



Mayumi Laura Daniel Kamachi
Universidade Estadual Paulista
(Unesp), Instituto de Química,
Araraquara

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

Desenvolvimento de um modelo baseado em rede neural para estimar a massa de sólidos acumulada na filtração de água na irrigação localizada

Development of a neural network based model to estimate the mass of solids accumulated in water filtration for localized irrigation

Resumo

A conservação da água é de grande importância e, por isso, novas técnicas são constantemente desenvolvidas para minimizar esse desafio. No Brasil, a técnica de irrigação localizada tem sido adotada para maximizar a eficiência do uso da água. Mas a eficácia dessa técnica é comprometida pelo entupimento dos orifícios dos emissores de água por partículas sólidas de matéria orgânica e inorgânica que se acumulam nos próprios filtros. Por isso, foi empregado um modelo de rede neural para estimar a massa de sólidos acumulada na filtração, para monitoriar o processo para que a vazão de água seja minimamente afetada. Utilizando um banco de dados experimental disponível na literatura, um modelo de rede neural foi implementado com o algoritmo de aprendizagem de Levenberg-Marquardt, mostrando-se muito eficaz ao caso, com erro relativo percentual médio de 0,29% na previsão dos valores de massa de sólidos acumulada.

Palavras-chave: modelagem; redes neurais artificiais; irrigação; massa de sólidos.

Abstract

Water conservation is great importance and, for this reason, new techniques are constantly being developed to minimize this challenge. In Brazil, localized irrigation techniques have been adopted to maximize water use efficiency. But the effectiveness of this technique is compromised by the clogging of the water emitters orifices by solid particles of organic and inorganic matter that accumulate in the filters themselves. That's why, a neural network model was employed to estimate this mass of solids accumulated in filtration, for the best conditions for it to be as low as possible, thereby minimally affecting the water flow rate. Using an experimental database available in the literature, a neural network model was implemented with the Levenberg-Marquardt learning algorithm, proving to be very effective in case, with an average percentage relative error of 0.29% in predicting values of mass of solids accumulated.

Keywords: modeling; artificial neural networks; irrigation; mass of solids.

1 Introdução

Redes Neurais Artificiais (RNAs) são sistemas computacionais baseados no funcionamento do cérebro humano (Braga; Carvalho; Ludemir, 2000). Seu treinamento se baseia na exposição a um conjunto de dados exemplares, os quais são generalizados por meio de um algoritmo de aprendizagem, ajustando-se os pesos dos neurônios artificiais de modo a obter respostas coerentes para dados não pertencentes ao conjunto de treinamento. As RNAs apresentam muitas vantagens como alta precisão nos resultados, fácil implementação, baixo custo computacional, além de permitir o desenvolvimento de uma ferramenta não invasiva capaz de monitorar vários processos e técnicas em diferentes áreas (Hagan; Demuth; Beale, 1996; Haykin, 1999).

Uma técnica que pode ter benefícios com a utilização de modelos neurais para o controle de qualidade é a irrigação localizada. Essa técnica destina-se a regar especificamente a área onde se encontram as raízes das plantas e sua principal função é propiciar vazões reduzidas e objetivas, aumentando a precisão e consequentemente, a economia de custos.

