



**Revista Eletrônica  
Paulista de Matemática**

ISSN 2316-9664  
Volume 17, fev. 2020  
Edição Ermac

**Camila Proni**

Instituto de Química  
UNESP-Universidade Estadual  
Paulista "Júlio de Mesquita  
Filho"  
camilaproni1999@hotmail.com

**Renata Natsumi Haneda**

CPEA - Centro Paulista de  
Estudos em Agronegócio  
renatanathaneda@gmail.com

**Érica Regina Filletti**

Instituto de Química  
UNESP-Universidade Estadual  
Paulista "Júlio de Mesquita  
Filho"  
erica.filletti@unesp.br

## **Desenvolvimento de redes neurais artificiais para análise do fluxo de permeado de uma bebida à base de açaí no processo de microfiltração tangencial**

Development of artificial neural networks for permeate flow analysis of a beverage based on açaí in the crossflow microfiltration process

### **Resumo**

Neste trabalho foi proposta a utilização de Redes Neurais Artificiais (RNAs) com o Método de Levenberg-Marquardt (MLM) para estimar o fluxo de permeado de uma bebida à base de açaí através do processo de microfiltração tangencial com duas membranas cerâmicas com poros de diâmetro médio de 0,8 e 1,2  $\mu\text{m}$  em escoamento turbulento. As variáveis de entrada das RNAs foram o número de Reynolds, a pressão transmembrana e o tempo de microfiltração; as variáveis de saída foram os correspondentes valores de fluxo de permeado. Os resultados fornecidos pelas RNAs tiveram baixos erros médios, sendo 4,1%, 10,6% e 7,6% para a membrana de 0,8  $\mu\text{m}$  e 5,3%, 4,7% e 9,9%, para a membrana de 1,2  $\mu\text{m}$ , para os conjuntos de treinamento, validação e teste, respectivamente.

**Palavras-chave:** Redes Neurais Artificiais. Microfiltração tangencial. Membranas Cerâmicas. Açaí.

### **Abstract**

In this work we proposed the use of Artificial Neural Networks (ANNs) with the Levenberg-Marquardt Method to estimate the permeate flow of a beverage based on açaí through the crossflow microfiltration process using two ceramic membranes with average pore diameter of 0.8 and 1.2 $\mu\text{m}$  in turbulent flow. ANN input variables were Reynolds number, transmembrane pressure and microfiltration time; the output variables were the corresponding permeate flow values. The results provided by the ANNs had low average errors, being 4.1%, 10.6% and 7.6% for the 0.8 $\mu\text{m}$  membrane and 5.3%, 4.7% and 9.9%, for the the 1.2 $\mu\text{m}$  membrane for the training, validation and test sets, respectively.

**Keywords:** Artificial Neural Networks. Crossflow microfiltration. Ceramic Membranes. Açaí.



# 1 Introdução

A separação por membranas é uma tecnologia que se revela cada vez mais promissora para a resolução de inúmeros problemas de processos químicos, pois se mostra eficaz na remoção de componentes em misturas sólido-líquido, líquido-líquido e gás-sólido, apresentando assim grande relevância na indústria de bebidas e alimentos (CASSANO; CONIDI, 2017), no tratamento de água residuária (ZUO *et al.*, 2018); na indústria farmacêutica (ZARKADAS; SIRKAR, 2019) e até mesmo nas indústrias produtoras de biogás (CERVEIRA; BORGES; KRONEMBERGER., 2018).

A tecnologia de membranas é um termo usado para caracterizar o processo de separação de uma corrente líquida em duas correntes distintas através de uma membrana semipermeável, cujo fluido com capacidade de atravessar a membrana é designado de permeado e o que fica retido é chamado de rejeitado (MACHADO *et al.*, 2012; MORAIS, 2018). Em relação à membrana, dentre outros materiais de composição, os cerâmicos e os poliméricos são amplamente utilizados, porém materiais cerâmicos como alumina, zircônio e sílica ganham bastante destaque por permitirem aumentar limites de operação a temperaturas mais elevadas e meios quimicamente mais agressivos. O tamanho dos poros das membranas também está diretamente relacionado ao tipo do processo de filtração e, conseqüentemente à sua aplicação, ou seja, membranas com poros de diâmetro médio entre 0,1 e 10 micrômetros ( $\mu\text{m}$ ) são típicas do processo de microfiltração (CHERYAN, 1998). Cabe ressaltar que micrômetro ( $\mu\text{m}$ ) é uma unidade de comprimento do Sistema Internacional de Unidades (SI), definido como 1 milionésimo de metro ( $1 \times 10^{-6}$  m) e equivale à milésima parte do milímetro, fazendo com que o processo de microfiltração se consagrasse na separação de micropartículas, microrganismos e emulsões.

A microfiltração é um processo que utiliza o gradiente de pressão como força motriz, junto a uma superfície permeável (membrana), podendo ser realizada perpendicular e tangencialmente. Na microfiltração perpendicular, a vazão de alimentação ocorre perpendicularmente à superfície da membrana, enquanto na microfiltração tangencial a solução ou suspensão escoam paralelamente à superfície da membrana, enquanto o permeado é transportado transversalmente à mesma (HASAN *et al.*, 2013; ZEMAN; ZYDNEY, 1996), o que facilita o arraste das partículas depositadas na superfície da membrana.

O sucesso do processo de separação por membranas nas indústrias de bebidas e alimentos está diretamente relacionado à baixa variação de temperatura (CHEMAT *et al.*, 2017; MACHADO *et al.*, 2012; PICART-PALMADE *et al.*, 2019) ao longo do processamento, o que minimiza efeitos, como a mudança de fases, desnaturação de proteínas e alteração de características sensoriais do produto (DORNIER; BELLEVILLE; VAILLANT, 2018). Além disso, o processo de separação por membranas permite ainda a remoção de microrganismos e sedimentos, tornando o produto final mais atrativo em termos de textura, bem como o aumento da sua vida útil (KUMAR *et al.*, 2013; ZHANG *et al.*, 2015), proporcionando o desenvolvimento de novos produtos com baixo consumo de energia e reduzido impacto ambiental (DORNIER; BELLEVILLE; VAILLANT, 2018; MACEDONIO; DRIOLI, 2017).

Como todo processo, há desvantagens como os fenômenos de polarização de concentração e colmatção que causam uma redução no fluxo e conseqüente perda de produtividade ao longo do tempo (FAGNANI; PUPPIO; ZANON, 2018; NOURBAKHSH *et al.*, 2014). Portanto, o estudo de novos métodos eficazes para quantificar a interação interfacial de forma direta é de extrema importância. Desta forma, as modelagens matemáticas, juntamente com os resultados experimentais podem contribuir para a compreensão dos fenômenos responsáveis pela diminuição do fluxo de permeado ao longo dos processos de microfiltração, de modo a auxiliar na escolha das melhores condições de operação, maximizando o fluxo de permeado.



