

Uso das redes neurais artificiais na modelagem do processo de adsorção de corantes têxteis

Use of artificial neural networks to model the textile adsorption process

- **Data de entrada:**
12/12/2021
- **Data de aprovação:**
27/09/2023

Marcos Renato Basilio Amorim^{1*} | Cinthia Sany França Xavier¹ | William De Paiva¹ | Otaciana Pereira Leite Neta¹ | Fernando Fernandes Vieira¹

DOI: <https://doi.org/10.36659/dae.2024.051>

Orcid ID

Amorim MRB  <https://orcid.org/0000-0003-1042-2808>
Xavier CSF  <https://orcid.org/0000-0002-4840-2653>

Paiva W  <https://orcid.org/0000-0003-0220-1247>
Neta OPL  <https://orcid.org/0000-0002-1191-046X>
Vieira FF  <https://orcid.org/0000-0002-1823-6236>

Resumo

A indústria têxtil, em razão de seu grande desenvolvimento e crescimento, vem utilizando mais corantes, o que gera um volume grande de efluentes altamente coloridos e contaminados. Esses efluentes, ao serem descartados sem um tratamento prévio em corpos hídricos, podem gerar problemas ambientais graves. Uma maneira simples, eficiente e barata de remover esses corantes é a técnica de adsorção, um dos métodos mais intensamente investigados e amplamente utilizados para a remoção de poluentes de águas residuais, devido à sua facilidade de operação, viabilidade econômica e alta eficiência. Na literatura são encontrados diversos trabalhos que utilizaram a técnica de modelagem matemática a partir do treinamento de rede neural artificial (RNA) a fim de encontrar um modelo que relacione a eficiência do processo de adsorção. Esta pesquisa visou modelar os dados experimentais da adsorção de corantes têxteis em bagaço de cana-de-açúcar, usando as RNA. A técnica de adsorção foi aplicada em dados globais, de treinamento e teste com uma e duas camadas, todas com 20 repetições, para as quais foram obtidas retas de ajuste do modelo com coeficientes de determinação maiores que 90% para variação dos dados da variável Q_t (quantidade de massa adsorvida). Os dados utilizados são provenientes da pesquisa de uma aluna da Universidade Estadual da Paraíba que realizou três tratamentos para o processos de adsorção. A rede *FeedForward* foi a que apresentou o melhor ajuste aos dados em estudo.

Palavras-chave: Indústria têxtil. Corantes. Adsorção. RNA.

Abstract

The textile industry has shown great development and growth. As a result, it has been using more dyes, generating a large volume of highly colored and contaminated effluents. These effluents, when discarded without prior treatment in water bodies, can generate serious environmental problems. A simple, efficient, and cheap way to remove these dyes is to use an adsorption technique. Adsorption is one of the most intensively investigated and widely used methods for removing impurities from wastewater due to its ease of operation, economical viability, and high efficiency. The literature contains several studies that used the mathematical modeling techniques based on ANN training to find the model that relates the efficiency of the adsorption process. This research

¹ Universidade Estadual da Paraíba – Campina Grande – Paraíba – Brasil.

* **Autor correspondente:** marcosrenato85@gmail.com

aimed to model experimental data on the adsorption of textile dyes in sugar cane bagasse by using ANN. The adopted technique was globally applied to the data for training and testing with one and two layers (all with 20 repetitions), from which model adjustment lines were obtained that calculated coefficients of determination greater than 90% for variation in the variable data Q_t . The used data stems from research by a student at the State University of Paraíba, who carried out three treatments for the adsorption process. The FeedForward network was the one that best fit the studied data.

Keywords: Textile industry. Dyes. Adsorption. RNA.

1 INTRODUÇÃO

Segundo Bezerra (2015), o segmento de beneficiamento têxtil é composto por tinturarias, estamparias e lavanderias. As tinturarias, responsáveis por conferir cor ao substrato têxtil, trabalham com fios, manchões, tecidos planos e de malha; já as estamparias, que efetuam estampas localizadas nos artigos, trabalham tanto com tecidos planos como malhas e peças confeccionadas; e as lavanderias industriais trabalham apenas com peças confeccionadas. E são nessas etapas do processo produtivo que ocorre um grande consumo de água e, como consequência, é também gerada uma quantidade proporcional de água residual com efeito poluidor bastante significativo ao meio ambiente, devido às elevadas vazões, toxicidade, composição variável e resistência química dos componentes ao tratamento de efluente (Queiroz *et al.*, 2016).

Entre os vários setores industriais responsáveis pela poluição do meio ambiente, o setor têxtil merece um destaque especial, pois utiliza uma grande quantidade de água e lança milhares de efluentes contaminados com corantes (Hynes *et al.*, 2020; Mokri *et al.*, 2015). No processo de produção têxtil são utilizadas substâncias químicas (corantes) para o tingimento dos tecidos, os quais, se lançados nos corpos hídricos, podem causar problemas ambientais. Esses corantes, além de causarem impacto visual, turvam a água, reduzindo a penetração solar, diminuindo, assim, a fotossíntese e a concentração de oxigênio dissolvido na água, sendo extremamente prejudicial aos seres vivos aquáticos (Marin, 2015).

O processo de tratamento de efluentes têxteis envolvendo a adsorção é uma das técnicas físico-químicas considerada mais eficaz em relação aos métodos convencionais e de custos relativamente moderados em relação às novas técnicas de tratamento de efluentes. A adsorção é um dos métodos mais intensamente investigado e amplamente utilizado para remover poluentes de águas residuais devido à sua facilidade de operação, viabilidade econômica e alta eficiência (Anastopoulos; Bhatnagar, 2017). A necessidade de se definir um modelo matemático que represente dados experimentais é muito fácil de ser suprida, o difícil é dizer o quão bem esse modelo matemático se ajusta aos dados obtidos, e quão bons serão as suas previsões para outros pontos que não se farão experimentos. Um dos procedimentos mais comuns na área de adsorção é o ajuste dos dados experimentais aos modelos de isotermas mais conhecidos.

