de umidade obtidos pela rede em relação aos valores esperados para as amostras de teste, no caso da banana. 30
Figura 21 – Valores de fluxo mássico obtidos pela rede em relação aos valores esperados para as amostras de teste, no caso da banana. 31
Figura 22 – Distribuição dos erros absolutos da umidade estimada pela rede utilizada com as amostras de banana. 31
Figura 23 – Distribuição dos erros absolutos do fluxo mássico estimada pela rede utilizada com as amostras de banana. 32
Figura 24 - Histograma dos erros para o treinamento, validação e teste para a rede utilizada com as amostras de banana. 32
Figura 25 - Valores de umidade obtidos pela rede em relação aos valores esperados para as amostras de treinamento, no caso do abacate. 33
Figura 26 - Valores de fluxo mássico obtidos pela rede em relação aos valores esperados para as amostras de treinamento, no caso do abacate. 34
Figura 27 - Valores de umidade obtidos pela rede em relação aos valores esperados para as amostras de validação, no caso do abacate. 35
Figura 28 - Valores de fluxo mássico obtidos pela rede em relação aos valores esperados para as amostras de validação, no caso do abacate. 35
Figura 29 - Valores de umidade obtidos pela rede em relação aos valores esperados para as amostras de teste, no caso do abacate. 35
Figura 30 - Valores de fluxo mássico obtidos pela rede em relação aos valores esperados para as amostras de teste, no caso do abacate. 36
Figura 31 – Distribuição dos erros absolutos da umidade estimada pela rede utilizada com as amostras de abacate. 36
Figura 32 – Distribuição dos erros absolutos do fluxo mássico estimada pela rede utilizada com as amostras de abacate. 37
Figura 33 - Histograma dos erros para o treinamento, validação e teste para a rede utilizada com as amostras de abacate. 37
Figura 34 – Massa das amostras de banana encontrada em cada instante pela rede neural em relação a massa esperada para as amostras de treinamento. 38
Figura 35 - Massa das amostras de banana encontrada em cada instante pela rede neural em relação a massa esperada para as amostras de validação. 39
Figura 36 - Massa das amostras de banana encontrada em cada instante pela rede neural em relação a massa esperada para as amostras de teste. 39

Figura 37 – Distribuição dos erros absolutos para a rede utilizada com as amostras de banana. 40
Figura 38 - Histograma dos erros para o treinamento, validação e teste para a rede utilizada com as amostras de banana. 40
Figura 39 - Massa das amostras de abacate encontrada em cada instante pela rede neural em relação a massa esperada para as amostras de treinamento. 41
Figura 40 - Massa das amostras de abacate encontrada em cada instante pela rede neural em relação a massa esperada para as amostras de teste. 42
Figura 41 - Massa das amostras de abacate encontrada em cada instante pela rede neural em relação a massa esperada para as amostras de validação. 42
Figura 42 – Distribuição dos erros absolutos para a rede utilizada com as amostras de abacate. 43
Figura 43 - Histograma dos erros para o treinamento, validação e teste para a rede utilizada com as amostras de abacate. 43

SUMÁRIO

1. INTRODUÇÃO 11

1.1 Secagem de alimentos 11

1.2 Redes neurais artificiais 12

1.3 Função de ativação 14

1.4 Principais arquiteturas de RNAs 15

1.5 Método de Levenberg-Marquardt 17

1.6 Aplicação de redes neurais no processo de secagem 17

2. OBJETIVOS 20

2.1 Objetivos específicos 20

3. METODOLOGIA 21

3.1 Obtenção dos dados 21

3.2 Tratamento dos dados 22

3.3 Implementação das redes neurais 26

4. RESULTADOS E DISCUSSÃO 28

4.1 Avaliação da umidade e do fluxo mássico da banana, utilizando-se as redes neurais 28

4.2 Avaliação da umidade e do fluxo mássico do abacate, utilizando-se as redes neurais 32

4.3 Avaliação da massa da banana, utilizando-se redes neurais 38

4.4 Avaliação da massa do abacate, utilizando-se redes neurais 41

5. CONCLUSÃO 44

6. REFERÊNCIAS 45

1. INTRODUÇÃO

As Redes Neurais Artificiais (RNAs) são modelos matemáticos inspirados no sistema nervoso de seres vivos formados por um conjunto de unidades de processamento que são interligados por um enorme número de interconexões representadas por vetores/matrizes de peso sináptico. Essas técnicas computacionais usam camadas de neurônios matemáticos para processar dados, sendo cada uma um algoritmo simples e uniforme contendo um tipo de função de ativação. Sua principal vantagem é aprender através de exemplos e extrair as informações necessárias para dar respostas coerentes a dados não usados em seu treinamento. Assim, as RNAs aparecem como uma opção atrativa em relação aos modelos cinéticos tradicionais, como os empíricos e semi-teóricos, pois são de fácil implementação e fornecem respostas precisas ao problema estudado[1]. Devido a estas vantagens, optou-se por utilizar RNAs para avaliar alguns parâmetros do processo de secagem de frutas, em específico de banana e de abacate.

1.1 Secagem de alimentos

Secagem é uma operação unitária de remoção térmica de um solvente, através de um gás de arraste, que normalmente é o ar, que fornece energia para a superfície do material a ser seco fazendo com que o solvente evapore a partir do sólido para a corrente de gás. Na secagem, ocorrem dois processos simultaneamente: a transferência de calor e a transferência de massa. A transferência de calor pode ocorrer por convecção, condução, radiação ou por combinações destes[2].

A secagem é um dos métodos existentes mais antigos de preservação de alimentos, permitindo que produtos alimentícios pudessem ser estocados por maior tempo, ter um menor peso e uma menor quantidade de embalagem. Métodos mais tradicionais como a secagem ao sol eram processos muito utilizados antigamente, principalmente pela simplicidade e pelo baixo custo[3].

A modernização desse processo que buscou principalmente diminuir o longo tempo de secagem e a possibilidade de contaminação microbiota desses alimentos fez com que surgissem processos de secagem artificial, permitindo um controle mais apropriado das condições de experimento e tornando-o mais eficiente[1].

A importância dessa operação está diretamente relacionada a capacidade de armazenamento de um determinado produto por um tempo adequado sem deterioração ou sem contaminação, pois a eliminação da água livre do alimento possibilita a diminuição da proliferação de micro-organismos, diminuindo, e até mesmo bloqueando, a ação de enzimas que podem provocar alterações no produto[4].

A secagem é controlada por diversas variáveis: temperatura, umidade, direção, vazão do ar e qualquer variável que possa afetar a transferência de calor e massa e interferir na difusão do vapor da superfície do sólido para a atmosfera das redondezas através de uma película de ar em contato com a superfície[2].

A umidade de um sólido pode ser expressa em termos de base seca, que é definida como a razão entre a massa de umidade e a massa de material seco. E também pode ser expressa em base úmida, que é a relação da massa de umidade com a massa de material úmido[2].

1.2 Redes neurais artificiais

O primeiro modelo matemático artificial de um neurônio foi proposto por Warren McCulloch e Walter Pitts, em 1943, como mostra a Figura 1. Essa unidade de processamento era caracterizada por ter p valores de entrada $x_1, \dots, x_p$ multiplicados pesos sinápticos $w_1, \dots, w_p$ que indicam sua influência na saída da unidade apresentados à entrada, sendo que a ativação do neurônio é obtida através de uma função de ativação[8].

Figura 1 - Modelo de processamento proposto por McCulloch e Pitts

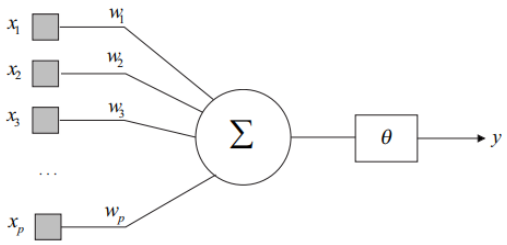

Fonte: NASCIMENTO, 2007

A atividade do neurônio apresentado por McCulloch e Pitts é caracterizada por ser binária: quando a soma do produto das entradas pelos pesos ultrapassa um determinado limiar fixo, denotado por θ, o neurônio responde com uma atividade igual

a um (ativando a saída), caso contrário o neurônio responde com uma atividade igual a zero (não ativando a saída). Sendo assim, a função de ativação desse modelo pode ser representada pela equação[9]:

$$\sum_{i=1}^{p} x_i w_i \geq \theta \qquad (1)$$

Em 1949, Donald Hebb elaborou uma teoria baseada no processo de aprendizagem que ocorre no cérebro humano que serviu de base para a aprendizagem das redes neurais[10].

Em 1957, Frank Rosenblatt propôs a primeira rede neural a se tornar popular. Nesse modelo foram desenvolvidas novas técnicas de ajuste de pesos sinápticos aprimorando a aprendizagem dos padrões de entrada e possibilitando o reconhecimento de padrões mais complexos, essa rede ficou conhecida como Perceptron[11].

Originalmente, o Perceptron consistia em três camadas: uma de unidades sensoriais, uma intermediária e uma de saída. A conectividade entre a retina e a camada associativa não é total, isso porque um neurônio específico da camada associativa recebe sinapses apenas de uma parte da retina, em contrapartida, cada neurônio da camada de saída recebe conexões sinápticas de cada neurônio da camada associativa, indicando uma conectividade total entre essas duas camadas[12].

Atualmente, os neurônios mais utilizados pelos pesquisadores na área de RNAs são os modelos de neurônio não lineares baseados no Perceptron. Esse modelo pode ser representado na Figura 2.

Figura 2 - Modelo de neurônio não linear

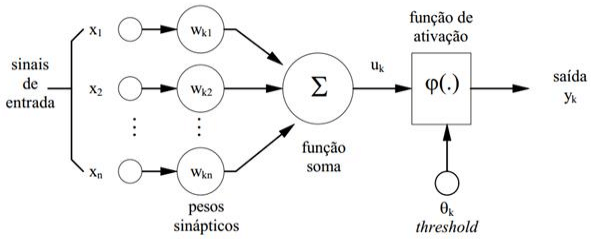

Fonte: HAYKIN, 2001

O modelo representado na Figura 2 é caracterizado por três elementos básicos:

(i) Um conjunto de sinapses contendo pesos próprios. No qual um sinal x_j, na entrada da sinapse j, conectada ao neurônio k, é multiplicado pelo seu respectivo peso w_{kj}.

(ii) Um somador responsável por somar os sinais de entrada ponderados pelos seus respectivos pesos.

(iii) Uma função de ativação, responsável por restringir a amplitude da saída do neurônio.

Além disso, esse modelo neural inclui um bias aplicado externamente, denotado por b_k, que tem o efeito de aumentar ou diminuir a entrada da função de ativação. Em termos matemáticos, o neurônio k é descrito pelas equações[13]:

$$u_k = \sum_{j=1}^{m} w_{kj} x_j \qquad (2)$$

e,

$$y_j = \varphi(u_k + b_k) \quad (3)$$

sendo x_j os sinais de entrada; w_{kj} os respectivos pesos do neurônio k; u_k a combinação linear de saída de acordo com as entradas; b_k o bias; φ a função de ativação; e y_j os sinais de saída[13].

O uso do bias tem o efeito de aplicar uma transformação na combinação linear de saída, demonstrada pela equação:

$$v_k = u_k + b_k \qquad (4)$$

1.3 Função de ativação

A função de ativação denotada por φ define a saída do neurônio em termos do potencial de ativação v_k, definindo o processamento do neurônio. Na Figura 3 estão ilustrados alguns tipos de função[13]:

Figura 3 - Representação de função linear, degrau e sigmoide, respectivamente.