Nesse sentido, as Redes Neurais Artificiais (RNAs) tem chamado a atenção dos pesquisadores por ser uma técnica computacional baseada no funcionamento do cérebro humano, capaz de produzir resultados altamente precisos com baixo custo computacional e por ser de fácil implementação. A principal vantagem das RNAs é sua capacidade de aprender com exemplos e generalizar as informações para obter respostas para dados não inclusos em seu treinamento (HAYKIN, 1999).

Atualmente, as RNAs têm sido utilizadas em diversas áreas do conhecimento, como Química, Física, Geologia, Medicina, Neurocomputação (CUSTÓDIO; FILLETTI; FRANCA, 2019; ORTEGA-ZAMORANO *et al*, 2017; RAMIL *et al*, 2018; TANZIFI *et al*, 2018; WALCZAK; VELANOVICH, 2018;), entre outras.

Referente à utilização de RNAs em processos de microfiltração tangencial, redes neurais foram utilizadas para prever o desempenho do processo de microfiltração para a remoção de metais pesados, como chumbo e zinco, em águas residuais, mostrando que o modelo neural possui excelente desempenho na previsão do fluxo de permeado com coeficiente de correlação entre os dados de 0,96 (SEKULIC *et al*, 2019); Phalak *et al*. (2017) fizeram um estudo sobre a filtração de proteínas usando RNAs e concluíram que elas são ótimas para a modelagem de processos de membrana, como ultrafiltração e microfiltração; Ghandehari, Montazer-Rahmati e Asghari (2013) desenvolveram duas redes neurais para modelar o declínio do fluxo de permeado na microfiltração de proteínas, com bastante precisão; RNAs também foram utilizadas para analisar o fluxo de permeado na microfiltração tangencial para clarificação de vinhaça com membrana porosa com poros de diâmetro médio de 0,8  $\mu\text{m}$  com erro percentual médio de 1,62% (SILVA, 2018).

Assim, considerando a importância do desenvolvimento de novas técnicas de conservação, clarificação e minimização da degradação de frutos na indústria de bebidas, é fundamental monitorar o fluxo de permeado durante o processo de microfiltração. Portanto, neste artigo, propõe-se a utilização de RNAs, como uma ferramenta matemática alternativa, para estimar o fluxo de permeado na separação por membranas no processo de microfiltração tangencial para uma bebida à base de açaí.

Este artigo está organizado da seguinte forma: na Seção 2 encontra-se a metodologia utilizada, descrevendo o Método de Levenberg-Marquardt aplicado às RNAs; a Seção 3 apresenta os resultados obtidos e a Seção 4 traz as conclusões do trabalho.

## 2 Redes neurais artificiais

Segundo Braga, Carvalho e Ludernir (2000), as RNAs são modelos computacionais inspirados na estrutura funcional do cérebro humano, capazes de realizar o aprendizado de máquina bem como o reconhecimento de padrões, adquirindo conhecimento através da experiência. A principal semelhança entre as RNAs e os circuitos formados no cérebro está no extenso processamento paralelo apresentado por ambos. Outra semelhança é que as operações nos dois circuitos não são dependentes de qualquer neurônio isolado, mas sim de uma função do conjunto dos neurônios. Na maioria dos modelos as conexões entre os neurônios estão associadas a pesos, os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede neural.

Em seu funcionamento, o neurônio artificial recebe determinada mensagem e a encaminha por meio de sinais sinápticos (pesos) criados, tornando-se capaz de organizar suas estruturas, aprender novas tarefas e fazer novas descobertas, permitindo, assim, que a RNA consiga estabelecer uma relação entre os valores de entrada e de saída que representam o problema estudado.



Para desenvolver uma RNA, as amostras que representam o problema tratado são divididas em três conjuntos:

- (i) Conjunto de treinamento, que contém as amostras apresentadas à rede neural durante seu treinamento e a RNA é ajustada de acordo com o erro calculado pelo algoritmo de aprendizagem escolhido;
- (ii) Conjunto de validação: contém amostras que são usadas para medir a generalização da rede e interromper o treinamento quando a generalização para de melhorar;
- (iii) Conjunto de teste: cujas amostras não têm efeito no treinamento e, portanto, fornecem uma medida independente do desempenho da rede durante e após o treinamento.

Neste trabalho, as redes neurais desenvolvidas foram do tipo *feedforward* (FF) com múltiplas camadas. Segundo Haykin (1999) uma rede neural FF é formada por neurônios (ou nós), com tendência natural para armazenar conhecimento experimental e torná-lo disponível para uso, além disso, neste tipo de rede nota-se a presença de camadas intermediárias, aumentando a capacidade de processamento da mesma. O problema tratado aqui foi inicialmente discutido em Proni, Haneda e Filletti, (2019), onde foi criada uma RNA *feedforward* para estimar o fluxo de permeado através da membrana com poros de diâmetro médio de 0,8  $\mu\text{m}$ ; já o presente trabalho apresenta um melhor treinamento para a membrana anterior e acrescenta a criação de uma segunda RNA para avaliar o mesmo problema, porém utilizando uma membrana com poros de diâmetro médio de 1,2  $\mu\text{m}$ .

A implementação das RNAs foi realizada com a ferramenta *Neural Network Getting Started* do software MATLAB R2016a, usando o Método de Levenberg-Marquardt (MLM) como o algoritmo de aprendizagem das redes neurais desenvolvidas.

## 2.1 O método de Levenberg-Marquardt aplicado às RNAs

O Método de Levenberg-Marquardt é um dos algoritmos de treinamento existentes, responsável pelo aprendizado da rede neural. Ele trabalha com a função residual dos erros quadráticos, ou seja, com a função obtida pela diferença entre a resposta desejada e a resposta obtida pela RNA e é bastante utilizado em aplicações que se reduzem a um problema de quadrados mínimos.

Segundo Hagan e Menhaj (1994), este método de aprendizado consiste em uma modificação ao método de Gauss-Newton (BURKE; FERRIS, 1995), sendo a função  $E_n(x)$  correspondente à função erro na iteração  $n$  (que deve ser minimizada em relação a um vetor  $x=(x_1, \dots, x_n)$ ), de acordo com a equação (1)

$$E_n(x) = \sum_{i \in C} e_i^2(x) \quad (1)$$

onde, no caso de se aplicar esse método às redes neurais, tem-se que  $C$  é o conjunto de todos os neurônios da RNA, e o erro  $e_i$  é dado por

$$e_i(x) = d_i(x) - y_i(x) \quad (2)$$

sendo que  $d_i$  se refere à resposta desejada para o neurônio  $i$ , aqui sendo o fluxo de permeado, e  $y_i$  é a resposta obtida pela RNA. O vetor  $x=(x_1, \dots, x_n)$  representa os pesos da rede neural.



