

Revista Eletrônica
Paulista de Matemática

ISSN 2316-9664
v. 25, 2025
Edição Ermac

Matheus Nonis Passerini

Universidade Estadual Paulista
(Unesp), Instituto de Química (IQ),
Araraquara

Érica Regina Filletti

Universidade Estadual Paulista
(Unesp), Instituto de Química (IQ),
Araraquara, erica.filletti@unesp.br

Identificação de ácidos graxos provenientes do açai em misturas submetidas ao processo de microfiltração tangencial por meio de redes neurais artificiais

Identification of fatty acids from açai in mixtures submitted to
crossflow microfiltration using artificial neural networks

Resumo

O presente artigo propõe a utilização de redes neurais artificiais como uma ferramenta alternativa para classificar misturas de ácidos graxos provenientes do açai submetidas ao processo de microfiltração tangencial. As redes neurais foram treinadas com os algoritmos de aprendizado supervisionado *Levenberg-Marquardt* e Regularização Bayesiana, utilizando-se o software MATLAB e dados experimentais obtidos na literatura, referentes à pressão, velocidade de escoamento, tempo e fluxo transmembrana. Os critérios de avaliação consistiram na análise da matriz de confusão, histograma do erro e gráfico de performance. A rede neural com a Regularização Bayesiana mostrou resultados com 99,1% de acerto para a classificação de misturas de água/ácido oleico e água/ácido palmítico e 96,5% quando uma terceira classe foi acrescentada aos dados, contendo água e ambos os ácidos graxos, demonstrando a efetividade da ferramenta.

Palavras-chave: Redes Neurais Artificiais. Ácidos Graxos. Açai. Microfiltração Tangencial.

Abstract

This article proposes artificial neural networks as an alternative tool to classify mixtures of fatty acids from açai submitted to crossflow microfiltration. The neural networks were trained with the Levenberg-Marquardt and Bayesian Regularization supervised learning algorithms, using the software MATLAB and datasets from literature, related to pressure, flow speed, time, and transmembrane flow rate. The evaluation criteria analyzed the confusion matrix, the error histogram, and the performance graphics. The neural network that used the Bayesian Regularization had 99,1% accuracy for the mixtures with water/oleic acid and water/palmitic acid and also 96,5% accuracy when a third class was added to the datasets, containing water and both the fatty acids, showing the effectiveness of the tool.

Keywords: Artificial Neural Networks. Fatty Acids. Açai. Crossflow Microfiltration.



1 Introdução

O açaí (*Euterpe oleracea*), espécie pertencente à família das palmeiras (*Arecaceae*) e nativa das regiões centrais e sulinas da América, é uma árvore cujo fruto tem adquirido crescente relevância na indústria global (Laurindo *et al.*, 2023), sendo amplamente utilizado nas indústrias alimentícias e de cosméticos (Oliveira *et al.*, 2020).

A cultura do açaí tem sido explorada pelos povos nativos da região há muito tempo e, nos últimos anos, especialmente no século XXI, ganhou destaque global devido à sua versatilidade como ingrediente (Quaresma; Euler, 2023). O açaí também tem sido objeto de estudos medicinais, com aplicações potenciais no tratamento de problemas ósseos (Santos *et al.*, 2022) e câncer de próstata (Jobim *et al.*, 2019).

A composição do açaí revela que a fruta possui propriedades antioxidantes e anti-inflamatórias, além de contribuir para a prevenção de diabetes, hipertensão e doenças cardiovasculares (Laurindo *et al.*, 2023). Esses benefícios são atribuídos à presença de ácidos graxos insaturados em sua composição, destacando-se os ácidos oleico, palmitoleico e palmítico (Nascimento *et al.*, 2008), que desempenham um papel importante no bom funcionamento do sistema cardiovascular.

Segundo Gavras (2023), o Brasil é o maior produtor e exportador de açaí do mundo, sendo que, em 2022, o estado do Pará exportou mais de 8.158 toneladas de açaí, o que correspondeu a mais de 90% das exportações do fruto no país, gerando receitas superiores a US\$ 26,5 milhões.

Dessa forma, é evidente que, com o aumento da demanda pelo fruto do açaí nos últimos anos, a produção tende a se tornar cada vez mais industrializada. Nesse contexto, as Redes Neurais Artificiais (RNAs), modelos matemáticos computacionais capazes de simular o sistema nervoso central de seres vivos inteligentes (Wu; Fang, 2018), surgem como uma ferramenta alternativa para o controle de operações unitárias, cuja importância tem crescido significativamente na indústria química (Aglodiya, 2017).

As RNAs têm a capacidade de identificar padrões físicos e matemáticos por meio de uma técnica conhecida como aprendizado de máquina (*Machine Learning*), na qual dados previamente conhecidos são fornecidos ao modelo que por sua vez desenvolve uma solução que melhor se ajusta ao problema com base em um processo iterativo de tentativa e erro (Asadollahfardi, 2015).

Em relação ao açaí, uma das etapas industriais que envolve a fabricação de seu óleo ou seu suco é a clarificação, processo que visa remover os sólidos presentes no fluido, tornando-o mais límpido (Sousa, 2020). Uma das alternativas para essa etapa é a utilização de membranas cerâmicas em um processo de microfiltração tangencial, operação unitária cujo objetivo é separar as fases de uma solução com base no princípio da diferença de pressão resultante da movimentação perpendicular entre o permeado e o retido (Pelegrin, 2004).

A aplicação dessa operação durante a produção do suco de açaí apresenta vantagens como alta resistência a solventes orgânicos, maior durabilidade a altas temperaturas, ausência de geração de resíduos e a não utilização de conservantes químicos, o que preserva as características originais da fruta (Wu; Lee, 1999). No entanto, a principal desvantagem dessa técnica é o declínio do fluxo de permeado ao longo do tempo, devido ao aumento da concentração de retido na membrana, o que acaba obstruindo seus poros (Caminoto, 2012).

Nesse sentido, Caminoto (2012) investigou a influência dos ácidos graxos, especificamente os ácidos oleico e palmítico presentes no açaí, na obstrução dos poros das membranas. Para tanto, monitorou o fluxo de permeado e analisou seu declínio durante o processo de microfiltração, gerando dados experimentais de fluxo em função do tempo sob diferentes valores de pressão e velocidade do escoamento.

Com isso, Rossi (2023) utilizou parte do conjunto de dados obtidos por Caminoto (2012)

para desenvolver uma Rede Neural Artificial que classificava as diferentes misturas de água/ácido palmítico e água/ácido oleico a partir de valores de pressão, fluxo transmembrana e tempo de coleta, totalizando 216 dados de 972 presentes na base de dados, obtendo redes neurais com até 100% de precisão em seus resultados.

