

II-141 - OTIMIZAÇÃO DE REDES NEURAIS ARTIFICIAIS NA MODELAGEM DE REATORES BIOLÓGICOS: ESTUDO DE CASO – REATOR UASB

Pedro Nogueira da Silva Neto⁽¹⁾

Licenciado em Química pelo IFPB. Especialista em Educação ambiental pela UNICID e Mestre em Ciência e Tecnologia ambiental pela Universidade Estadual da Paraíba (MCTA/UEPB).

Polyana de Brito Januário

Tecnóloga em Geoprocessamento pelo IFPB. Licencianda em Química no IFPB e Mestre em Engenharia civil e ambiental pela UFCG.

Dennis Dantas de Sousa

Química Industrial pela Universidade Estadual da Paraíba. Mestre em Ciência e Tecnologias Ambientais pela Universidade Estadual da Paraíba (MCTA/UEPB). Doutorando em Engenharia de Processos na Universidade Federal de Campina.

Hélder de Carvalho da Silva Fernandes

Engenheiro Químico (UFCG). Mestre em Engenharia Química (UFCG). Doutorando em Engenharia Química (UFCG)

Fernando Fernandes Vieira

Engenheiro Químico (UFPB). Mestre em Engenharia Química (UFPB). Doutorado em Engenharia Mecânica (UFPB). Professor Associado-A do Departamento de Engenharia Sanitária e Ambiental (UEPB).

Endereço⁽¹⁾: Rua/Manoel Santos Leal, 36 – São Bento - Bayeux - Paraíba - CEP: 58305-250 - Brasil - Tel: +55 (83) 3612 1363 - e-mail: pedronetog7@hotmail.com

RESUMO

Reatores UASB constituem uma possibilidade para tratamento de vários tipos de águas residuárias, tendo como aspecto essencial do processo a natureza da biomassa ativa. As Redes Neurais Artificiais (RNA) constituem um tipo de modelo matemático da área da Inteligência Artificial onde há cada vez mais uma intensificação das pesquisas de forma multidisciplinar. Assim, através da possibilidade de correlação entre estas duas áreas, esta pesquisa se estrutura com o objetivo de modelar e simular um reator UASB, através de RNA. O conjunto de dados, referentes aos 13 parâmetros analisados foi subdividido de 3 formas diferentes, usando uma camada oculta e variação do número de neurônios em 5, 10 e 15 e variação da função de ativação. Concluiu-se que quando se utiliza uma única camada intermediária, a melhor função de ativação foi a Logsig e a melhor distribuição de dados apresentou-se quando foi combinado 80% dos dados usados para treinamento, 10% para teste e 10% para validação. Paralelamente, é possível concluir que quanto maior é o número de neurônio usado na camada oculta, melhores coeficientes de determinação são encontrados. Nesta circunstância, o R^2 foi de 0,9985, valor considerado muito satisfatório para predição dos parâmetros analisados.

PALAVRAS-CHAVE: Tratamento de esgotos, matéria orgânica, MATLAB, função de ativação, coeficiente de determinação.

INTRODUÇÃO

Uma unidade de tratamento de esgotos deverá promover a remoção de poluentes de maior concentração presente nos efluentes. A legislação ambiental vigente, tanto a nível nacional pela resolução CONAMA nº 357/2005 como também a nível estadual pelas legislações dos estados, estabelece normas e procedimentos para o seu tratamento e lançamento nos recursos hídricos.

Segundo Campos (1999), as estações de tratamento de esgotos podem ter um ou mais reatores biológicos em seus arranjos, dependendo da disponibilidade de área, da variação das vazões, da operação e manutenção, dos custos, do consumo de energia, do uso de equipamentos, da mão-de-obra disponível, dos impactos ambientais, entre outros. De acordo com Fernandes (2000), o reator anaeróbio UASB, desenvolvido na década de 70 por Lettinga e sua equipe da Universidade de Wageningen, consiste de um leito de lodo (sludge bed), uma zona de

sedimentação (sludge blanket), e o separador de fase (gas-solid separator – GSS), que é um dispositivo típico do UASB.

As Redes Neurais Artificiais (RNA) constituem um conjunto bem estruturado de unidades de processamento interligado por um canal de comunicação, tendo como unidade fundamental o neurônio artificial, cuja concepção de sua estrutura perpassa pela de um neurônio biológico. (Braga et al ,2007; Haykin, 2001).