O erro médio quadrático para todos os  $N$  exemplos do conjunto de treinamento da RNA é obtido somando-se os  $E_n(x)$  para todos os  $N$  e então normalizando em relação ao tamanho do conjunto de treinamento (NASCIMENTO, 2007), ou seja,

$$E_{med} = \frac{1}{N} \sum_{n=1}^N E_n(x). \quad (3)$$

Note que o erro médio  $E_{med}$  é uma função dos pesos da RNA e representa a função objetivo como a medida de desempenho de aprendizagem da rede neural cuja meta é ajustar os pesos da RNA para minimizar o erro médio. Para isto, considera-se um algoritmo de aprendizagem para atualizar os pesos da RNA, que neste artigo foi o MLM.

Assim, o método de Newton (HAGAN; MENHAJ, 1994) para a atualização dos pesos da RNA se dá pela equação (4):

$$\Delta x = -[\nabla^2 E_n(x)]^{-1} \nabla E_n(x) \quad (4)$$

onde  $\nabla^2 E_n(x)$  é a matriz Hessiana (que envolve derivadas parciais de segunda ordem) e  $\nabla E_n(x)$  é o gradiente de  $E_n$ , sendo que  $\Delta x$  é a direção de busca do método de Newton. Assim, temos

$$\nabla E_n(x) = J^T(x)e(x) \quad (5)$$

sendo que  $e(x) = (e_1, \dots, e_N)$ , onde cada  $e_i$  é dado pela equação (2) e  $J(x)$  é a matriz Jacobiana dada por

$$J(x) = \begin{bmatrix} \frac{\partial e_1}{\partial x_1} & \dots & \frac{\partial e_1}{\partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial e_N}{\partial x_1} & \dots & \frac{\partial e_N}{\partial x_n} \end{bmatrix}. \quad (6)$$

Logo, uma aproximação para a matriz Hessiana é

$$\nabla^2 E_n(x) = J^T(x)J(x) + S(x) \quad (7)$$

onde  $S(x)$  é dada por

$$S(x) = \sum_{i=1}^N e_i(x) \nabla^2 e_i(x). \quad (8)$$

Substituindo tais termos e levando-se em consideração que no método de Gauss-Newton  $S(x) \cong 0$ , tem-se que a atualização da equação (4) é dada pela equação (9) abaixo:

$$\Delta x = [J^T(x)J(x)]^{-1} J^T(x)e(x). \quad (9)$$

E o MLM consiste na modificação deste método para a equação (10) a seguir:



$$\Delta x = [J^T(x)J(x) + \mu I]^{-1}J^T(x)e(x) \quad (10)$$

na qual foi introduzido o parâmetro  $\mu > 0$  na diagonal de  $J^T(x)J(x)$ ,  $I$  é a matriz identidade,  $e(x)$  é o erro e  $J$  é a matriz Jacobiana. Note que a matriz Hessiana é aproximada por  $J^T(x)J(x) + \mu I$ , que é definida positiva (BENATTI, 2017). O parâmetro  $\mu$ , chamado de parâmetro de Levenberg-Marquardt, sempre será multiplicado por um fator  $\beta$  quando a propagação resultar em um aumento na função erro, mas quando resultar na sua diminuição,  $\mu$  será dividido pelo fator  $\beta$ . O parâmetro  $\mu$  ajusta a aproximação de forma a evitar grandes propagações que possam levar a um erro de convergência, assim qualquer valor positivo e significativo de  $\mu$  será suficiente para restaurar a matriz  $J^T(x)J(x)$  e produzir uma boa direção de busca do erro pela rede neural.

A parte mais importante deste algoritmo é o cálculo da matriz jacobiana, pois se houver problemas de mapeamento da rede neural, os termos desta matriz podem ser alterados e calculados através de uma modificação simples do algoritmo de retropropagação.

O MLM aplicado às RNAs pode ser descrito resumidamente pelos seguintes passos (CUSTÓDIO, 2019):

- (i) Apresentam-se à RNA todas as variáveis de entrada, nesse caso, a pressão transmembrana, o número de Reynolds e o tempo de microfiltração, com a saída correspondente que é o fluxo de permeado;
- (ii) Iniciam-se os parâmetros da RNA (pesos) com valores aleatórios;
- (iii) Calculam-se novos valores para o fluxo de permeado, referentes às variáveis de entrada;
- (iv) Calcula-se o erro da equação (2), da equação (1) e o erro médio quadrático da equação (3);
- (v) Calcula-se a matriz Jacobiana e resolve-se a equação (10);
- (vi) Modificam-se os pesos da RNA de acordo com a direção de busca do MLM (equação (10));
- (vii) Itera-se de (iii) até (vi), modificando sucessivamente os pesos da RNA até que o gradiente da equação (5) atinja um valor menor que o pré-determinado ou até o erro médio quadrático atingir o valor desejado ou ainda, até que um critério de parada conveniente seja alcançado.

### 3 Resultados e discussões

A partir de dados experimentais da literatura publicados por Haneda (2010) referentes aos valores do fluxo de permeado de uma bebida à base de açaí no processo de microfiltração tangencial por meio de membranas cerâmicas com poros de diâmetro médio de 0,8 e 1,2  $\mu\text{m}$  que retêm os microrganismos presentes, preparou-se as matrizes numéricas para desenvolvimento das RNAs.

Para avaliar o desempenho do processo de microfiltração tangencial em relação ao fluxo transmembrana, a variação de parâmetros fluidodinâmicos (pressão transmembrana, regime de escoamento e tempo de filtração) foi investigada ao longo do processamento. Um exemplo da influência da variação desses parâmetros em relação ao fluxo de permeado pode ser visualizado na Tabela (1):



**Tabela 1:** Comportamento do fluxo transmembrana em função da variação de parâmetros fluidodinâmicos durante o processo de microfiltração usando membrana com poros de diâmetro médio de  $0,8 \mu\text{m}$ .

Pressão transmembrana (bar)	Re = 60000	Re = 40000	Re = 20000	Tempo (minuto)
	J (L/h.m <sup>2</sup> )	J (L/h.m <sup>2</sup> )	J (L/h.m <sup>2</sup> )	
1	403,56836	242,32436	64,32444	5
2	140,31182	84,26348	62,03259	
3	39,75077	62,77108	51,6429	
4	28,18969	34,3522	50,23	
1	39,82717	97,98909	64,57909	10
2	54,24032	66,48896	60,14819	
3	35,47266	42,06808	49,0964	
4	21,97624	30,99083	50,16593	

Todos os testes foram realizados variando-se a pressão transmembrana (1 – 4 bar) em base contínua sem interrupção do processo (durante 60 minutos). Após esse período, a velocidade média do fluido foi alterada ao variar a rotação da bomba, enquanto a pressão transmembrana foi controlada através da abertura ou fechamento da válvula globo presente na bancada de microfiltração.