Essas isotermas geralmente trazem como variável independente a concentração final do adsorbato em solução e como variável dependente a concentração de adsorbato na fase sólida, que é obtida por balanço de massa. Apesar de a maioria dos modelos de equilíbrio de adsorção ser não linear, a popularidade de softwares e rotinas para realizar regressões lineares, além da facilidade da sua utilização, faz com que muitas vezes os pesquisadores recorram à linearização do modelo.

Na modelagem matemática tem-se a necessidade de investigação dos dados, sendo uma importante ferramenta de tomada de decisão que se baseia na

tecnologia da informação, conhecimentos matemáticos, estatísticos e do meio ambiente (Dohler *et al.*, 2020; Ferreira; Penereiro, 2012; Santos *et al.*, 2020). O modelo matemático reproduz a realidade de um determinado estudo, isto é, ilustrando as suas mudanças (Santos *et al.*, 2020; Sodré, 2007).

As Redes Neurais Artificiais (RNA) são ótimas para aprender padrões por meio de um conjunto de dados e têm sido úteis na resolução de problemas complexos e não lineares; uma resposta abrangente aos problemas de inteligência computacional de alta importância. Um dos principais objetivos da RNA é prever com precisão o comportamento do estado estacionário ou dinâmico, a fim de monitorar e melhorar o desempenho de um processo. As RNA são modelos computacionais de inteligência artificial, aprendizado em máquina, baseados no cérebro humano e na sua capacidade de previsão de resultados a partir do reconhecimento de padrões provenientes da experiência por exemplos previamente estudados (Ripley, 1996). O seu desenvolvimento matemático é baseado na idealização da forma como os neurônios humanos funcionam e na sua capacidade de percepção e aprendizagem de fenômenos complexos, não lineares e multivariados (Bishop, 1995; Dantas Neto *et al.*, 2017; Haykin, 2008; Schmidhuber, 2015).

Na literatura são encontrados diversos trabalhos (Aghav; Kumar; Mukherjee, 2011; Hassanzadeh *et al.*, 2015; Mesci; Ozgonenel; Turan, 2011) que utilizaram a técnica de modelagem matemática a partir do treinamento de RNA a fim de encontrar o modelo que relacione a eficiência do processo de adsorção. A RNA é um sistema de processamento de dados similar à estrutura de um sistema neural biológico. Ela simula o princípio de funcionamento do cérebro humano e executa a aprendizagem e a previsão (Mesci; Ozgonenel; Turan, 2011).

Os modelos matemáticos são determinados por meio de regressão. Na regressão linear, simples ou múltipla, uma reta ou curva alcança ao máximo os dados associados. A análise de regressão baseia-se na produção

de uma análise estatística para averiguar a presença de uma conexão entre uma variável dependente com uma ou mais variáveis independentes, o que significa conseguir uma equação matemática que explique a alternância da variável dependente, por meio da variação dos níveis das variáveis independentes (Chavarette; Cossi; Lopes, 2017). Este trabalho propõe a previsão por meio da modelagem matemática baseada no conhecimento de RNA para a previsão de dados de adsorção de corantes têxteis.

2 METODOLOGIA

O trabalho foi desenvolvido no Laboratório de Pesquisa em Ciências Ambientais (LAPECA), da Universidade Estadual da Paraíba (UEPB).

2.1 Origem dos dados experimentais

Usou-se o material lignocelulósicos para adsorver os corantes têxteis presentes em águas residuárias. Como adsorvente, foi utilizado o bagaço de cana de açúcar para adsover o corante têxtil da marca Tupy, cor bordô nº 16. No trabalho, foi usado o adsorvente na forma *in-natura* e após a ativação química e alcalina, usando soluções HCl e NaOH 0,1mol.L-1. O conjunto de dados obtido das pesquisas é composto por experimentos realizados *in natura* e após os tratamentos químicos, sendo 46×3 experimentos *in natura*, 46×3 experimentos com material ácido e 46×3 experimentos com material alcalino. Na Figura 1, observa-se a adsorção em material adsorvente.

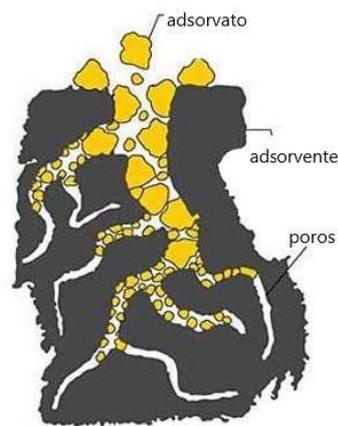


Figura 1 – Adsorção em material adsorvente.

Fonte: Adaptado de Smart Carbon, 2018.

2.2 Análise preliminar e divisão dos dados

Para realizar o treinamento dos dados e avaliar seu desempenho foi utilizada a RNA. O conjunto de dados será dividido em três subconjuntos. Será utilizado um conjunto de 70% das amostras para o treinamento da rede, 15% para a validação cruzada e 15% para a verificação do modelo.

2.3 Determinação das variáveis de entrada

Como dados de entrada para a RNA foram usados massa de adsorvente, concentração da solução de corante, pH da solução, tempo de contato e agitação, estes foram definidos como variáveis independentes na investigação sobre o efeito gerado nas variáveis quantidade de corante removida por unidade de massa de adsorvente (Q_t) (mg.g^{-1}) e eficiência na Remoção (Rem) (%).

2.3 Treinamento da rede neural

Na criação da rede, considera-se uma arquitetura do tipo *FeedForward* de múltipla camada, que observa-se na Figura 2.