O presente trabalho visa ampliar os resultados discutidos em Rossi (2023) utilizando Redes Neurais Artificiais mais robustas, acrescentando mais uma variável de entrada - referente a velocidade do escoamento - e mais uma variável de saída - referente a mistura água/ácido oleico/ácido palmítico -, consequentemente, aumentando a quantidade de *datasets* para a totalidade do conjunto de dados presentes na literatura de Caminoto (2012).

Vale ressaltar que este trabalho é uma continuação do estudo apresentado ao VII Encontro Regional de Matemática Aplicada e Computacional - ERMAC (Passerini; Filletti, 2024b) no qual uma Rede Neural Artificial foi desenvolvida com o mesmo propósito, obtendo uma precisão de acerto de 81% no conjunto total de dados. As mudanças realizadas nas redes neurais do estudo até o presente trabalho serão abordadas na seção 3 "Metodologia".

O objetivo dos modelos neurais desenvolvidos neste trabalho foi fomentar modelos que classifiquem as misturas de água/ácido palmítico, água/ácido oleico e água/ácido oleico/ácido palmítico, apresentando-se como uma ferramenta alternativa no controle de lotes do processo, além de verificar a existência de um padrão que permita diferenciá-las, trazendo a vantagem de ser uma técnica não invasiva e de fácil implementação.

Este artigo está organizado de forma que a Seção 2 apresenta uma breve revisão bibliográfica sobre Redes Neurais Artificiais, desde seu início até trabalhos atuais na área de pesquisa deste trabalho; a Seção 3 descreve os modelos neurais desenvolvidos e os algoritmos de aprendizagem testados; a Seção 4 apresenta e analisa os resultados obtidos e a Seção 5 mostra as conclusões do trabalho.

2 RNAs e filtração tangencial

De maneira geral, uma Rede Neural Artificial (RNA) é um modelo computacional que simula a forma como o cérebro humano realiza tarefas. O cérebro processa informações por meio de um conjunto de células chamadas neurônios, que recebem estímulos do ambiente externo ou do próprio organismo. Analogamente, as RNAs são constituídas por uma interligação de células computacionais simples, conhecidas como neurônios artificiais ou unidades de processamento (Haykin, 2001).

O principal diferencial de uma RNA é sua capacidade de aprendizagem baseada em algoritmos que minimizam os erros entre a resposta real e a resposta fornecida pela RNA por tentativa e erro, utilizando esse aprendizado para desenvolver um modelo que traz uma solução para o problema apresentado. Dessa forma, a aplicação de sistemas baseados em Redes Neurais Artificiais pode ser explorada em diversos campos do conhecimento, proporcionando a otimização de processos complexos ou trabalhosos e trazendo benefícios significativos para o cotidiano humano (Wu; Feng, 2018).

O histórico do desenvolvimento das Redes Neurais Artificiais conta com trabalhos dos pesquisadores Mcculloch e Pitts (1943), Hebb (1949), Block (1962), Minsky e Papert (1969), Hopfield (1982) e Rumelhart, Hinton e Williams (1986) de extrema relevância para a área. Desde então, pesquisas envolvendo a utilização de RNAs têm aumentado em muitas áreas do conhecimento humano, como a engenharia química, na qual pode-se citar a aplicação de inteligência artificial nos processos de filtração tangencial.

A filtração tangencial é uma técnica de separação amplamente utilizada em processos biotec-

nológicos, industriais e farmacêuticos para a purificação e concentração de soluções. Ao contrário da filtração convencional, onde o fluxo de solução é perpendicular à membrana filtrante, na filtração tangencial o fluxo ocorre paralelamente à membrana, o que minimiza o acúmulo de material sobre a superfície da membrana e melhora a eficiência da filtração (Bowen; Jenner, 1995). A Figura 1 ilustra como isso funciona.




Figura 1: Filtração tangencial.
Fonte: HANEDA, 2010.

É possível encontrar na literatura alguns trabalhos que apresentam a utilização de Redes Neurais Artificiais para otimizar problemas envolvendo a filtração tangencial, com precisões altíssimas e uma gama interessante de aplicações.

Sekulić *et al.* (2017) desenvolveram uma rede neural para prever o desempenho do processo de microfiltração de íons de metais pesados, como chumbo, cádmio e zinco, em águas residuais. As variáveis de entrada consistiam em valores de pH, pressão, concentração de íon metálico, concentração de agente complexante (nesse caso, escolhidos dois derivados solúveis da celulose) e tipo de contra-íon. Duas diferentes RNAs foram utilizadas, a RNA de regressão geral e a RNA de retropropagação sendo que, o erro quadrático médio resultante ficou entre 4% e 14% e o coeficiente de determinação foi de 0,717 a 0,852 e 0,897 a 0,955, respectivamente.

Proni, Haneda e Filletti (2020) desenvolveram uma Rede Neural Artificial capaz de estimar o fluxo de permeado de uma bebida a base de açaí submetida a microfiltração tangencial com membranas com dois diferentes diâmetros médios porosos, de $0,8 \mu\text{m}$ e $1,2 \mu\text{m}$. O algoritmo de treinamento utilizado foi o *Levenberg-Marquardt* (LM), as variáveis de entrada foram valores referentes ao número de Reynolds, à pressão transmembrana e ao tempo, e a variável de saída, o fluxo do permeado. As RNAs desenvolvidas obtiveram resultado satisfatório, sendo o erro 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.

Jokić *et al.* (2020) desenvolveram uma Rede Neural Artificial que foi capaz de modelar um sistema de microfiltração tangencial com promotores de turbulência que separavam a biomassa microbiana cultivada a partir da bactéria *Bacillus velezensis*. O algoritmo utilizado para a aprendizagem foi o *Levenberg-Marquardt*, e os resultados obtidos foram considerados satisfatórios para os autores, sendo o coeficiente de determinação correspondente a 99,23% e o erro relativo absoluto menor que 20% em 95% dos dados previstos.

Viana *et al.* (2022) combinaram processos de microfiltração tangencial com processos de atomização para obter suco de caju (*Anacardium occidentale L.*) em pó. Para isso, desenvolveram uma Rede Neural Artificial de múltiplas camadas, combinada com um algoritmo genético. Com isso, foi determinado o efeito da concentração de maltodextrina (a 10%) e da temperatura de secagem (a 150 °C) em duas variáveis de saída, sendo elas, rendimento e umidade. O valor do coeficiente de determinação obtido ficou acima de 0,99 em todo o conjunto de dados, e o MSE (*mean squared error*) resultante foi de 0,16, 0,02 e 0,11, para os conjuntos de treinamento, validação e teste, respectivamente.

Passerini e Filletti (2024a) desenvolveram Redes Neurais capazes de identificar soluções aquosas com gomas Guar e Xantana durante o processo de microfiltração tangencial cujos dados de entrada eram referentes à temperatura, velocidade de escoamento, pressão, vazão, tempo e tamanho dos poros da membrana. A precisão obtida foi acima de 98,8%, com algumas das RNAs com precisão de 100% para o algoritmo *Levenberg-Marquardt*.