A pressão transmembrana (PTM) é dada pela equação (11):

$$PTM = \frac{(P_a + P_r)}{2} - P_f \quad (11)$$

sendo que  $P_a$  é a pressão de alimentação ( $\text{N/m}^2$ ),  $P_r$  é a pressão do retido ( $\text{N/m}^2$ ) e  $P_f$  é a pressão do filtrado ( $\text{N/m}^2$ ). No trabalho Haneda (2010) a pressão transmembrana foi medida e controlada com manômetro instalado na bancada de microfiltração.

O coeficiente de Reynolds é um número adimensional usado para calcular o regime de escoamento de determinado fluido sobre uma superfície, calculado a partir da equação (12):

$$Re = \frac{\rho \bar{v} D}{\mu} \quad (12)$$

em que  $\rho$  é a massa específica do fluido ( $\text{kg/m}^3$ ),  $\bar{v}$  é a velocidade do fluido (m/s),  $D$  é o diâmetro interno da membrana (m) e  $\mu$  é a viscosidade dinâmica do fluido (Pa.s). Dependendo do valor do número de Reynolds, o escoamento é classificado como: Escoamento Laminar ( $Re < 2000$ ), Escoamento de Transição ( $2000 < Re < 2400$ ) e Escoamento Turbulento ( $Re > 2400$ ).

O fluxo transmembrana é obtido usando a equação (13):

$$J = \frac{m}{tA\rho} \quad (13)$$

sendo que  $m$  é a massa de permeado coletada durante a microfiltração (kg),  $t$  é o tempo de filtração (h),  $A$  é a área efetiva de filtração ( $\text{m}^2$ ) e  $\rho$  é a densidade do permeado ( $\text{kg.m}^{-3}$ ).

A cada 5 minutos o permeado era coletado e pesado e a partir dessa massa, o fluxo transmembrana era calculado. Para tanto, vale ressaltar que os ensaios de microfiltração foram conduzidos com membranas cerâmicas tubulares comerciais de  $\alpha$ -alumina ( $\text{Al}_2\text{O}_3$ ) de tama-

no médio de poro (distribuição média do diâmetro de poro) de 0,8  $\mu\text{m}$  e 1,2  $\mu\text{m}$ , diâmetro interno do tubo de 0,006 m, comprimento da membrana de 0,25 m e área de filtração de 0,0047  $\text{m}^2$ .

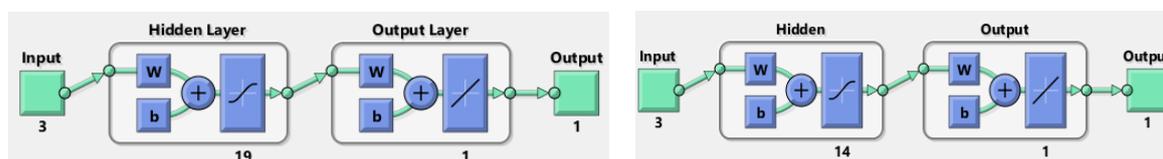
Construiu-se uma matriz de dados de entrada contendo 144 amostras com três parâmetros: número de Reynolds, pressão transmembrana e tempo de filtração, onde cada uma dessas amostras corresponde a um valor de fluxo de permeado e com estes valores, montou-se uma matriz de saída desejada para as RNAs. Estas matrizes, de entrada com dimensão  $3 \times 144$  e de saída com dimensão  $1 \times 144$ , foram montadas para ambas as membranas, com poros de 0,8 e 1,2  $\mu\text{m}$ .

Para implementação das RNAs utilizou o *software* Matlab com a ferramenta *nnstart – fitting app* e o Método de Levenberg-Marquardt (*trainlm*), com 19 neurônios na camada intermediária para a membrana com poros de diâmetro médio de 0,8  $\mu\text{m}$  e 14 neurônios na camada intermediária para a membrana com poros de diâmetro médio de 1,2  $\mu\text{m}$ . Para ambas as RNAs desenvolvidas, as 144 amostras de cada membrana foram divididas aleatoriamente em três conjuntos (treinamento, validação e teste), seguindo a divisão 70%-15%-15%. A Tabela (2) mostra a quantidade de amostras utilizada em cada conjunto.

**Tabela 2** – Quantidade de amostras utilizadas para as RNAs com as membranas de 0,8 e 1,2  $\mu\text{m}$ .

	Conjunto de treinamento	Conjunto de validação	Conjunto de teste	Total
Quantidade de amostras	100	22	22	144

A representação estrutural das redes neurais para a membrana de 0,8 e 1,2  $\mu\text{m}$  estão ilustradas na Figura 1(a) e 1(b), respectivamente.



**Figura 1** - Representação das redes neurais para as membranas de 0,8 e 1,2  $\mu\text{m}$ .

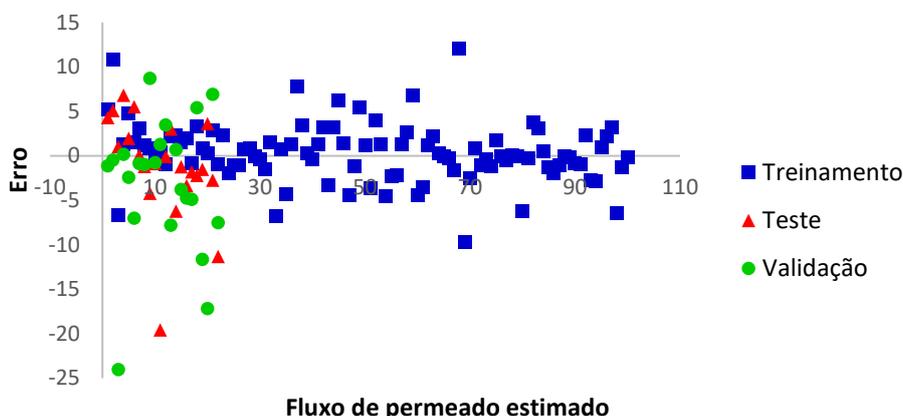
Fonte: MATLAB, 2019

Para melhor análise dos resultados obtidos divide-se esta seção em dois tópicos: a Seção 3.1 relacionada à membrana com poros de diâmetro médio de 0,8  $\mu\text{m}$  e a Seção 3.2 para a membrana com poros de diâmetro médio de 1,2  $\mu\text{m}$ .

