

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
Instituto de Química
Campus de Araraquara – SP

Gabriela Dias Benevenuto

**Estimativa do fluxo de permeado do soro de leite no processo de
microfiltração tangencial através de modelos neurais**

ARARAQUARA
2021

Gabriela Dias Benevenuto

**Estimativa do fluxo de permeado do soro de leite no processo de
microfiltração tangencial através de modelos neurais**

Trabalho de Conclusão de Curso (TCC)
apresentado ao Instituto de Química da
Universidade Estadual Paulista “Júlio de
Mesquita Filho” como requisito parcial para
obtenção do título de Bacharel em
Engenharia Química.

**Orientadora: Prof^a Dr^a Érica Filletti
Nascimento**

Araraquara

2021

GABRIELA DIAS BENEVENUTO

Estimativa do fluxo de permeado do soro de leite no processo de microfiltração tangencial através de modelos neurais

Trabalho de Conclusão de Curso
apresentado ao Instituto de Química de
Araraquara, da Universidade Estadual
Paulista “Júlio de Mesquita Filho” para
obtenção do título de Bacharel em
Engenharia Química.

Araraquara, 18 de janeiro de 2022.

BANCADA EXAMINADORA



Prof. Dr. Fábio Roberto Chavarette
Instituto de Química – UNESP, Araraquara.



Prof. Dr. Elias de Souza Monteiro Filho
Instituto de Química – UNESP, Araraquara.

Prof. Dr. Rodrigo Fernando Costa Marques
Instituto de Química – UNESP, Araraquara.

AGRADECIMENTOS

Primeiramente agradeço a Deus, à Ele seja dada toda honra e glória.

Aos meus pais e meu noivo Matheus, que sempre me apoiaram e torceram por mim em toda a minha vida, principalmente durante a graduação e em minha vida pessoal.

À Profa. Dra. Érica Filletti, pelas instruções e norteamentos para a realização do trabalho, assim como todo o apoio dado durante a graduação.

À Universidade Estadual Paulista “Júlio de Mesquita Filho” pelo ensino oferecido e à todos que indiretamente ou diretamente fizeram parte da minha vida e formação.

RESUMO

As Redes Neurais Artificiais (RNAs) são funções matemáticas que tentam reproduzir a estrutura e o funcionamento das redes neurais biológicas, através de técnicas computacionais, e adquirem conhecimento através da experiência. Assim, fazendo uma breve comparação das RNAs com as redes biológicas, ambos os sistemas são baseados em conexões sinápticas e funcionam através de uma função do conjunto de 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. Dessa forma, a resolução de problemas se inicia com uma fase de aprendizagem, onde exemplos são apresentados à rede neural e depois, após extrair características necessárias para representar a informação recebida, essas características são utilizadas para gerar respostas para o problema, para dados não utilizados no treinamento da RNA. Essa ferramenta foi utilizada para estimar o fluxo do permeado do soro de leite no processo da microfiltração tangencial, a qual foi bem sucedida, especialmente com a membrana de filtração que continha mais amostras para serem analisadas, com erros de 3% a 9%.

Palavras-chave: algoritmo de aprendizagem, microfiltração tangencial, soro do leite, fluxo de permeado.

ABSTRACT

Artificial Neural Networks (ANNs) are mathematical functions that try to reproduce the neural structure and functioning of biological neural networks, through computational techniques, and acquire knowledge through experience. Thus, making a brief comparison of ANNs and biological networks, both systems are based on synaptic connections and work through a function of the set of neurons. In most models, the connections between neurons are associated with weights, which store the knowledge represented in the model and serve to weight the input received by each neuron in the neural network. Thus, problem solving starts with a learning phase, where examples are presented to the neural network and then, after extracting characteristics necessary to represent the information received, these characteristics are used to generate answers to the problem, for unused data in ANN training. This tool was used to estimate the whey permeate flux in the crossflow microfiltration process, which was successful, especially with the filtration membrane that contained more samples to be analyzed, with errors ranging from 3% to 9%.

Keywords: learning algorithm, crossflow microfiltration, whey, permeate flow.

LISTA DE FIGURAS

Figura 1 - Estrutura do neurônio.....	11
Figura 2 - Tipos de filtração.....	12
Figura 3 - Esquema de microfiltração tangencial.....	13
Figura 4 - Modelo de um neurônio de McCulloch e Pitts.....	14
Figura 5 - Modelo de um perceptron simples com uma única saída.	15
Figura 6 - Rede neural ADALINE	16
Figura 7 - Esquema do <i>perceptron</i>	19
Figura 8 - Exemplos de Funções de Ativação: a) Degrau, b) Linear por Partes, c) Sigmóide.....	20
Figura 9 - Ilustração dos sinais funcionais e sinais de erro em um MLP.....	21
Figura 10 - Representação da rede neural com cinco neurônios.....	27
Figura 11 - Gráfico da regressão linear das amostras utilizadas para o treinamento.....	28
Figura 12 - Gráfico da regressão linear das amostras utilizadas para a validação.....	28
Figura 13 - Gráfico da regressão linear das amostras utilizadas para o teste.....	29
Figura 14 - Gráfico da distribuição aleatória dos erros.....	29
Figura 15 - Gráfico da distribuição aleatória dos erros considerando a maior parte dos dados.....	30
Figura 16 - Representação da rede neural com vinte neurônios.....	31
Figura 17 - Gráfico da regressão linear das amostras utilizadas para o treinamento.....	31
Figura 18 - Gráfico da regressão linear das amostras utilizadas para a validação.....	32
Figura 19 - Gráfico da regressão linear das amostras utilizadas para o teste.....	32
Figura 20 - Gráfico da distribuição aleatória dos erros.....	33
Figura 21 - Gráfico da distribuição aleatória dos erros considerando a maior parte dos dados.....	33
Figura 22 - Representação da rede neural com oito neurônios.....	35

Figura 23 - Gráfico da regressão linear das amostras utilizadas para o treinamento.....	35
Figura 24 - Gráfico da regressão linear das amostras utilizadas para a validação.....	36
Figura 25 - Gráfico da regressão linear das amostras utilizadas para o teste	
Figura 26 - Gráfico da distribuição aleatória dos erros.....	37
Figura 27 - Representação da rede neural com trinta neurônios.....	37
Figura 28 - Gráfico da regressão linear das amostras utilizadas para o treinamento.....	38
Figura 29 - Gráfico da regressão linear das amostras utilizadas para a validação.....	38
Figura 30 - Gráfico da regressão linear das amostras utilizadas para o teste.....	39
Figura 31 - Gráfico da distribuição aleatória dos erros.....	39
Figura 32 - Representação da rede neural com onze neurônios.....	40
Figura 33 - Gráfico da regressão linear das amostras utilizadas para o treinamento.....	40
Figura 34 - Gráfico da regressão linear das amostras utilizadas para a validação.....	41
Figura 35 - Gráfico da regressão linear das amostras utilizadas para o teste.....	41
Figura 36 - Gráfico da distribuição aleatória dos erros.....	42