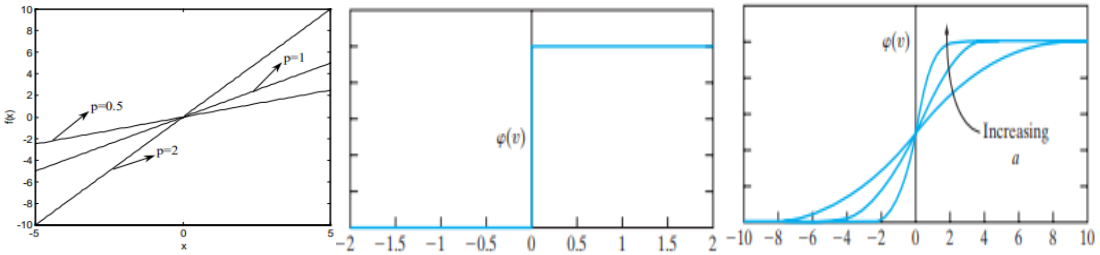

Fonte: HAYKIN, 2009

(ι) Função linear: muito utilizada nas unidades que compõem a camada de saída. A saída linear com p = 1 simplesmente repete o sinal que entra no neurônio na sua saída.

(ιι) Função degrau: o neurônio que segue a função degrau é referido como modelo McCulloch-Pitts, em reconhecimento do trabalho de McCulloch e Pitts, onde a saída do neurônio leva o valor de 1 se o potencial de ativação não for negativo e 0 se for negativo[13]. Essa função é descrita por:

$$\varphi(v) = \begin{cases} 1 \; if \; v \geq 0 \\ 0 \; if \; v < 0 \end{cases} \qquad (5)$$

(ιιι) Função sigmóide: é a forma mais comum de função de ativação utilizada na construção de redes neurais, definida por uma função estritamente crescente que mostra um balanço entre o comportamento linear e não linear. Um exemplo desse tipo de função é:

$$\varphi(v) = \frac{1}{1 + \exp(-av)} \qquad (6)$$

onde a é o parâmetro da curva da função sigmoide e alterando esse parâmetro é possível se obter funções com diferentes curvaturas.

1.4 Principais arquiteturas de RNAs

A arquitetura de uma rede depende da maneira pela qual os neurônios são estruturados e trata-se de um importante parâmetro para definir qual tipo de problema é possível tratar com a rede. Por exemplo, redes de nós MCP com uma única camada só conseguem resolver problemas linearmente separáveis. Os parâmetros que

definem a arquitetura da rede são: número de camadas da rede, número de nós em cada camada, tipo de conexão entre os nós e a topologia da rede[13].

As redes neurais podem ser organizadas em função do número de camadas, conforme ilustradas na Figura 4. Na forma mais simples de uma rede em camadas, temos uma camada de entrada de nós de origem que se liga diretamente a uma camada de saída. As redes também podem ser compostas de múltiplas camadas, que possuem camadas ocultas porque essa parte do sistema da rede neural não é vista diretamente da entrada ou da saída da rede. Os nós de origem na camada de entrada da rede fornecem os sinais de entrada aplicados aos neurônios na segunda camada e os sinais de saída dessa camada são usados como entradas para a terceira camada e assim por diante[13].

Figura 4 - Exemplo de arquitetura de rede neural de camada única (esquerda) e de múltiplas camadas (direita).

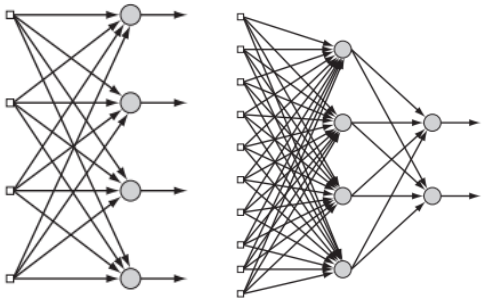

Fonte: HAYKIN, 2009

Em relação aos tipos de conexões entre os nós, podem ser:

(ι) Feedforward: a saída de um neurônio não pode ser usada como entrada de nós em camadas de índice menor ou igual a i, conforme ilustrado na Figura 4.

(ιι) Feedback: a saída de algum neurônio na i-ésima camada da rede é usada como entrada de nós em camadas de índice menor ou igual a i, conforme ilustrado na Figura 5.

Figura 5 - Exemplo de conexão do tipo feedback

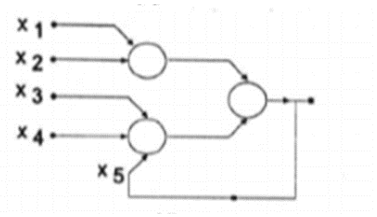

Fonte: HAYKIN, 2009

1.5 Método de Levenberg-Marquardt

O algoritmo de Levenber-Marquardt é considerado um método de segunda ordem já que se baseia em informações da derivada segunda da função erro. É caracterizado por utilizar uma aproximação do mínimo da função erro obtida introduzindo-se o parâmetro μ no método de Gauss-Newton, de acordo com a equação 7[11]:

$$\Delta x = [J^t(x)J(x) + \mu I]^{-1} J^t(x)e(x) \qquad (7)$$

sendo I é a matriz identidade, e(x) é o erro e J é a matriz Jacobiana.

O parâmetro μ ajusta a aproximação para utilizar a rápida convergência do método de Newton, funcionando como uma estabilização do treinamento e evitando possíveis erros de convergência[14]. Esse parâmetro pode ser escolhido de várias maneiras, como por exemplo escolhendo-o como zero ao menos que a matriz hessiana encontrada na iteração i seja singular, mas é importante perceber que quanto maior o valor escolhido menor a influência da informação de segunda ordem e mais este algoritmo se aproxima de um método de primeira ordem[15].

1.6 Aplicação de redes neurais no processo de secagem

A secagem é essencial na indústria alimentícia e consiste em um processo com diferentes níveis de complexidade. Os modelos físicos dinâmicos existentes resultam em equações diferenciais que requerem softwares especializados para sua manipulação e consomem muito tempo. Modelos empíricos podem ser usados para aproximar a cinética de secagem, mas podem ter uma validade mais estreita[9].

A modelagem por redes neurais tem grande vantagem por conta da sua fácil implementação e da capacidade de fornecer respostas precisas, através da

aprendizagem com exemplos. Em princípio, no presente estudo a partir dos dados coletados em diferentes condições, tentou-se estimar a massa e umidade usando como entrada as variáveis de tempo e temperatura.

Modelos matemáticos podem ser desenvolvidos para predizer certos valores desconhecidos em um processo partindo de valores conhecidos e fornecem resultados precisos para condições específicas. Os métodos empíricos, por exemplo, são baseados em dados experimentais e análises adimensionais, mostrando uma relação direta entre o teor médio de umidade e o tempo de secagem, mas que não fornece uma visão precisa dos processos que ocorrem durante o fenômeno.[20]

Os modelos semiteóricos baseados na Lei de Resfriamento de Newton aplicada à transferência de massa são muito utilizados no estudo do processo de secagem, no entanto, funcionam apenas quando a temperatura, umidade relativa, velocidade do ar e umidade estão na faixa em que os modelos são desenvolvidos. Exemplos muito utilizados desses modelos são o exponencial de dois termos e o modelo de Lewis.[20]

Os modelos cinéticos existentes não levam em consideração a interação entre os parâmetros além do tempo de secagem, por conta da complexidade do processo. Por isso, existe uma grande dificuldade de obter boas equações gerais que descrevam o processo de forma precisa. Portanto, a capacidade de aprendizagem de redes neurais e sua habilidade em aproximar funções não-lineares permite que o estudo do processo de secagem através da aplicação de RNAs apresente bons resultados[1].

A capacidade de aprendizagem de redes neurais permite que essa técnica seja uma boa opção em relação aos modelos matemáticos mais utilizados. Domenico et al. (2017) usaram RNAs para otimizar o processo de secagem de bacalhau, com o objetivo de reduzir o consumo energético. Os resultados mostraram que para minimização dos custos energéticos por hora de secagem do bacalhau os parâmetros de secagem devem ser: tempo de 71h, temperatura de 15°C, umidade relativa de 54% e velocidade de 1,5m/s[5]. Omari et al. (2018) desenvolveram modelos neurais para modelar o processo de secagem de cogumelos em secador de ar com micro-ondas para avaliar a variação do teor de umidade. Os resultados foram satisfatórios e mostraram que RNAs seriam muito adequadas em um sistema preditivo para controle de secagem[4]. Hernández-Pérez et al. (2004) realizaram um experimento de secagem em três diferentes temperaturas (50, 60 e 70°C) para avaliar o desempenho de RNAs

no estudo da transferência de umidade durante a secagem de manga e mandioca. O estudo concluiu que redes neurais apresentam bons resultados utilizando três neurônios na camada intermediária[6].

Jafari et al. (2015) provaram que redes neurais artificiais são capazes de prever a cinética de secagem das cebolas durante a secagem em leito fluidizado. Além disso, concluíram que o uso do algoritmo de treinamento Levenberg-Marquardt e RNAs de uma única camada intermediária apresentam melhores resultados no estudo da secagem de frutas e vegetais[7].

Estudos anteriores afirmam que a melhor temperatura de secagem da banana gira em torno de 70°C.[17] Segundo Medina et al. (1978), essa é a melhor temperatura de secagem da fruta e o tempo de secagem varia entre 12 a 16 horas.[16] Bansal & Garg et al. (1987), afirmam que a temperatura de secagem não deve ultrapassar de 70°C e que as condições ideais giram em torno dessa temperatura.[19]

No caso dos ensaios realizados com abacate, adotaram-se as mesmas condições utilizadas nos ensaios realizados com as bananas, usando esses como parâmetro.

2. OBJETIVOS

O principal objetivo desse trabalho foi analisar o processo de secagem de bananas e abacates através dos dados obtidos experimentalmente em diferentes condições de temperatura, utilizando redes neurais artificiais.

2.1 Objetivos específicos

Os objetivos específicos desse trabalho foram:

- Implementar redes neurais artificiais através do software MATLAB R2018a, utilizando como base de dados os dados obtidos experimentalmente, através de ensaios de secagem;

- Realizar treinamento de cada RNA por tentativa e erro para definir a quantidade de neurônios da camada intermediária, visando a menor porcentagem de erro para o conjunto de treinamento, validação e teste;

- Analisar o desempenho das redes neurais artificiais após treinamento a partir dos histogramas, coeficientes de correlação e distribuições dos erros absolutos.

3. METODOLOGIA

Neste Capítulo serão apresentados uma descrição da obtenção dos dados experimentais utilizados como base de dados das redes neurais e uma descrição da implementação das RNAs.

3.1 Obtenção dos dados

Os dados utilizados nos testes foram obtidos experimentalmente através de ensaios de secagem de 24 horas de duração com coletas a cada 5 minutos em uma estufa de convecção natural, em três temperaturas diferentes: 50, 60 e 70ºC.

Os ensaios foram feitos inicialmente em duplicata, mas para facilitar as medições, uma das placas foi descartada ao longo do processo. Após o ensaio, as amostras foram colocadas na estufa à 105 ºC por um período de 24 horas, para obter-se a massa de sólido seco. As Figuras 6 e 7 ilustram, respectivamente, uma amostra de banana e uma de abacate ao final do processo de secagem.

Figura 6 - Amostra de banana no final do experimento.