### 3.1 Membrana com poros de diâmetro médio de 0,8 $\mu\text{m}$

O número de épocas realizadas pela RNA foi de 26 e o melhor desempenho se deu na época 20. No resultado fornecido para a membrana com poros de diâmetro médio de 0,8  $\mu\text{m}$ , o erro relativo médio obtido para as amostras de treinamento foi de 4,1%, para validação foi de 10,6% e para o teste foi de 7,6%. A diferença entre o resultado da RNA apresentado neste artigo, para o resultado apresentado em Proni, Haneda e Filletti (2019), é que a divisão das amostras nos conjuntos de treinamento, validação e teste não é mais do tipo 80%-10%-10% e sim, 70%-15%-15%, que é a mais usual para este tipo de problema e resultou em um melhor treinamento da RNA.

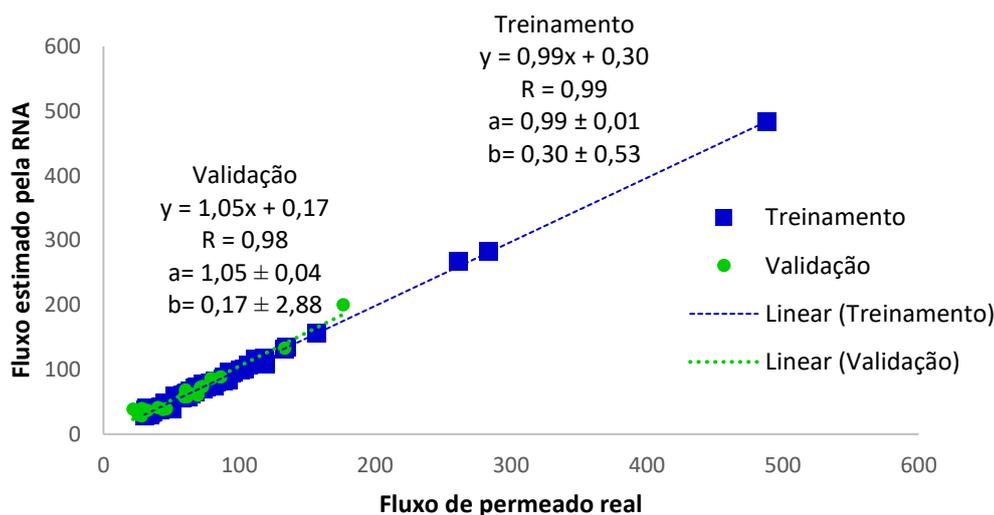
Na Figura 2 pode-se observar a distribuição de erros (que é a diferença entre os valores estimados pela RNA e os valores reais do fluxo de permeado) das amostras de treinamento, validação e teste. Nota-se que os erros permanecem próximos de zero, conforme o esperado e, além disso, há aleatoriedade na distribuição destes erros, o que mostra que os resultados obtidos não têm tendência.



**Figura 2** - Distribuição do erro para a membrana com poros de 0,8  $\mu\text{m}$ .

Fonte: Elaborado pelo autor

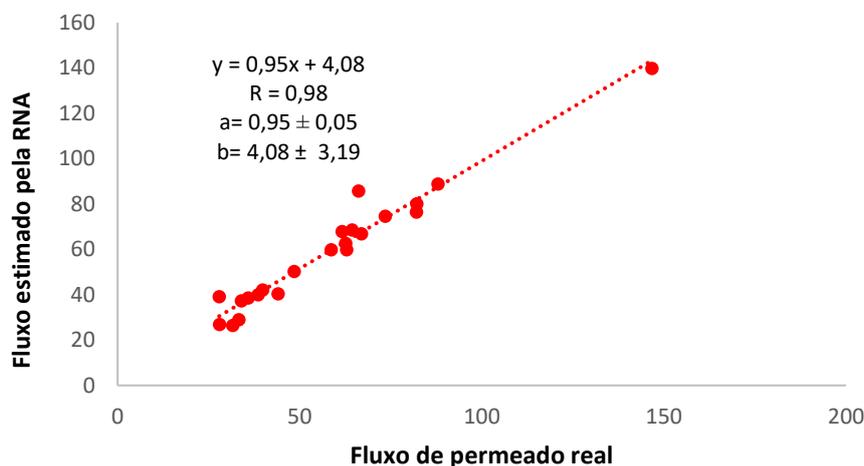
A Figura 3 mostra a relação entre os valores do fluxo de permeado da bebida à base de açaí reais e obtidos pela RNA no treinamento e na validação, cujos coeficientes de correlação entre os dados obtidos foram 0,99 e 0,98, respectivamente, mostrando também a proximidade dos pontos com a linha de tendência central  $y = ax + b$ , e os valores dos coeficientes angular  $a$  e linear  $b$ , com seus respectivos erros padrões.



**Figura 3** - Valores do fluxo de permeado estimados pela RNA versus valores reais para os conjuntos de treinamento e validação da membrana com poros de 0,8  $\mu\text{m}$ .

Fonte: Elaborado pelo autor

Para o conjunto de teste, a análise estatística do modelo de regressão também se mostrou satisfatória. A Figura 4 traz a reta de ajuste para o conjunto de teste, cuja equação é  $y = 0,95x + 4,08$ , com coeficiente de correlação entre os valores obtidos de 0,98, bem como os respectivos erros padrões para os coeficientes angular,  $a$ , e linear,  $b$ , da reta. Na Tabela (3) encontram-se os valores de fluxo de permeado estimados pela RNA e os valores reais, para a membrana com poros de  $0,8 \mu\text{m}$  para as amostras do conjunto de teste.



**Figura 4** - Valores do fluxo de permeado estimados pela RNA versus valores reais para o conjunto de teste para a membrana com poros de diâmetro médio de  $0,8 \mu\text{m}$ .

Fonte: elaborado pelo autor

**Tabela 3** – Valores do fluxo de permeado estimados pela RNA e valores reais para a membrana com poros de diâmetro médio de  $0,8 \mu\text{m}$  para dados do conjunto de teste.