LISTA DE TABELAS

Tabela 1 - Tamanho dos poros da membrana, tipo da membrana e dimensão das matrizes de entrada e saída de cada situação.....	26
Tabela 2 - Resultados do coeficiente de determinação e correlação e erro percentual médio da membrana com poros de 0,8 µm de diâmetro.....	34
Tabela 3 - Resultados do coeficiente de determinação e correlação e erro percentual médio da membrana com poros de 1,2 µm de diâmetro.....	43

SUMÁRIO


1. INTRODUÇÃO E JUSTIFICATIVA	11
1.1 Microfiltração tangencial do soro do leite	12
1.2 Histórico das redes neurais artificiais	14
1.3 Pesquisas recentes envolvendo RNAs e filtração tangencial.....	17
2. OBJETIVOS	17
2.1 Objetivos específicos	18
3. MATERIAIS E MÉTODOS	18
3.1 Teoria básica de Redes Neurais Artificiais	18
3.1.1 O algoritmo de retropropagação do erro	21
3.1.2 O algoritmo de Levenberg - Marquardt.....	23
3.2 Base de dados e experimento.....	24
3.3 Desenvolvimento das RNAs.....	25
4. RESULTADOS E DISCUSSÃO	27
4.1 Membrana com poros de 0,8 µm de diâmetro.....	27
4.1.1 Sem impregnação de prata.....	27
4.1.2 Com uma camada de impregnação de prata.....	30
4.2 Membrana com poros de 1,2 µm de diâmetro.....	34
4.2.1 Sem impregnação de prata	34
4.2.2 Com uma camada de impregnação de prata	37
4.2.3 Com duas camadas de impregnação de prata.....	40
5. CONSIDERAÇÕES FINAIS	43
6. REFERÊNCIAS.....	45

1. INTRODUÇÃO E JUSTIFICATIVA

O sistema nervoso central contém mais de 100 bilhões de neurônios. Ele recebe, a cada minuto, milhões de *bits* de informação provenientes de diferentes órgãos e nervos sensoriais e os integra para determinar as respostas a serem executadas pelo corpo. A informação é transmitida para o sistema nervoso e se propaga por uma sucessão de neurônios [1].

O neurônio é formado pelos três componentes expostos na Figura 1: corpo celular, dendritos e axônio. O corpo celular contém núcleo e citoplasma com as organelas citoplasmáticas usualmente encontradas em outras células e é o local de recepção de estímulos, através de contatos sinápticos. Os dendritos, geralmente curtos e ramificados, são especializados em receber estímulos e traduzi-los. E o axônio, constituído de uma fibra tubular que pode alcançar até alguns metros, é responsável por transmitir os estímulos para outras células [2].

Figura 1 - Estrutura do neurônio.




Fonte: HALL, 2011.

As Redes Neurais Artificiais (RNAs) tentam reproduzir a estrutura e o funcionamento das redes neurais biológicas, buscando programar seu comportamento básico e sua dinâmica. São baseadas em unidades de computação paralela e distribuídos que se comunicam por conexões sinápticas, possuem detectores de características, redundância e modularização das conexões, assim, as RNAs funcionam como um mecanismo que é capaz de reproduzir com fidelidade as funções encontradas no corpo humano [3].

1.1 Microfiltração tangencial do soro do leite

A filtração é um processo físico de separação de misturas heterogêneas que consiste na presença de um meio filtrante responsável por reter a fração sólida da mistura, a fração retida recebe o nome de torta e a fração líquida ou gasosa de permeado. Amplamente utilizada em análises laboratoriais e em escala industrial, uma das modalidades de filtração mais utilizada é a filtração tangencial por membrana, a qual utiliza o gradiente de pressão como força motriz aplicado tangencialmente a uma superfície permeável (membrana), capaz de separar partículas em função da sua massa molecular e dimensão dos poros.

A técnica é separada em microfiltração, ultrafiltração, nanofiltração ou osmose reversa e o que difere entre elas é a seletividade da membrana, a qual é diretamente relacionada com o tamanho e forma dos solutos a serem retidos e também pela pressão aplicada à membrana [4]. Na Figura 2 a seguir, são ilustrados o tipos de filtração e suas seletividades.




Fonte: MGC Soluções, s. d.

Essa tecnologia possui como vantagem a possibilidade de separação sem a aplicação de calor, fazendo com que propriedades dos alimentos e outras substâncias não sejam alteradas, além disso, há também economia de custos de utilidade, uma vez que não fazem o uso do vapor [5].

A microfiltração, por sua vez, possui abertura dos poros de 0,1 a 10 μm e trabalha na faixa de pressão transmembrana de 0,1 a 2,0 bar, estando entre a ultrafiltração e a filtração convencional que não possui operação com membrana [6]. A Figura 3 a seguir ilustra o mecanismo.

Figura 3 – Esquema de microfiltração tangencial.



Fonte: Autora, 2021.

No meio alimentício essa técnica é amplamente utilizada na clarificação de sucos, cervejas e vinhos, e ultimamente vem ganhando destaque na indústria de laticínios, pois é responsável por remover bactérias e reter gorduras e proteínas do soro de alto peso molecular, de pequenas proteínas de soro, nitrogênio não protéico (NPN), lactose e minerais de baixo peso molecular [14].

Apesar das vantagens descritas, a filtração por membrana possui algumas desvantagens, como a polarização de concentração e o *fouling*. A polarização de concentração é devido ao aumento da concentração de soluto na interface membrana/solução, porém, quando o fluxo é tangencial, ocorre a retrodifusão do soluto no sentido do seio da solução [8], estabelecendo-se um perfil de concentração deste soluto na interface membrana/solução, chamado *fouling* (deposição de partículas e espécies solúveis na superfície da membrana), responsável por ocasionar o aumento da resistência ao fluxo de permeado e a perda de produtividade ao longo do tempo [9].


Diante disso, é de extrema importância o estudo de métodos para aumentar a produtividade da filtração. A rede neural artificial atua de modo a

prever comportamentos e apresentar resultados que sejam combinados com condições de operações favoráveis capazes de aumentar o fluxo de permeado.