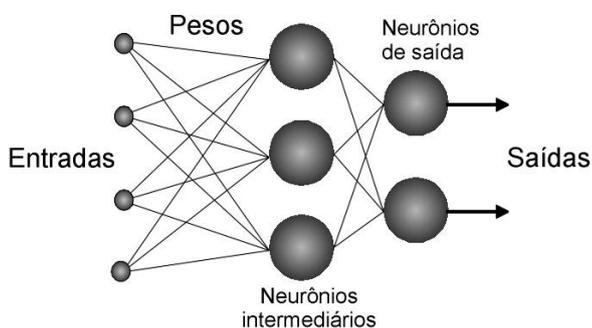


Figura 2 – Representação da rede *FeedForward* de camadas múltiplas.

Fonte: Imagem obtida do Google.

Na tentativa de buscar uma relação entre a camada intermediária, consideram-se duas situações: uma rede composta por uma camada intermediária e outra com duas camadas intermediárias.

A rede mostra a estrutura da rede neural artificial, na qual utilizou-se uma RNA com uma camada que usou 2, 4, 6, 8, 10, 15 e 20 neurônios; já na RNA com duas camadas analisaram-se as

combinações entre os números de neurônios da camada 1 e 2, por exemplo 2 a 2, 4 a 4 etc.

2.4 Treinamento da rede neural artificial

Para avaliar o desempenho da rede, dividem-se os dados de entrada em três grupos: treinamento, validação e teste. Os dados de treinamento que foram utilizados para definir os parâmetros dos pesos formam o conjunto de validação, em geral composto por 10 a 25% das amostras disponíveis, o que representa uma avaliação não enviesada dos resultados, pois utiliza um segundo conjunto de dados independente do treinamento usado para a predição (Zhao *et al.*, 2015). Por meio dos resultados dos dados de validação a arquitetura da rede (número de neurônios em cada camada) pode ser ajustada. Por fim, utiliza-se o conjunto de dados de teste, que apresenta a mesma probabilidade de distribuição dos dados de treinamento, embora independente.

No treinamento da rede, serão utilizados dois tipos de algoritmos: o gradiente descendente com *momentum* e a taxa de aprendizagem adaptativa (GDMTA) e o Levenberg Marquardt. Serão usados os parâmetros de treinamento tanto GDMTA quanto Levenberg Marquardt, que serão implementados no programa *Python*. Segundo Zhao *et al.* (2015) e Haykin (1999), os maiores desafios da rede neural são associados à adequada seleção de dados para o treinamento da rede, que deve compor uma gama extensa de possibilidades de valores e ocorrências (também para não serem considerados pontos *outliers*) e o correto ajuste da rede.

Uma análise será realizada para o desempenho da rede utilizando o algoritmo de treinamento gradiente descendente com momento e taxa de aprendizagem adaptativa. Dessa forma, a rede treinada com o gradiente descendente com momento e taxa de aprendizagem adaptativa poderá ser adequada para fazer a simulação do processo de tratamento de adsorção. Espera-se que os dados de saída simulados com esse algo-

ritmo se aproximem dos valores experimentais e que a distância entre os valores simulados e os experimentais seja representativa. Isso só será possível se o método gradiente decrescente conseguir corrigir os pesos sinápticos da rede e, por sua vez, atingir o erro mínimo global.

2.5 Utilização da linguagem *Python* em redes neurais

A linguagem de programação *Python* foi criada por Guido van Rossum (1991) e é focada em produtividade e legibilidade, ou seja, visa produzir um código fácil para o programador entender. Entre os itens que cooperam para esses aspectos estão: baixo uso de caracteres especiais; baixo índice de palavras-chave; gerenciador de memória eficiente que evita vazamento de memória (Borges, 2014). Além do mais, a biblioteca padrão é muito extensa, de forma a ter uma diversidade de abordagens prontas para serem utilizadas, seja acesso a banco de dados, trabalho com números complexos, interfaces gráficas etc.

O *Python* também é multiplataforma e, caso apareça alguma que ele ainda não tenha suporte, os desenvolvedores podem modificar o código para que seja possível compilar para aquela linguagem, pois o *Python* também é uma linguagem livre. Assim, todos esses fatores fazem com que o *Python* seja uma das linguagens preferidas para o trabalho com inteligência artificial, *data mining* e *machine learning*. A utilização da linguagem *Python* se tornou significativamente mais ativa desde os anos 2000. Entre as linguagens utilizadas na comunidade de computação científica, o *Python* se destaca por ter uma das maiores comunidades ativas (Mckinney, 2013). Os fatores que tornaram decisiva a escolha de tal linguagem para o projeto foram: a facilidade de aprendizagem e a variedade de bibliotecas voltadas para a análise de dados.

Considerada como uma linguagem de alto nível na solução de cálculos matemáticos complexos por envolver grande número de interação, será

utilizada na pesquisa para o treinamento das redes neurais artificiais, o ajuste dos pesos e os cálculos do erro das funções de ativação.

3 RESULTADOS E DISCUSSÕES

3.1 Modelagem usando redes neurais artificiais

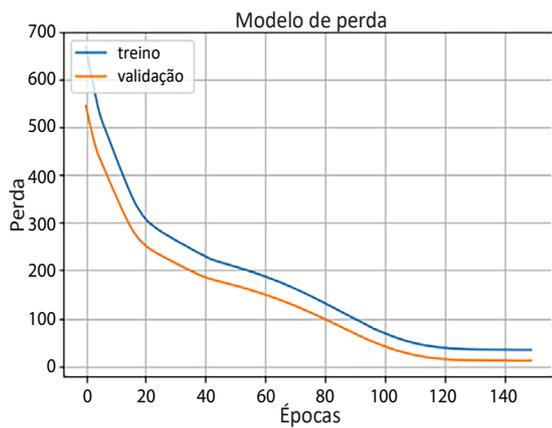
Para começar a estruturar a rede neural, foi realizado o primeiro dimensionamento de dados. Com ele, o objetivo era descobrir a melhor divisão dos dados para treinamento, validação e teste. Essa etapa tem grande importância, pois nela é possível entender como a divisão dos dados experimentais consegue influenciar o resultado.