Assim, fica evidente a importância da inteligência artificial nas pesquisas sobre os processos de microfiltração tangencial, tanto para estimar parâmetros, como para classificar padrões para auxiliar no controle de operações unitárias. Neste contexto, o avanço que este artigo traz é o desenvolvimento de uma ferramenta alternativa, baseada em redes Neurais Artificiais, que pode auxiliar no controle de um importante processo químico na indústria e na análise da competência em lotes industriais, para o caso de bebidas a base de açaí.

3 Metodologia

Nesta seção serão descritos os modelos neurais desenvolvidos neste artigo, os algoritmos de aprendizagem testados na implementação das redes neurais e os critérios de avaliação utilizados para a seleção dos melhores modelos.

3.1 Implementação das RNAs

As Redes Neurais Artificiais foram implementadas utilizando o Software MATLAB com auxílio da ferramenta *nnstart*. Por meio dela, obteve-se o código de programação da RNA e alterou-se apenas a quantidade de neurônios na camada intermediária - 5 a 20 neurônios - e o algoritmo de aprendizado supervisionado para que várias combinações diferentes para a resolução do problema fossem testadas.

Na apresentação realizada no VII Encontro Regional de Matemática Aplicada e Computacional - ERMAC (Passerini; Filletti, 2024a), o algoritmo utilizado foi o *Scaled Conjugate Gradient Backpropagation (trainscg)*, um algoritmo mais simples e abrangente que ajusta os pesos a partir da descida mais íngreme da função de desempenho, ou seja, aquele ponto da rede no qual o erro é maior (Møller, 1993). Uma das mudanças do presente trabalho em relação ao anterior é a utilização de algoritmos de treinamento mais sofisticados, sendo eles, o *Levenberg-Marquardt Backpropagation (trainlm)* e o *Bayesian Regularization Backpropagation (trainbr)*.

Ademais, os conjuntos de treinamento, testagem e validação foram divididos entre 70%-15%-15% do conjunto total de dados para o algoritmo *trainlm* e 80%-20% para o algoritmo *trainbr*, visto a inexistência do conjunto de validação neste último. Ambas configurações foram empiricamente definidas.

3.2 Algoritmo de retropropagação do erro (*backpropagation*)

Uma Rede Neural Artificial é formada por uma interconexões de neurônios artificiais, unidades básicas de processamento. Essas interconexões configuram a arquitetura da RNA, sendo a camada de entrada a camada responsável por interpretar os dados de entrada, a camada de saída sendo a responsável por apresentar a resposta da rede neural e a camada intermediária a responsável por todos os cálculos envolvidos no processo (Haykin, 2001).

Cada neurônio artificial é composto por unidades de entrada (*features*) e seus respectivos pesos sinápticos associados, um somador, um valor de bias, uma função de ativação e uma unidade de saída. De forma geral, é possível alterar os pesos sinápticos - valores que quantificam e a importância e a funcionalidade de cada sinal de entrada -, as bias e os caminhos interneurônios na camada intermediária com o intuito de aprimorar a precisão de acertos da rede neural durante a etapa de treinamento (Burden; Winkler, 2009; Hecht-Nielsen, 1992).

As metodologias aplicadas nas correções dos parâmetros do modelo criado pela RNA são denominadas de algoritmos de treinamento. A grande maioria é derivada do algoritmo de retropropagação do erro (*backpropagation*), que tem como finalidade a minimização da diferença entre a resposta obtida pela RNA e a resposta esperada (Hecht-Nielsen, 1992). O sinal de erro de um neurônio k , pertencente a camada de saída, na época i é definido pela Equação 1:

$$e_k(i) = y_k(i) - \bar{y}_k(i), \quad (1)$$

onde y_k é o resultado real e $\bar{y}_k$ o resultado previsto pela RNA. É definido como erro total da Rede Neural Artificial na iteração i o somatório de todos os erros ao quadrado dos n neurônios da camada de saída, como explicitado na Equação 2:

$$E = \sum_{k=1}^n e_k^2(i) \quad (2)$$

A retropropagação do erro, consiste basicamente em dois passos: um para “frente”, a propagação, e um para “trás”, a retropropagação (Hecht-Nielsen, 1992). No primeiro, o algoritmo opera a partir de um vetor que segue adiante na RNA, camada por camada até a saída. Nesse passo, os pesos são todos fixos e a resposta é subtraída pela resposta real do *dataset* fornecido, gerando um sinal de erro. Após isso, a retropropagação ocorre, camada por camada, ajustando todos os pesos a fim de aproximar os dois valores, do fim da RNA até o começo. Isso ocorre sempre ao final de cada época de treinamento, gerando uma nova época até o fim de seu aprendizado.

3.3 Levenberg-Marquardt *backpropagation*

O algoritmo de treinamento supervisionado *Levenberg-Marquardt*, em suma, é uma combinação de dois outros algoritmos de retropropagação de erro: o método do Gradiente Descendente e o método de Gauss-Newton (Burke; Ferris, 1995). Assim como no Gradiente Descendente, o algoritmo *Levenberg-Marquardt* é iterativo, entretanto, possui a vantagem de escolher entre o melhor resultado dos dois métodos que o compõem.

Barros (2018, p. 35) afirma que "o algoritmo *Levenberg-Marquardt* tende a ser muito rápido e eficiente para o treinamento de Redes Neurais Artificiais, porém requer uma grande quantidade de memória". Portanto, as LMRNAs (RNAs treinadas com o algoritmo de treinamento *Levenberg-Marquardt*) são mais robustas que aquelas treinadas com o algoritmo *Scaled Conjugate Gradient Backpropagation*, entretanto, necessita de uma CPU mais eficiente.

A Equação 3 demonstra como o método de Gauss-Newton funciona:

$$\Delta w_k = [J^T J]^{-1} J^T e \quad (3)$$

sendo o vetor $w = (w_1, w_2, \dots, w_n)$ os pesos sinápticos da RNA, o vetor $e = (e_1, \dots, e_n)$ o sinal do erro do neurônio k , dado pela Equação 1 e J a matriz Jacobiana dada pela derivada do erro em relação a cada peso sináptico w . O algoritmo *Levenberg-Marquardt* faz uma modificação no método de Gauss-Newton de forma que se obtém a Equação 4:

$$\Delta w_k = [J^T J + \mu I]^{-1} J^T e \quad (4)$$

onde I é a matriz identidade e $\mu > 0$ é denominado parâmetro de *Levenberg-Marquardt*. O efeito da matriz adicional μI é adicionar μ a cada autovalor de $J^T J$, visto que a matriz $J^T J$ é positiva e semidefinida, portanto, o autovalor mínimo possível é zero, e qualquer valor positivo numericamente significativo de μ será suficiente para produzir uma direção de pesquisa descendente (Barros, 2018).