Neste trabalho em questão, foram utilizados dados experimentais retirados da dissertação de mestrado da Renata Natsumi Haneda, intitulada Investigação do desempenho de diferentes estruturas microporosas tubulares na retenção de bactérias em suspensão por microfiltração tangencial. Haneda (2006) apresentou resultados experimentais do processo de filtração tangencial de uma suspensão de soro de leite aplicada na retenção de bactérias do grupo coliforme. Além da membrana utilizada na filtração possuir diferentes tamanhos de diâmetro, Haneda também utilizou uma atividade química de prata na membrana para aumentar a ação bactericida, pois os íons prata reagem com resíduos de aminoácidos nucleofílicos nas proteínas das bactérias e desencarregam a desnaturação protéica. Dessa maneira, algumas membranas receberam tratamento de uma ou duas camadas de citrato de prata [10].

1.2 Histórico das redes neurais artificiais

As redes neurais artificiais foram introduzidas por McCulloch e Pitts em 1943, que criaram um modelo bem próximo da rede neural humana, porém este modelo não apresentava capacidade de aprendizagem. Esse neurônio ficou conhecido como nó MCP (iniciais dos pesquisadores), descrito na Figura 4 abaixo.




Fonte: RAUBER, s.d.

O primeiro neurônio que iniciou os trabalhos sobre aprendizado foi desenvolvido por Donald Hebb, em 1949. Hebb apresentou uma teoria para explicar o aprendizado em neurônios biológicos a partir das sinapses.

Em 1958, Rosenblatt apresentou um modelo de rede chamada *perceptron*, que consistia de uma rede formada por nós MCP acrescidos de pesos sinápticos ajustáveis por uma regra de aprendizado. Alguns anos depois, demonstrou o teorema de convergência do perceptron, que mostra que um nodo MCP treinado com o algoritmo de aprendizado do perceptron sempre converge caso o problema em questão seja linearmente separável. Esse modelo ficou conhecido como perceptron de única camada, embora fosse composta por unidades de entrada (retina), por um nível intermediário formado pelas unidades de associação e por um nível de saída formado pelas unidades de resposta. Esse neurônio está esquematizado na Figura 5 [12].

Figura 5 - Modelo de um perceptron simples com uma única saída.




Fonte: BRAGA, 2000.

Em 1960, logo depois da teoria de Rosenblatt, Widrow e Hoff apresentaram uma nova forma de aprendizagem, conhecida como a regra delta, a qual foi utilizado no modelo neural linear ADELIN (Adaptive Linear Element). O algoritmo de treinamento tem extrema importância na área de RNAs já que deu origem ao algoritmo de back-propagation para treinamento de perceptrons de múltiplas camadas. Neste, há diversas saídas binárias bipolares e tem seus pesos adaptados em função do erro de sua saída linear antes

mesmo da aplicação da função de ativação [3]. A rede neural ADELINe está apresentada na Figura 6.

Figura 6 - Rede neural ADALINE.



Fonte: MINUSSI, 2008.

Após o modelo ADELINe, surgiu o MADELINE (Multi- ADELINe), em que o processamento é bem mais complexo e há o mecanismo de adaptação de pesos (treinamento) [13].

Entretanto, em 1969, Minsky e Pappert apresentaram algumas restrições do perceptron, mostrando que ele era muito limitado e não seria capaz de superar as limitações do perceptron de uma única camada. Dessa forma, os estudos na área de RNAs só voltaram com força na década de 80 [14].

Porém, ainda na década de 70, Kohonen foi um pesquisador que continuou seus trabalhos com redes neurais e desenvolveu mapas - auto organizáveis, que são redes neurais artificiais que utilizam treinamento não supervisionado, agrupando entradas iguais e criando classes denominadas clusters [15].

Em 1982, John Hopfield criou uma rede capaz de associar modelos de entrada com modelos previamente armazenadas na memória da RNA [15].

Com as pesquisas de Rumelhart, Hinton e Williams, somente no final da década de 80 foi desenvolvido o algoritmo de retropropagação do erro, o qual é visto como uma resposta às críticas feitas por Minsky e Papert, pois são capazes de resolver problemas complexos [15]. Assim, as pesquisas na área de Redes Neurais Artificiais voltaram a ser impulsionadas trazendo

possibilidades de aplicações dessa ferramenta em diversas áreas como Física [16], Medicina [17], Neurocomputação [18], Química [19] e outras.

1.3 Pesquisas recentes envolvendo RNAs e filtração tangencial

Atualmente, o estudo da microfiltração tangencial com Redes Neurais Artificiais tem crescido e tem se tornado um grande aliado ao aumento de produtividade das indústrias. Por exemplo, Phalak *et al.* (2017) direcionaram seus estudos para a modelagem de vários tipos de processos de separação de membrana com o foco na separação de proteínas obtendo erros percentuais inferiores a 2,3%.

Com a finalidade de remover metais pesados, Sekulic *et al.* (2019) estudaram o fluxo de permeado da filtração de águas residuais. Com o uso das Redes Neurais Artificiais foi possível prever resultados com um coeficiente de correlação de 0,96, tornando possível a antecipação de medidas preventivas através da inserção de diversos parâmetros da água residual.

No trabalho de Jokic *et al.* (2020) foi realizada a microfiltração para a separação de biomassa microbiana após o processo de cultivo, porém, utilizou métodos hidrodinâmicos como promotores de turbulência e pulverização de ar para melhorar o fluxo de permeado durante a microfiltração. A partir dos dados, treinou uma rede neural artificial para prever o fluxo de permeado e obteve excelentes resultados. O coeficiente de determinação foi de 0,99, e erro relativo absoluto inferior a 20% para mais de 95% dos dados previstos.

As pesquisas mostram que as redes neurais artificiais são promissoras e ainda possuem muito espaço no ramo acadêmico e também industrial, tornando este trabalho em questão um estudo pertinente e atual para o tema.

2. OBJETIVOS

O principal objetivo deste trabalho foi desenvolver modelos de redes neurais artificiais, com o algoritmo de retropropagação de erro ou com o algoritmo de Levenberg-Marquardt, capazes de estimar o fluxo de permeado no processo de microfiltração tangencial do soro do leite.

2.1 Objetivos específicos

Os objetivos específicos desse trabalho foram:

- Implementar modelos neurais para analisar o fluxo de permeado no processo de microfiltração tangencial para membranas com poros de tamanhos 0,8 μm e 1,2 μm de diâmetro, com e sem impregnação de prata, utilizando o software MATLAB;
- Realizar treinamento de cada RNA a partir da base de dados experimentais publicada na literatura [10].
- Definir o algoritmo de aprendizagem e a quantidade de neurônios da camada intermediária, visando a menor porcentagem de erro para os conjuntos de treinamento, validação e teste;
- Analisar o desempenho dos modelos neurais após treinamento a partir dos gráficos da regressão linear, do coeficiente de correlação e dos erros percentuais.