O melhor resultado obtido representa a divisão de dados que permite à rede treinar de maneira suficiente para compreender o sistema, e ainda permite que existam dados suficientes para realizar a validação do treinamento e os testes. Em um estudo de Tarelko e Rudzki (2020), referente ao desenvolvimento de RNA ligadas ao consumo de combustível, foram testados quatro métodos de divisão de dados, aliados a uma função de divisão para randomizar a quantidade de dados para treino, validação e teste. Como resultado, as taxas obtidas foram de 70% dos dados para treino, 20% dos dados para validação e 10% dos dados para teste. Já no trabalho de Ansari *et al.* (2018), referente à predição da viscosidade de nanofluidos por RNA, a configuração de dimensionamento de dados foi de 70% para treino, 15% para validação e 15% para teste. Portanto, o melhor resultado para o dimensionamento de dados encontrados se aproxima daquele da literatura, que apresenta valores semelhantes de divisão para uma grande quantidade de casos.

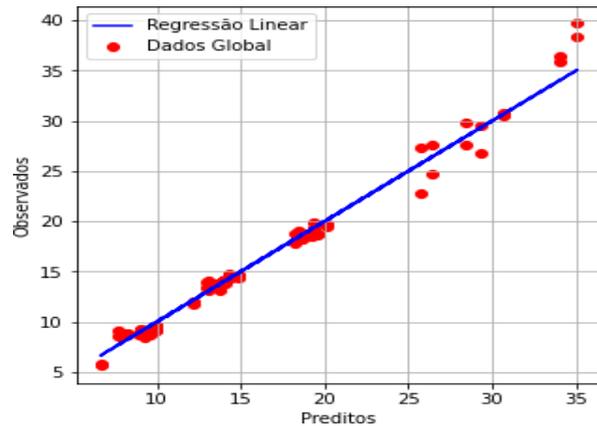
Com o intuito de verificar se a implementação da metodologia RNA é mais eficiente que a Regressão Múltipla, realizou-se, durante o tratamento dos dados, a aplicação de RNA. Nessa aplicação foi executado o treinamento da RNA com uma camada e 20 repetições nas primeiras medições; em seguida,

foram utilizadas duas camadas, cada uma com 20 repetições. Ainda realizou-se o treinamento da RNA com 2, 4, 6, 8, 10, 15 e 20 neurônios em uma camada, e a combinação 2×2, 4×4, 6×6, 8×8, 10×10, 15×15, 20×20 em duas camadas, com o objetivo de verificar se a adição de uma camada apresenta uma melhor representatividade para os dados experimentais. Para os tratamentos foram realizadas três medições de cada variável, a Qt e Rem; em cada uma das medições empregou-se um treinamento com uma e duas camadas e 20 repetições, para verificar qual o melhor treinamento que se ajusta à análise dos dados experimentais.

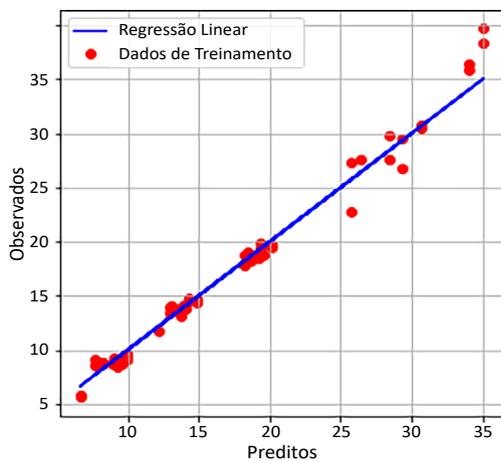
As RNA foram utilizadas para analisar os dados, obtendo-se gráficos de treino × validação, dados globais, treinamento e teste para o bagaço de cana de açúcar nos três tratamentos empregados. Nas figuras 3.1, 3.2 e 3.3 é possível observar o treino × validação para cada tratamento da variável Qt (quantidade de massa adsorvida), como também o ajuste do modelo para os três tratamentos com dados globais, treinamento e teste, sendo 20% para teste e 80% para treinamento. Esses gráficos representam o ajuste do modelo por meio da RNA que apresentaram um bom ajuste para a variável em estudo.



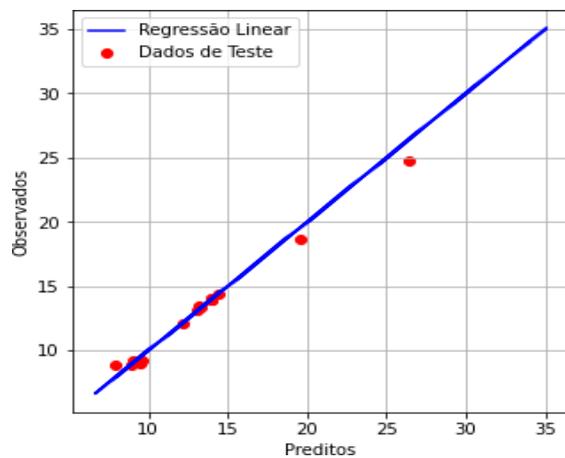
(a)



(b)

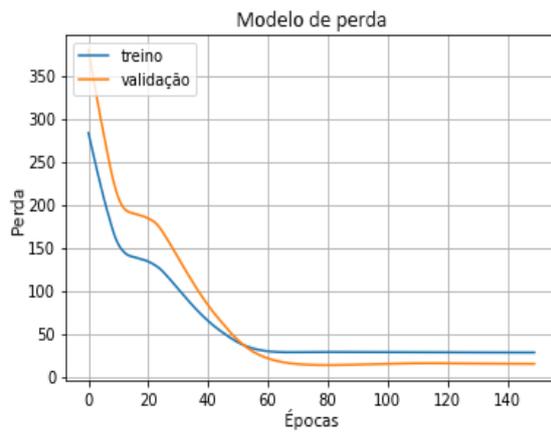


(c)