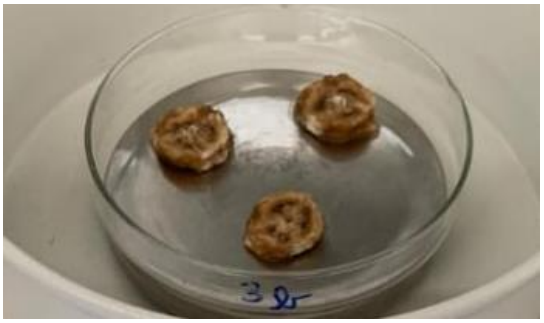

Fonte: Elaborado pelo autor, 2020.

Figura 7 - Amostra de abacate no final do experimento.

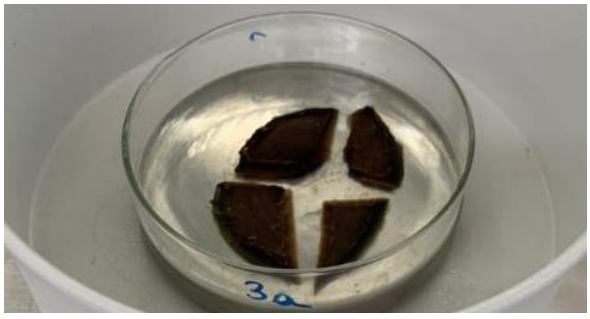

Fonte: Elaborado pelo autor, 2020.

Os dados de todos os ensaios foram utilizados como base de dados para a implementação da rede, foram utilizadas as massas de sólido úmido, a umidade de base seca e o fluxo mássico (calculado pela diferença da massa em um intervalo de tempo dividida por esse mesmo intervalo de tempo e pela área de superfície da amostra).

3.2 Tratamento dos dados

Após a coleta dos dados, foram feitas as curvas de secagem e os gráficos da taxa de umidade em função do tempo para cada temperatura para as amostras de banana e abacate.

Como os ensaios para cada temperatura foram feitos com três amostras semelhantes que foram colocadas na estufa em horários diferentes, simulando um ensaio de 24 horas, apesar do cuidado de tentar manter as massas das amostras o mais próximo possível, as curvas de secagem apresentaram degraus por conta da diferença das massas. Para corrigir essa diferença, foi feito um ajuste nos dados para se obter uma curva continua. As Figuras 8 e 9 representam as curvas de secagem (umidade de base seca em função do tempo) para as três temperaturas avaliadas para as amostras de banana e abacate, respectivamente.

Figura 8 – Curvas de secagem das amostras de banana em diferentes temperaturas

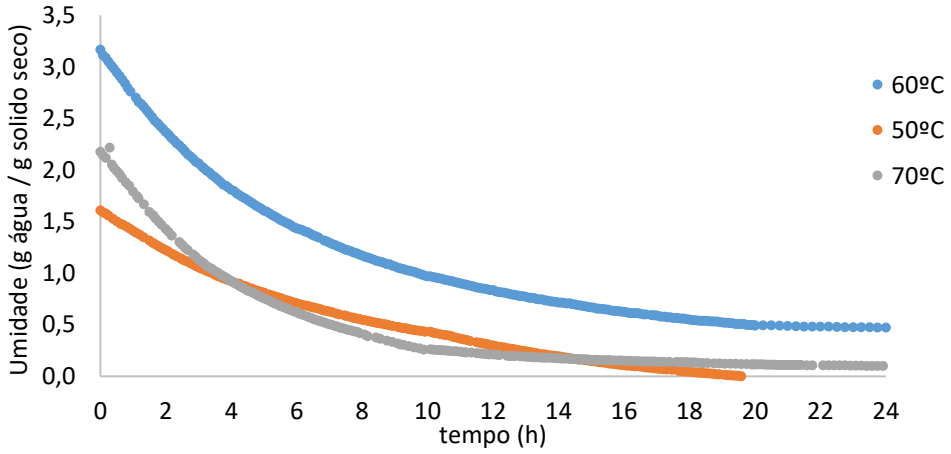

Fonte: Elaborado pelo autor, 2020.

Figura 9 - Curvas de secagem das amostras de abacate em diferentes temperaturas

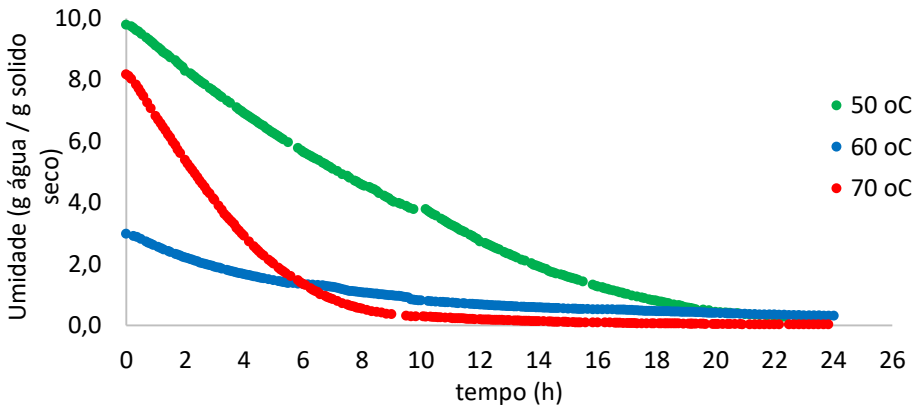

Fonte: Elaborado pelo autor, 2020.

No caso das amostras de abacate, o ensaio realizado na temperatura 60°C apresentou uma curva de secagem diferente do esperado, isso porque a curva a 60°C deveria ser mais acentuada em comparação com a de 50°C. O comportamento da velocidade em função do tempo também se mostrou diferente do esperado, não apresentando uma tendência de velocidade constante no fim do ensaio. Essa diferença pode ser explicada pelo ponto de maturação do abacate, que dificulta o manuseio da fruta e pelo fato de que nesse ensaio, o corte foi feito por uma pessoa diferente dos outros ensaios. Por isso, esses dados foram desconsiderados na implementação da rede, para que não afetassem os resultados e não foi possível refazer esse ensaio durante o ano de 2020 devido à pandemia Covid-19.

A partir das umidades também foi possível obter a umidade de equilíbrio, correspondente a umidade do final do ensaio, que foi utilizada para encontrar a taxa de umidade (*moisture ratio*) em cada ponto, através da Fórmula 8:

$$MR = \frac{X - X_e}{X_0 - X_e} \qquad (8)$$

Sendo:

X: umidade em cada ponto

X_e: umidade de equilíbrio

X_0: umidade inicial

Os gráficos da taxa de umidade (*moisture ratio*) em relação ao tempo encontrados estão ilustrados nas Figuras 10 a 15.

Figura 10 - Moisture ratio das amostras de banana em função do tempo para o ensaio à 50ºC

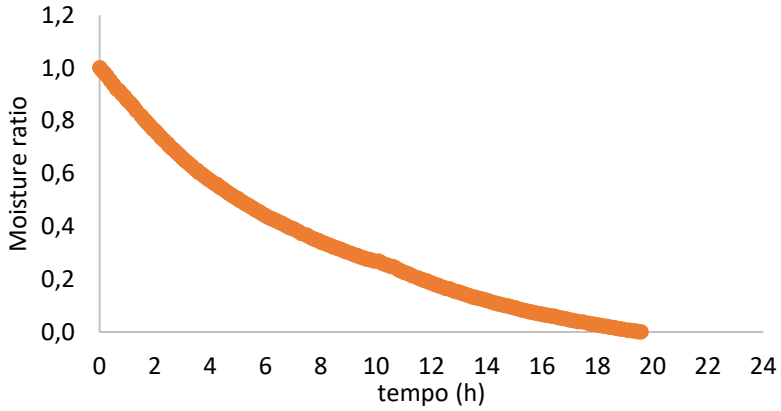

Fonte: Elaborado pelo autor, 2020.

Figura 11 - Moisture ratio das amostras de banana em função do tempo para o ensaio à 60ºC

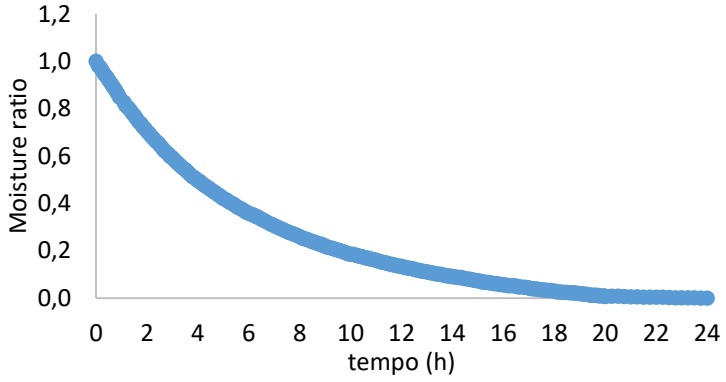

Fonte: Elaborado pelo autor, 2020.

Figura 12 - Moisture ratio das amostras de banana em função do tempo para o ensaio à 70ºC

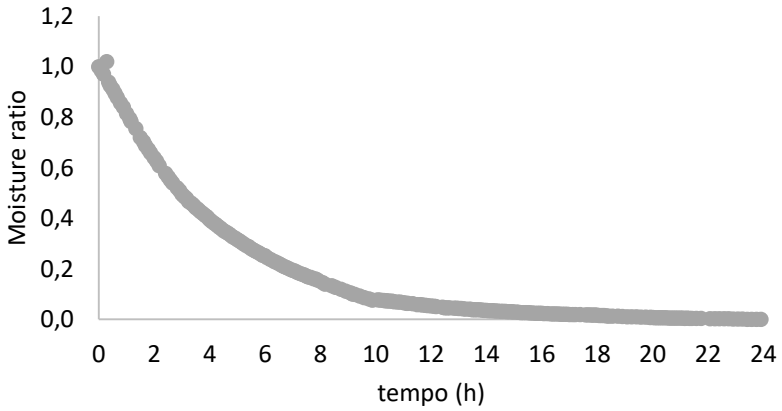

Fonte: Elaborado pelo autor, 2020.

Figura 13 - Moisture ratio das amostras de abacate em função do tempo para o ensaio à 50ºC

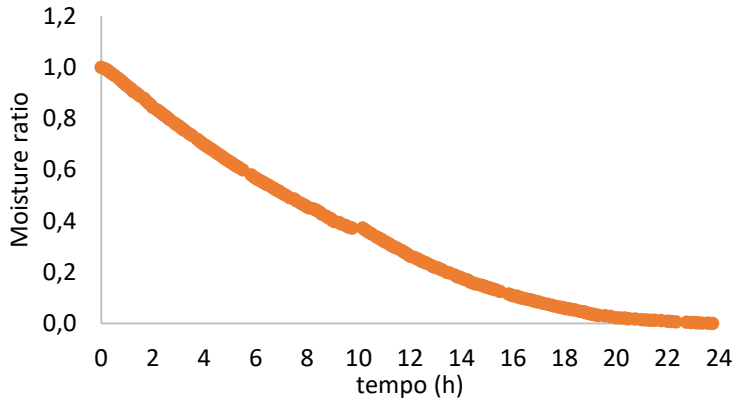

Fonte: Elaborado pelo autor, 2020.