3. MATERIAIS E MÉTODOS

Nesta seção serão apresentados os principais conceitos de Redes Neurais Artificiais, como a sua teoria, algoritmos mais utilizados atualmente, descrição do experimento em questão e da base de dados.


3.1 Teoria básica de Redes Neurais Artificiais

O modelo de neurônio mais utilizado pelas pesquisas é o *perceptron*, que pode ser visto na Figura 7, onde são identificados seus elementos básicos.

As principais partes do neurônio artificial genérico são: sinapses, caracterizadas pelos seus pesos associados (w_{kj}), onde o primeiro índice do peso sináptico se refere ao neurônio em questão e o segundo ao sinal de entrada da sinapse à qual o peso está conectado; a junção somadora e a função de ativação [8]. Também há um *bias* (*threshold*), aplicado

externamente (θ_k), o qual tem o efeito de aumentar ou diminuir a entrada da função de ativação.

Figura 7 – Esquema do *perceptron*.



Fonte: HAYKIN, 1999.

Em termos matemáticos, um neurônio k é descrito pelas Equações 1, 2 e 3 a seguir:

$$u_k = \sum_{j=1}^p w_{kj} x_j \quad (1)$$


$$v_k = u_k + \theta_k \quad (2)$$

$$y_k = \varphi(v_k) \quad (3)$$

sendo que u_k é a saída da função agregadora, v_k o potencial de ativação do neurônio k e y_k o sinal de saída do mesmo.

A função de ativação, denotada por $\varphi(v)$, define a saída de um neurônio em termos do potencial de ativação v . Há três tipos básicos de funções de ativação ilustrados na Figura 8, as quais são descritas pelas Equações 4, 5 e 6 [19].

Figura 8 - Exemplos de Funções de Ativação: a) Degrau, b) Linear por Partes, c) Sigmóide.



Fonte: HAYKIN, 1999.

Função Degrau

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 0 \\ 0, & \text{se } v < 0 \end{cases} \quad (4)$$

Função Linear por Partes

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq a \\ v, & \text{se } -a < v < a \\ -1, & \text{se } v \leq -a \end{cases} \quad (5)$$

Função Sigmóide

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

Além da função de ativação, as redes neurais são classificadas por mais dois aspectos principais: o padrão de conexões entre as unidades (arquitetura) e o método de determinação dos pesos das conexões (algoritmo de treinamento ou aprendizado) [15]. Sendo assim, as camadas de uma rede neural são classificadas em três grupos:

- a) Camada de Entrada: onde os padrões são apresentados à rede;
- b) Camadas Intermediárias ou Ocultas: onde é feita a maior parte do processamento;
- c) Camada de Saída: onde o resultado final é concluído e apresentado.


Além disso, uma característica importante das RNAs é o aprendizado de problemas através de exemplos, que se baseia em treinamento supervisionado e não supervisionado. O primeiro necessita de um “professor”. Já o segundo é direcionado por correlações existentes nos dados de entrada e, portando, não necessita de um “professor” [15].

3.1.1 O algoritmo de retropropagação do erro

Um dos algoritmos de aprendizagem mais utilizados nas RNAs é o algoritmo de retropropagação do erro, o qual é baseado em uma regra de aprendizagem que “corrige” o erro durante o treinamento. Ele é constituído de duas fases, a primeira é a fase de propagação do sinal funcional (*feedforward*) e a segunda é a de retropropagação do erro (*backpropagation*). Na primeira, os vetores de dados são aplicados às unidades de entrada e se propagam de camada a camada. Depois, um conjunto de saídas é produzido como resposta da rede neural. Por outro lado, na segunda fase, os pesos são ajustados de acordo com uma regra de correção do erro, assim, a resposta da rede em um instante de tempo é subtraída da saída desejada (*target*) para produzir um sinal de erro, o qual é propagado da saída para a entrada, camada a camada, originando o nome “retro propagação do erro” [15].

A Figura 9 a seguir representa uma porção do *perceptron* de múltiplas camadas (MLP).

Figura 9 – Ilustração dos sinais funcionais e sinais de erro em um MLP.



Fonte: HAYKIN, 1999.

Seja n a iteração onde o n -ésimo padrão de treinamento é apresentado à rede, o conjunto formado por todos os exemplos de treinamento é denominado conjunto de treinamento. Assim, o sinal de erro na saída do neurônio j (neurônio de saída), na iteração n , é definido pela Equação 7 [14]:

$$e_j(n) = d_j(n) - y_j(n) \quad (7)$$

sendo que $d_j(n)$ se refere à resposta desejada para o neurônio j , e $y_j(n)$ se refere ao sinal funcional que aparece na saída do neurônio j , na iteração n .

Os erros quadráticos instantâneos de todos os neurônios de saída expressa o erro total, dado pela Equação 8 [14]:

$$E(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (8)$$

onde o conjunto C inclui todos os neurônios da camada de saída da rede.

O erro médio quadrático, definido na equação 9 é obtido somando-se os $E(n)$ para todos os N e então normalizando em relação ao tamanho do conjunto de treinamento [14]:

$$E_{med} = \frac{1}{N} \sum_{n=1}^N E(n) \quad (9)$$

A finalidade do processo de aprendizagem é ajustar os parâmetros livres da rede para minimizar E_{med} .

Considerando o neurônio j sendo alimentado por um conjunto de sinais funcionais produzidos por uma camada de neurônios à sua esquerda, o potencial de ativação é descrito pela Equação 10 abaixo:

$$v_{(n)} = \sum_{i=0}^m w_{ij}(n) y_i(n) \quad (10)$$

onde m é o número total de entradas (excluindo o bias) aplicadas ao neurônio j , $w_{ji}(n)$ representa o peso sináptico conectando a saída do neurônio i à entrada do neurônio j , na iteração n e $y_i(n)$ o sinal funcional que aparece na saída do neurônio i , também na iteração n . O peso sináptico w_{j0} é igual ao *bias* aplicado no neurônio j . A entrada correspondente ao *bias* é o $y_0 = +1$ [14].