É explícita a importância e presença de pesquisas utilizando os benefícios das RNAs para avaliar e monitorar processos de irrigação, como o trabalho de Umair e Usman (2015), que a partir da maioria dos sistemas de irrigação que apenas ligam e desligam, projetaram um sistema de controle inteligente baseado em RNAs para uma programação de irrigação mais eficaz. Kouadri *et al.* (2022) também usaram redes neurais artificiais para prever seis parâmetros de qualidade da água de irrigação, como a razão de absorção de sódio, porcentagem de sódio, carbonato residual de sódio, risco de magnésio, índice de permeabilidade e razão de Kelly. Essahlaoui *et al.* (2023) usaram uma técnica de rede neural artificial para processar um conjunto de dados que incluía parâmetros como condutividade elétrica, sólidos totais dissolvidos, níveis de cloro, teor de nitrogênio, concentrações de bicarbonato e valores de pH, para o controle e gerenciamento de águas residuais em práticas de irrigação, obtendo taxas de reconhecimento de amostras superiores a 95% de acerto. A pesquisa de Zhao *et al.* (2023) visando otimizar o limite inferior de um sistema de irrigação por gotejamento automático com múltiplos objetivos utilizou da terceira geração do algoritmo genético de ordenação não-dominada. Assim, as relações matemáticas entre o limite inferior de irrigação e a quantidade de irrigação, volume de irrigação, produção e ADF-50 foram estabelecidas pelo modelo de balanço hídrico, função de produção hídrica e modelo de RNA, respectivamente. A boa concordância entre o modelo de balanço hídrico e o da RNA foi então comprovada. Tendo isso em vista, evidencia-se a importância e a relevância de estudos que utilizem inteligência artificial para otimizar rapidamente e precisamente processos de irrigação, em uma sociedade na qual a economia de água de qualidade é crucial para a sustentabilidade.

Dentro deste contexto, o objetivo deste trabalho foi desenvolver uma ferramenta alternativa baseada em RNAs para estimar a massa de sólidos suspensos acumulada após o processo de filtração de água, a fim de avaliar o desempenho de filtros utilizados na irrigação localizada. É importante ressaltar que há dificuldades em estimar a massa de sólidos suspensos devido à variação temporal e espacial da concentração de sólidos (Bucks; Nakayama; Gilbert, 1979). Ainda, como a eficiência dos filtros variam conforme a qualidade da água e o tempo de operação, o processo torna-se difícil de ser modelado com precisão (Capra; Scicolone, 2004).

Este trabalho é uma continuação do estudo apresentado ao VII Encontro Regional de Matemática Aplicada e Computacional - ERMAC (Kamachi; Filletti, 2024), no qual mostrou-se o desempenho de um modelo baseado em neural para estimar a massa de sólidos suspensos acumulada após o processo de filtração de água, e assim avaliar o desempenho de filtros de discos 1 polegada mesh 120 utilizados na irrigação localizada. O erro percentual médio entre os valores reais e os previstos

de massa de sólidos retida foi de 0,018% para treinamento, 0,096% para validação e 0,119% para teste. No presente trabalho são apresentados os resultados de um modelo de rede neural mais robusto que foi aplicado a dados disponíveis na literatura (Oliveira, 2010) de filtros de discos 1 polegada mesh 120 e 155 conjuntamente. A ferramenta ora desenvolvida busca ser uma opção alternativa para o controle da irrigação no monitoramento da obstrução dos orifícios dos filtros aprimorando a eficiência do sistema de irrigação, podendo dispensar a necessidade de testes empíricos e facilitar a otimização do processo.

2 Desenvolvimento do modelo de rede neural

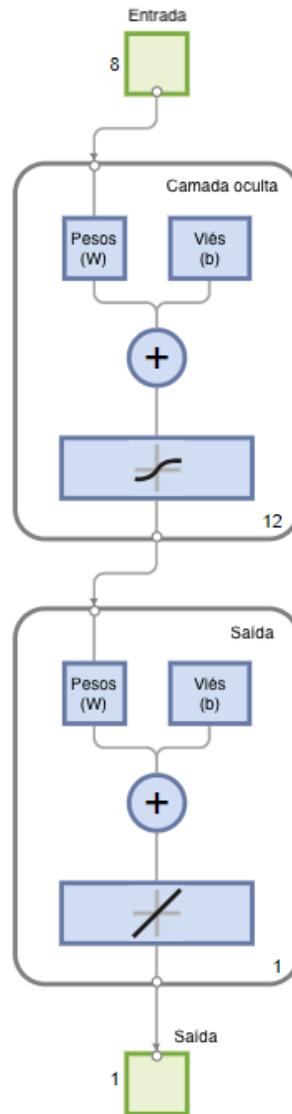
O modelo de rede neural desenvolvido neste trabalho foi implementado utilizando-se o software Matlab com o auxílio da biblioteca Neural Networks Start Toolbox (NNSTART), mais especificamente com a ferramenta Neural Net Fitting app. O algoritmo de aprendizagem utilizado foi o de Levenberg-Marquardt (Custódio; Filletti; França, 2019; Proni; Haneda; Filletti, 2020), com a função de ativação tangente sigmoidal.