Figura 14 - Moisture ratio das amostras de abacate em função do tempo para o ensaio à 60ºC

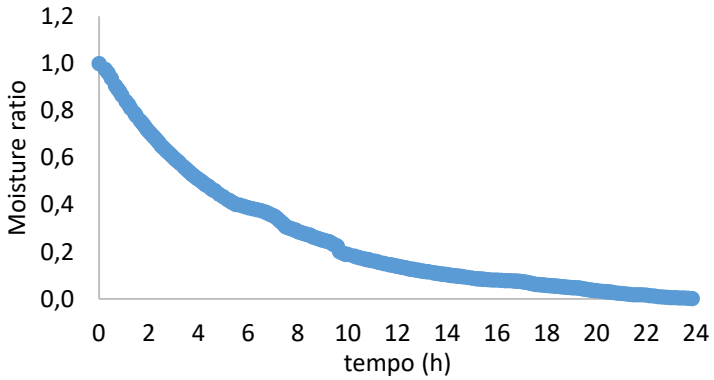

Fonte: Elaborado pelo autor, 2020.

Figura 15 - Moisture ratio das amostras de abacate em função do tempo para o ensaio à 70ºC

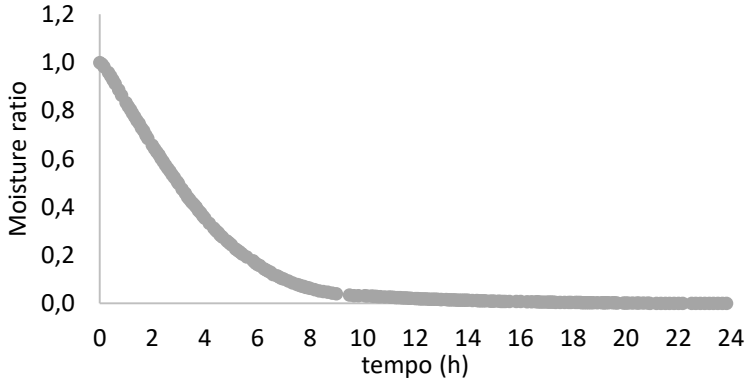

Fonte: Elaborado pelo autor, 2020.

3.3 Implementação das redes neurais

Foram criadas quatro redes neurais diferentes utilizando como dados de entrada e saída os valores coletados durante os experimentos de secagem. Sendo duas redes para avaliar o comportamento dos valores de umidade e fluxo mássico tanto do processo de secagem da banana quanto do abacate e duas redes para avaliar a variação da massa da amostra durante o processo tanto da banana quanto do abacate. Todas as redes que foram construídas seguiram a ferramenta *nftool* do *software Matlab*, com o algoritmo de treinamento de Levenber-Marquardt (*trainlm*) e uma camada oculta de neurônios. O número de épocas foi estipulado para todos os testes como 1000, assim como o erro de performance de 10^{-4}. Além disso, também foi estipulado que 15% das amostras seriam usadas no teste, 15% na validação e 70% no treinamento, sendo que essa divisão foi aleatória.

Para as redes responsáveis por avaliar o comportamento da umidade de base seca e o fluxo mássico ($g.cm^{-2}.h^{-1}$) ao longo da secagem de amostras, as entradas da rede foram compostas de três neurônios que corresponderam à massa da amostra em cada instante, o tempo e a temperatura do ensaio. A camada de saída das redes foi composta dois neurônios, que corresponderam aos valores de umidade e fluxo mássico esperados, que foram calculados a partir do tempo e da massa medida em cada instante durante o experimento.

No caso da banana foram usados 708 dados, sendo que: 496 foram usados para o treinamento, 106 para a validação e 106 para o teste. No caso do abacate, para avaliar os mesmos parâmetros foram usadas 418 amostras de dados, sendo que: 292 foram usadas para o treinamento, 63 para a validação e 63 para o teste.

Para as redes responsáveis por avaliar a variação de massa de banana e abacate das amostras ao longo da secagem foram usadas como entradas das redes matrizes com duas linhas, que correspondem a duas variáveis: o tempo decorrido de cada medida realizada e a temperatura do ensaio. Como saída foram utilizadas matrizes de uma linha, correspondente a massa medida em cada instante durante o experimento.

Para a rede utilizada com as amostras de banana foram usadas 753 amostras de dados, sendo que: 527 foram usadas para o treinamento, 113 para a validação e

113 para o teste da rede neural. Para a rede utilizada na secagem das amostras de abacate ao longo da secagem foram usadas 418 amostras de dados, sendo que: 292 foram usadas para o treinamento, 63 para a validação e 63 para o teste da rede neural.

Os testes foram realizados variando o número de neurônios da camada intermediária, através do software utilizado. Era esperado que as RNAs obtivessem resultados próximos aos valores de saída obtidos experimentalmente.

4. RESULTADOS E DISCUSSÃO

Neste Capítulo serão apresentados os resultados obtidos das quatro redes neurais implementadas e a análise dos seus desempenhos.

4.1 Avaliação da umidade e do fluxo mássico da banana, utilizando-se as redes neurais

Para a rede utilizada com as amostras de banana, o melhor resultado obtido foi para 11 neurônios na camada intermediária. Os valores encontrados pelas redes foram comparados com os valores da matriz de saída, correspondente aos valores experimentais coletados durante os ensaios de secagem, encontrando-se os erros de cada amostra em relação aos valores esperados.

Para as amostras utilizadas no treinamento, o erro relativo médio para a umidade foi igual a 0,4% e para o fluxo mássico igual a 3,01%. As Figuras 16 e 17 mostram a alta correlação entre os valores obtidos pela RNA e os valores esperados para os parâmetros avaliados. As retas que melhor representam os resultados obtidos pelos conjuntos de treinamento são y = 0,997x + 0,0041, para o caso da umidade e y = 0,84x + 0,0058, para o caso do fluxo mássico. Já os coeficientes de correlação obtidos para esses dois parâmetros foram, respectivamente, 1 e 0,946.

Figura 16 - Valores de umidade obtidos pela rede em relação aos valores esperados para as amostras de treinamento, no caso da banana.

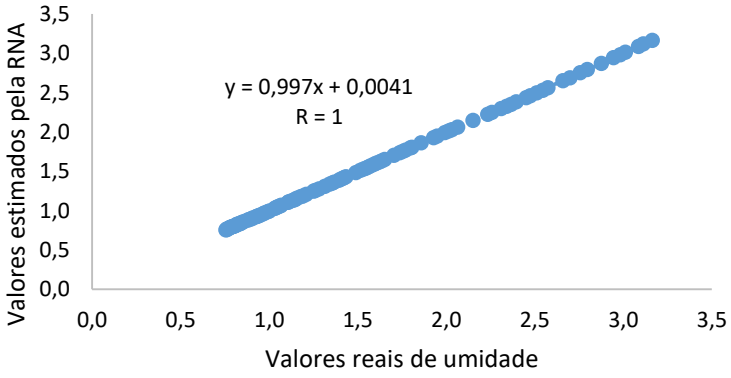

Fonte: Elaborado pelo autor, 2020

Figura 17 - Valores de fluxo mássico obtidos pela rede em relação aos valores esperados para as amostras de treinamento, no caso da banana.

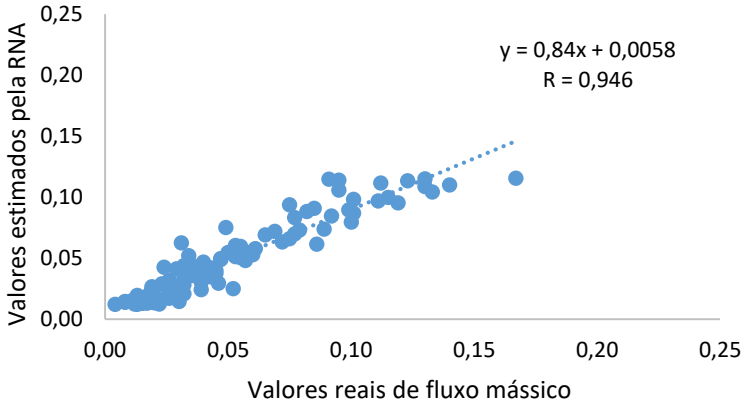

Fonte: Elaborado pelo autor, 2020.

Para as amostras de validação, o erro médio encontrado foi igual a 4,70% para a umidade e 12% para o fluxo mássico. Já para as amostras de teste, encontrou-se um erro médio de 2,85% para a umidade e 2,59% para o fluxo mássico.

As Figuras 18 a 21 mostram a alta correlação entre os valores obtidos pela RNA e os valores esperados tanto para as amostras utilizadas na validação (Figuras 18 e 19) quanto para as utilizadas no teste (Figuras 20 e 21). As retas que melhor representam os resultados obtidos pelos conjuntos de validação são y = 0,9976x + 0,0026, para o caso da umidade e y = 1,0565x + 7.10^{-5}, para o caso do fluxo mássico. Para os conjuntos de teste, as retas que melhor representaram os resultados da RNA foram y = 0,9981x + 0,0018, para o caso da umidade e y = 0,88x + 0,0026, para o caso do fluxo mássico. Já os coeficientes de correlação obtidos para esses dois parâmetros foram, respectivamente, 1 e 0,9489 para as amostras de validação e 0,9998 e 0,957 para as amostras de teste.

Figura 18 - Valores de umidade obtidos pela rede em relação aos valores esperados para as amostras de validação, no caso da banana.

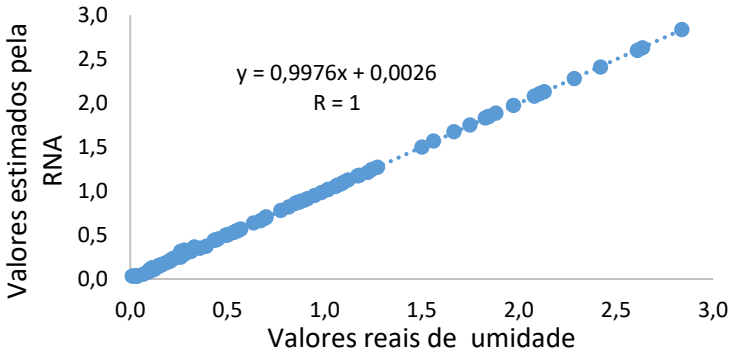

Fonte: Elaborado pelo autor, 2020.

Figura 19 - Valores de fluxo mássico obtidos pela rede em relação aos valores esperados para as amostras de validação, no caso da banana.

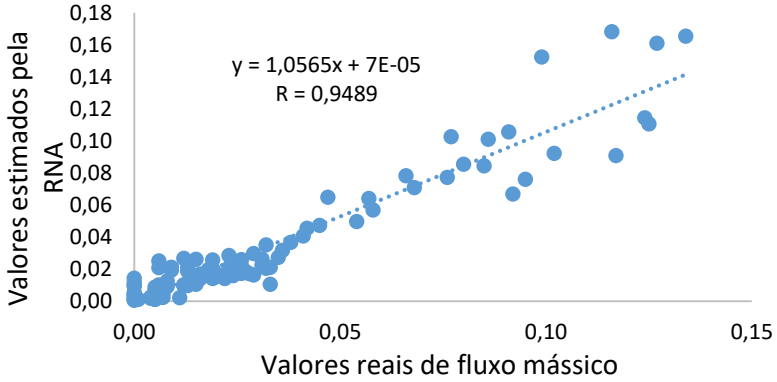

Fonte: Elaborado pelo autor, 2020.

Figura 20 - Valores de umidade obtidos pela rede em relação aos valores esperados para as amostras de teste, no caso da banana.