Assim, o sinal funcional $y_j(n)$ é dado pela Equação 11:

$$y_j(n) = \varphi_j(v_j(n)) \quad (11)$$

O peso sináptico ($w_{ij}(n)$) recebe uma correção $\Delta w_j(n)$. Essa correção é proporcional à derivada parcial abaixo:

$$\frac{\partial E(n)}{\partial w_{ji}(n)}$$

Deduzindo essas equações, simplificando e diferenciando, pode-se chegar à Equação 12 descrita:

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = -e_j(n)\varphi'(v_j(n))y_i(n) \quad (12)$$

A correção $\Delta w_{ij}(n)$ aplicada ao peso sináptico é dada pela Equação 13 abaixo:

$$\Delta w_{ji}(n) = -\eta \frac{\partial E(n)}{\partial w_{ij}(n)} \quad (13)$$

onde η é o parâmetro da taxa de aprendizado do algoritmo de retro propagação. O sinal negativo indica que o algoritmo busca reduzir o valor de $E(n)$ [14].

Por fim, é possível obter a Equação 14:

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n) \quad (14)$$

em que o gradiente local $\delta_j(n)$ é dado pela Equação 15 abaixo:

$$\delta_j(n) = e_j(n)\varphi'_j(v_j(n)) \quad (15)$$

3.1.2 O algoritmo de Levenberg - Marquardt

O algoritmo de Levenber-Marquardt se baseia em informações da derivada segunda da função erro, sendo assim, é um método de segunda ordem. Além disso, utiliza uma aproximação do mínimo da função erro obtida

introduzindo-se o parâmetro μ no método de Gauss-Newton, de acordo com a equação 16 [20]:

$$\Delta x = [J^t(x)J(x) + \mu I]^{-1}J^t(x)e(x) \quad (16)$$

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 [24]. Assim, pode ser escolhido de várias maneiras, como por exemplo, escolhendo-o como zero a 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 [25].

3.2 Base de dados e experimento

Os dados do conjunto experimental que foi utilizado neste estudo foram descritos e obtidos por Haneda (2006) [10]. A fim de elucidar, um breve resumo do método de obtenção dos dados será relatado aqui.

Amostras de soro de leite foram submetidas ao processo de microfiltração tangencial, a fim de investigar a retenção de microrganismos presentes no soro do leite e estudar a influência dos parâmetros fluidodinâmicos como o número de *Reynolds* e pressão transmembrana. Tais amostras foram fornecidas pela cooperativa leiteira de São Carlos (COTILASC/São Carlos-Brasil) e microfiltradas no mesmo dia da coleta para preservar suas propriedades originais. Foi realizada microfiltração de fluxo cruzado em lotes usando membrana cerâmica comercial α -alumina com tamanho de poro de 0,8 μm e 1,2 μm , em um tubo de canal único de 0,006m de diâmetro interno, 0,25m de comprimento e 0,0047m² de área de filtração.

As experiências foram realizadas em uma bancada de microfiltração construída com aço inoxidável AISI 304 e composta por um tanque de alimentação de parede dupla, uma bomba de deslocamento positivo, uma válvula para melhorar a limpeza do circuito, um interruptor de pressão, um

medidor de fluxo, um medidor de pressão, um módulo para a instalação da estrutura de filtrado, uma válvula de controle, um sistema de refrigeração e uma unidade de controle eletrônico.

A temperatura do soro de leite no tanque de alimentação foi controlada a $25 \pm 5^{\circ}\text{C}$ durante as experiências que utilizaram um dispositivo termopar ligado a um sistema de refrigeração, e uma bomba centrífuga para circular a água fria no interior da parede dupla do tanque de alimentação. A cada 5 minutos o permeado foi colhido e pesado numa balança eletrônica para se obter o comportamento do fluxo de permeado ($J, \text{Lh}^{-1}\text{m}^{-2}$) durante a microfiltração. Os parâmetros observados durante o experimento foram o tempo, pressão transmembrana e número de *Reynolds*.

3.3 Desenvolvimento das RNAs

Os dados fornecidos para o treinamento das RNAs continham três variáveis, as quais foram o número de *Reynolds*, a pressão transmembrana e o tempo de microfiltração. O fluxo de permeado foi o parâmetro que os modelos neurais estimaram a partir dessas três características.

Foram testados dois algoritmos de aprendizagem: o de retropropagação do erro (*traingd*) e o de Levenberg-Marquard (*trainlm*), sendo que os melhores resultados foram obtidos com o algoritmo de retropropagação. Assim, a RNA gerada com a ferramenta *nftool* do MATLAB, com o algoritmo de retropropagação de erro, separou 70% das amostras para o treinamento, 15% para a validação e 15% para teste. Os dados de treinamento foram utilizados para o aprendizado da RNA e os dados de validação foram utilizados para verificar a previsibilidade da RNA, enquanto os dados de teste foram utilizados para verificar a previsibilidade das redes neurais utilizando dados não utilizados no processo de treinamento e validação.

Com membranas com poros de dois tamanhos de diâmetro, 0,8 μm e 1,2 μm , foram realizados experimentos em cinco situações: com a membrana com poros de 1,2 μm de diâmetro sem nenhum tipo de impregnação de prata, com apenas uma camada de impregnação e com duas camadas de impregnação de prata. Já com a membrana com poros de 0,8 μm de diâmetro, não houve

experimento utilizando a membrana com duas camadas de impregnação de prata.

Cada uma das cinco situações foi composta por uma matriz de entrada e uma de saída, as quais são construídas na estrutura número de linhas por número de colunas. Para a matriz de entrada, o número de linhas é a quantidade de variáveis inseridas (número de Reynolds, pressão transmembrana e o tempo de microfiltração) e o número de colunas é a quantidade de amostras. Sendo assim, para as cinco situações o número de linhas foi três e o número de colunas variou-se de acordo com a quantidade de amostras retiradas no experimento. A matriz de saída é composta por uma linha, sendo ela o valor do fluxo do permeado, e o número de colunas é a quantidade de amostras.

Na Tabela 1 a seguir, estão descritas as cinco situações e as dimensões das matrizes de entrada e de saída de cada uma.

Tabela 1 – Tamanho dos poros da membrana, tipo da membrana e dimensão das matrizes de entrada e saída de cada situação.

Situação	Tamanho dos poros da membrana (µm)	Sem impregnação de prata	Com uma camada de impregnação de prata	Com duas camadas de impregnação de prata	Dimensão matriz de entrada	Dimensão matriz de saída
1	0,8	X			3x40	1x40
2	0,8		X		3x119	1x119
3	1,2	X			3x270	1x270
4	1,2		X		3x270	1x270
5	1,2			X	3x120	1x120

Fonte: Autora, 2021.