Este enfoque tem recebido grande interesse da comunidade científica, sendo realizadas pesquisas de forma multidisciplinar. Na área de engenharia ambiental há uma intensificação nos estudos que se utilizam de RNA para tomada de decisões. Com a função de minimização dos impactos ambientais e agilidade nas decisões é crescente a utilização das redes para soluções que visem o desenvolvimento sustentável. (Ljung, 1994; Vemuri,1994).

A principal motivação desse trabalho foi contribuir com a predição dos resultados dessas análises, visto que as RNA são capazes de representar relações lineares e não lineares pelo processo de aprendizagem, mesmo conhecendo pouco sobre o processo, desde que a estrutura de correlação do processo não mude. Assim, esse estudo apresenta a modelagem e simulação de um reator UASB, utilizando o software computacional MATLAB, para redes com uma camada oculta, analisando a influência da função de ativação e do número de neurônios para a formação da rede.

MATERIAL E MÉTODOS

Segundo Bação (2006), o objetivo principal do pré-processamento dos dados é facilitar e simplificar o problema a ser tratado sem que haja exclusão ou danifique informação importante para a modelagem e entendimento do problema. Desta forma, os dados experimentais utilizados no processo de modelagem que são dados provenientes de Sousa (1996), sofreram um pré-tratamento. Para tanto, os dados estavam dispostos em formato de texto tabelado, o que nos levou a trabalho inicial para introdução destes dados no software EXCEL, para que estes pudessem ser importados para o software MATLAB.

Neste processo de transcrição dos dados, de forma a minimizar a perda de informação e maximizar a obtenção dos resultados, o conjunto de dados referentes a entrada do reator UASB, excetuando-se o parâmetro pH, tiveram mudança, passando a ser expresso em Carga Volumétrica ao invés de Concentração. Esse processo ocorreu mediante experiência anterior de Moraes (2011) que verificou em seu estudo que a utilização da DQO como carga em vez de concentração, melhor representar a quantidade de matéria orgânica dissolvida no efluente.

O reator UASB foi monitorado durante 54 semanas, havendo duas fases distintas: a primeira que durou 16 semanas e a segunda com o restante das semanas e com a junção de uma coluna de desnitrificação para completar o sistema de tratamento disposto. Desta forma, foi considerado os valores de vazão nas duas fases do reator UASB, ou seja, até a 16ª semana a vazão foi de 20,4 L/dia e na segunda fase, até a 54ª semana, a vazão foi de 24L/dia.

Em seguida, no processo de construção da RNA os dados foram separados em três subconjuntos: Treinamento – usado para estimar os parâmetros do modelo; Validação – usado para verificar a generalização do modelo em comparação a amostras independentes do conjunto de treinamento e Teste – usado para validar o modelo usando novas amostras. No presente trabalho o conjunto de dados foi subdividido de três formas diferentes:

- a) 80 % dos dados para treinamento, 10 % para teste e 10 % para validação.
- b) 70 % dos dados para treinamento, 15 % para teste e 15 % para validação.
- c) 60 % dos dados para treinamento, 20 % para teste e 20 % para validação.

Para execução da modelagem e simulação o modelo de rede neural escolhido foi o de tipo MLP com algoritmo de aprendizagem Levenberg-Marquardt, uma adaptação do algoritmo backpropagation. Alguns aspectos permaneceram fixos a exemplo da taxa de aprendizagem fixa em 0,05 e a função de ativação da saída como Purelin. No entanto, alguns parâmetros da rede foram modificados com o intuito de se encontrar um modelo com o resultado mais satisfatório possível. Assim apresentadas:

- I. Número de neurônios da camada oculta: foram variadas nas quantidades de 5, 10 e 15 neurônios;
- II. Tipo de função de ativação: foram avaliadas o uso das funções Logsig e Tansig.

Desta maneira, os modelos das redes neurais foram estruturados em 13 parâmetros de entrada, uma camada oculta e 13 camadas de saída (Figura 1), que representam a simulação de todos os parâmetros utilizados no reator UASB.




Figura 1. Representação da arquitetura da rede com uma camada oculta

Durante o processo de treinamento, os pesos e as bias foram ajustadas de maneira iterativa, para minimizar a função de performance utilizada, o erro quadrático médio (MSE). É importante ressaltar que o software computacional MATLAB traz seu próprio algoritmo de aleatorização utilizado para construção dos modelos, evitando algum resultado tendencioso e aumentando a eficiência do modelo estatístico.