O conjunto de dados publicados na literatura por Oliveira (2010) foi dividido em 70% para o treinamento, 15% para validação e 15% para teste. Essa divisão garante que cada subconjunto tenha exemplos variados e representativos da distribuição original dos dados, o que é importante para evitar que o modelo aprenda padrões artificiais e oferece maior confiabilidade nas métricas de desempenho obtidas no teste. Ainda, a divisão dos dados nos três subconjuntos foi feita de forma aleatória para evitar viés de amostragem. A etapa de teste em um modelo de rede neural consiste em avaliar o desempenho do modelo treinado utilizando um conjunto de dados que não foi usado durante o treinamento. Essa etapa é fundamental para verificar se o modelo de rede neural realmente aprendeu os padrões subjacentes aos dados e se é capaz de generalizar para novas situações. Essa divisão traz equilíbrio entre aprendizado e avaliação do modelo, uma vez que 70% dos dados para treinamento fornece uma quantidade suficiente de exemplos para que o modelo de rede neural aprenda os padrões dos dados e ajuste bem seus pesos; os 15% para validação permitem ajustar hiperparâmetros (como taxa de aprendizado, número de camadas, neurônios) sem interferir no teste final; e os 15% para teste asseguram uma avaliação independente e estatisticamente significativa do desempenho do modelo de rede neural. Foram usados 638 dados experimentais para constituir os conjuntos de treinamento, validação e teste do modelo de rede neural desenvolvido.

Assim, uma matriz de entrada abrangendo todos os dados experimentais dos dois tipos de mesh foi criada, com dimensão de 8 linhas por 638 colunas. Cada linha representa uma das variáveis de entrada, sendo 6 variáveis numéricas: tempo, concentração de entrada, concentração de saída, massa retida, volume acumulado e pressão, e duas variáveis categóricas constituídas por valores binários para diferenciar os dois filtros, sendo o filtro com mesh 120 identificado por $(1, 0)^T$ e o filtro com mesh 155 por $(0, 1)^T$. Também criou-se uma matriz de saída correspondente aos 638 dados experimentais com apenas uma linha contendo os respectivos valores da massa de sólidos suspensos acumulada, que é a variável de saída do modelo de rede neural.

Em seguida, foram realizados testes variando o número de neurônios na camada oculta, e os melhores resultados foram obtidos, por tentativa e erro, com 12 neurônios nesta camada. A Figura 1 representa a arquitetura neural desenvolvida. O treinamento foi interrompido com poucas iterações para evitar *overtraining*, o que faz a RNA memorizar o conjunto de treinamento em vez de mapear seus principais aspectos, gerando pouca ou nenhuma reproduzibilidade dos resultados dos conjuntos de validação e teste, ou seja, a RNA perde sua capacidade de generalização.

Figura 1: Arquitetura do modelo de rede neural desenvolvido.