Para obter o melhor resultado, foram realizados testes de forma a variar o número de neurônios da camada intermediária e observar os resultados para o treinamento, teste e validação da RNA. Assim, a rede terá um bom desempenho se os valores encontrados por ela forem próximos aos introduzidos na matriz de saída, os quais foram o fluxo do permeado do soro de leite.

4. RESULTADOS E DISCUSSÃO

Para melhor análise dos resultados obtidos neste trabalho, optou-se por dividir esta seção em duas subseções: a Seção 4.1 relacionada à membrana com poros de 0,8 μm de diâmetro e a Seção 4.2 para a membrana com poros de 1,2 μm de diâmetro.


4.1 Membrana com poros de 0,8 μm de diâmetro

Esta seção será dividida em duas subseções: a Seção 4.1.1 apresentará os resultados da membrana sem impregnação de prata e a Seção 4.1.2 para a membrana com apenas uma camada de impregnação de prata.

4.1.1 Sem impregnação de prata

No caso da membrana com poros de 0,8 μm de diâmetro sem impregnação de prata, o melhor resultado obtido pela RNA foi com cinco neurônios na camada intermediária. Na Figura 10 pode-se ver a representação para esta rede neural.

Figura 10 – Representação da rede neural com cinco neurônios.




Fonte: Autora, 2021.

Para as amostras utilizadas no treinamento da RNA, o erro relativo percentual médio foi de 7,28%. A Figura 11 mostra a relação dos dados experimentais, dispostos no eixo x, e os dados previstos pela RNA dispostos

no eixo y. A partir dessa relação, foi possível obter a equação de reta $y = 0,97x + 0,99$, que melhor ajusta os dados.


Figura 11 – Gráfico da regressão linear das amostras utilizadas para o treinamento.



Fonte: Autora, 2021.


Para a validação e teste, os erros relativos percentuais médios foram de 8,87% e 15,37% respectivamente. As Figuras 12 e 13 a seguir mostram a relação entre esses valores e também a equação de reta que melhor ajusta os dados de ambos.

Figura 12 – Gráfico da regressão linear das amostras utilizadas para a validação.



Fonte: Autora, 2021.

Figura 13 – Gráfico da regressão linear das amostras utilizadas para o teste.




Fonte: Autora, 2021.

Na Figura 14, é possível observar a distribuição aleatória dos erros divididos entre as amostras utilizadas para o treinamento, validação e teste. O gráfico da distribuição de erro mostra que os erros foram distribuídos de forma homogênea ao longo das amostras sem haver um padrão de repetição.

Tal erro foi calculado a partir da diferença entre os valores experimentais e os valores preditos pela RNA.


Figura 14 – Gráfico da distribuição aleatória dos erros.



Fonte: Autora, 2021.

Analisando o gráfico da Figura 14, pode-se perceber duas amostras utilizadas no teste com erro próximo a 80, e outras três amostras do treinamento com erros por volta de 20. Tais erros são justificados pelo valor do fluxo destas amostras ser maior, fazendo com que a diferença também obtenha um valor maior, uma vez que não é um erro relativo. Dessa maneira, retirando tais pontos, a Figura 15 a seguir mostra o comportamento das amostras restantes, as quais possuem erros entre -4 e +4.

Figura 15 – Gráfico da distribuição aleatória dos erros considerando a maior parte dos dados.




Fonte: Autora, 2021.

4.1.2 Com uma camada de impregnação de prata

Para a membrana com poros de 0,8 μm de diâmetro com uma camada de impregnação de prata, o melhor resultado obtido pela RNA foi com vinte neurônios na camada intermediária. A Figura 16 mostra a representação desta rede neural.


Figura 16 – Representação da rede neural com vinte neurônios.



Fonte: Autora, 2021.

Para as amostras utilizadas no treinamento da RNA o erro relativo percentual médio foi de 6,06%. A Figura 17 mostra a relação dos dados experimentais, dispostos no eixo x, e os dados previstos pela RNA dispostos no eixo y. A partir dessa relação, foi possível obter a equação de reta $y = 0,99x - 0,03$, que melhor ajusta os dados.


Figura 17 – Gráfico da regressão linear das amostras utilizadas para o treinamento.



Fonte: Autora, 2021.


Para a validação e teste, os erros relativos percentuais médios foram de 16,56% e 36,82% respectivamente. As Figuras 18 e 19 a seguir mostram a relação entre esses valores e também a equação de reta de ambos.

Figura 18 – Gráfico da regressão linear das amostras utilizadas para o validação.



Fonte: Autora, 2021.


Figura 19 – Gráfico da regressão linear das amostras utilizadas para o validação.



Fonte: Autora, 2021.

Na Figura 20, é possível observar a distribuição aleatória dos erros divididos entre as amostras utilizadas para o treinamento, validação e teste. Novamente, não houve padrão de repetição.


Figura 20 – Gráfico da distribuição aleatória dos erros.



Fonte: Autora, 2021.

Retirando as amostras que não tornaram resultados bons, conforme explicado na situação anterior, a Figura 21 a seguir mostra o comportamento das amostras restantes, as quais possuem erros entre -12 e +13. Porém, a maior parte das amostras encontram-se entre -2 e +3.

Figura 21 – Gráfico da distribuição aleatória dos erros considerando a maior parte dos dados.



Fonte: Autora, 2021.

Resumindo, a Tabela 2, em relação à membrana com poros de 0,8 μm de diâmetro sem impregnação de prata e com uma camada de impregnação de prata, apresenta os coeficientes de correlação e de determinação, R e R^2 e o

erro percentual médio para os conjuntos de treinamento, validação e teste para os melhores modelos neurais desenvolvidos neste caso.

Tabela 2 – Resultados do coeficiente de determinação e correlação e erro percentual médio da membrana com poros de 0,8 μm de diâmetro.

	Sem impregnação de prata		
	Treinamento	Validação	Teste
R	0,98	0,99	0,98
R²	0,97	0,99	0,96
Erro percentual médio	7,28	8,87	15,37
	Com uma camada de impregnação de prata		
	Treinamento	Validação	Teste
R	0,99	0,99	0,91
R²	0,99	0,99	0,83
Erro percentual médio	6,06	16,56	36,82

Fonte: Autora, 2021.


4.2 Membrana com poros de 1,2 μm de diâmetro

Esta seção será dividida em três subseções: a Seção 4.2.1 apresentará os resultados da membrana sem impregnação de prata, a Seção 4.2.2 para a membrana com apenas uma camada de impregnação de prata, e por fim, a Seção 4.2.3 para a membrana com duas camadas de impregnação de prata.