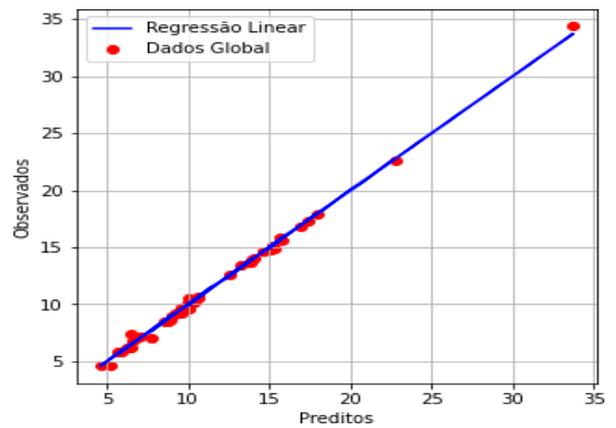


(d)

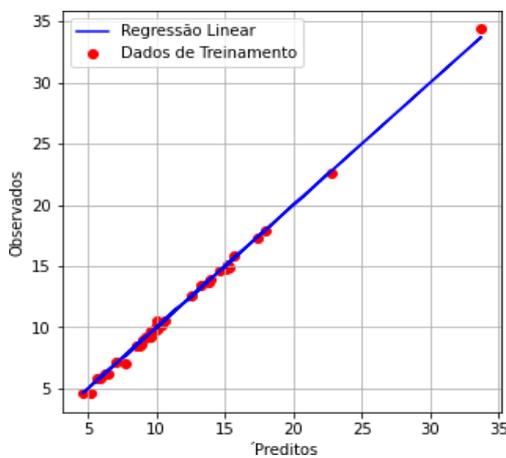
Figura 3.1 – Gráficos do treinamento ácido – Qt – (a) Treino e validação, (b) Dados globais, (c) Dados treinamento e (d) Dados teste.



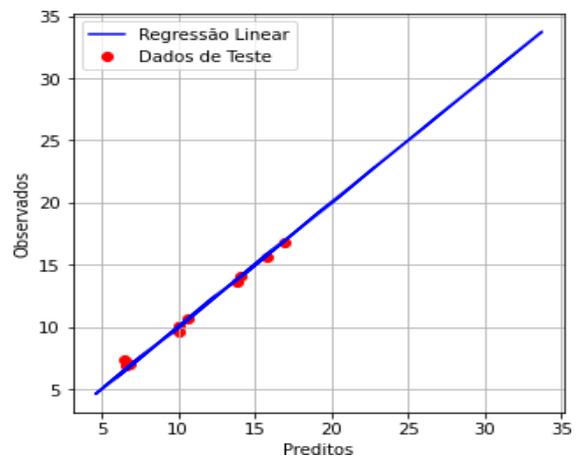
(a)



(b)



(c)



(d)

Figura 3.2 – Gráficos do treinamento alcalino – Q_t – (a) Treino e validação, (b) Dados globais, (c) Dados treinamento e (d) Dados teste.

Para a análise da RNA, com o objetivo de obter o melhor coeficiente de determinação, utilizou-se os *Box-Plots*, todos construídos por meio do software *Minitab*, no qual foi permitido verificar o melhor valor para a variação de ajuste do modelo. Ao avaliar a influência do aumento do número de neurônios e do número de camadas na RNA, verifica-se nas figuras acima que para a variável Q_t o aumento do número de neurônios ocasiona uma melhor variação para o ajuste da modelagem dos dados experimentais em uma e em duas camadas. Na Figura 4.1 verifica-se que a RNA com NN6 para a variável $Q_t - 1$ apresentou o melhor coeficiente de determinação, com um

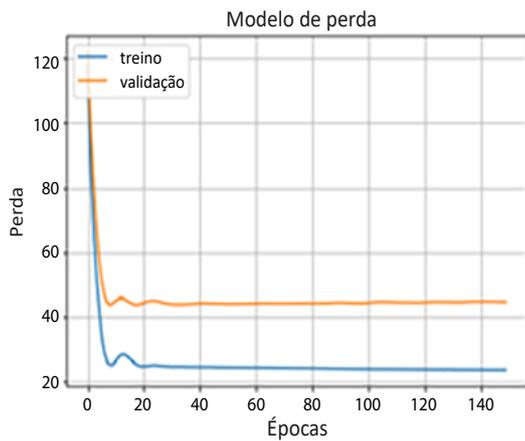
valor maior que 90%, e que em uma camada a maioria dos números de neurônios utilizados apresentam melhor resultado para a variação do ajuste do modelo.

Percebe-se que as RNA utilizadas apresentaram bons resultados para os coeficientes de determinação, recebendo destaque a RNA com uma camada e NN2 para a variável $Q_t - 2$, que apresenta o melhor resultado para o coeficiente de determinação para a variação de ajuste do modelo que obteve um valor maior que 90%. Observa-se na figura 4.1 que a utilização das RNA com uma camada e todos os números de neurônios apresentaram melhores resultados para a variação do

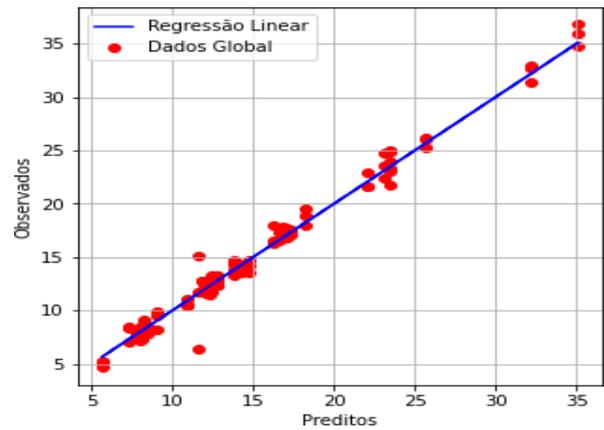
ajuste do modelo, com destaque para a RNA com NN6, (Qt-3), que apresentou o melhor coeficiente de determinação, indicando que, nesse caso, a utilização de uma camada é suficiente para ajustar o modelo.