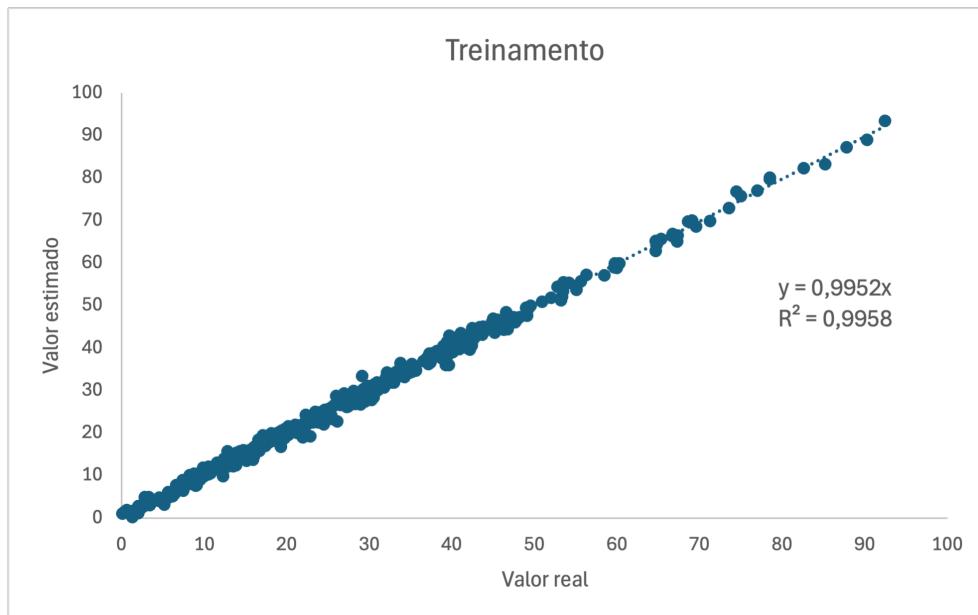
Fonte: Matlab R2023a

3 Resultados e discussão

O modelo de rede neural desenvolvido neste trabalho forneceu resultados muito satisfatórios, como demonstrado a seguir.

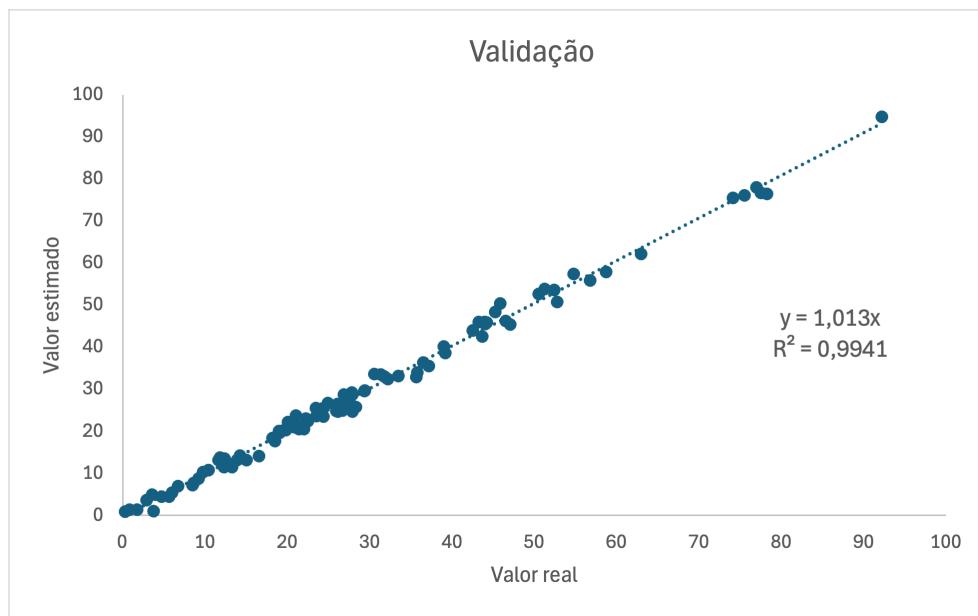
Os gráficos de regressão linear para os conjuntos de treinamento (Figura 2), de validação (Figura 3) e de teste (Figura 4), mostraram que o coeficiente de determinação (R^2) está muito próximo de 1 (0,995 para treinamento, 0,994 para validação e 0,994 para teste). Pode-se reforçar os resultados satisfatórios do modelo pelas equações aproximadas das retas de regressão linear: $y = 0,9952x$ para o treinamento, $y = 1,013x$ para a validação e $y = 1,0039x$ para o teste.

Figura 2: Valores da massa de sólidos estimados pelo modelo versus valores reais para o conjunto de treinamento.