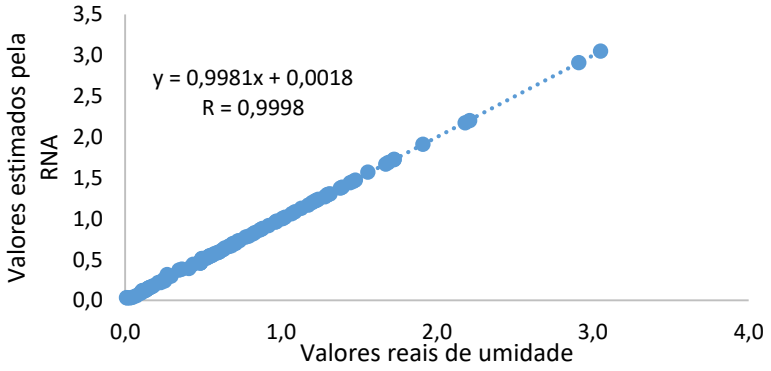

Fonte: Elaborado pelo autor, 2020.

Figura 21 – Valores de fluxo mássico obtidos pela rede em relação aos valores esperados para as amostras de teste, no caso da banana.

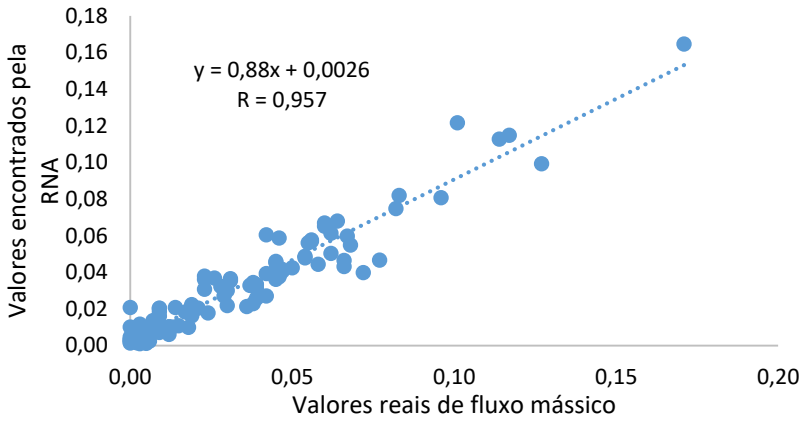

Fonte: Elaborado pelo autor, 2020.

Em todos os gráficos gerados para o resultado dessa rede neural para as amostras de treinamento, validação e teste observou-se uma tendência linear entre os dados. A distribuição de erros absolutos das amostras de treinamento, validação e teste para o processo de secagem da banana, representada nas Figuras 22 e 23 para a umidade e o fluxo mássico, respectivamente, também mostra que os erros permanecem próximo a zero, conforme o esperado e que há aleatoriedade na distribuição destes erros, o que mostra que os resultados obtidos não têm tendência.

Figura 22 – Distribuição dos erros absolutos da umidade estimada pela rede utilizada com as amostras de banana.

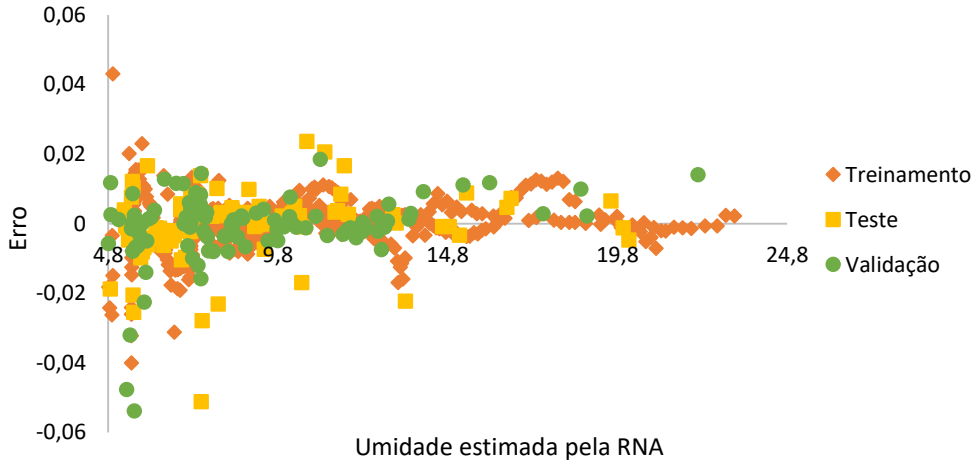

Fonte: Elaborado pelo autor, 2020.

Figura 23 – Distribuição dos erros absolutos do fluxo mássico estimada pela rede utilizada com as amostras de banana.

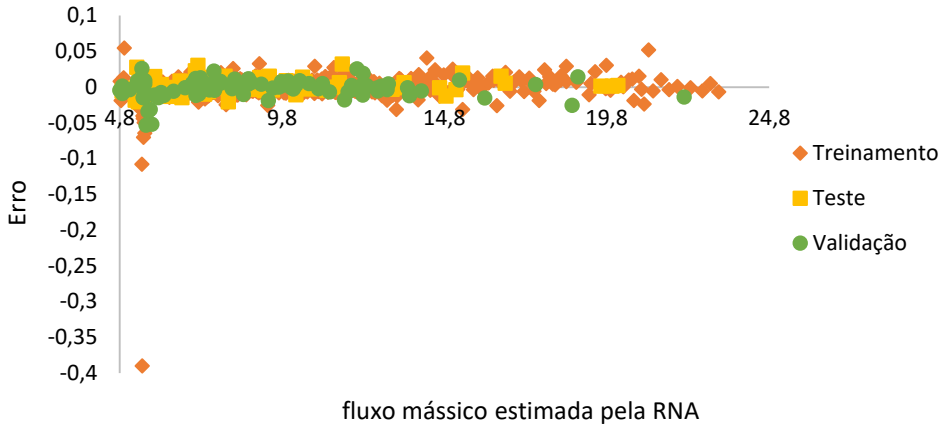

Fonte: Elaborado pelo autor, 2020.

O histograma referente aos erros gerado no software utilizado, se mostrou em torno de um valor próximo de zero, conforme a Figura 24.

Figura 24 - Histograma dos erros para o treinamento, validação e teste para a rede utilizada com as amostras de banana.

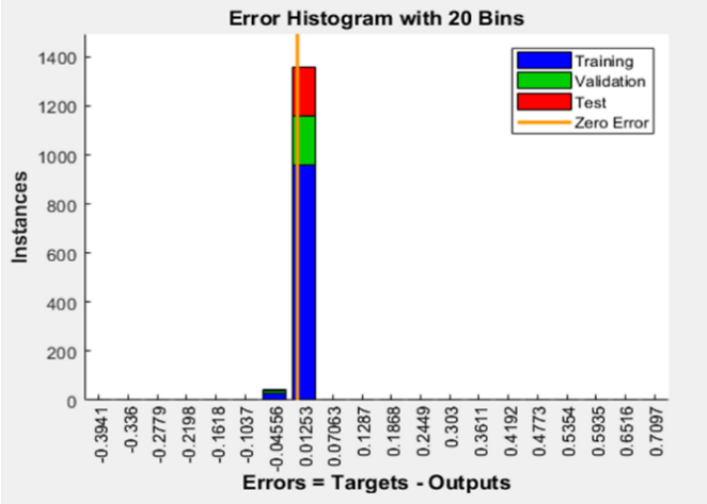

Fonte: Elaborado pelo autor, 2020.

4.2 Avaliação da umidade e do fluxo mássico do abacate, utilizando-se as redes neurais

Para a rede utilizada com as amostras de abacate, o melhor resultado obtido foi para 10 neurônios na camada intermediária. Os valores encontrados pelas redes

foram comparados com os valores da matriz de saída, correspondente aos valores experimentais coletados durante os ensaios de secagem, encontrando-se os erros de cada amostra em relação aos valores esperados.

Para as amostras utilizadas no treinamento, o erro médio para a umidade foi igual a 0,226% e para o fluxo mássico igual a 20,602%. As Figuras 25 e 26 mostram a alta correlação entre os valores obtidos pela RNA em relação aos valores esperados para os parâmetros avaliados. As retas que melhor representam os resultados obtidos pelos conjuntos de treinamento são y = x + 10^{-5}, para o caso da umidade e y = 0,9066x + 0,0037, para o caso do fluxo. Já os coeficientes de correlação obtidos para esses dois parâmetros foram, respectivamente, 1 e 0,9506.

Figura 25 - Valores de umidade obtidos pela rede em relação aos valores esperados para as amostras de treinamento, no caso do abacate.

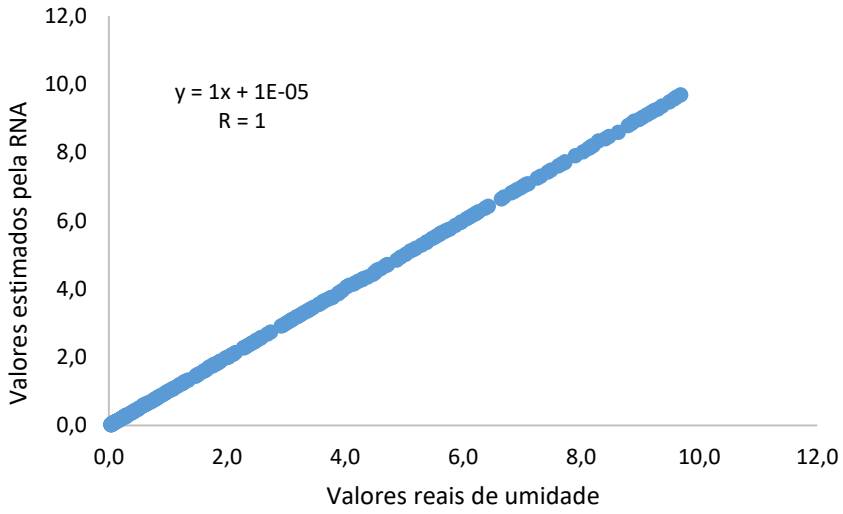

Fonte: Elaborado pelo autor, 2020.

Figura 26 - Valores de fluxo mássico obtidos pela rede em relação aos valores esperados para as amostras de treinamento, no caso do abacate.

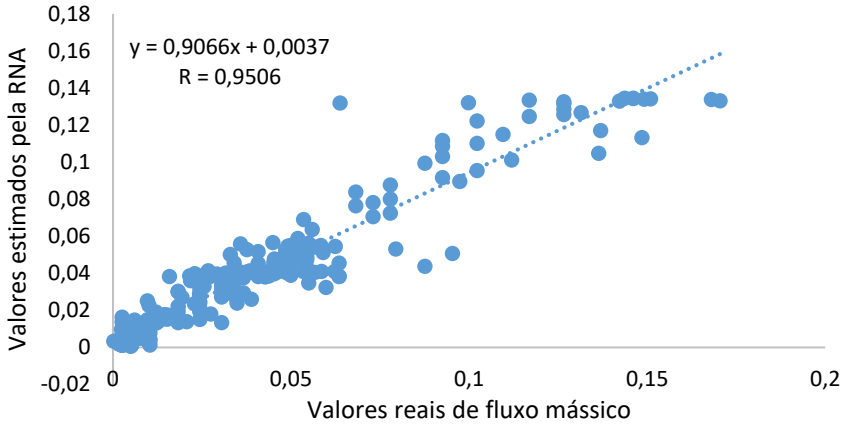

Fonte: Elaborado pelo autor, 2020.

Para as amostras de validação, o erro médio da umidade foi igual a 1,48% e o do fluxo mássico igual a 24,06%. Para as amostras utilizadas no teste o erro médio da umidade foi igual a 1,48% e o do fluxo mássico igual a 45,28%.