3.4 Bayesian regularization backpropagation

O algoritmo de treinamento supervisionado *Bayesian Regularization*, em português, Regularização Bayesiana, combina o treinamento realizado por meio do algoritmo *Levenberg-Marquardt* com uma estratégia estatística conhecida como Interferência Bayesiana, que visa minimizar os parâmetros irrelevantes do modelo, convergindo-os para 0 (Burden; Winkler, 2009). Com isso, a utilização da Regularização Bayesiana converte um problema não linear em um problema estatístico conhecido.

Assim, os modelos criados por RNAs cujo algoritmo de treinamento é a Regularização Bayesiana são mais robustos que os habituais, consumindo mais memória. Ademais, a etapa de validação torna-se desnecessária, aumentando a quantidade de dados nos outros dois conjuntos de datasets.

De acordo com Burden e Winkler (2009), as RBRNAs (RNAs treinadas com o algoritmo de Regularização Bayesiana) são menos propensas a sofrerem tanto *overtrain* como *overfit*, uma vez que o algoritmo fornece um critério bayesiano para interromper o treinamento e descarta parâmetros irrelevantes efetivamente.

Como o algoritmo sustenta-se na correção realizada pelo algoritmo *Levenberg-Marquardt*, as Equações 1, 3 e 4 são válidas para a interpretação do modelo, sendo a escolha dos parâmetros desnecessários baseada na densidade de probabilidade da importância de cada um dos parâmetros presentes na rede. Em termos matemáticos, tem-se a Equação 5:

$$P(w|D, H_i) = \frac{P(D|w, H_i)P(w|H_i)}{P(D|H_i)} \quad (5)$$

sendo w o conjunto de pesos sinápticos da RNA, D o conjunto de datasets e H_i o modelo fomentado pela RBRNA (Burden; Winkler, 1999).

3.5 Datasets

O conjunto de dados experimentais utilizado para o treinamento das RNAs foi publicado na literatura, no trabalho de Caminoto (2012). Os dados de entrada utilizados referem-se a valores de pressão, velocidade do escoamento, fluxo transmembrana e tempo, totalizando 972 dados para três diferentes classes de misturas, água/ácido oleico, água/ácido palmítico, e água/ácido oleico/ácido palmítico.

Os dados experimentais foram divididos em dois conjuntos para o desenvolvimento das redes neurais: o primeiro conjunto, com 648 de 972 dados, foi referente apenas aos dados das classes água/ácido oleico, representada por (1,0) e água/ácido palmítico, representada por (0,1), que são as classes 1 e 2, respectivamente; e o segundo conjunto com todos os dados, sendo que (1,0,0) representa a mistura de água/ácido oleico, (0,1,0) representa a mistura de água/ácido palmítico e (0,0,1) representa a mistura de água/ácido oleico/ácido palmítico, que são as classes 1, 2 e 3, respectivamente. O intuito dessa separação é analisar como o comportamento da rede neural difere-se na ausência e presença de uma variável de saída que engloba, em sua composição, as outras variáveis, na intenção de estudar a diferença obtida na precisão de acerto da RNA.

A inserção dos dados referentes à mistura de água/ácido oleico/ácido palmítico é mais uma das melhorias propostas na apresentação realizada no VII Encontro Regional de Matemática Aplicada e Computacional - ERMAC (Passerini; Filletti, 2024a), na qual foi utilizado 612 dados de entrada/saída referentes às misturas água/ácido oleico e água/ácido palmítico, com o intuito de obter uma rede neural mais abrangente e robusta para a resolução do problema.

3.6 Critérios de avaliação e redes neurais selecionadas

Para a avaliação do desempenho das RNAs, os seguintes critérios foram levados em consideração:

- **Matriz de confusão:** A matriz de confusão é uma tabela que organiza as previsões do modelo fomentado pela RNA em quatro categorias principais, o verdadeiro positivo, o falso positivo, o verdadeiro negativo e o falso negativo. De forma geral, a matriz de confusão mostra a quantidade de acertos que a rede neural obteve, sendo o parâmetro mais importante a ser levado em consideração na análise dos resultados finais em um problema de classificação.
- **Histograma do erro:** O gráfico do histograma do erro ilustra a pertinência do erro entre o conjunto de respostas obtidas pela RNA e os valores reais dos dados. Um gráfico ideal de histograma do erro deve se comportar uma curva Gaussiana centrada no zero, ou seja, a maioria das frequências de sinais de erro, dados pela Equação 1, devem estar próximos de 0, diminuindo exponencialmente conforme aumenta essa diferença.
- **Curvas de performance:** As curvas de performance são gráficos que mostram como o erro quadrático médio (MSE, da sigla em inglês Mean Squared Error), dado pela divisão da Equação 2 pelo total de dados n e posterior extração da raiz desse valor, comporta-se ao passo em que as épocas de treinamento passam, para os três conjuntos de datasets, treinamento, validação e teste.

As quatro Redes Neurais Artificiais apresentadas neste artigo foram as que se saíram melhor na análise dos parâmetros mencionados, para cada um dos dois conjuntos de dados por algoritmo de treinamento utilizado.

4 Resultados e discussões

Nesta seção apresentam-se os resultados das redes neurais desenvolvidas neste trabalho. A rede neural que utilizou o algoritmo de Levenberg-Marquardt será chamada de LMRNA, enquanto a rede neural desenvolvida com o algoritmo de Regularização Bayesiana será denominada por BRRNA.

4.1 Conjunto de dados de água/ácido oleico e água/ácido palmítico

Nesta subseção serão discutidos e analisados os resultados obtidos com o conjunto de 648 dados das classes água/ácido oleico e água/ácido palmítico.

4.1.1 Rede neural LMRNA para duas classes

A LMRNA que obteve os melhores resultados para o conjunto de dados de água/ácido oleico e água/ácido palmítico foi aquela que continha 14 neurônios na camada intermediária. A Figura 2 mostra a matriz de confusão obtida ao final do treinamento, sendo que a classe 1 representa a mistura de água/ácido oleico (1,0) e a classe 2 refere-se à mistura água/ácido palmítico, (0,1). Nota-se que a RNA teve precisão acima de 97% para todo o conjunto de dados, e os erros ficaram concentrados majoritariamente na classe 2, ou seja, o modelo previu mistura de água/ácido palmítico, (0,1), enquanto a resposta real era água/ácido oleico, (1,0), representando 1,9% dos *datasets*, o dobro dos erros mostrados na classe 1.




Figura 2: Matriz de confusão da LMRNA para o conjunto de dados com as duas classes: água/ácido oleico e água/ácido palmítico.

A Figura 3 mostra o histograma do erro associado às respostas do modelo da LMRNA para o primeiro conjunto de dados. A análise do histograma permite concluir que a grande maioria dos sinais de erro absoluto ficaram com valores entre -0,05 e 0,05, ou seja, a LMRNA previu as respostas com mais de 95% de precisão na maioria dos dados. O gráfico obteve um bom comportamento ideal - uma gaussiana centrada no 0 - com picos de instâncias pelo erro próximas de 0, diminuindo muito afastando-se desse valor. A Tabela 1 compila todas as respostas erradas da LMRNA para o primeiro conjunto de dados.