4.2.1 Sem impregnação de prata

No caso da membrana com poros de 1,2 μm de diâmetro sem impregnação de prata, o melhor resultado obtido pela RNA foi com oito neurônios na camada intermediária. Na Figura 22 pode-se ver a representação para esta rede neural artificial.


Figura 22 – Representação da rede neural com oito neurônios.



Fonte: Autora, 2021.

Para as amostras utilizadas no treinamento da RNA o erro relativo percentual médio foi de 3,12%. A Figura 23 mostra a relação dos dados experimentais, dispostos no eixo x, e os dados que a RNA previu dispostos no eixo y. A partir dessa relação, foi possível obter a equação de reta $y = 0,95x + 0,41$, que melhor ajusta os dados.


Figura 23 – Gráfico da regressão linear das amostras utilizadas para o treinamento.



Fonte: Autora, 2021.


Para a validação e teste, os erros relativos percentuais médios foram de 3,68% e 4,44% respectivamente. As Figuras 24 e 25 a seguir mostram a relação entre esses valores e também a equação de reta de ambos.

Figura 24 – Gráfico da regressão linear das amostras utilizadas para a validação.



Fonte: Autora, 2021.


Figura 25 – Gráfico da regressão linear das amostras utilizadas para o teste.



Fonte: Autora, 2021.

Na Figura 26, é possível observar a distribuição aleatória dos erros divididos entre as amostras utilizadas para o treinamento, validação e teste. Novamente, não houve padrão de repetição.

Figura 26 – Gráfico da distribuição aleatória dos erros.




Fonte: Autora, 2021.

4.2.2 Com uma camada de impregnação de prata

Para esta membrana, a RNA que retornou o melhor resultado foi com trinta neurônios na camada intermediária. Na Figura 27 pode-se ver a representação para esta rede neural.

Figura 27 – Representação da rede neural com trinta neurônios.




Fonte: Autora, 2021.

Para as amostras utilizadas no treinamento da RNA o erro relativo médio foi de 3,73%. A Figura 28 mostra a relação dos dados experimentais, dispostos

no eixo x, e os dados que a RNA previu dispostos no eixo y. A partir dessa relação, foi possível obter a equação de reta $y = 0,97x - 0,22$.


Figura 28 – Gráfico da regressão linear das amostras utilizadas para o treinamento.



Fonte: Autora, 2021.


Para a validação e teste os erros relativos médios foram de 3,59% e 5,43% respectivamente. As Figuras 29 e 30 a seguir mostram a relação entre esses valores e também a equação de reta de ambos.

Figura 29 – Gráfico da regressão linear das amostras utilizadas para a validação.



Fonte: Autora, 2021.


Figura 30 – Gráfico da regressão linear das amostras utilizadas para o teste.



Fonte: Autora, 2021.

A seguir, na Figura 31, observa-se a distribuição aleatória dos erros. Novamente, não houve padrão de repetição.

Figura 31 – Gráfico da distribuição aleatória dos erros.




Fonte: Autora, 2021.

4.2.3 Com duas camadas de impregnação de prata

Por fim, para essa situação, a RNA que retornou o melhor resultado foi com onze neurônios na camada intermediária. Na Figura 32 pode-se ver a representação para esta rede neural.


Figura 32 – Representação da rede neural com onze neurônios.



Fonte: Autora, 2021.

Para as amostras utilizadas no treinamento da RNA o erro relativo médio foi de 3,42%. A Figura 33 mostra a relação dos dados experimentais, dispostos no eixo x, e os dados que a RNA previu dispostos no eixo y. A partir dessa relação, foi possível obter a equação de reta $y = 0,99x + 0,03$.


Figura 33 – Gráfico da regressão linear das amostras utilizadas para o treinamento.



Fonte: Autora, 2021.


Para a validação e teste os erros relativos médios foram de 7,11% e 9,41% respectivamente. As Figuras 34 e 35 a seguir mostram a relação entre esses valores e também a equação de reta de ambos.

Figura 34 – Gráfico da regressão linear das amostras utilizadas para a validação.



Fonte: Autora, 2021.

Figura 35 – Gráfico da regressão linear das amostras utilizadas para o teste.




Fonte: Autora, 2021.

Na Figura 36, é possível observar a distribuição aleatória dos erros divididos entre as amostras utilizadas para o treinamento, validação e teste. A

maior parte das amostras se encontraram entre os erros -3 e +3. Novamente, não houve padrão de repetição.

Figura 36 – Gráfico da distribuição aleatória dos erros.



Fonte: Autora, 2021.

Resumindo, a Tabela 3, em relação à membrana com poros de 1,2 μm de diâmetro sem impregnação de prata e com uma camada de impregnação de prata e com duas camadas de impregnação de prata, apresenta os coeficientes de correlação e de determinação, R e R^2 , e o erro percentual médio para os conjuntos de treinamento, validação e teste para os melhores modelos neurais desenvolvidos neste caso.

Tabela 3 – Resultados do coeficiente de determinação e correlação e erro percentual médio da membrana com poros de 1,2 µm de diâmetro.

	Sem impregnação de prata		
	Treinamento	Validação	Teste
R	0,97	0,97	0,97
R²	0,95	0,95	0,95
Erro percentual médio	3,12	3,68	4,44
	Com uma camada de impregnação de prata		
	Treinamento	Validação	Teste
R	0,98	0,99	0,99
R²	0,97	0,98	0,99
Erro percentual médio	3,73	3,59	5,43
	Com duas camadas de impregnação de prata		
	Treinamento	Validação	Teste
R	0,99	0,98	0,97
R²	0,99	0,96	0,95
Erro percentual médio	3,42	7,11	9,41

Fonte: Autora, 2021.

5. CONSIDERAÇÕES FINAIS

Os resultados apresentados mostraram uma ótima resposta das redes neurais artificiais para prever o fluxo de permeado do soro do leite no processo de microfiltração tangencial, especialmente para a membrana com poros de 1,2 µm de diâmetro, cujos erros percentuais relativos médios ficaram entre 3,12% e 9,41% e os coeficientes de determinação foram acima de 0,95. Para a membrana com poros de 0,8 µm de diâmetro os erros percentuais relativos médios ficaram entre 6,06% e 36,82% e os coeficientes de determinação foram acima de 0,83.

Os erros altos provenientes da RNA utilizada na membrana com poros de 0,8 µm de diâmetro podem ser justificados pelo menor número de amostras em comparação com a membrana com poros de 1,2 µm de diâmetro, uma vez que a estimativa do fluxo torna-se mais viável e com correlações mais elevadas quanto maior o número de amostras analisadas pela RNA. Além disso, o fluxo

de permeado era muito pequeno, fazendo com que uma pequena variação ocasionasse erros maiores.