As Figuras 27 a 30 mostram a alta correlação entre os valores obtidos pela RNA e os valores esperados tanto para as amostras utilizadas na validação (Figuras 27 e 28) quanto para as utilizadas no teste (Figuras 29 e 30). As retas que melhor representam os resultados obtidos pelos conjuntos de validação são y = 0,9986x + 0,003, para o caso da umidade e y = 0,9681x + 0,0008, para o caso do fluxo. Para os conjuntos de teste, as retas que melhor representaram os resultados da RNA foram y = 1,0013x - 0,0014, para o caso da umidade e y = 0,9578x + 0,0023, para o caso do fluxo. Já os coeficientes de correlação obtidos para esses dois parâmetros foram, respectivamente, 1 e 0,981 para as amostras de validação e 1 e 0,9259 para as amostras de teste.

Figura 27 - Valores de umidade obtidos pela rede em relação aos valores esperados para as amostras de validação, no caso do abacate.

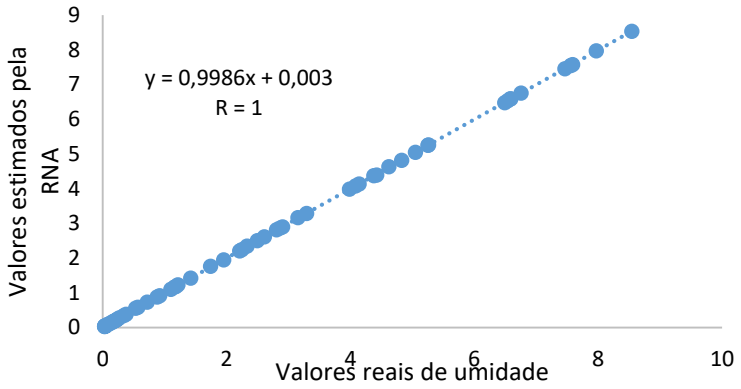

Fonte: Elaborado pelo autor, 2020.

Figura 28 - Valores de fluxo mássico obtidos pela rede em relação aos valores esperados para as amostras de validação, no caso do abacate.

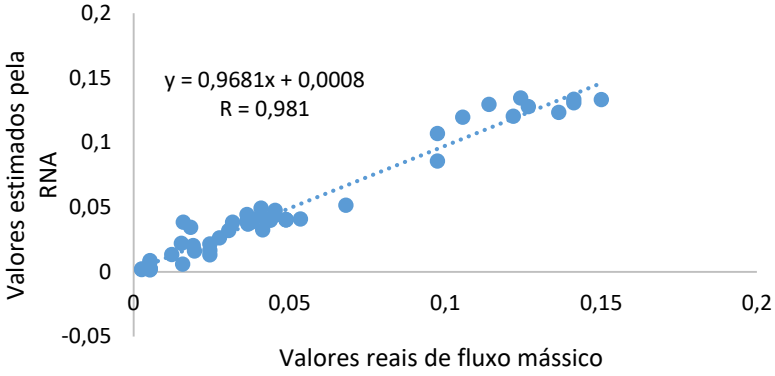

Fonte: Elaborado pelo autor, 2020.

Figura 29 - Valores de umidade obtidos pela rede em relação aos valores esperados para as amostras de teste, no caso do abacate.

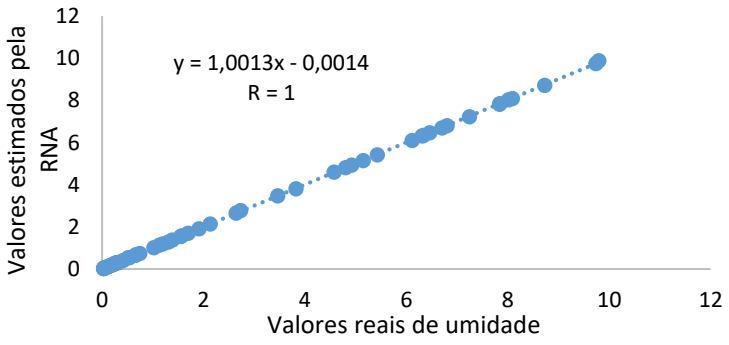

Fonte: Elaborado pelo autor, 2020.

Figura 30 - Valores de fluxo mássico obtidos pela rede em relação aos valores esperados para as amostras de teste, no caso do abacate.

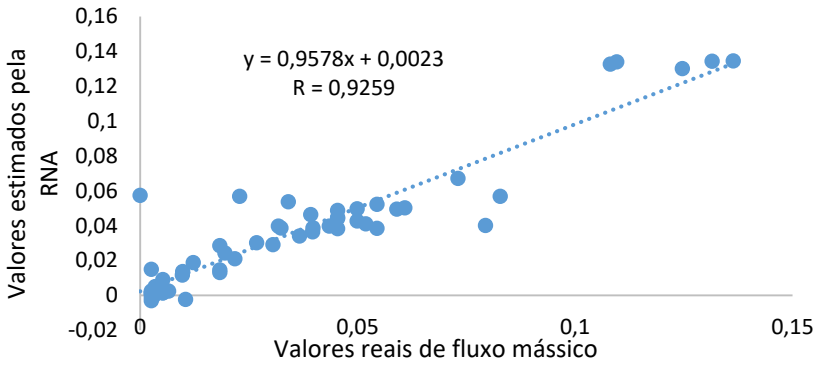

Fonte: Elaborado pelo autor, 2020.

Os gráficos gerados para essa rede das amostras de validação e teste observou-se uma tendência linear entre os dados, assim como observado anteriormente nos gráficos gerados para as amostras de treinamento. Também foi observado que os gráficos apresentaram um coeficiente de correlação (R) relativamente próximos a 1, principalmente os gráficos que representavam a umidade.

Através da distribuição de erros absolutos, representada nas Figuras 31 e 32 para a umidade e o fluxo mássico, respectivamente, nota-se que os erros permanecem próximo a zero e que há aleatoriedade na distribuição destes erros, assim como o observado na rede utilizada com as amostras de banana.

Figura 31 – Distribuição dos erros absolutos da umidade estimada pela rede utilizada com as amostras de abacate.

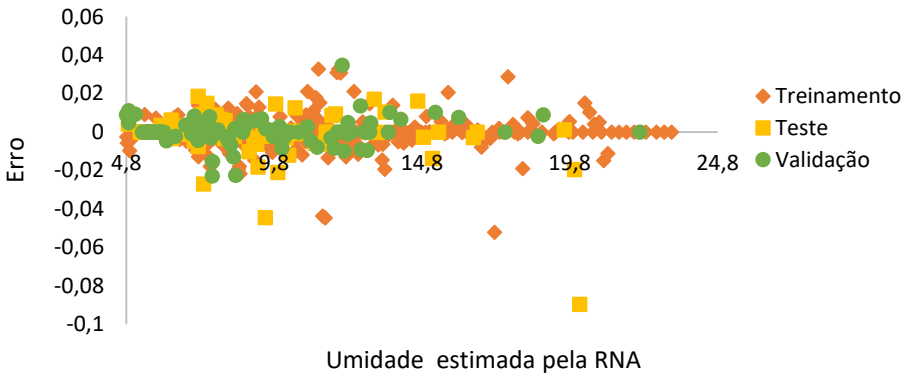

Fonte: Elaborado pelo autor, 2020.

Figura 32 – Distribuição dos erros absolutos do fluxo mássico estimada pela rede utilizada com as amostras de abacate.

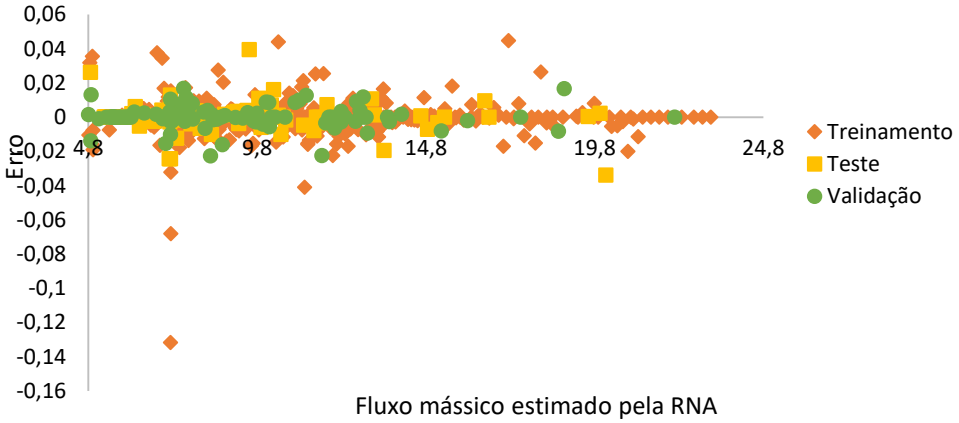

Fonte: Elaborado pelo autor, 2020.

Para o caso da rede utilizada nas amostras de abacate, o histograma, representado na Figura 33, se mostrou semelhante a uma curva gaussiana em torno de um valor muito próximo de zero, mostrando que não houve tendência nos resultados.

Figura 33 - Histograma dos erros para o treinamento, validação e teste para a rede utilizada com as amostras de abacate.

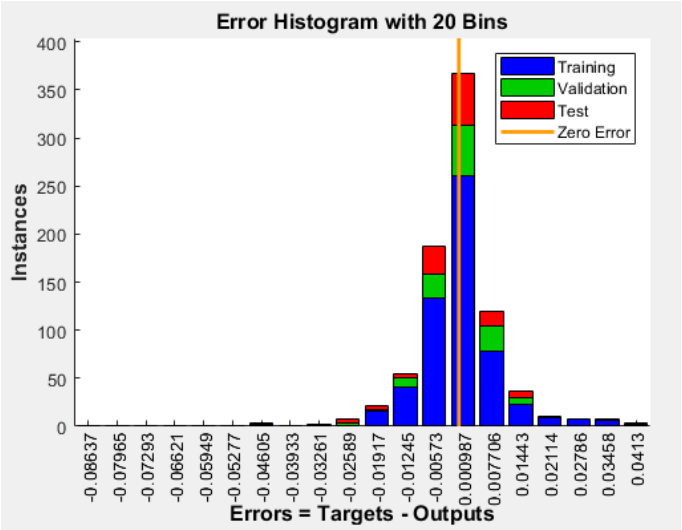

Fonte: Elaborado pelo autor, 2020.

4.3 Avaliação da massa da banana, utilizando-se redes neurais

Para a rede utilizada no processo de secagem da banana, o melhor resultado obtido foi para 13 neurônios intermediários. Os valores encontrados pelas redes foram comparados aos valores experimentais coletados durante os ensaios de secagem, encontrando-se os erros de cada amostra em relação aos valores esperados.

Para as amostras utilizadas no treinamento, o erro médio para a massa de amostra foi igual a 0,35%. A Figura 34 mostra a alta correlação entre os valores obtidos pela RNA em relação aos valores esperados para as massas das amostras. A reta que melhor representa os resultados obtidos pelo conjunto de treinamento são y = 0,992x + 0,0082. Já o coeficiente de correlação obtido para esse parâmetro foi 0,9996.

Figura 34 – Massas das amostras de banana encontradas pela rede neural em relação às massas esperadas para as amostras de treinamento.

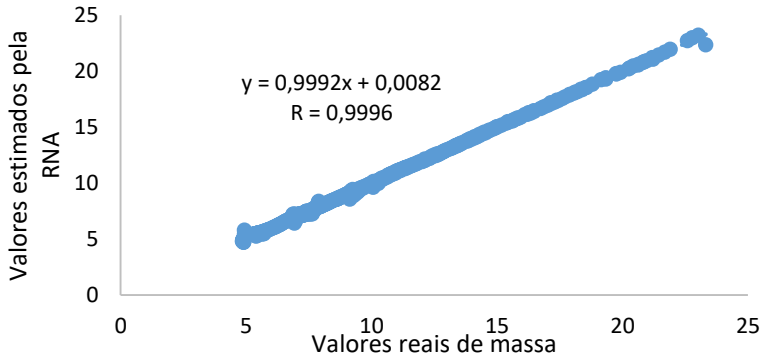

Fonte: Elaborado pelo autor, 2020.