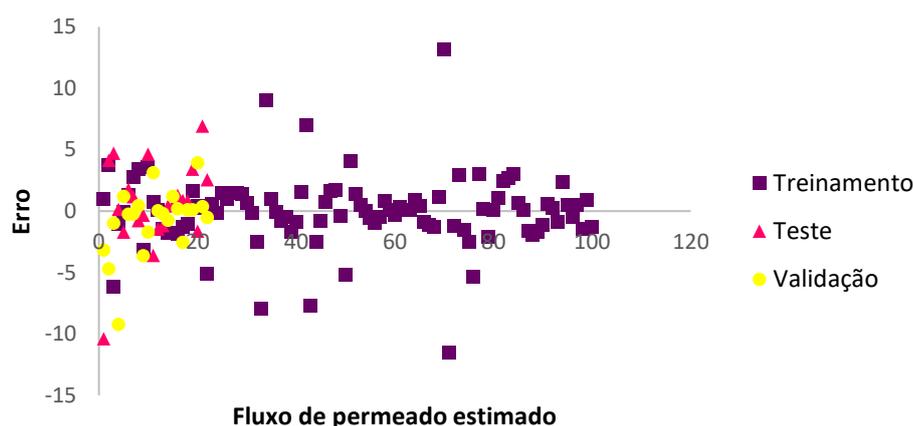
Amostra	Valor estimado pela RNA J (L/h.m <sup>2</sup> )	Valor real J (L/h.m <sup>2</sup> )
1	33,24	28,95
2	31,58	26,51
3	27,96	26,94
4	146,67	139,88
5	82,16	80,21
6	81,99	76,50
7	66,94	66,87
8	73,45	74,66
9	64,37	68,58
10	87,98	88,87
11	66,16	85,77
12	62,64	62,72
13	62,85	59,84
14	61,61	67,84
15	58,66	59,89
16	33,93	37,28
17	48,49	50,29
18	39,82	42,04
19	38,54	40,06

20	44,06	40,44
21	35,85	38,60
22	27,88	39,22

Para os três conjuntos analisados notam-se que os coeficientes de correlação se encontram próximos de 1, indicando a proximidade entre os valores de fluxo permeado reais e obtidos, confirmando a efetividade do resultado fornecido pela RNA.

### 3.2 Membrana com poros de diâmetro médio de 1,2 $\mu\text{m}$

Para a membrana com poros de diâmetro médio de 1,2  $\mu\text{m}$  o procedimento realizado, bem como o tratamento dos resultados obtidos, é bem similar ao da membrana de 0,8  $\mu\text{m}$  citado acima. O número de épocas realizadas pela RNA neste caso foi 36 e os melhores valores foram obtidos na época 30. No resultado apresentado pela RNA, os erros médios obtidos foram de 5,3%, 4,7% e 9,9% para o conjunto de treinamento, validação e teste, respectivamente. O gráfico da distribuição dos erros para todas as 144 amostras da membrana com poros de diâmetro médio de 1,2  $\mu\text{m}$  encontra-se na Figura 5.

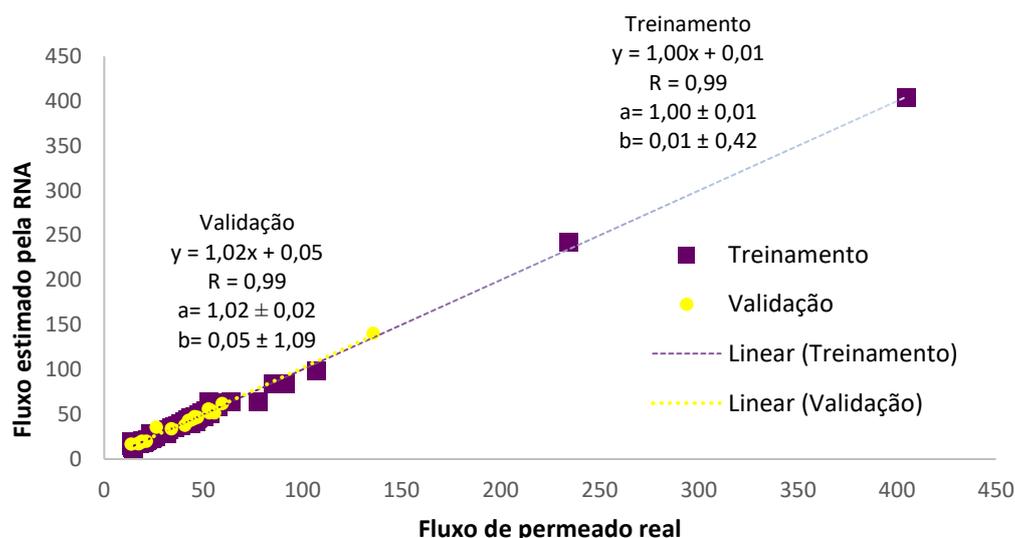


**Figura 5** - Dispersão do erro para treinamento, validação e teste da membrana com poros de diâmetro médio de 1,2  $\mu\text{m}$ .

Fonte: Elaborado pelo autor

Assim como para a membrana com poros de diâmetro médio de 0,8  $\mu\text{m}$ , os erros permanecem, em sua maior parte, próximo de zero indicando um bom resultado fornecido pela RNA e sua distribuição também é aleatória, não havendo tendência nos resultados obtidos.

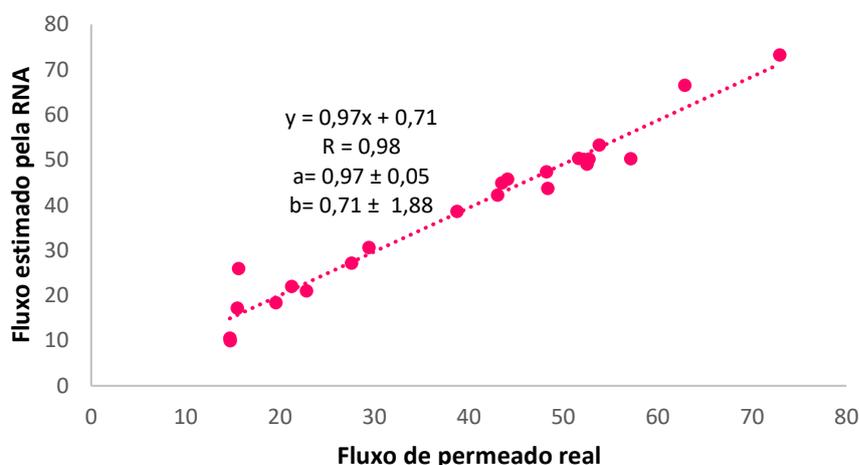
Realizando a análise para cada conjunto separadamente, obtém-se a linha de tendência central entre os valores de fluxo da bebida à base de açaí reais e obtidos pela RNA e seus respectivos coeficientes de correlação, que foram 0,99 para o treinamento e para a validação. Na Figura 6 é possível observar estas informações para os conjuntos de treinamento e validação, além dos respectivos erros padrões para os valores dos coeficientes angular,  $a$ , e linear,  $b$ , das retas ajustadas.



**Figura 6** - Valores do fluxo de permeado estimados pela RNA versus valores reais para os conjuntos de treinamento e validação da membrana com poros de diâmetro médio de 1,2  $\mu\text{m}$ .

Fonte: Elaborado pelo autor.

Para o conjunto de teste, a análise estatística do modelo de regressão dado pela reta  $y = 0,97x + 0,71$  também foi satisfatória e obtiveram-se os valores dos erros padrões para os coeficientes angular e linear da linha de tendência, conforme mostrado na Figura 7.