Entre as situações que utilizaram a membrana com poro de 0,8 μm de diâmetro, a que obteve o resultado menos favorável recebeu uma camada de impregnação de prata. Tal fato é esperado, pois a atuação da prata é bactericida, capaz de aumentar a seletividade da membrana e reter mais microrganismos e bactérias, assim, o fluxo foi menor ainda comparado às outras membranas.

Dessa maneira, pode-se concluir que os modelos neurais gerados a partir da ferramenta *nftool* do software MATLAB com o algoritmo de retropropagação de erro foram capaz de prever os resultados do fluxo de permeado do soro de leite no processo de microfiltração tangencial, contribuindo para as pesquisas experimentais na área, pois podem ser utilizados para auxiliar a definir qual membrana é mais adequada para o processo, economizando custos com protótipos e simulações.

Trabalhos futuros incluem analisar as RNAs para outros tipos de membranas, com o propósito de atribuir maior versatilidade e robustez aos modelos neurais desenvolvidos.

6. REFERÊNCIAS

- [1] HALL, J. E. **Tratado de Fisiologia Médica**. 12. ed. Rio de Janeiro: Elsevier, 2011.
- [2] MACHADO, A. **Neuroanatomia Funcional**. 2. ed. São Paulo: Atheneu, 2002.
- [3] CARLOS, A. **Redes Neurais Artificiais: Teoria e aplicações**. Rio de Janeiro: LTC, 2000.
- [4] TECNAL. **Filtração por membrana: Tipos e equipamentos necessários**, s.d. Disponível em: https://tecnal.com.br/pt-BR/blog/174_filtracao_por_membrana_tipos_e Equipamentos_necessarios.
- [5] MGC Soluções. **Sistema de filtração por membrana**, s. d. Disponível em: <https://www.mgcsolucoes.com/filtracao-por-membranas>. Acesso em: 20. Set. 2021.
- [6] QUEIROZ, V.M.S. **Estudo experimental do escoamento e da concentração de mistura no processo de filtração tangencial de suspensões macromoleculares**. 120p. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2004.
- [7] GEAFILTRATION. **Microfiltração do soro do leite**. Niro Inc, 2006. Disponível em: http://www.geafiltration.com/Portuguese/mercados_aplicacoes/microfiltracao_d_o_leite.htm. Acesso em: 20. Set. 2021.
- [8] ALVES, M. J. **Avaliação dos processos de filtração por membranas e de adsorção na purificação de biodiesel**. 138p. Tese (Doutorado) – Programa de Pós-Graduação em Engenharia Química, Universidade Federal de Uberlândia, Uberlândia, 2015.
- [9] HUGH, T. et al. **Fouling Characteristics of Membrane Filtration In Membrane Bioreactors**. Lancaster: s.n., 2000.
- [10] HANEDA, R.N. **Investigação do desempenho de diferentes estruturas microporosas tubulares na retenção de bactérias em suspensão por microfiltração tangencial**. Dissertação, Universidade de São Paulo, Brasil, São Paulo University, Brazil, 2006.
- [11] RAUBER, T. **Redes Neurais Artificiais**, s. d. Acesso em: 05 fev. 2021. Disponível em:

http://www.riopomba.ifsudestemg.edu.br/dcc/dcc/materiais/1926024727_reconhecimento-de-caracter2.pdf

[12] BRAGA, B. C. L. **Redes Neuras Artificias Teoria e Aplicações**. Rio de Janeiro: TLC, 2000.

[13] MINUSSI, C. **Redes neurais – introdução e principais conceitos**. UNESP, 2008. Acesso em: 05 fev. 2021. Disponível em: <https://www.feis.unesp.br/Home/departamentos/engenhariaeletrica/pos-graduacao/apostila-redes-neurais-anna-diva_minussi.pdf.

[14] FILLETTI, E.R. **Desenvolvimento de Modelos Neurais para o Processamento de Sinais Acústicos Visando a Medição de Propriedades Topológicas em Escoamentos Multifásicos**. Tese (Doutorado), Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos - SP. 2007.

[15] VONZUBEN, F. J. **Redes neurais artificiais**. UNICAMP, 2010. Acesso em 05 fev 2018. Disponível em: ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/theses/lnunes_mest/cap2.pdf

[16] CUSTÓDIO, C. A.; FILLETTI, E. R.; FRANÇA, V. V. **Artificial neural networks for density-functional optimizations in fermionic systems**. Scientific Reports, v. 9, p. 1886, 2019. Disponível em: <https://www.nature.com/articles/s41598-018-37999-1>. Acesso em: 12 set.. 20121.

[17] WALCZAK, S; VELANOVICH, V. **Improving prognosis and reducing decision regret for pancreatic cancer treatment using artificial neural networks**. Decis. Support. Syst. 106, 110–118, 2018.

[18] ORTEGA-ZAMORANO, F. et al. **Implementation of Neurocomputational Models: Comparison Between Standard Backpropagation and C-Mantec Constructive Algorithm**. Neural Process. Lett. 46, 1–16, 2017.

[19] GUEDES, W. N.; DOS SANTOS, L. J.; FILLETTI, E. R.; PEREIRA, F. M. V. **Sugarcane Stalk Content Prediction in the Presence of a Solid Impurity Using an Artificial Intelligence Method Focused on Sugar Manufacturing**. Food Analytical Methods, v. 13, p. 140-144, 2020.

[20] PHALAK, P. et. al. **Study of Membrane Transport for Protein Filtration Using Artificial Neural Networks**. International Journal of Engineering Research and Development, 2017.

- [21] 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: 15 nov. 2021, 2019.
- [22] JOKIC, A. et. al. **Dynamic modeling using artificial neural network of bacillus velezensis broth cross-flow microfiltration enhanced by air-sparging and turbulence promoter,** Membranes, 2020.
- [23] HAYKIN, S. **Neural Networks: a comprehensive foudation.** 2nd ed. New Jersey: Prentice Hall, 1999.
- [24] HAGAN, M. T.; MENHAJ, M. B. **Training Feedforward Networks with the Marquardt Algorithm.** IEEE Transactions on Neural Networks, vol. 5, no. 6, 1994.
- [25] SILVA, L. N. **Análise e Síntese de Estratégias de Aprendizado para Redes Neurais Artificiais.** Dissertação (Mestrado) - Faculdade de Engenharia Elétrica e de Computação, UNICAMP, Campinas, 1998.