Para as amostras de validação, o erro médio encontrado foi igual a 0,80%. Já para as amostras de teste, encontrou-se um erro médio de 1,03%.

As Figuras 35 e 36 mostram a alta correlação entre os valores obtidos pela RNA em relação aos valores esperados para o parâmetro avaliado. As retas que melhor representam os resultados obtidos são y = 0,9984x + 0,0134, para as amostras de validação e y = 1,0032x - 0,0458, para as amostras de teste. Já os coeficientes de correlação obtidos para esses conjuntos foram, respectivamente, 0,9995 e 0,9992.

Figura 35 - Massas das amostras de banana encontradas pela rede neural em relação às massas esperadas para as amostras de validação.

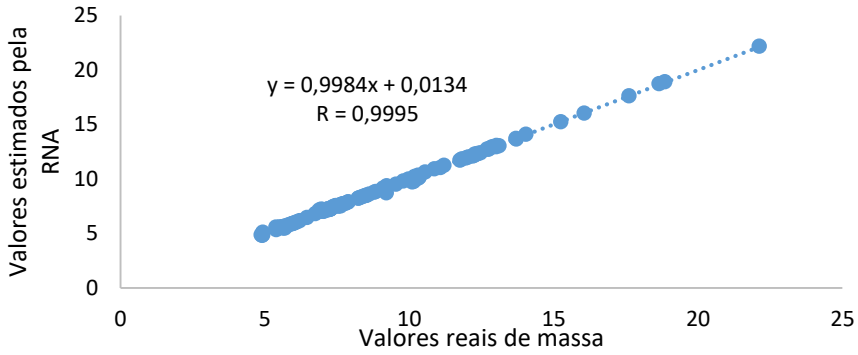

Fonte: Elaborado pelo autor, 2020.

Figura 36 - Massas das amostras de banana encontradas pela rede neural em relação às massas esperadas para as amostras de teste.

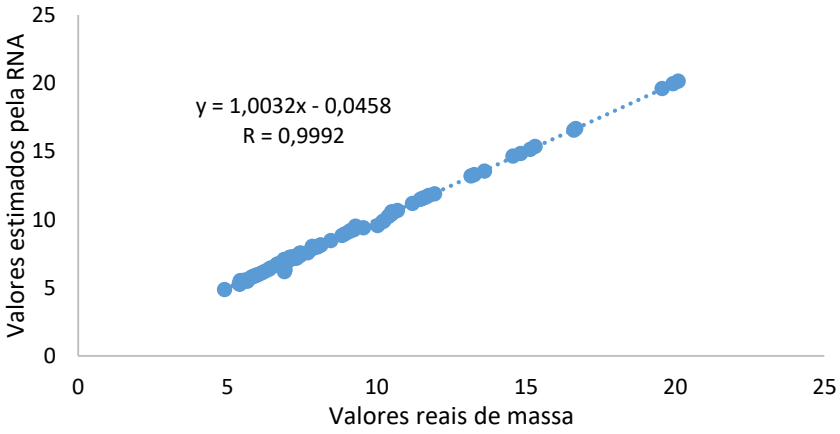

Fonte: Elaborado pelo autor, 2020.

Observou-se uma tendência linear entre os dados para ambos os gráficos acima, que apresentaram um coeficiente de correlação (R) próximo a 1, assim como observado anteriormente no gráfico gerado para as amostras de treinamento.

A Figuras 37 mostra a distribuição de erros absolutos das amostras de treinamento, validação e teste para o processo de secagem da banana

Figura 37 – Distribuição dos erros absolutos para a rede utilizada com as amostras de banana.

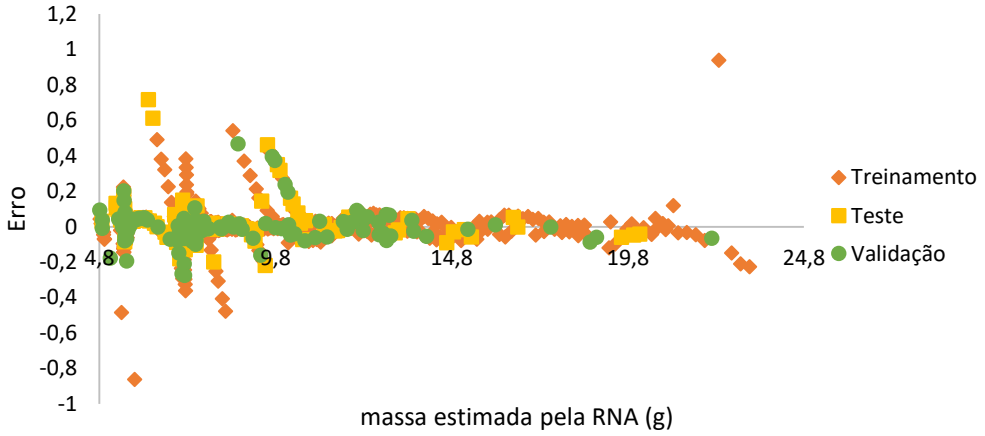

Fonte: Elaborado pelo autor, 2020.

Nota-se que os erros permaneceram próximo de zero, conforme o esperado e os resultados obtidos não têm tendência, fato evidenciado pela aleatoriedade na distribuição dos erros.

O histograma referente aos erros da rede neural se mostrou semelhante a uma curva gaussiana em torno de um valor muito próximo de zero, mostrando que não houve tendência nos resultados, conforme a Figura 38.

Figura 38 - Histograma dos erros para o treinamento, validação e teste para a rede utilizada com as amostras de banana.

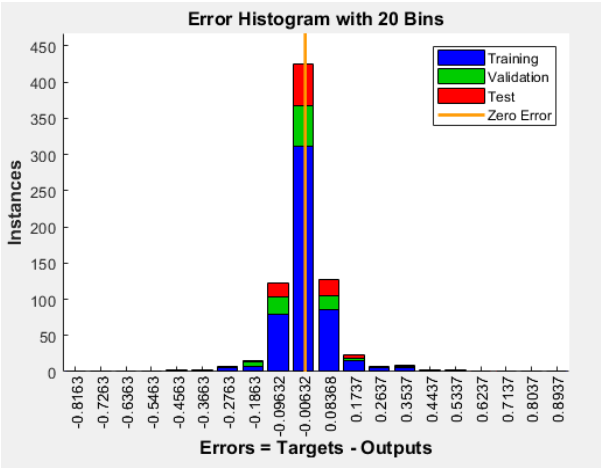

Fonte: Elaborado pelo autor, 2020.

4.4 Avaliação da massa do abacate, utilizando-se redes neurais

Para a rede utilizada no processo de secagem do abacate, o melhor resultado obtido foi para 10 neurônios na camada intermediária. Os valores encontrados pelas redes foram comparados aos valores experimentais coletados durante os ensaios de secagem, encontrando-se os erros de cada amostra em relação aos valores esperados.

Para as amostras utilizadas no treinamento, o erro médio para a massa de amostra foi igual a 0,20%. A Figura 39 mostra a alta correlação entre os valores obtidos pela RNA em relação aos valores esperados para as massas das amostras. A reta que melhor representa os resultados obtidos pelo conjunto de treinamento são y = x + 0,0002. Já o coeficiente de correlação obtido para esse caso foi 1.

Figura 39 - Massas das amostras de abacate encontradas pela rede neural em relação às massas esperadas para as amostras de treinamento.

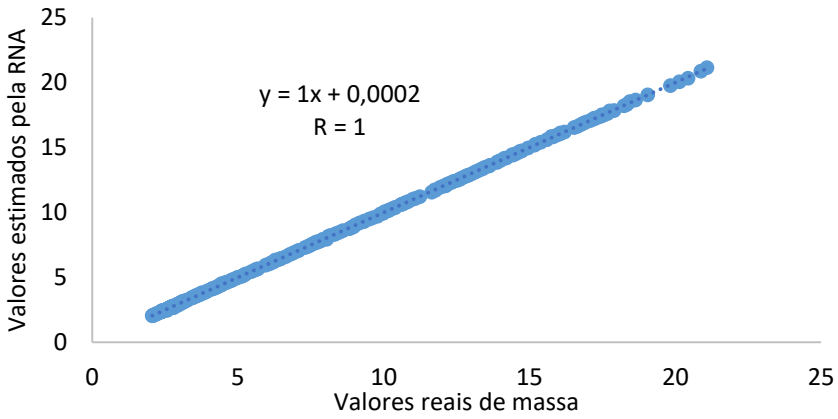

Fonte: Elaborado pelo autor, 2020.

Para as amostras de validação, o erro médio encontrado foi igual a 0,37%. Já para as amostras de teste, encontrou-se um erro médio de 0,42%.

As Figuras 40 e 41 mostram a alta correlação entre os valores obtidos pela RNA em relação aos valores esperados para o parâmetro avaliado. As retas que melhor representam os resultados obtidos são y =1,0013x - 0,0044, para as amostras de validação e y = 1,001x - 0,0045, para as amostras de teste. Já os coeficientes de correlação obtidos para ambos os conjuntos foram 1.

Figura 40 - Massas das amostras de abacate encontradas pela rede neural em relação às massas esperadas para as amostras de teste.

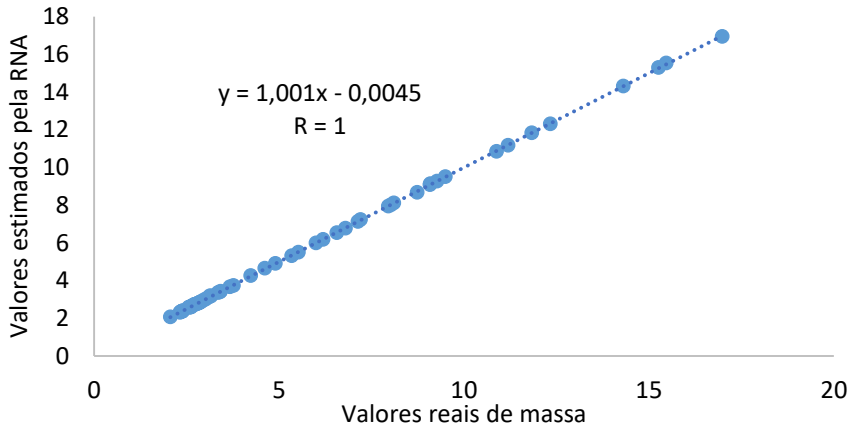

Fonte: Elaborado pelo autor, 2020.

Figura 41 - Massas das amostras de abacate encontradas pela rede neural em relação às massas esperadas para as amostras de validação.

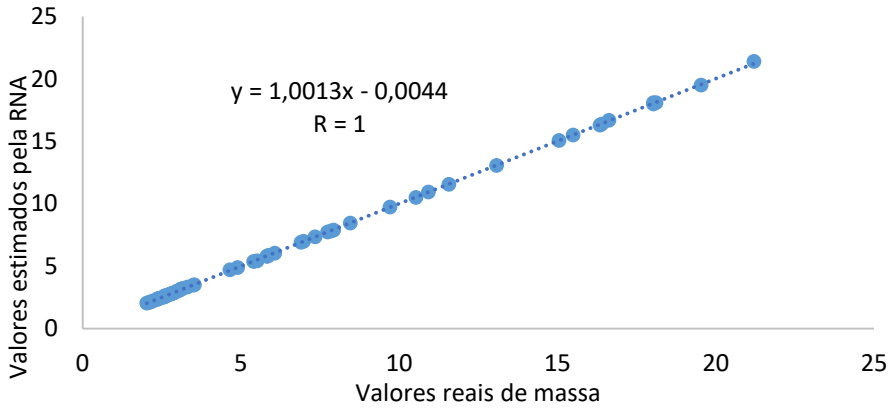

Fonte: Elaborado pelo autor, 2020.