Figura 3: Histograma do erro da LMRNA para o conjunto de dados com as duas classes: água/ácido oleico e água/ácido palmítico.

Amostra	Resposta da RNA		Classe obtida pela RNA		Classe esperada	
46	0,2715	0,7285	0	1	1	0
109	0,0000	1,0000	0	1	1	0
110	0,0000	1,0000	0	1	1	0
111	0,0000	1,0000	0	1	1	0
146	0,4279	0,5721	0	1	1	0
147	0,2793	0,7207	0	1	1	0
148	0,4485	0,5515	0	1	1	0
154	0,3724	0,6276	0	1	1	0
181	0,0639	0,9361	0	1	1	0
193	0,0000	1,0000	0	1	1	0
194	0,0000	1,0000	0	1	1	0
229	0,3305	0,6695	0	1	1	0
468	1,0000	0,0000	1	0	0	1
476	0,5463	0,4537	1	0	0	1
521	0,5005	0,4995	1	0	0	1
526	1,0000	0,0000	1	0	0	1
548	1,0000	0,0000	1	0	0	1
573	0,5800	0,4200	1	0	0	1

Tabela 1: Erros da LMRNA no conjunto de dados com as duas classes: água/ácido oleico e água/ácido palmítico.

Por fim, a Figura 4 mostra a performance da LMRNA, a soma dos erros quadráticos médios durante as épocas de treinamento. O gráfico mostra que as curvas do MSE obtiveram um perfil de

decaimento, com pequenas irregularidades no conjunto de teste. A LMRNA parou sua etapa de treinamento após seis acréscimos consecutivos no MSE do conjunto de validação, na época 146.




Figura 4: Performance da LMRNA para o conjunto de dados com as duas classes: água/ácido oleico e água/ácido palmítico.

De maneira geral, a LMRNA comportou-se bem para esse conjunto de dados. A matriz de confusão mostrou um valor alto de acertos do modelo, o histograma permitiu verificar a alta precisão na maioria das respostas e a performance mostrou um baixo MSE. Com isso, pode-se inferir que a LMRNA conseguiu encontrar um padrão que permite diferenciar as misturas de água/ácido oleico e água/ácido palmítico durante o processo de microfiltração tangencial com membranas cerâmicas de maneira precisa.

4.1.2 Rede neural BRRNA para duas classes

A BRRNA que obteve os melhores resultados para o conjunto de dados de água/ácido oleico e água/ácido palmítico foi também aquela que continha 14 neurônios na camada intermediária. A Figura 5 mostra a matriz de confusão obtida ao final do treinamento. A BRRNA previu água/ácido oleico, ao invés de água/ácido palmítico quatro vezes, errando no total seis vezes em suas previsões, 1/3 do valor total de erros da LMRNA, obtendo 99,1% de acerto.



Figura 5: Matriz de confusão da BRRNA para o conjunto de dados com as duas classes: água/ácido oleico e água/ácido palmítico.

A Figura 6 mostra o histograma do erro associado as respostas do modelo da BRRNA para o primeiro conjunto de dados. É possível perceber que praticamente a totalidade de dados encontra-se no centro do gráfico, com poucos dados em sua extremidade, ou seja, a BRRNA foi extremamente precisa em suas respostas. A Tabela 2 compila todas as respostas erradas da BRRNA para este conjunto de dados.




Figura 6: Histograma do erro da BRRNA para o conjunto de dados com as duas classes: água/ácido oleico e água/ácido palmítico.

Amostra	Resposta da RNA	Classe obtida pela RNA	Classe esperada
117	1,39E-28	1	0
298	5,59E-11	1	0
435	0,99622	0,00378	1
506	1	7,35E-10	0
512	0,99609	0,00391	0
526	1	5,16E-49	0

Tabela 2: Erros da BRRNA no conjunto de dados com as duas classes: água/ácido oleico e água/ácido palmítico.

Por fim, a Figura 7 mostra a performance da BRRNA, na qual é possível notar que a mesma fomentou um modelo que se adequou perfeitamente ao conjunto de treinamento, com um valor de MSE inferior a 10^{-8} , o que não aconteceu com o conjunto de teste. Isso pode indicar um possível *overfit*, que é quando a rede neural "vicia" nos dados de treinamento, não conseguindo resolver problemas com um conjunto de dados que não foi apresentado a RNA ainda. Entretanto, visto o alto valor de acertos da BRRNA no conjunto de teste dado pela Figura 5, esse fato pode ser descartado, indicando apenas que a RNA realmente criou um modelo adequado para a resolução do problema.

Com isso, a BRRNA comportou-se muito bem na classificação de misturas de água/ácido oleico e água/ácido palmítico durante a o processo de microfiltração tangencial com membranas cerâmicas, ainda melhor que a LMRNA. A matriz de confusão mostrou um valor alto de acertos do modelo, o histograma permitiu verificar a alta precisão na maioria das respostas e a performace mostrou um baixo MSE.

Adicionalmente, visto a alta precisão de ambas redes neurais, pode-se concluir que existe um padrão po trás do problema de classificação envolvendo a teoria de Rossi (2023), mesmo quando é inserida à RNA uma nova variável de entrada, referente a velocidade do escoamento. Com isso, as redes neurais criadas para esse conjunto de dados abrangem uma maior quantidade de parâmetros, otimizando processos em condições operacionais distintas. Na próxima subseção, será analisado

como o comportamento da RNA mudará com a inserção de uma nova variável de saída, uma mistura de água e ambos ácidos graxos.




Figura 7: Performance da BRRNA para o conjunto de dados com as duas classes: água/ácido oleico e água/ácido palmítico.

4.2 Conjunto de dados de água/ácido oleico, água/ácido palmítico e água/ácido oleico/ácido palmítico

Nesta subseção serão discutidos e analisados os resultados obtidos com o conjunto de 972 dados das classes água/ácido oleico, água/ácido palmítico e água/ácido oleico/cido palmítico.

4.2.1 Rede neural LMRNA para três classes

A LMRNA que obteve os melhores resultados para o segundo conjunto de dados o foi aquela que continha 17 neurônios na camada intermediária. A Figura 8 mostra a matriz de confusão obtida ao final do treinamento. É possível observar que houve um decréscimo na taxa de acerto da rede neural, valor sendo inferior a 93% para todo o conjunto de dados. Ademais, o conjunto de teste corroborou como sendo o mais afetado, com apenas 83,6% de acerto. De forma geral, a inserção de uma classe a mais também prejudicou os acertos envolvendo apenas as classes 1 e 2, com 3,1% do total de dados sendo respostas erradas referentes às mesmas. Ademais, a classe em que a LMRNA obteve menor acerto foi a classe 3, referente à mistura de água/ácido oleico/ácido palmítico.