Para avaliação da eficiência das RNA's, valores reais de cada um dos parâmetros foram comparados com os valores preditos pelo modelo de RNA.

RESULTADOS

Na tabela 1 pode-se observar a influência do número de neurônios na camada oculta sobre o coeficiente de determinação, mantendo-se constante a subdivisão do conjunto de dados experimentais. Nos três casos estudados, é possível constatar que à medida que se aumenta o número de neurônios, também se eleva o coeficiente de determinação. Caso que reafirma o trabalho de Gonçalves et al. (2013) que constatou em seu estudo que com o aumento do número de neurônio o coeficiente de determinação aumentava também.

Tabela 1- Coeficiente de determinação em função da subdivisão do conjunto de dados e do número de neurônios da camada oculta.

Divisão dos dados experimentais	Coeficiente de determinação (R^2)		
	NN = 5	NN = 10	NN = 15
80.10.10	0,9677	0,9821	0,9985
70.15.15	0,9768	0,9522	0,9808
60.20.20	0,9718	0,9316	0,9754

Os coeficientes de treinamento, teste, validação e total para a melhor combinação encontrada pode ser observado na figura 2.

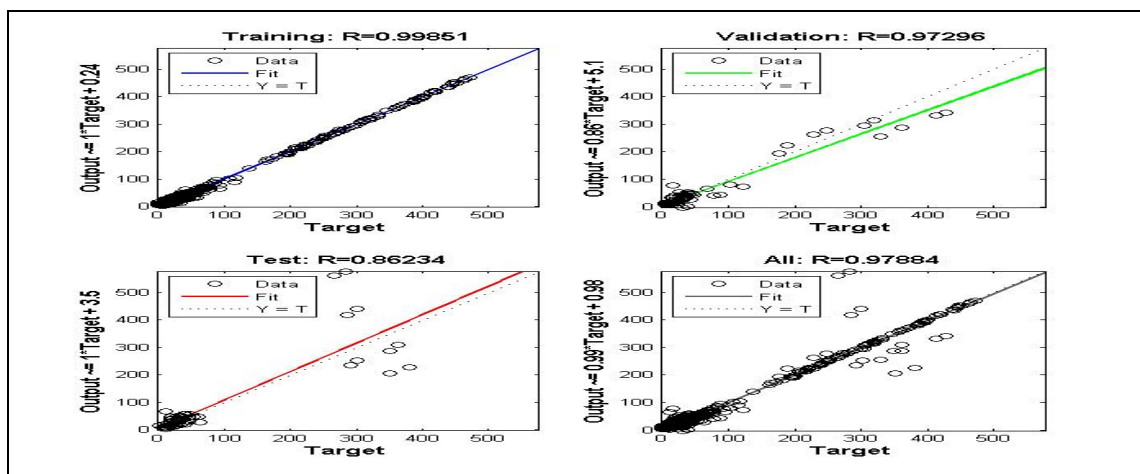


Figura 2. Arquitetura Neural com uma camada oculta, com 15 neurônios, função de ativação na camada oculta Logsig e combinação 80% treinamento, 10 % teste e 10 % validação

No que diz respeito à simulação do reator UASB, nas figuras 3 e 4, pode ser observado comparação entre os dados experimentais e os resultados simulados, quando o conjunto de dados experimentais usados foi subdividido em 80% para treinamento, 10% para validação e 10% para teste. Observando-se estas figuras pode-se constatar que houve uma boa concordância entre os valores experimentais e os simulados pelo modelo de RNA, visto que o coeficiente de determinação médio para este caso foi igual a 0,9985. Ressalta-se que resultados semelhantes foram obtidos por Moraes (2011) e Svridevi (2014).




Figura 3- Representação gráfica de valores experimentais e simulados, usando o conjunto 80.10.10 para 30ª semana de operação.




Figura 4- Representação gráfica de valores experimentais e simulados, usando o conjunto 80.10.10 para 19ª semana de operação

Nas figuras 5 e 6 está representada a comparação entre os dados experimentais e os resultados simulados, quando o conjunto de dados experimentais usados foi subdividido em 70% para treinamento, 15% para validação e 15% para teste.

