



## **Aplicação de redes neurais artificiais a processos de adsorção de corantes têxteis**

**Gustavo Petroli<sup>1</sup>, Vitória Brocardo de Leon<sup>2</sup>, Fernanda Batista de Souza<sup>3</sup>,  
Claiton Zanini Brusamarello<sup>4</sup>**

<sup>1</sup>Universidade Tecnológica Federal do Paraná-Câmpus Francisco Beltrão  
(gustavo\_petroli@hotmail.com)

<sup>2</sup>Universidade Tecnológica Federal do Paraná-Câmpus Francisco Beltrão  
(vitoria\_brocardo@hotmail.com)

<sup>3</sup>Universidade Tecnológica Federal do Paraná-Câmpus Francisco Beltrão  
(fernandasouza@utfpr.edu.br)

<sup>4</sup> Universidade Tecnológica Federal do Paraná-Câmpus Francisco Beltrão  
(claitonz@utfpr.edu.br)

### **Resumo**

Os corantes de industriais têxteis podem se tornar extremamente prejudiciais ao meio ambiente, devido a este fato, o tratamento destes efluentes tem sido amplamente estudado pela técnica da adsorção. As redes neurais artificiais são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. Os estudos envolvendo redes neurais artificiais vêm crescendo substancialmente nos últimos anos, devido a sua vasta aplicabilidade na resolução de problemas complexos de engenharia, problemas os quais o processo de adsorção permeia. O objetivo desse trabalho é mostrar o uso das redes neurais artificiais em trabalhos recentes da literatura, com foco no tratamento de efluentes têxteis por adsorção, além de salientar a sua eficiência prevendo resultados experimentais.

Palavras-chave: Redes neurais artificiais. Efluentes têxteis. Adsorção.

Área Temática: Tecnologia Ambiental

## **Application of artificial neural networks to adsorption processes of textile dyes**

### **Abstract**

*Textile dyes can become extremely harmful to the environment, due to this fact, the treatment of these effluents has been studied extensively by the adsorption technique. Artificial neural networks are computational techniques that present a mathematical model inspired by the neural structure of intelligent organisms and that acquire knowledge through experience. Studies involving artificial neural networks have been growing substantially in recent years due to their wide applicability in solving complex engineering problems, problems that the adsorption process permeates. The objective of this work is to show the use of artificial neural networks in recent works of the literature, focusing on the treatment of textile effluents by adsorption, besides emphasizing their efficiency, predicting experimental results.*

*Key words: Artificial neural networks. Textile effluent. Adsorption.*

*Theme Area: Environmental Technology*



## 1 Introdução

Os corantes originados de tingimento e acabamento de industriais têxteis podem se tornar extremamente prejudiciais ao meio ambiente e aos organismos presentes nele. Isso se deve ao fato de que a maioria dos compostos encontrados nos corantes sintéticos apresentam uma estrutura molecular aromática e complexa, tornando a biodegradação desses componentes inviável. Por esse motivo o aprimoramento de técnicas para o tratamento desses efluentes vem se tornando necessário. Entre todos os métodos existentes para a remoção de corantes, a adsorção é um dos mais eficazes (ASFARAM et al., 2017; GHAEDI et al., 2014a; KHALED et al., 2009).

A adsorção é amplamente conhecida pela sua aplicabilidade em tratamento de efluentes, devido a sua facilidade, rapidez e, algumas vezes, baixo custo. Além de ser um processo não prejudicial, pois faz uso de um adsorvente não nocivo (GHAEDI et al., 2015; KARIMI et al., 2017). Porém a eficiência do tratamento está bastante relacionada com as propriedades do adsorvente envolvido, o que torna a escolha desse adsorvente de suma importância para o processo de adsorção (XIAO et al., 2018).

O adsorvente mais popular para o tratamento de efluentes têxteis é o carvão ativado, em razão da sua grande capacidade de adsorção e elevada área superficial, no entanto o seu alto custo abre espaço para a busca de um adsorvente eficiente mais acessível (ASFARAM et al., 2017; XIAO et al., 2018). Dessa maneira o estudo de novos adsorventes vem crescendo e uma ferramenta que pode auxiliar nessas pesquisas são as redes neurais artificiais (DUTTA et al., 2010; KARIMI et al., 2017).