A maioria dos dados na Figura 4.2, para a variável Qt-1 com duas camadas, descreve que o coeficiente de determinação obteve bons valores na utilização da RNA, com destaque para o NN2 com um coeficiente maior que 90%. Identifica-se na figura 4.2, para a variável Qt-2, que a maioria

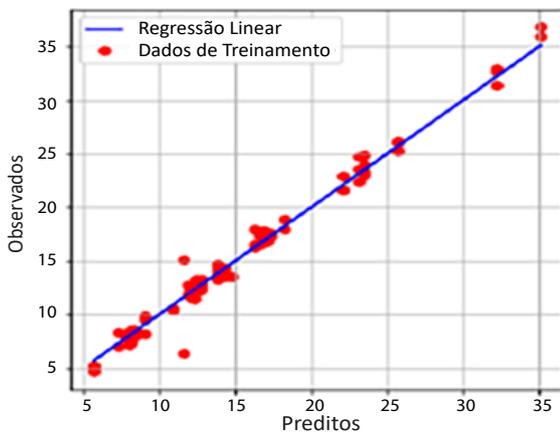
dos dados apresentaram coeficientes de determinação maior que 85%, com destaque para o NN2, que apresenta o maior valor para o coeficiente de determinação. Observa-se na figura 4.2 que a maioria dos dados obtidos, para a variável Qt-3, apresentaram coeficientes de determinação maior que 85% para a variação de ajuste do modelo, indicando que a RNA apresenta um melhor ajuste para o modelo, com destaque para o NN2 e o NN4, que apresentaram valores maiores que 90% para os coeficientes de determinação.



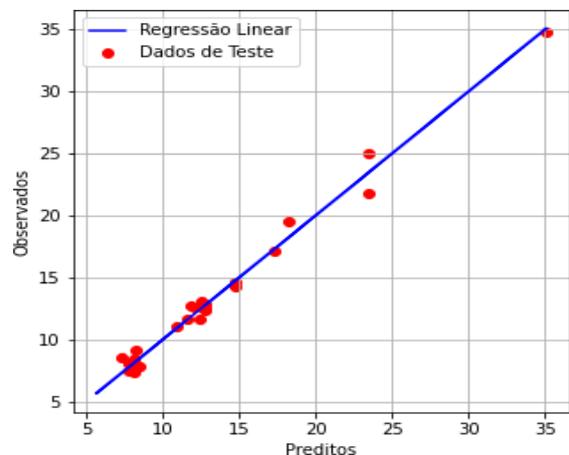
(a)



(b)



(c)



(d)

Figura 3.3 – Gráficos do treinamento *in-natura* – Qt – (a) Treino e validação, (b) Dados globais, (c) Dados treinamento e (d) Dados teste.

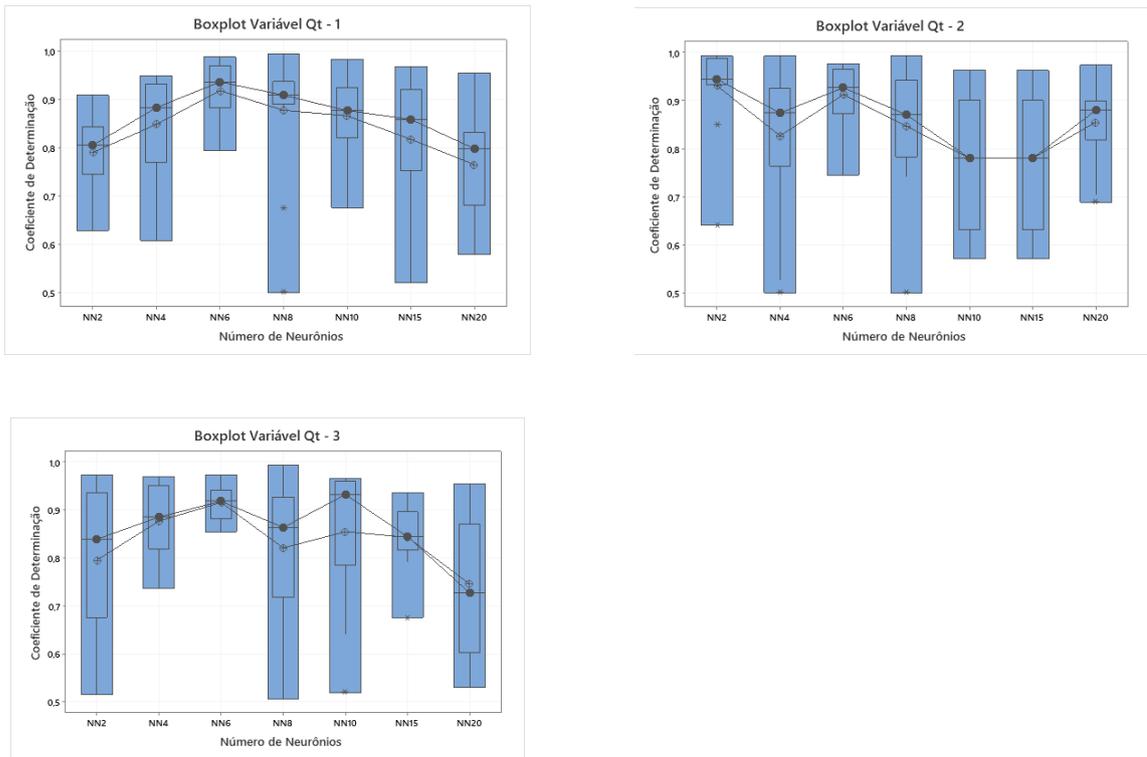


Figura 4.1 – Tratamentos com uma camada e 20 repetições.