Figura 8: Matriz de confusão da LMRNA para o conjunto de dados com três classes: água/ácido oleico, água/ácido palmítico e água/ácido oleico/cido palmítico.

A Figura 9 mostra o histograma do erro associado às respostas do modelo da LMRNA para o segundo conjunto de dados. O histograma obteve bom comportamento ideal - uma gaussiana centrada no 0 - com picos de instâncias pelo erro próximas de 0, diminuindo ao se afastar desse valor. A grande maioria dos sinais de erro absoluto ficaram com valores entre -0,05 e 0,05, ou seja, a LMRNA previu as respostas com mais de 95% de precisão na maioria dos dados, também nesse caso. Contudo, é possível observar um pequeno pico irregular nas extremidades do gráfico, mostrando que, em alguns casos, a RNA obteve erros superiores a 95%.




Figura 9: Histograma do erro da LMRNA para o conjunto de dados com três classes: água/ácido oleico, água/ácido palmítico e água/ácido oleico/cido palmítico.

Por fim, a Figura 10 mostra a performance da LMRNA. O gráfico mostra que as curvas do MSE obtiveram um perfil de decaimento, com um valor final de 0,04674, praticamente o dobro em relação a LMRNA treinada com o primeiro conjunto de dados. A rede neural parou sua etapa de treinamento após seis acréscimos consecutivos no MSE do conjunto de validação, na época 74.




Figura 10: Performance da LMRNA para o conjunto de dados com três classes: água/ácido oleico, água/ácido palmítico e água/ácido oleico/cido palmítico.

De forma geral, a LMRNA treinada com a inserção de uma terceira classe na saída do modelo, apesar de apresentar um comportamento ideal tanto para o histograma quanto para o gráfico de performance, não obteve uma taxa de acerto tão precisa, mostrando que a inserção de uma nova classe que engloba ambas as outras resulta em um possível problema mais complexo, apresentando certa dificuldade em fomentar um modelo adequado para o problema em questão.

4.2.2 Rede neural BRRNA para três classes

A BRRNA que obteve os melhores resultados para o segundo conjunto de dados foi aquela que continha 19 neurônios na camada intermediária. A Figura 11 mostra a matriz de confusão obtida ao final do treinamento, na qual fica evidente que a taxa de acerto é substancialmente maior em relação à mesma taxa da LMRNA para esse conjunto de dados, 96,5%. Ademais, a inserção da nova classe não implicou em mudanças na quantidade de erros envolvendo as classes (1,0,0) e (0,1,0), mantendo seis erros no total, assim como na rede neural treinada com o algoritmo de Regularização Bayesiana com o primeiro conjunto de dados. Isso ocorre devido ao fato desse algoritmo excluir caminhos que não geram boa convergência no modelo da rede neural, ou seja, possivelmente os caminhos entre os neurônios no qual afetava-se a precisão dos acertos envolvendo essas duas classes não eram interferidos pela terceira classe, (0,0,1). Ademais, assim como na LMRNA a classe com maior quantidade de respostas erradas também foi a mistura de água/ácido oleico/ácido palmítico, com 18 erros no total.



Figura 11: Matriz de confusão da BRRNA para o conjunto de dados com três classes: água/ácido oleico, água/ácido palmítico e água/ácido oleico/cido palmítico.

A Figura 12 mostra o histograma do erro associado as respostas do modelo da BRRNA para o

segundo conjunto de dados. É possível perceber que praticamente a totalidade de dados encontra-se no centro do gráfico, com alguns dados em sua extremidade, ou seja, a BRRNA foi extremamente consisa em suas respostas, mesmo nas que ela errou.



Figura 12: Histograma do erro da BRRNA para o conjunto de dados com três classes: água/ácido oleico, água/ácido palmítico e água/ácido oleico/cido palmítico.

Por fim, a Figura 13 mostra a performance da BRRNA, com um decaimento contínuo nas primeiras épocas de treinamento para ambos conjuntos de treinamento e teste, até que alcançam um valor constante. Ainda sim, o MSE do treinamento foi inferior a 0,02, mostrando que a rede neural obteve sinais de erros com valores baixos no geral.




Figura 13: Performance da BRRNA para o conjunto de dados com três classes: água/ácido oleico, água/ácido palmítico e água/ácido oleico/cido palmítico.

De forma geral, a BRRNA saiu-se substancialmente melhor que a LMRNA para esse conjunto

de dados. A exclusão de caminhos que não convergem em respostas úteis a rede neural treinada com o algoritmo de Regularização Bayesiana foi crucial para que BRRNA não "se confundisse" com uma terceira variável que transformou a classificação em um problema mais complexo que o anterior. Ainda sim, ambas redes neurais apresentaram certa dificuldade em classificar precisamente a classe na qual continha a mistura de ambos ácidos graxos, enfatizando a complexidade envolvida no problema. No entanto, de 972 dados no total, a BRRNA conseguiu acertar 938 dados com precisão acima de 95% para quase sua totalidade. Portanto, é possível dizer que a BRRNA fomentou um modelo que conseguiu desdobrar o padrão por trás dessas três classes, em virtude da alta taxa de acerto obtida ao final de seu treinamento.

5 Conclusões

As Redes Neurais Artificiais são ferramentas precisas para resolução de diversos problemas enfrentados pela humanidade, sejam eles cotidianos, físicos, químicos, matemáticos, ou até mesmo filosóficos, desde simples, como a classificação de imagens, até muito complexos, como a presença de redes neurais em carros autônomos.

O presente trabalho utilizou a ferramenta de Redes Neurais Artificiais como uma alternativa para estudar um problema complexo dentro da área de engenharia química em um mercado crescente no mundo, visando auxiliar os produtores de açaí no controle de produção e estoque, além de aumentar a relevância deste fruto tanto na economia brasileira quanto na área acadêmica.

As RNAs criadas durante a realização do projeto comprovaram que existe um padrão por trás da classificação de misturas bifásicas de água/ácido oleico e água/ácido palmítico, mesmo quando presentes na mesma mistura, no processo de microfiltração tangencial com membranas cerâmicas para uma ampla gama de condições operacionais, que pode ser desdobrado por meio da utilização dessa ferramenta.

Em suma, ambas as redes neurais obtiveram ótimos resultados para o conjunto de dados com duas classes (água/ácido oleico e água/ácido palmítico), com precisão de acerto de 97,2% para a RNA treinada com o algoritmo *Levenberg-Marquardt* e 99,1% para a RNA treinada com o algoritmo de Regularização Bayesiana. No caso do conjunto de dados com três classes (água/ácido oleico, água/ácido palmítico e água/ácido oleico/cido palmítico), no qual fez-se a inserção de uma classe que engloba as outras duas, a LMRNA não conseguiu explicar tão bem a variação dos *datasets*, perdendo precisão inclusive nos parâmetros que envolviam o primeiro conjunto de dados. Isso não ocorreu com a BRRNA, que obteve uma taxa de 96,5% de acerto, mesmo em um problema mais complexo que o anterior e manteve a taxa de acerto inalterada para o primeiro conjunto.