O método das redes neurais artificiais (RNA's) é uma técnica inspirada no próprio cérebro humano e pode ser utilizada para prever o resultado de uma gama extremamente ampla de estudos. É composta por uma estrutura computacional que envolve unidades de processamento conectadas paralelamente, conhecidas como neurônios (ASSEFI et al., 2014; DUTTA et al., 2010). Mas o que torna a RNA tão versátil é a sua capacidade de aprender a partir de dados experimentais, criando uma relação entre as variáveis de entrada e saída (KARIMI; GHAEDI, 2014; KHAJEH; KAYKHAI; SHARAFI, 2013; LV; ZHENG, 2017).

As RNA's tem como maior foco resolver problemas complexos de engenharia. A adsorção por si só é um processo bastante complexo, pois é afetado por vários fatores (pH, dosagem de adsorvente, período de agitação, temperatura, etc.). Assim as RNA's podem ser bastante úteis prevendo os efeitos desses fatores, ajudando a entender o processo de tratamento de resíduos recorrentes da indústria têxtil (GHAEDI et al., 2014b, 2014c).

O objetivo desse estudo é expressar a importância das redes neurais, auxiliando em pesquisas na área de tratamento de efluentes têxteis por adsorção.

## 2 Metodologia

Segundo Haykin (2001), existem três tipos de RNA's, que estão classificadas mediante a sua arquitetura. A primeira e mais simples entre as três é a chamada rede de camada única, conhecida como Single-Layer Feed Forward Network. É composta por somente duas camadas de neurônios, a camada de entrada e a de saída, porém a camada de entrada não é considerada uma camada propriamente dita, já que não ocorre nenhuma computação dentro dela.

A segunda classe é certamente a mais utilizada, pois as redes de múltiplas camadas têm uma grande aplicação na resolução de problemas em diversas áreas. Sua estrutura também é formada pelas camadas de entrada e saída, mas possui a presença de camadas



escondidas que auxiliam a rede a extrair estatísticas de ordem mais elevada (GHAEDI; VAF AEI, 2017).


Por fim, existem as redes recorrentes, em que ocorre a realimentação de alguns dados. Esse tipo de RNA pode possuir a mesma estrutura que uma rede de camada única ou de uma rede com multicamadas, porém os neurônios de saída podem alimentar os seus sinais de volta para um neurônio de entrada, ajudando muito no seu processo de aprendizagem (HAYKIN, 2001).

Uma maneira de melhorar o processo de aprendizagem de uma RNA é fazendo uso de um algoritmo de otimização, e nos últimos anos a combinação dos algoritmos genéticos nas redes neurais tem sido muito bem-sucedido (ASSEFI et al., 2014). Os algoritmos genéticos, assim como as RNA's, também são inspirados pelos organismos vivos, desta vez pelo processo de seleção natural e pela evolução genética. Esse método aplica um procedimento de mutação, crossover e seleção, direcionando a busca para uma região onde exista uma alta probabilidade de otimização da rede (KARIMI; GHAEDI, 2014).

O algoritmo do sistema imunológico artificial (AIS), o algoritmo de otimização de enxame de partículas (PSO), o algoritmo de evolução diferencial (DE) e o algoritmo competitivo imperialista (ICA) são exemplos que podem otimizar o treinamento de uma RNA (AGARWAL et al., 2016; ASFARAM et al., 2017).

Para a modelagem do processo de adsorção na remoção de corantes provenientes da indústria têxtil vem se destacando o uso de redes com 3 camadas, sendo essa uma rede de múltiplas camadas ou Multilayer feedforward neural networks (MLP). A estrutura desse tipo de RNA é demonstrada na figura a seguir:

Figura 1 - Estrutura de uma MLP de 3 camadas.