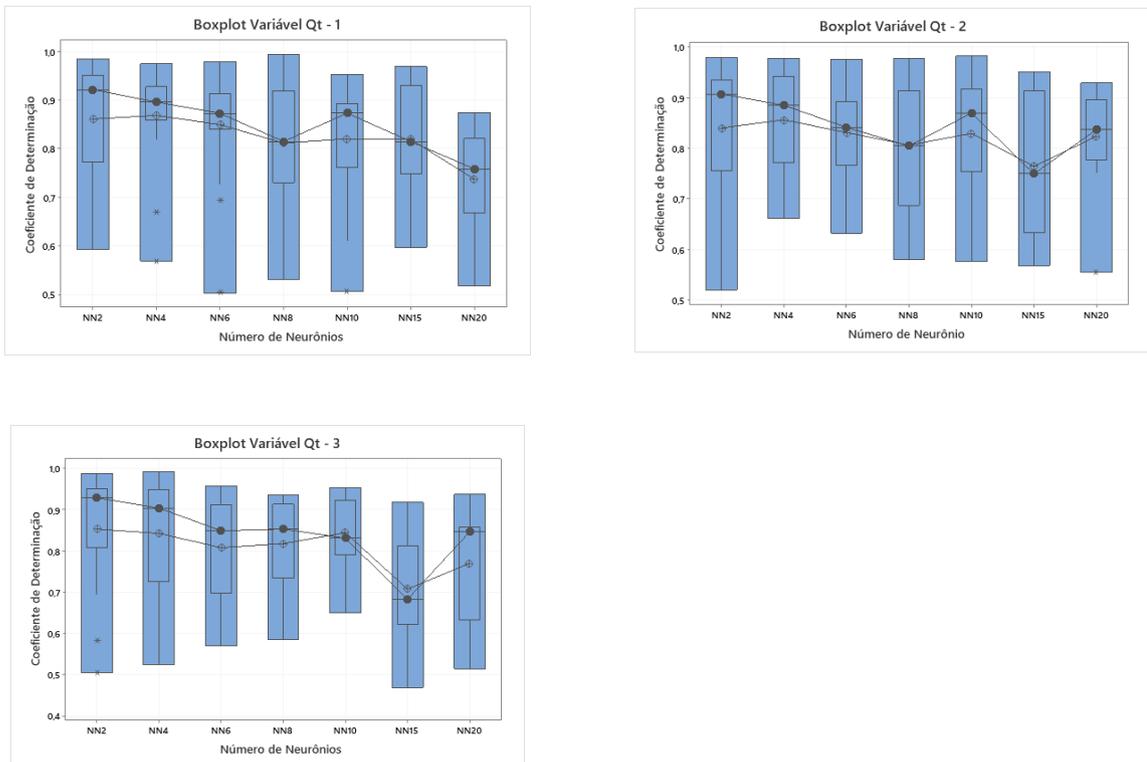


Figura 4.2 – Tratamentos com duas camadas e 20 repetições.

4 CONCLUSÕES

As RNA apresentaram bons resultados para os coeficientes de determinação com valores próximos a 93%; para a variável Q_t e para a variável Rem , a RNA apresentou valores maiores que 95%. Sendo assim, a RNA representa uma boa variação para o ajuste do modelo. Neste trabalho verificou-se o comportamento do coeficiente de determinação para escolher se a metodologia RNA é a mais apropriada, embora estudos indiquem que medidas estatísticas baseadas em correlação não sejam adequadas para tal decisão, uma vez que essas medidas são hipersensíveis a valores extremos e são insensíveis a diferenças aditivas e proporcionais entre as previsões do modelo e observações.

Nesta pesquisa não é possível afirmar que a adição de mais uma camada melhora o ajuste do modelo, bem como não é possível afirmar que o aumento do número de neurônios indica que a RNA é uma metodologia adequada para o problema. A seleção da RNA para analisar os dados indicou um bom valor de ajuste e convergência na obtenção dos modelos matemáticos, mesmo ao se empregar um baixo número de neurônios. O acréscimo no número de neurônios na RNA construída em boa parte dos tratamentos analisados forneceu melhores resultados, que foram significativos para os dados, impactando positivamente, além de possibilitar uma chance maior de ajuste da rede.

5 CONTRIBUIÇÃO DOS AUTORES

Resumo: Amorim MRB, Vieira FF; **Introdução:** Amorim MRB, Vieira FF, Paiva W; **Metodologia:** Amorim MRB, Vieira FF, Paiva W, Xavier CSF, Neta OPL; **Resultados e Discussões:** Amorim MRB, Vieira FF, Paiva W, Xavier CSF, Neta OPL; **Conclusões:** Amorim MRB, Vieira FF.

6 AGRADECIMENTOS

Os autores agradecem a Universidade Estadual da Paraíba (UEPB) e o Programa de Pós Graduação de Ciência e Tecnologia Ambiental.