Com isso, as Redes Neurais Artificiais mostraram-se uma ferramenta adequada para a resolução do problema proposto, levando também em consideração seu baixo custo, fácil aplicação e precisão quanto aos resultados, sobretudo aquela treinada com o algoritmo de Regularização Bayesiana.

6 Referências Bibliográficas

AGLODIYA, A. Application of artificial neural network (ANN) in chemical engineering: a review. **International Journal of Advance Research and Innovative Ideas in Education**, v. 3, n. 2, p. 5322-5328, 2017.

ASADOLLAHFARDI, G. Artificial neural network. *In*: ASADOLLAHFARDI, G. **Water quality**

management. Heidelberg: Springer, 2015. p. 77-91. *E-book.* (SpringerBriefs in Water Science and Technology). Disponível em: <https://doi.org/10.1007/978-3-662-44725-3>. Acesso em: 19 jul. 2024.

BARROS, V. P. A. **Avaliação do desempenho de algoritmos de retropropagação com redes neurais artificiais para a resolução de problemas não-lineares.** 2018. Dissertação (Mestrado em Ciência da Computação) - Universidade Tecnológica Federal do Paraná, Ponta Grossa, 2018. Disponível em: <http://repositorio.utfpr.edu.br/jspui/handle/1/3340>. Acesso em: 17 jul. 2024.

BLOCK, H. D. The perceptron: a model for brain functioning. **Reviews of Modern Physics**, v. 34, n. 1, p. 123-135, jan. 1962. Disponível em: <https://doi.org/10.1103/RevModPhys.34.123>. Acesso em: 23 out. 2023.

BOWEN, W. R.; JENNER, F. Theoretical descriptions of membrane filtration of colloids and fine particles: an assessment and review. **Advances in Colloid and Interface Science.** v. 56, p. 141-200, 1995. Disponível em: [https://doi.org/10.1016/0001-8686\(94\)00232-2](https://doi.org/10.1016/0001-8686(94)00232-2). Acesso em: 23 mar. 2024.

BURDEN F. R.; WINKLER D. A. Robust QSAR models using bayesian regularized neural networks. **Journal of Medicinal Chemistry**, v. 42, n. 16, p. 3183-3187, 1999. Disponível em: <https://doi.org/10.1021/jm980697n>. Acesso em: 18 jul. 2024.

BURDEN, F.; WINKLER, D. Bayesian regularization of neural networks. In: LIVINGSTONE, D. J. (ed.). **Artificial neural networks: methods and applications.** Totowa: Human Press, 2009. p. 23-42. (Methods in molecular biology; v. 458). Disponível em: https://doi.org/10.1007/978-1-60327-101-1_3. Acesso em: 23 ago. 2024.

BURKE, J. V.; FERRIS, M. C. A Gauss-Newton method for convex composite optimization. **Mathematical Programming**, v. 71, n. 2, p. 179-194, 1995. Disponível em: <https://doi.org/10.1007/BF01585997>. Acesso em: 28 jul. 2024.

CAMINOTO, K. B. S. **Estudo do declínio no fluxo transmembrana via microfiltração tangencial de misturas bifásicas de óleos vegetais e água.** 2012. Dissertação (Mestrado em Engenharia Mecânica) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2012. Disponível em: <https://www.teses.usp.br/teses/disponiveis/18/18147/tde-29082013-170447/pt-br.php>. Acesso em: 05 jan. 2024.

GAVRAS, D. Açaí brasileiro vira febre fora do país e ganha o mundo. **Estado de Minas**, Belo Horizonte, atualizado em 15 out. 2023. Economia. Disponível em: https://www.em.com.br/app/noticia/economia/2023/10/15/internas_economia,1576667/acai-brasileiro-vira-febre-fora-do-pais-e-ganha-o-mundo.shtml. Acesso em: 09 mar. 2024.

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. Tese (Doutorado em Engenharia Mecânica) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2010. Disponível em:

<https://doi.org/10.11606/T.18.2010.tde-27122010-102018>. Acesso em: 23 mar. 2024.

HAYKIN, S. **Redes neurais: princípios e práticas**. 2. ed. Porto Alegre: Bookman, 2001.

HEBB, D. O. **The organization of behavior: a neuropsychological theory**. New York: Wiley, 1949.

HECHT-NIELSEN, R. Theory of the backpropagation neural network. In: WECHSLER, H. (ed.). **Neural networks for perception: computation, learning, and architectures**. Boston: Academic Press, 1992, p. 65-93, v. 2. Disponível em: <https://doi.org/10.1016/B978-0-12-741252-8.50010-8>. Acesso em: 18 ago. 2024.

HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities. **Proceedings of the National Academy of Science of the USA**, v. 79, n. 8, p. 2554-2558, 1982. Disponível em: <https://doi.org/10.1073/pnas.79.8.2554>. Acesso em: 23 out. 2023.

JOBIM, M. L. *et al.* Açai (*Euterpe oleracea*, Mart.), an amazonian fruit has antitumor effects on prostate cancer cells. **Archives in Biosciences & Health**, v. 1, n. 1, p. 61-76, 2019. Disponível em: <https://doi.org/10.18593/abh.16966>. Acesso em: 22 fev. 2024.

JOKIĆ, A. *et al.* Dynamic modeling using artificial neural network of *Bacillus Velezensis* broth cross-flow microfiltration enhanced by air-sparging and turbulence 21 promoter. **Membranes**, v. 10, n. 12, Article Number 372, 2020. Disponível em: <https://doi.org/10.3390/membranes10120372>. Acesso em: 17 mar. 2024.

LAURINDO, L. F. *et al.* Açai (*Euterpe oleracea* Mart.) in health and disease: a critical review. **Nutrients**, v. 15, n. 4, Article Number 989, 16 fev. 2023. Disponível em: <https://doi.org/10.3390/nu15040989>. Acesso em: 21 fev. 2024.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 5, p. 115-133, 1943. Disponível em: <https://doi.org/10.1007/BF02478259>. Acesso em: 23 out. 2023.

MINSKY, M.; PAPERT, S. A. **Perceptrons: an introduction to computational geometry**. Cambridge, MA: MIT Press, 1969, p. 1-20. Disponível em: <https://doi.org/10.7551/mitpress/11301.001.0001>. Acesso em: 24 out. 2023.

MØLLER, M. F. A scaled conjugate gradient algorithm for fast supervised learning. **Neural Networks**, v. 6, n. 4, p. 525-533, 1993. Disponível em: [https://doi.org/10.1016/S0893-6080\(05\)80056-5](https://doi.org/10.1016/S0893-6080(05)80056-5). Acesso em: 28 jul. 2024.