**Figura 7** - Valores do fluxo de permeado estimados pela RNA versus valores reais para o conjunto de teste para a membrana com poros de diâmetro médio de 1,2  $\mu\text{m}$ .

Fonte: Elaborado pelo autor.

Na Tabela (4) encontram-se os valores de fluxo de permeado estimados pela RNA e os valores reais, para a membrana com poros de diâmetro médio de 1,2  $\mu\text{m}$  para as amostras do conjunto de teste.

**Tabela 4** – Valores do fluxo de permeado estimados pela RNA e valores reais para a membrana com poros de diâmetro médio de 1,2  $\mu\text{m}$  para dados do conjunto de teste.

Amostra	Valor estimado pela RNA J (L/h.m <sup>2</sup> )	Valor real J (L/h.m <sup>2</sup> )
1	15,59	25,97
2	14,68	10,54
3	14,73	10,01
4	38,73	38,60
5	15,48	17,19
6	22,78	21,01
7	19,54	18,36
8	21,21	21,98
9	72,92	73,24
10	48,35	43,72
11	62,87	66,49
12	43,47	44,92
13	29,40	30,58
14	27,56	27,12
15	53,79	53,32
16	51,63	50,34
17	48,23	47,36
18	43,05	42,22
19	52,51	49,10
20	44,11	45,74
21	57,16	50,23
22	52,73	50,17

Novamente os coeficientes de correlação estão próximos de 1, indicando a proximidade dos valores obtidos pela RNA com os valores reais e confirmando a efetividade da mesma para o problema em questão.

## 4 Conclusão

Neste artigo é possível verificar que as Redes Neurais Artificiais mostraram-se eficazes para estimar o fluxo de permeado de uma bebida à base de açaí através do processo de micro-filtração tangencial com membranas cerâmicas com poros de diâmetro médio de 0,8 e 1,2  $\mu\text{m}$  de diâmetro em escoamento turbulento, visando um melhor controle de qualidade na produção de tal bebida. Os resultados de ambas RNAs criadas, uma para a membrana de poros de 0,8  $\mu\text{m}$  e outra para a membrana de 1,2  $\mu\text{m}$ , foram satisfatórios, tendo em vista os baixos erros médios encontrados, além da aproximação dos pontos com a linha de tendência central para ambos os conjuntos de teste e da análise estatística plausível. Com tais resultados conclui-se que é viável utilizar RNAs para estimar o fluxo de permeado de uma bebida à base de açaí através do processo de microfiltração tangencial.

É interessante ressaltar que a aplicação dos processos com membranas apresenta fatores limitantes, dos quais o fenômeno conhecido como *fouling* e/ou polarização de concentração é alvo de muitas pesquisas atuais já que geram redução do fluxo transmembrana (HE *et al.*, 2017; KOONANI; AMIRINEJAD, 2019; TANUDJAJA; CHEW, 2019). Assim, fluxos bai-



xos são pouco lucrativos e, caso haja necessidade de se trabalhar com altas pressões, grande consumo de energia será requerido, resultando em altos custos de operação. Para melhorar o desempenho de quaisquer processos de separação com membranas, se faz necessário o controle do *fouling* e/ou da polarização de concentração (QAISRANI; SAMHABER, 2011). Diante disso, trabalhos futuros envolvem pesquisas com modelos matemáticos (como as RNAs) que determinem ou auxiliem na previsão e definição dos parâmetros fluidodinâmicos ideais, sem a necessidade de se realizar tantos experimentos, o que resultaria em uma ótima forma de minimizar tempo e gastos às empresas.

## 5 Referências

BENATTI, K. A. **O método de Levenberg-Marquardt para o problema de quadrados mínimos não linear**. 2017. 106 f. Dissertação (Mestrado em Matemática) – Setor de Ciências Exatas, Universidade Federal do Paraná, Curitiba, 2017.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2000.

BURKE, J. V.; FERRIS, M. C. A Gauss-Newton method for convex composite optimization. **Mathematical Programming**, v. 71, n. 2, p. 179–194, 1995.

CASSANO, A.; CONIDI, C. Integration of membrane Technologies into conventional existing systems in the food industry. *In*: DALENA, F.; BASILE, A.; ROSSI, C. (ed.). **Bioenergy Systems for the Future: prospects for biofuels and biohydrogen**. Duxford: Woodhead Publishing, p. 451-479, 2017.

CERVEIRA, G. S.; BORGES, C. P.; KRONEMBERGER, F. A. Gas permeation applied to biogas upgrading using cellulose acetate and polydimethylsiloxane membranes. **Journal of Cleaner Production**, v. 187, p. 830-838, 2018.

CHEMAT, F. *et al.* Review of green food processing techniques. Preservation, transformation, and extraction. **Innovative Food Science and Emerging Technologies**, v. 41, p. 357–377, 2017.

CHERYAN, M. **Ultrafiltration and microfiltration handbook**. Lancaster: Technomic Pub. Co., 1998.

CUSTÓDIO, C. A. **Redes neurais artificiais e teoria do funcional da densidade: otimização de funcionais para modelagem de nanomateriais**. 2019. 48 f. Dissertação (Mestrado em Química) – Instituto de Química de Araraquara, Universidade Estadual Paulista “Júlio Mesquita Filho”, Araraquara, 2019.

CUSTÓDIO, C. A.; FILLETTI, É. R.; FRANCA, V. V. Artificial neural networks for density-functional optimizations in fermionic systems. **Scientific Reports**, v. 9, Article number: 1886, 2019. Disponível em: <https://www.nature.com/articles/s41598-018-37999-1>. Acesso em: 27 nov. 2019.



DORNIER, M.; BELLEVILLE, M.-P.; VAILLANT, F. Membrane technologies for fruit juice processing. In: ROSENTHAL, A. *et al.* (ed.). **Fruit preservation**. New York: Springer, 2018. chapt. 8, p. 211-248. (Food Engineering Series).

FAGNANI, R.; PUPPIO, A. A. N.; ZANON, E. O. Sustainable alternative for the food industry: converting whey and orange juice into a micro-filtered beverage. **Scientia Agricola**, v. 75, n. 2, p. 136-143, 2018.

GHANDEHARI, S.; MONTAZER-RAHMATI, M. M.; ASGHARI, M. Modeling the flux decline during protein microfiltration: a comparison between feed-forward back propagation and radial basis function neural networks. **Separation Science and Technology**, v. 48, n. 9, p. 1324-1330, 2013.

HAGAN, M. T.; MENHAJ, M. B. Training feedforward networks with the Marquardt algorithm. **IEEE Transactions on Neural Networks**, v. 5, n. 6, p. 989-993, 1994.