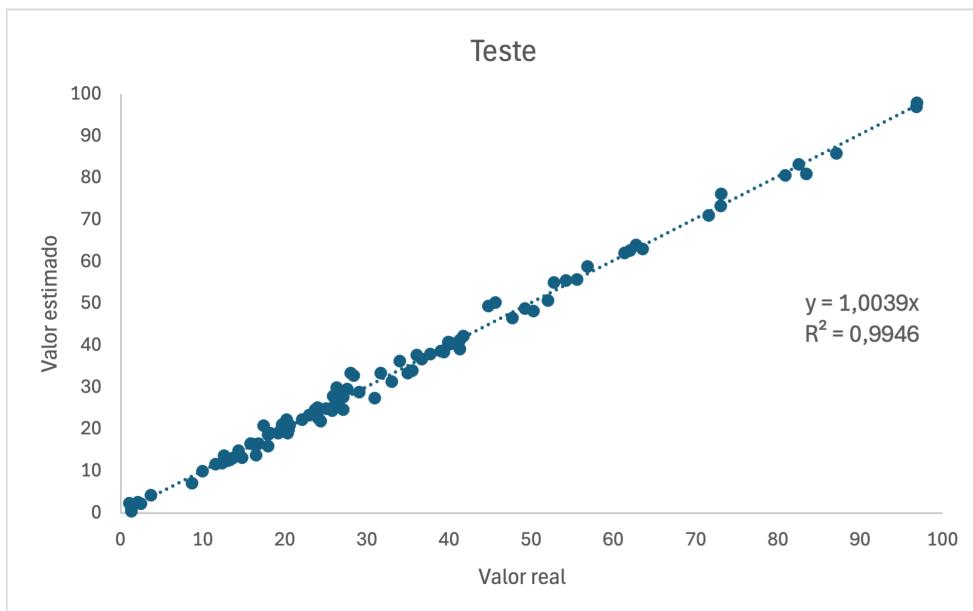
Fonte: próprios autores.

Figura 3: Valores da massa de sólidos estimados pelo modelo versus valores reais para o conjunto de validação.



Fonte: próprios autores.

Figura 4: Valores da massa de sólidos estimados pelo modelo versus valores reais para o conjunto de teste.

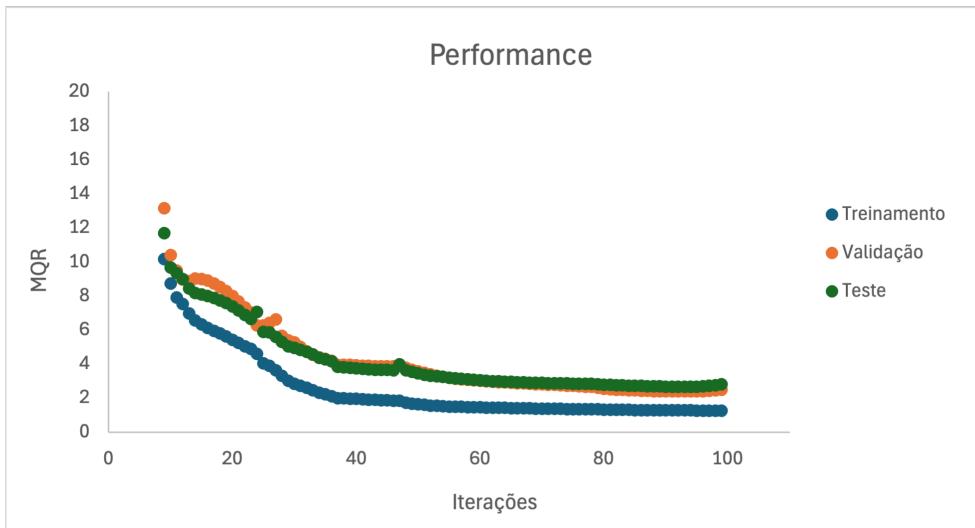


Fonte: próprios autores.

O erro percentual médio entre os valores reais e os previstos para a massa de sólidos foram de 0,018% para treinamento, 0,096% para validação e 0,119% para teste. Portanto, a média do erro relativo percentual foi 0,29%, valor ínfimo ao comparar os valores reais e estimados.