7. REFERÊNCIAS BIBLIOGRÁFICAS

- AGHAV, R.M.; KUMAR, S.; MUKHERJEE, N. Artificial Neural Network Modeling in Competitive Adsorption of Phenol and Resorcinol from Water Environment Using Some Carbonaceous Adsorbents. **J. Hazard.Mater**, [S. l.], v. 188, p. 67, 2011.
- ANSARI, H. R. *et al.* A New Comprehensive Model for Relative Viscosity of Various Nanofluids Using Feed-Forward Back-Propagation MLP Neural Networks. **International Communications in Heat and Mass Transfer**, Amsterdam, v. 91, n. 1, p. 158-164, 2018. <https://doi.org/10.1016/j.icheatmasstransfer.2017.12.012>
- BEZERRA, Katia Crystina Hipólito. **Estudo de remoção de cor de efluentes têxteis por meio do processo oxidativo avançado: UV/H2O2**. 2015. 123 f. Dissertação (Mestrado em Têxtil e Moda) – Programa de Pós- Graduação em Têxtil e Moda, Escola de Artes, Ciências e Humanidades, Universidade de São Paulo, São Paulo, 2015.
- BHATNAGAR, A., ANASTOPOULOS, I. Adsorptive Removal of Bisphenol A (BPA) from Aqueous Solution: A Review. **Chemosphere**, Amsterdam, v. 168, p. 885-902, 2017. <https://doi.org/10.1016/j.chemosphere.2016.10.121>
- BISHOP, C. M. **Neural networks for pattern recognition**. New York: Oxford University Press, 1995.
- BORGES, L. E. **Python para desenvolvedores**. Rio de Janeiro: Novatec, 2014.
- DANTAS NETO, S. A. *et al.* Modelling the Shear Behaviour of Clean Rock Discontinuities Using Artificial Neural Networks. **Rock Mechanics and Rock Engineering**, Berlin, v. 50, p. 1817-1831, 2017.
- DOHLER R. E. *et al.* Aplicação de diferentes métodos de calibração do modelo de Hargreaves-Samani no Sudeste do Brasil. **Research, Society and Development**, Vargem Grande Paulista, v. 9, n. 8, e368984811, 2020. <https://doi.org/10.33448/rsd-v9i8.4811>
- HASSANZADEH, Z. *et al.* Combining Radial Basis Function Neural Network with Genetic Algorithm to QSPR Modeling of Adsorption on Multi-Walled Carbon Nanotubes Surface. **Journal of Molecular Structure**, Amsterdam, v. 1098, p. 191-198, 2015. <https://doi.org/10.1016/j.molstruc.2015.05.039>
- HAYKIN, S. **Neural Networks**. Virginia: Prentice Hall, 1999.
- HYNES, N. R. J. *et al.* Modern Enabling Techniques and Adsorbents Based Dye Removal with Sustainability Concerns in Textile Industrial Sector: A Comprehensive Review. **Journal of Cleaner Production**, Amsterdam, v. 272, p. 1-17, 2020. <https://doi.org/10.1016/j.jclepro.2020.122636>
- LOPES, M. L. M.; CHAVARETTE, F. R.; COSSI, A. M. Avaliação do modelo de regressão linear múltipla e redes neurais artificiais na previsão do ganho de massa em animais. **Revista Brasileira**

de **Engenharia de Biosistemas**, Tupã, v. 11, n. 1, p. 1-17, 2017. <https://doi.org/10.18011/bioeng2017v11n1p01-17>

MARIN, Sandra Liliana Albornoz. **Remoção dos corantes têxteis C.I. Reactive Blue 203 e C.I. Reactive Red 195 mediante o uso de bagaço de maçã como adsorvente**. 2015. 153 f. Dissertação (Mestrado em Tecnologia de Processos Químicos e Bioquímicos) – Universidade Tecnológica Federal do Paraná, Pato Branco, 2015.

MCKINNEY, W. **Python for Data Analysis**. [S. l.]: O'Reilly Media, 2013.

MOKRI, H. S. G. *et al.* Adsorption of C.I. Acid Red 97 Dye from Aqueous Solution onto Walnut Shell: Kinetics, Thermodynamics Parameters, Isotherms. **International Journal of Environmental Science and Technology**, Berlin, v. 12, p. 1401-1408, 2015.

PENEREIRO, J. C.; FERREIRA, D. H. L. A modelagem matemática aplicada às questões ambientais: uma abordagem didática no estudo da precipitação pluviométrica e da vazão de rios. **Millenium**, Viseu, v. 42, n. 1, p. 27-47, 2012.

QUEIROZ, M. T. A. *et al.* Gestão de resíduos na indústria têxtil e sua relação com a qualidade da água: estudo de caso. **Iberoamerican Journal of Industrial Engineering**, [S. l.], v. 8, n. 15, p. 114-135, 2016.

RIPLEY, B. D. **Pattern Recognition and Neural Networks**. Cambridge: Cambridge University Press, 1996.

SANTOS, G. C. de L. *et al.* Modelagem na nutrição de não ruminantes: aspectos gerais, dinâmica de nutrientes, limitações e sistemas de serviços. **Brazilian Journal of Animal and Environmental Research**, São José dos Pinhais, v. 3, n. 1, p. 114-132, 2020.

SCHMIDHUBER, J. Deep learning in neural networks: an overview. **Neural Networks**, Amsterdam, v. 61, p. 85-117, 2015. <https://doi.org/10.1016/j.neunet.2014.09.0>

SODRÉ, U. **Modelos matemáticos**. Londrina: UEL, 2007.

TARELKO, W.; RUDZKI, K. Applying Artificial Neural Networks for Modelling Ship Speed and Fuel Consumption. **Neural Computing and Applications**, Berlin, v. 32, n. 23, p. 17379-17395, 2020.

TURAN, N. G.; MESCI, B.; OZGONENEL, O. The Use of Artificial Neural Networks (ANN) for Modeling of Adsorption of Cu (II) from Industrial Leachate by Pumice. **Chemical Engineering Journal**, Amsterdam, v. 171, n. 3, p. 1091-1097, 2011. <https://doi.org/10.1016/j.cej.2011.05.005>

XAVIER, C. S. F.; **Avaliação da remoção de corantes têxteis presentes em águas residuárias utilizando bagaço da cana-de-açúcar como adsorvente**. 2020. 77 f. Dissertação (Mestrado em Ciência e Tecnologia Ambiental) – Programa de Pós-Graduação em Ciência e Tecnologia Ambiental, Universidade Estadual da Paraíba, Campina Grande, 2020.

ZHAO, T. *et al.* A Comparison of Classification Techniques for Seismic Facies Recognition. **Interpretation**, Houston, v. 3, n. 4, 2015. <https://doi.org/10.1190/INT-2015-0044.1>