Fonte: (HAYKIN, 2001)

Na figura 1 é possível observar os parâmetros experimentais  $x_1$ ,  $x_2$  e  $x_{m0}$  na camada de entrada que representam as variáveis de entrada. No caso do tratamento de efluentes têxteis por adsorção as variáveis de entrada são em sua maioria: tamanho de partícula, pH inicial, concentração inicial de corante, tempo de contato, temperatura e a velocidade de agitação, podendo variar para diferentes procedimentos. Esses são os fatores que interferem diretamente com o resultado obtido no experimento ( $y$ ), sendo este a capacidade de adsorção do adsorvente estudado (ÇELEKLI; BOZKURT; GEYIK, 2016; HASSANI et al., 2014).

A topologia determina o número de neurônios envolvidos na RNA e diferentes topologias são analisadas para que o número de neurônios seja o melhor possível. O número de neurônios encontrados na camada escondida depende da complexidade do problema a ser

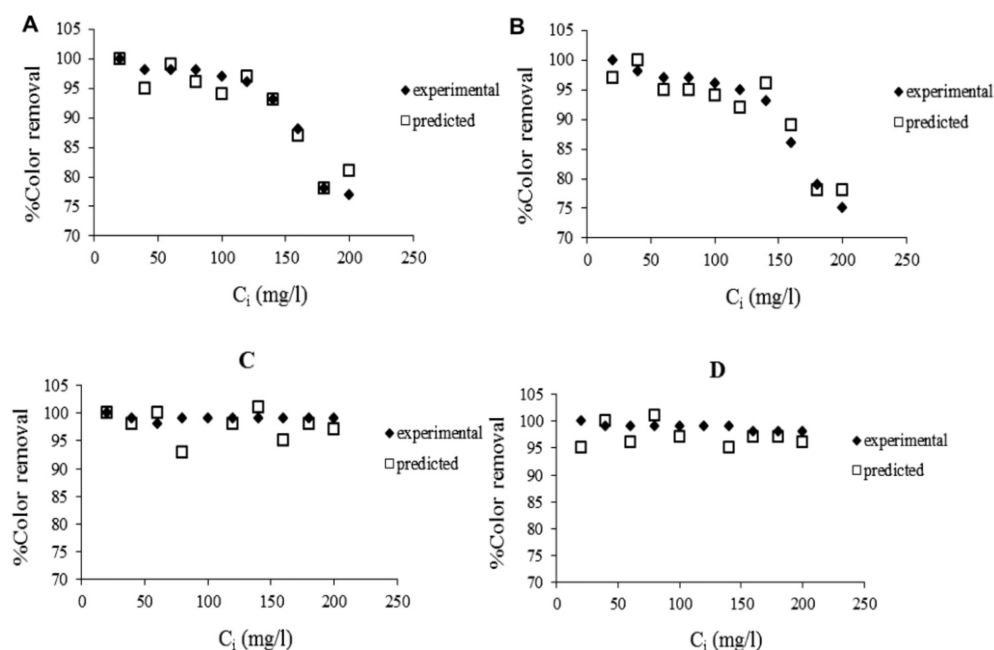


resolvido e tem grande importância na determinação do resultado final (ÇELEKLI; BOZKURT; GEYIK, 2016; KARIMI; GHAEDI, 2014; KHAJEH; KAYKHAI; SHARAFI, 2013).

### 3 Resultados e discussões

Existem diversas pesquisas que fazem uso das redes neurais para encontrar novos adsorventes eficientes, como o estudo conduzido por Elemen et al., 2012. O objetivo do autor foi a descolorização do corante reactive red 141 utilizando argilas organofílicas como adsorventes. Nele fez-se o uso de uma RNA MLP de três camadas para prever a eficiência adsorptiva do processo, sendo esta a variável de saída. A camada de entrada foi constituída de quatro neurônios, portanto foram avaliadas apenas quatro variáveis de entrada em suas respectivas faixas: concentração inicial de corante ( $20\text{--}200\text{ mgL}^{-1}$ ), dosagem de adsorvente ( $0,05\text{--}0,1\text{ gL}^{-1}$ ), temperatura ( $30\text{--}40\text{ }^{\circ}\text{C}$ ) e tempo de contato ( $0\text{--}1440\text{ min}$ ). Observa-se que os dados experimentais obtidos (Figura 2) condiziam com os dados previstos pela RNA.