Ao analisar o gráfico de performance ao longo das iterações, na Figura 5, pode-se notar um decaimento da média quadrática residual (MQR), que é a média dos quadrados das diferenças entre os valores preditos pelo modelo e os valores reais, sendo que seu valor mínimo (2,37) ocorreu para 92 iterações, o que indica que o modelo de rede neural apresentou uma boa convergência durante seu treinamento, com um ótimo desempenho.

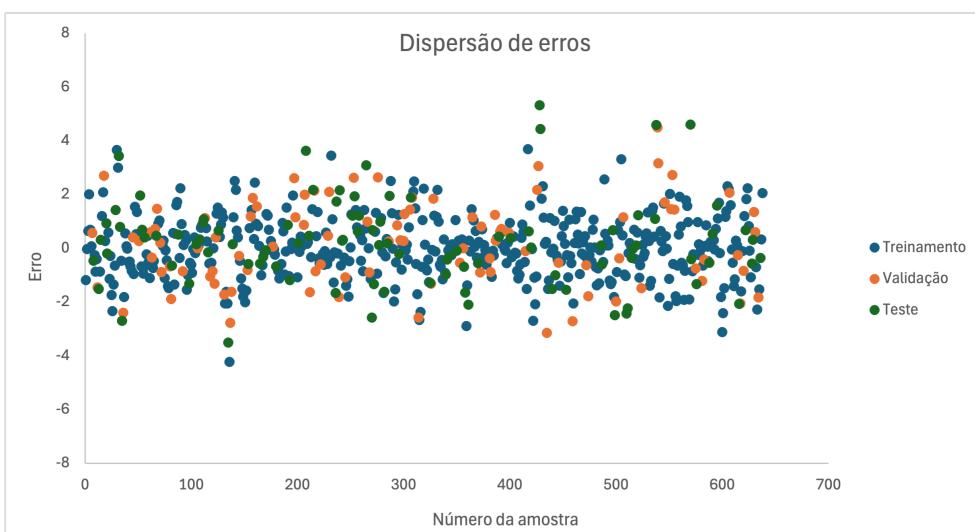
Figura 5: Performance do modelo de rede neural durante o treinamento, validação e teste.



Fonte: próprios autores.

Por fim, a Figura 6 mostra o gráfico de dispersão de erros (que é a diferença entre os valores estimados pelo modelo e os valores reais da massa de sólidos). Esse gráfico mostra uma distribuição aleatória dos erros em torno de zero ao longo de todo o intervalo de valores previstos, para todos os dados de treinamento, validação e teste. Isso indica que o modelo não apresenta viés sistemático e que os erros são independentes dos valores previstos, evidenciando que o modelo capturou bem os padrões no comportamento dos dados sem omitir nenhuma tendência relevante. A ausência de padrões identificáveis reforça que o modelo de rede neural tem uma boa capacidade de generalização e que os erros são distribuídos de forma aleatória, o que ressalta a confiabilidade nas previsões realizadas.

Figura 6: Dispersão de erros das respostas do modelo de rede neural.



Fonte: próprios autores.

4 Conclusão

Neste trabalho foi realizado um estudo sobre a possibilidade de utilização de inteligência artificial na descrição do processo de irrigação localizada. Em específico, foi desenvolvido um modelo neural robusto para estimar a massa de sólidos suspensos acumulada após o processo de filtração de água, a fim de avaliar o desempenho de filtros de discos 1 polegada, mesh 120 e 155, utilizados na irrigação localizada. Os dados experimentais utilizados para a implementação do modelo de rede neural foram obtidos da literatura, estando publicados no trabalho de Oliveira (2010).

Com base na análise apresentada, pode-se concluir que o modelo de rede neural foi bem-sucedido em seu processo de aprendizado, demonstrando um comportamento robusto e eficaz. O erro relativo percentual médio entre os valores estimados pelo modelo e os valores experimentais de massa acumulada foi 0,29%, demonstrando que a ferramenta baseada em redes neurais artificiais é uma técnica potencialmente aplicável ao processo de irrigação localizada.