Tanto nos gráficos acima quanto o gráfico representado na Figura 39, referente aos dados utilizados no treinamento apresentaram uma boa linearização, fato confirmado pelos coeficientes de correlação (R) próximos a 1.

A distribuição dos erros das amostras de treinamento, validação e teste para o processo de secagem do abacate, representada na Figura 42, mostra que os erros permaneceram próximo de zero, conforme o esperado e os resultados obtidos não têm tendência, fato evidenciado pela aleatoriedade na distribuição dos erros.

Figura 42 – Distribuição dos erros absolutos para a rede utilizada com as amostras de abacate.

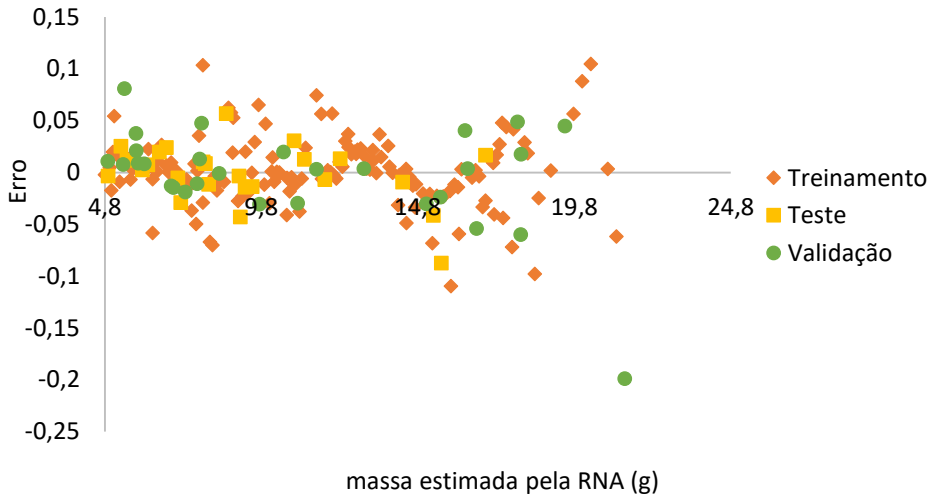

Fonte: Elaborado pelo autor, 2020.

O histograma referente aos erros se mostrou semelhante a uma curva gaussiana em torno de um valor muito próximo de zero, mostrando que não houve tendência nos resultados, conforme a Figura 43.

Figura 43 - Histograma dos erros para o treinamento, validação e teste para a rede utilizada com as amostras de abacate.

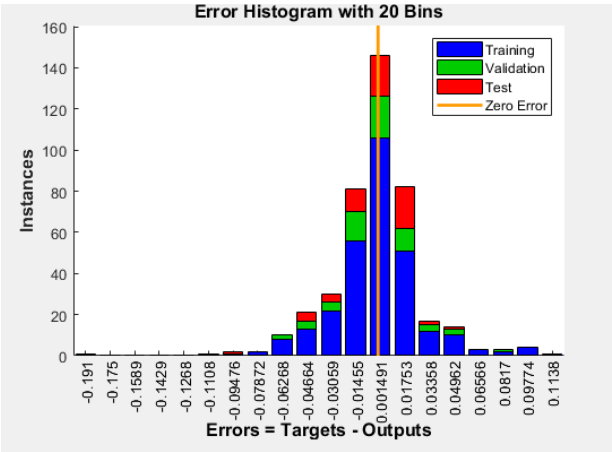

Fonte: Elaborado pelo autor, 2020.

5. CONCLUSÃO

As RNAs apresentaram bons resultados em relação aos erros entre os valores esperados e obtidos, especialmente no cálculo da massa e da umidade, apresentando erros relativos médios entre 0,2% e 1,5%. Entre todos os parâmetros estipulados, o fluxo mássico obteve maiores erros relativos médios, que se apresentaram entre 2% e 45%, devido ao fato de que os valores de fluxo mássico eram muito pequenos, fazendo com que os resultados da rede, mesmo próximos dos dados experimentais, apresentassem erros maiores.

Para ambos os casos de banana e de abacate, observou-se que os coeficientes de correlação dos gráficos gerados para as amostras de treinamento, teste e validação foi em torno de 0,9 e 1. Sendo assim, os resultados obtidos pelas redes para estimar a massa e a umidade foram satisfatórios. No caso do fluxo mássica, a rede neural com os dados da banana apresentou melhores resultados do que a do abacate, mas ambas foram satisfatórias.

As redes responsáveis por avaliar a variação de massa tanto do abacate quanto da banana apresentaram as melhores linearizações e menores erros médios em relação aos valores esperados comparados com os valores obtidos para todas as amostras.

A análise do desempenho das redes implementadas reforça as conclusões de outros trabalhos, como é o caso do Jafari et al. (2015), que afirmou que o uso de RNAs nos processos de secagem apresentam bons resultados, sendo uma alternativa aos métodos mais tradicionais de modelagem.[7] Com isso, podemos concluir que a técnica de Redes Neurais Artificiais é uma boa candidata para ser usada para avaliar parâmetros do processo de secagem de alimentos, em particular, de frutas.

6. REFERÊNCIAS

[1] MARTÍNEZ-MARTÍNEZ, Victor; GOMEZ-GIL, Jaime; STOMBAUGH, Timothy S.; MONTROSS, Michael D.; AGUIAR, Javier M. **"Moisture Content Prediction in the Switchgrass (Panicum virgatum) Drying Process Using Artificial Neural Networks".** Drying Technology, vol. 33 (14). 1708–1719, 2015.

[2] ARAÚJO, Everaldo Cesar da Costa. **Operações unitárias envolvendo transmissão de calor.** São Carlos: EduUFSCAR, 2013. 161 p. ISBN 978-85-7600-333-5. (Coleção UAB-UFSCar).

[3] BEIGI, Mohsen, & AHMADI, Iman. (2019). **Artificial neural networks modeling of kinetic curves of celeriac (Apium graveolens L.) in vacuum drying**. Food Science and Technology, 39(Suppl. 1), 35-40. Epub July 30, 2018. https://dx.doi.org/10.1590/fst.35717

[4] Omari, A., Behroozi-Khazaei, N., Sharifian, F. **Drying kinetic and artificial neural network modeling of mushroom drying process in microwave-hot air dryer**. Journal of Food Process Engineering. 2018;41(4):e12849. https://doi.org/10.1111/jfpe.12849

[5] DOMENICO, C. N. B., SILVA, F. J. N., FERREIRA, J. A. F. 2017. **O uso de Redes Neurais Artificiais na otimização do processo de secagem convectiva de alimentos e redução do consumo energético.** ÁGORA Revista Eletrônica, ISSN 1809-4589, ano XII, n. 24, p. 90-108.

[6] Hernández-Pérez, J. A., García-Alvarado, M. A., Trystram, G., & Heyd, B. (2004). **Neural networks for the heat and mass transfer prediction during drying of cassava and mango.** Innovative Food Science & Emerging Technologies, 5(1), 57–64.

[7] JAFARI, S. M., GANJE, M., DEHNAD, D. and GHANBARI, V. 2015**. Mathematical, Fuzzy Logic and Artificial Neural Network Modeling Techniques to Predict Drying Kinetics of Onion**. Journal of Food Processing and Preservation, ISSN 1745-4549, 40, p. 329-339.

[8] CARVALHO, André Ponce de Leon F. de. **Redes Neurais Artificiais**. Disponível em: <http://conteudo.icmc.usp.br/pessoas/andre/research/neural> Acesso em: 11/02/2019. Instituto de Ciências Matemáticas e de Computação, USP São Carlos.

[9] NASCIMENTO, Erica Regina Filletti. **Desenvolvimento de Modelos Neurais para o Processamento de Sinais Acústicos Visando a Medição de Propriedades Topológicas em Escoamentos Multifásicos.** 2007. 144 f. Tese (Doutorado) - Curso de Engenharia Mecânica, Universidade de São Paulo, São Carlos, 2007.

[10] OLIVEIRA, Cristiano. **Redes Neurais**. Disponível em: <http://www.lem.ep.usp.br/Pef411/~Cristiano%20Oliveira/CristianoOliveira/Paginas/RedesNeurais.htm>. Acesso em: 10/12/2019. Laboratório de Estruturas e Materiais - Poli/USP São Paulo

[11] Deep Learning Book. **O Perceptron – Parte 1**. Disponível em: <http://deeplearningbook.com.br/o-perceptron-parte-1/>. Acesso em: 10/12/2019. Data Science Academy.

[12] ROQUE, Antonio. **Psicologia Conexionista - Aula 4**. Disponível em: < http://sisne.org/Disciplinas/PosGrad/PsicoConex/aula4.pdf>. Acesso em: 10/12/2019. Laboratório de Sistemas Neurais (SisNe). USP Ribeirão Preto.

[13] HAYKIN, S. **Neural Networks and Learning Machines**. 3nd ed. Pearson: Prentice Hall, 2009.

[14] HAGAN, Martin T.;MENHAJ, Mohammad B. **Training Feedforward Networks with the Marquardt Algorithm.** IEEE Transactions on Neural Networks, vol. 5, no. 6, pp. 989-993. Nov. 1994. doi: 10.1109/72.329697.

[15] SILVA, Leandro Nunes de Castro. **Análise e Síntese de Estratégias de Aprendizado para Redes Neurais Artificiais.** Dissertação (Mestrado) - Faculdade de Engenharia Elétrica e de Computação, UNICAMP , Campinas, 1998.

[16] MEDINA, J. C.; BLEINROTH, E. W.; DE MARTIN, Z. J.; TRAVAGLINI, D. A.; OKADA, M.; QUAST, D. G.; HASHIZUME, T.; RENESTO, O. V.; MORETTI, V. A. **Banana: da cultura ao processamento e comercialização.** São Paulo (Estado) Secretaria da Agricultura. Coordenadoria da Pesquisa Agropecuária,1978.

[17] D. C. HANAUER, E. R. MATIELLO , F. M. PAINI3 , P. F. BUENO. (2015) **Secagem de duas cultivares de banana em estufa com circulação de ar em diferentes temperaturas.** Universidade do Estado de Santa Catarina, Departamento de Engenharia de Alimentos. Revista CSBEA apresenta os trabalhos do I Congresso Sul Brasileiro de Engenharia de Alimentos, v. 1, n. 1.

[18] BARRETO, Jorge M. **Introdução às Redes Neurais Artificiais.** Disponível em: < http://www.inf.ufsc.br/~j.barreto/tutoriais/Survey.pdf > Acesso em: 12/02/2019.

[19] BANSAL, N. K., GARG, H. P. Solar crop drying ,In: A.S. Mujumdar (ed.). **Advances in drying**. New York: Hemisphere Publishing Corporation, Chapter 6: v. 4, p. 293-294, 1987

[20] Inyang, U.E., Oboh, I.O. and Etuk, B.R. (2018) **Kinetic Models for Drying Techniques—Food Materials**. Advances in Chemical Engineering and Science, 8, 27-48