Figura 2 – Percentagem de remoção para os dados experimentais e previstos pela RNA. Nas seguintes condições de adsorção: (A)  $30\text{ }^{\circ}\text{C}$ ,  $0,05\text{ g}$  de adsorvente,  $24\text{ h}$ ; (B)  $40\text{ }^{\circ}\text{C}$ ,  $0,05\text{ g}$  de adsorvente,  $24\text{ h}$ ; (C)  $30\text{ }^{\circ}\text{C}$ ,  $0,1\text{ g}$  de adsorvente,  $24\text{ h}$ ; (D)  $40\text{ }^{\circ}\text{C}$ ,  $0,1\text{ g}$  de adsorvente,  $24\text{ h}$ .




Fonte: (ELEMEN; AKÇAKOCA KUMBASAR; YAPAR, 2012)

Como já mencionado nesse artigo, o carbono ativado é um excelente adsorvente e por esse motivo muitos estudos vêm sendo feitos sobre ele na área de tratamento de efluentes.

Karimi & Ghaedi, 2013 realizaram estudo para tratamento do corante azul de metileno (MB). Para a determinação da porcentagem removida de MB utilizou-se uma RNA MPL com 3 camadas. A rede neural foi arquitetada de forma que a camada de entrada possuísse cinco variáveis de entrada, foram elas: o pH inicial, a taxa de agitação, a dosagem de adsorvente inicial, a concentração inicial de corante e o tempo de contato. Já a camada de saída continha a porcentagem de MB removida pelo adsorvente. Um método de tentativa e erro foi aplicado para estipular o número de neurônios presentes na camada escondida. Os testes realizados mostrados na Figura 3, revelam o impacto do número de neurônios no percentual de desvio médio (ADD%) da rede:




Figura 3 – Efeito da configuração do número de neurônios na ADD%.



Fonte: (KARIMI; GHAEDI, 2014)

É possível observar que os menores valores para o percentual de desvio médio ocorrem na faixa de 5-7 neurônios, ou seja a configuração ótima se encontra dentro dessa faixa. Karimo e Ghaedi (2014) utilizaram cinco neurônios na camada escondida para que assim a RNA apresentasse uma complexidade reduzida e os resultados da rede já treinada foram expostos na figura abaixo:

Figura 4 – Eficiência da RNA na determinação da porcentagem de remoção de MB.



Fonte: (KARIMI; GHAEDI, 2014)

A reta originada dos valores experimentais em relação aos resultados fornecidos pela rede teve um coeficiente linear de  $R^2 = 0,995$ . Portanto foi constatado que a RNA teve um ótimo desempenho prevendo a adsorção do poluente.

Outro estudo feito na Universidade de Gaziantep na Turquia, realizado por Çelekli, Bozkurt e Geyik (2016), propôs como adsorvente a casca de noz para o tratamento do corante Basic Red 46 (BR 46). Para determinar o quanto do corante seria adsorvido foram utilizados quatro métodos para a modelagem: o logístico, o cinético de pseudo segunda ordem, o modelo GEP (Gene Expression Programming) e as RNA's. Essa comparação foi feita através dos dados obtidos dispostos na tabela a seguir:

Quadro 1 – Parâmetros cinéticos para a adsorção de BR 46 na casca de noz (pH 10, tamanho da partícula = 125–250  $\mu\text{m}$  e  $t = 0\text{--}210$  min)

| Temperatura (K) | $C_0$ (mgL <sup>-1</sup> ) | $q_{\text{exp}}$ (mg g <sup>-1</sup> ) | $q_{\text{pred}}$ (mg g <sup>-1</sup> ) Cinético | $q_{\text{pred}}$ (mg g <sup>-1</sup> ) RNA | $q_{\text{pred}}$ (mg g <sup>-1</sup> ) GEP |
|-----------------|----------------------------|--|--|---|---|
| 293 K           | 20                         | 16,35                                  | 16,94  | 17,20                                       | 18,60                                       |
|                 | 40                         | 25,42                                  | 27,33  | 24,87                                       | 30,44                                       |
|                 | 60                         | 30,84                                  | 31,82  | 30,25                                       | 38,24                                       |
|                 | 80                         | 35,73                                  | 36,92  | 35,82                                       | 43,98                                       |
|                 | 100                        | 40,34                                  | 41,87  | 41,19                                       | 48,50                                       |
| 303 K           | 20                         | 17,51                                  | 17,92  | 17,38                                       | 17,51                                       |
|                 | 40                         | 27,64                                  | 29,89  | 27,01                                       | 27,64                                       |
|                 | 60                         | 34,54                                  | 35,49  | 34,81                                       | 34,54                                       |
|                 | 80                         | 39,34                                  | 39,83  | 39,88                                       | 39,34                                       |
|                 | 100                        | 44,15                                  | 44,95  | 44,76                                       | 44,15                                       |
| 313 K           | 20                         | 15,21                                  | 18,86  | 18,61                                       | 18,79                                       |
|                 | 40                         | 27,35                                  | 32,80  | 31,14                                       | 30,93                                       |
|                 | 60                         | 34,10                                  | 38,31  | 37,80                                       | 37,68                                       |
|                 | 80                         | 39,27                                  | 42,78  | 43,75                                       | 42,85                                       |
|                 | 100                        | 44,76                                  | 48,31  | 47,56                                       | 48,34                                       |

Fonte: adaptado de (ÇELEKLI; BOZKURT; GEYIK, 2016)

Observa-se no Quadro 1 que os resultados previstos pela rede neural descreveram melhor os valores obtidos pelo experimento do que os outros modelos. Além de ser o modelo mais adequado para a situação, a RNA também indicou os parâmetros experimentais que mais tiveram influência no processo de adsorção.

#### 4 Conclusão

Conclui-se que os processos de remoção de corantes por adsorção podem ser modelados, de forma robusta, pela ferramenta de redes neurais artificiais. Para essas situações as RNA's acabaram por ser a melhor escolha em relação aos outros métodos discutidos.

Outro ponto importante também é de que a estrutura e a arquitetura das redes têm uma grande influência na determinação do resultado final, tornando-o mais condizente com os resultados experimentais. Portanto estudos para melhorar e otimizar o funcionamento das redes neurais são de grande relevância.

#### Referências

AGARWAL, Shilpi et al. “Kinetics and thermodynamics of methyl orange adsorption from aqueous solutions—artificial neural network-particle swarm optimization modeling”. **Journal of Molecular Liquids**, [s. l.], v. 218, p. 354–362, 2016.

ASFARAM, Arash et al. “Ultrasound-assisted binary adsorption of dyes onto Mn@CuS/ZnS-NC-AC as a novel adsorbent: Application of chemometrics for optimization and modeling”. **Journal of Industrial and Engineering Chemistry**, [s. l.], v. 54, p. 377–388, 2017.





ASSEFI, P. et al. “Artificial neural network optimization for removal of hazardous dye Eosin Y from aqueous solution using Co<sub>2</sub>O<sub>3</sub>-NP-AC: Isotherm and kinetics study”. **Journal of Industrial and Engineering Chemistry**, [s. l.], v. 20, n. 5, p. 2905–2913, 2014.

ÇELEKLI, Abuzer; BOZKURT, Hüseyin; GEYIK, Faruk. “Artificial neural network and genetic algorithms for modeling of removal of an azo dye on walnut husk”. **Desalination and Water Treatment**, [s. l.], v. 57, n. 33, p. 15580–15591, 2016.

DUTTA, Suman et al. “Development of an artificial neural network model for adsorption and photocatalysis of reactive dye on TiO<sub>2</sub> surface”. **Expert Systems with Applications**, [s. l.], v. 37, n. 12, p. 8634–8638, 2010.