NASCIMENTO, R. J. S. *et al.* Composição em ácidos graxos do óleo da polpa de açaí extraído com enzimas e com hexano 1. **Revista Brasileira de Fruticultura**, vol. 30, n. 2, p. 498-502, jun. 2008. Disponível em: <https://doi.org/10.1590/S0100-29452008000200040>. Acesso em: 27 fev. 2024.

OLIVEIRA, A. R. *et al.* Structural and physicochemical properties of freeze-dried açaí pulp (*Euterpe oleracea* Mart.). **Food Science and Technology**, v. 40, n. 2, p. 282-289, 2020.

PASSERINI, M. N.; FILLETTI, E. R. Identificação de ácidos graxos provenientes do açaí em misturas submetidas ao processo de microfiltração tangencial por meio de redes neurais artificiais. **C.Q.D. – Revista Eletrônica Paulista de Matemática**, Bauru, v. 25, e205003, 2025. Edição Ermac. DOI: 10.21167/cqdv25e25003 Disponível em: <https://sistemas.fc.unesp.br/ojs/index.php/revistacqd/index>

Disponível em: <https://doi.org/10.1590/fst.34818>. Acesso em: 21 fev. 2024.

PASSERINI, M. N.; FILLETTI, E. R. Crossflow microfiltration of aqueous suspensions with guar and xanthan gums: identification of solutions using artificial neural networks. **Engineering & Technology Scientific Journal**, v. 1, n. 1, Article Number e024004, 2024b. Disponível em: [10.55977/etsjournal.v01i01.e024004](https://doi.org/10.55977/etsjournal.v01i01.e024004). Acesso em: 02 mai. 2024.

PASSERINI, M. N.; FILLETTI, E. R. Identificação de ácidos graxos provenientes do açaí no processo de microfiltração tangencial por meio de inteligência artificial. In: ENCONTRO REGIONAL DE MATEMÁTICA APLICADA E COMPUTACIONAL, 7., 2024, Bauru. **Caderno de trabalhos completos e resumos [...]**. Bauru: Unesp/FC, 2024a, p. 290-291. Disponível em: <https://drive.google.com/file/d/1jIVWriJT5X45vWa3ecgM8AaAp5EeDm7B/view>. Acesso em: 30 jul. 2024.

PELEGRIN, D. C. **Microfiltração tangencial de efluente sanitário após tratamento biológico**. 2004. Dissertação (Mestrado em Engenharia Ambiental) – Universidade Federal de Santa Catarina, Florianópolis, 2004. Disponível em: <https://repositorio.ufsc.br/handle/123456789/87076?show=full>. Acesso em: 08 mar. 2024.

PRONI, C.; HANEDA, R. N.; FILLETTI, E. R. Desenvolvimento de redes neurais artificiais para análise do fluxo de permeado de uma bebida à base de açaí no processo de microfiltração tangencial. **C.Q.D. - Revista Eletrônica Paulista de Matemática**, v. 17, 2020. Disponível em: <https://sistemas.fc.unesp.br/ojs/index.php/revistacqd/article/view/265>. Acesso em: 15 mar. 2024.

QUARESMA, A. P.; EULER, A. M. C. Açaí, mais que um fruto, símbolo da cultura alimentar e bioeconomia da Amazônia. In: VASCONCELLOS, M. B. de G. **Bioeconomia e o mercado dos produtos florestais não madeireiros: desafios e possibilidades**. São Paulo: Synergia Consultoria, 2023. v. 5, p. 74-99. Disponível em: <http://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/1155560>. Acesso em: 22 fev. 2024.

ROSSI, I. S. **Classificação de ácido oleico e ácido palmítico no processo de microfiltração tangencial por meio de redes neurais artificiais e árvores de decisão**. 2023. Trabalho de conclusão de curso (Bacharelado em Engenharia Química) – Instituto de Química, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Araraquara, 2023. Disponível em: <http://hdl.handle.net/11449/238990>. Acesso em: 05 jan. 2024.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning internal representations by error propagation. In: RUMELHART, D. E.; MCCLELLAND, J. L.; SAN DIEGO PDP RESEARCH GROUP UNIVERSITY OF CALIFORNIA. **Parallel distributed processing: explorations in the microstructures of cognition**. Cambridge, MA: MIT Press, 1986, v. 1, p. 318-362. Disponível em: <https://doi.org/10.1016/B978-1-4832-1446-7.50035-2>. Acesso em: 24 out. 2023.

SANTOS, V. R. N. *et al.* Açaí (*Euterpe oleracea* Mart.) Attenuates oxidative stress and alveolar bone damage in experimental periodontitis in rats. **Antioxidants**, v. 11, n. 10, Article Number 1902, 2022. Disponível em: <https://doi.org/10.3390/antiox11101902>. Acesso em: 22 fev. 2024.

SEKULIC, Z. *et al.* Application of artificial neural networks for estimating Cd, Zn, Pb removal efficiency from wastewater using complexation-microfiltration process. **International Journal of Environmental Science and Technology**, v. 14, p. 1383–1396, 2017. Disponível em: <https://doi.org/10.1007/s13762-017-1248-8>. Acesso em: 15 mar. 2024.

SOUSA, F. A. **Determinação de polifenóis extraíveis, não extraíveis e atividade antioxidante *in vitro* nos sucos da polpa e clarificado de açaí.** 2020. Dissertação (Mestrado Acadêmico em Sociobiodiversidade e Tecnologias Sustentáveis) - Instituto de Engenharia e Desenvolvimento Sustentável, Universidade da Integração Internacional da Lusofonia Afro-Brasileira, Redenção, 2020. Disponível em: repositorio.unilab.edu.br/jspui/handle/123456789/2158. Acesso em: 24 fev. 2024.

VIANA, J. D. R. *et al.* Optimization by artificial neural networks of a combined method for obtaining dried cashew juice (*Anacardium Occidentale* L.). In: CONGRESSO BRASILEIRO DE CIÊNCIA E TECNOLOGIA DE ALIMENTOS, 28., 2022, [S. l.]. **Anais [...]**. [S. l.]: CBCTA, 2022.

WU, J. C.-S.; LEE, E.-H. Ultrafiltration of soybean oil/hexane extract by porous ceramic membranes. **Journal of Membrane Science**, v. 154, n. 2, p. 251-259, 1999. Disponível em: [https://doi.org/10.1016/s0376-7388\(98\)00296-8](https://doi.org/10.1016/s0376-7388(98)00296-8). 27 fev. 2024.

WU, Y.-C.; FENG, J.-W. Development and application of artificial neural network. **Wireless Personal Communications**, v. 102, p. 1645–1656, 2018. Disponível em: <https://doi.org/10.1007/s11277-017-5224-x>. Acesso em: 18 jul. 2024.