HANEDA, R. N. **Estudo do desempenho do processo de microfiltração tangencial com membranas cerâmicas aplicado à retenção de bactérias e redução de sólidos suspensos de uma bebida à base de açaí**. 2010. 174 f. Tese (Doutorado em Engenharia Mecânica) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2010.

HASAN, A. *et al.* A surface-renewal model of cross-flow microfiltration. **Brazilian Journal of Chemical Engineering**, v. 30, n. 1, p. 167 – 186, 2013.

HAYKIN, S. **Neural networks: a comprehensive foundation**. 2nd ed. New Jersey: Prentice Hall, 1999.

HE, Z. *et al.* The effects of salt concentration and foulant surface charge on hydrocarbon fouling of a poly(vinylidene fluoride) microfiltration membrane. **Water Research**, v. 117, p. 230–241, 2017.

KOONANI, H.; AMIRINEJAD, M. Combined three mechanisms models for membrane fouling during microfiltration. **Journal of Membrane Science and Research**, v. 5, n. 4, p. 274-282, 2019.

KUMAR, P. *et al.* Perspective of membrane technology in dairy industry: a review. **Asian-Australasian Journal of Animal Science**, v. 26, n. 9, p. 1347–1358, 2013.

MACEDONIO, F.; DRIOLI, E. Membrane engineering for green process engineering. **Engineering**, v. 3, n. 3, p. 290-298, 2017.

MACHADO, M. R. D. *et al.* Effect of enzymatic treatment on the cross-flow microfiltration of açai pulp: analysis of the fouling and recovery of phytochemicals. **Journal of Food Engineering**, v. 113, n. 3, p. 442-452, 2012.

MORAIS, J. P. G. **Aplicações da filtração tangencial na indústria dos laticínios**. 2018. 71 f. Relatório de estágio (Mestrado em Engenharia de Alimentos) – Instituto Politécnico de Coimbra, Universidade Agrária de Coimbra, Coimbra/Portugal, 2018.



NASCIMENTO, E. R. F. **Desenvolvimento de modelos neurais para o processamento de sinais acústicos visando à medição de propriedades topológicas em escoamentos multifásicos**. 2007. 118 f. Tese (Doutorado em Engenharia Mecânica) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2007.

NOURBAKHS, H. *et al.* Study of different fouling mechanisms during membrane clarification of red plum juice. **International Journal of Food Science & Technology**, v. 49, n. 1, p. 58-64, 2014.

ORTEGA-ZAMORANO, F. *et al.* FPGA implementation of neurocomputational models: comparison between standard back-propagation and C-Mantec constructive algorithm. **Neural Processing Letters**, v. 46, n. 3, p. 899-914, 2017.

PHALAK, P. *et al.* Study of membrane transport for protein filtration using artificial neural networks. **International Journal of Engineering Research and Development**, v. 13, n. 6, p. 40-49, 2017.

PICART-PALMADE, L. *et al.* Potentialities and limits of some non-thermal technologies to improve sustainability of food processing. **Frontiers in Nutrition**, v. 5, art. 130, p. 1-18, 2019. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6344468/>. Acesso em: 27 nov. 2019.

PRONI, C.; HANEDA, R. N.; FILLETTI, E. R. Inteligência artificial aplicada ao processo de separação de misturas por membranas cerâmicas. In: ENCONTRO REGIONAL DE MATEMÁTICA APLICADA E COMPUTACIONAL, 6., 2019, Bauru. **Caderno de trabalhos completos e resumos** [...]. Bauru: Unesp, Faculdade de Ciências, 2019. p. 462-463, 2019. Disponível em: <https://www.fc.unesp.br#!/departamentos/matematica/eventos2341/ermac-2019/caderno-de-trabalhos-e-resumos/>. Acesso em: 27 nov. 2019.

QAISRANI, T. M.; SAMHABER, W.M. Impact of gas bubbling and blackflusing on fouling control and membrane cleaning. **Desalination**, v. 266, p. 154 – 161, 2011.

RAMIL, A. *et al.* A computer vision system for identification of granite-forming minerals based on RGB data and artificial neural networks. **Measurement**, v. 117, p. 90-95, 2018.

SEKULIC, Z. *et al.* The prediction of heavy metal permeate flux in complexation-microfiltration process: polynomial neural network approach. **Water Air and Soil Pollution**, v. 230, art. 23, 2019. Disponível em: <https://link.springer.com/article/10.1007%2Fs11270-018-4072-y>. Acesso em: 27 nov. 2019.

SILVA, A. A. B. **Análise do fluxo de permeado no processo de microfiltração tangencial para clarificação de vinhaça via redes neurais artificiais**. 2018. 86 f. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Química) - Instituto de Química, Universidade Estadual Paulista “Júlio Mesquita Filho”, Araraquara, 2018.

TANUDJAJA, H. J.; CHEW, J. W. In-situ characterization of cake layer fouling during cross-flow microfiltration of oil-in-water emulsion. **Separation and Purification Technology**, v. 218, p. 51-58, 2019.



---

TANZIFI, M. *et al.* Adsorption of Amido Black 10B from aqueous solution using polyaniline/SiO<sub>2</sub> nanocomposite: Experimental investigation and artificial neural network modelling. **Journal of Colloid and Interface Science**, v. 510, p. 246-261, 2018.

TREVISOLI, A. M. S. **Estudo experimental da microfiltração tangencial com membrana cerâmica aplicada na clarificação da vinhaça**. 2010. 137 f. Dissertação (Mestrado em Engenharia Mecânica) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2010.

WALCZAK, S.; VELANOVICH, V. Improving prognosis and reducing decision regret for pancreatic cancer treatment using artificial neural networks. **Decision Support Systems**, v. 106, p. 110-118, 2018.

ZARKADAS, D.; SIRKAR, K. K. (2019). Membrane systems for pharmaceutical applications. *In*: AM ENDE, D. J.; AM ENDE, M. T. (ed.). **Chemical engineering in the pharmaceutical industry**. 2nd ed. Hoboken: John Wiley and Sons, 2019. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/9781119600800.ch32>. Acesso em 27 nov. 2019.

ZEMAN, L. J.; ZYDNEY, A. L. **Microfiltration and ultrafiltration: principles and applications**. New York: Marcel Dekker, 1996.

ZHANG, S. *et al.* Use of microfiltration to improve quality and shelf life of ultra-high temperature milk. **Journal of Food Processing and Preservation**, v. 40, n. 4, p. 707-714, 2016.

ZUO, K. *et al.* Coupling microfiltration membrane with biocathode microbial desalination cell enhances advanced purification and long-term stability for treatment of domestic wastewater. **Journal of Membrane Science**, v. 547, p. 34-42, 2018.