Portanto, a ferramenta desenvolvida no presente trabalho pode se constituir numa alternativa bastante viável para o controle da irrigação no monitoramento da obstrução dos orifícios dos filtros utilizados no processo, aprimorando a eficiência do sistema de irrigação, podendo dispensar a necessidade de testes empíricos e facilitar a otimização do processo.

Referências

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

BUCKS, D. A.; NAKAYAMA, F. S.; GILBERT, R. G. Trickle irrigation water quality and preventive maintenance. **Agricultural Water Management**, v. 2, n. 2, p. 149-162, 1979. Disponível em: <https://ideas.repec.org/a/eee/agriwat/v2y1979i2p149-162.html>. Acesso em: 05 nov. 2025.

CAPRA, A.; Scicolone, B. Emitter and filter tests for wastewater reuse by drip irrigation. **Agricultural Water Management**, Elsevier, v. 68, n. 2, p. 135-149, 2004. Disponível em: <https://ideas.repec.org/a/eee/agriwat/v68y2004i2p135-149.html>. Acesso em: 06 nov. 2025.

CUSTÓDIO, C. A.; FILLETTI, É. R.; FRANCA, V. V. Artificial neural networks for density-functional optimizations in fermionic systems. **Scientific Reports**, London, v. 9, n. 1886, 2019. Disponível em: <https://www.nature.com/articles/s41598-018-37999-1.html>. Acesso em: 29 ago. 2024.

ESSAHLAQUI, F.; ELHAJRAT, N.; HALIMI, M.; ABBASSI, A. E. New approach to monitoring a wastewater irrigation system controlled by the artificial neural network (ANN). **Groundwater for Sustainable Development**. Amsterdam, v. 23, n. 100999, 2023. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2352801X23000991>. Acesso em: 14 ago. 2024.

HAGAN, M.T.; DEMUTH, H.B.; BEALE, M. **Neural network design.** Boston: PWS publishing company, 1996.

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

KAMACHI, M. L. D.; FILLETTI, E. R. Aplicação de redes neurais artificiais para estimar a massa de sólidos acumulada na filtração de água na irrigação localizada. In: ENCONTRO REGIONAL DE MATEMÁTICA APLICADA E COMPUTACIONAL, 7., 2024, Bauru. **Caderno** [...]. Bauru: Unesp, 2024. p. 259-260. Disponível em: <https://drive.google.com/file/d/1jIVWriJT5X45vWa3ecgM8AaAp5EeDm7B/view>. Acesso em: 14 ago. 2024.

KOUADRI, S., PANDE, C.B., PANNEERSELVAM, B., MOHARIR, K. N., ELBELTAGI, A. Prediction of irrigation groundwater quality parameters using ANN, LSTM, and MLR models. **Environmental Science and Pollution Research**, Heidelberg, v. 29, p. 21067–21091, 2022. Disponível em: <https://doi.org/10.1007/s11356-021-17084-3>. Acesso em: 14 ago. 2024.

OLIVEIRA, C. F. de. **Filtração de água com diferentes concentrações de argila e silte em filtros de discos para irrigação localizada**. 2010. 147 p. Tese (Doutorado em Agronomia). Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2010.

PRONI, C.; HANEDA, R. N.; FILLETTI, Érica 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**, Bauru, v. 17, p. 189-205, 2020.

UMAIR, S. M.; USMAN, R. Automation of Irrigation System Using ANN based Controller. Research Centre for Modeling & Simulation, National University of Science and Technology, Pakistan. **International Journal of Electrical & Computer Sciences IJECS-IJENS**, Islamabad, v. 10, n. 2, p. 45-51, 2015.

ZHAO, J.; YU, Y.; LEI, J.; LIU, J. Multi-Objective Lower Irrigation Limit Simulation and Optimization Model for Lycium Barbarum Based on NSGA-III and ANN. **Water**, Beijing, v. 15, n. 783, 2023.