ELEMEN, Seniha; AKÇAKOCA KUMBASAR, Emriye Perrin; YAPAR, Saadet. “Modeling the adsorption of textile dye on organoclay using an artificial neural network”. **Dyes and Pigments**, [s. l.], v. 95, n. 1, p. 102–111, 2012.

GHAEDI, Abdol Mohammad; VAFAEI, Azam. “Applications of artificial neural networks for adsorption removal of dyes from aqueous solution: A review”. **Advances in Colloid and Interface Science**, [s. l.], v. 245, n. April, p. 20–39, 2017.

GHAEDI, M. et al. “Principal component analysis-artificial neural network and genetic algorithm optimization for removal of reactive orange 12 by copper sulfide nanoparticles-activated carbon”. **Journal of Industrial and Engineering Chemistry**, [s. l.], v. 20, n. 3, p. 787–795, 2014. a.

GHAEDI, M. et al. “Random forest model for removal of bromophenol blue using activated carbon obtained from *Astragalus bisulcatus* tree”. **Journal of Industrial and Engineering Chemistry**, [s. l.], v. 20, n. 4, p. 1793–1803, 2014. b.

GHAEDI, M. et al. “Artificial neural network - Imperialist competitive algorithm based optimization for removal of sunset yellow using Zn(OH)<sub>2</sub> nanoparticles-activated carbon”. **Journal of Industrial and Engineering Chemistry**, [s. l.], v. 20, n. 6, p. 4332–4343, 2014. c.

GHAEDI, M. et al. “Artificial neural network-genetic algorithm based optimization for the adsorption of phenol red (PR) onto gold and titanium dioxide nanoparticles loaded on activated carbon”. **Journal of Industrial and Engineering Chemistry**, [s. l.], v. 21, p. 587–598, 2015.

HASSANI, A. et al. “Adsorption of a cationic dye from aqueous solution using Turkish lignite: Kinetic, isotherm, thermodynamic studies and neural network modeling”. **Journal of Industrial and Engineering Chemistry**, [s. l.], v. 20, n. 4, p. 2615–2624, 2014.

HAYKIN, Simon. **Redes Neurais: Princípios e práticas**. Ontário, Canadá: Booksman, 2001. 46-49 p.

KARIMI, H.; GHAEDI, M. “Application of artificial neural network and genetic algorithm to modeling and optimization of removal of methylene blue using activated carbon”. **Journal of Industrial and Engineering Chemistry**, [s. l.], v. 20, n. 4, p. 2471–2476, 2014.



KARIMI, Rezvan et al. “*Efficient adsorption of erythrosine and sunset yellow onto modified palladium nanoparticles with a 2-diamine compound: Application of multivariate technique*”. **Journal of Industrial and Engineering Chemistry**, [s. l.], v. 48, p. 43–55, 2017.

KHAJEH, Mostafa; KAYKHAIL, Massoud; SHARAFI, Arezoo. “*Application of PSO-artificial neural network and response surface methodology for removal of methylene blue using silver nanoparticles from water samples*”. **Journal of Industrial and Engineering Chemistry**, [s. l.], v. 19, n. 5, p. 1624–1630, 2013.

KHALED, Azza et al. “*Removal of Direct N Blue-106 from artificial textile dye effluent using activated carbon from orange peel: Adsorption isotherm and kinetic studies*”. **Journal of Hazardous Materials**, [s. l.], v. 165, n. 1–3, p. 100–110, 2009.

LV, Huichao; ZHENG, Yong. “*A newly developed tridimensional neural network for prediction of the phase equilibria of six aqueous two-phase systems*”. **Journal of Industrial and Engineering Chemistry**, [s. l.], 2017.

XIAO, Benyi et al. “*Effects of sludge thermal-alkaline pretreatment on cationic red X-GRL adsorption onto pyrolysis biochar of sewage sludge*”. **Journal of Hazardous Materials**, [s. l.], v. 343, p. 347–355, 2018.