Da mesma forma que a situação apresentada anteriormente (80% - 10% - 10%), a concordância entre os dados experimentais e os preditos pelo modelo pode ser considerada satisfatória, tendo em vista que o coeficiente de determinação para esse caso foi igual a 0,9808. Estes resultados concordam com os obtidos por Nasr (2012).




Figura 5- Representação gráfica de valores experimentais e simulados, usando o conjunto 70.15.15 para 7ª semana de operação.




Figura 6- Representação gráfica de valores experimentais e simulados, usando o conjunto 70.15.15 para 10ª semana de operação.

CONCLUSÕES

Dessa forma, concluiu-se que quando se utiliza uma única camada intermediária:

1. A melhor função de ativação foi a Logsig;
2. A melhor distribuição de dados apresentou-se quando foi combinado 80% dos dados usados para treinamento, 10 % para teste e 10 % para validação.
3. Paralelamente, é possível concluir que quanto maior é o número de neurônio usado na camada oculta, melhores coeficientes de determinação são encontrados. Nesta circunstância, o R2 foi de 0,9985, valor considerado muito satisfatório para predição dos parâmetros analisados.
4. A RNA modelada foi considerada satisfatória, visto o alto valor do coeficiente de determinação encontrado e o ajuste dos parâmetros simulados coincidirem bem com os resultados experimentais.

REFERÊNCIAS BIBLIOGRÁFICAS

1. BAÇÃO, F. – Introdução ao Data Mining. Lisboa, ISEGI-UNL, 2006.
2. BRAGA, A. de P.; CARVALHO, A. C. P. de Leon Ferreira de; LUDERMIR, T. B. Redes neurais artificiais: teoria e aplicações. 2. ed. Rio de Janeiro: LTC, 2007.
3. BRASIL. Ministério do Meio Ambiente, Conselho Nacional do Meio Ambiente – CONAMA. Resolução 357/2005. Brasília: 2005. 23p. Disponível em:
4. <http://www.mma.gov.br/port/conama/res/res05/res35705.pdf>. Acessado em 05/05/2015.
5. CAMPOS, J.R.; Tratamento de esgotos sanitários por processo anaeróbio e disposição controlada no solo. Rio de Janeiro: ABES, 464 p. 1999
6. FERNANDES, C. - "Esgotos Sanitários", Editora Universitária da UFPB, João Pessoa, Paraíba, 2000
7. GONÇALVES, D.N.S; LOPES, L.A.S; SILVA, M.A.V; Uso da técnica de redes neurais artificiais como modelo de distribuição de viagens – o caso do açúcar para a exportação – XVIII Congresso de Pesquisa e ensino em Transportes, Curitiba-2013.
8. HAMED, M.M, Khalafallah, G.M, Prediction of wastewater treatment plant performance using artificial neural networks; Elsevier, 2003.
9. HAYKIN, S., “Redes neurais: princípios e prática”, 2º Ed., Porto Alegre: BOOKMAN, 2001.
10. LJUNG, L. System Identification in a MIC perspective. Modeling, Identification and Control, v.15, n.3, p. 153-159. 1994
11. MORAIS, J.T.G., Modelagem de um sistema de membranas de microfiltração para água produzida de petróleo. Dissertação (Mestrado em Programa de Engenharia Industrial (PEI)) - Universidade Federal da Bahia, 2011
12. NASR, M. S., Moustafa M.A.E., Seif, H.A.E., Kobrosy, G. E. Modelling and simulation of German IOGEST/ELAGAMY wastewater treatment plants – Egypt using GPS-X simulator, Elsevier, 2012.
13. OLIVEIRA-ESQUERRE, K.P. ; Mori, M. ; Bruns, R.E. . Simulation of an industrial wastewater treatment plant using artificial neural networks and principal components analysis. Brazilian Journal of Chemical Engineering (Impresso) , v. 19, p. 365, 2004
14. SOUSA, J.T. de. Pós-tratamento de efluente de reator anaeróbio de fluxo ascendente em reator aeróbio seqüencial em batelada e coluna de lodo anaeróbio para desnitrificação. São Carlos: USP, 1996, 256p. Tese Doutorado
15. SRIDEVI, K., Sivaraman, E. , Mulla, P., Back propagation neural network modelling of biodegradation and fermentative biohydrogen production using distillery wastewater in a hybrid upflow anaerobic sludge blanket reactor. Elsevier, 2014
16. VEMURI, V.R. Artificial neural networks – forecasting time series. Los Alamitos, IEEE computer society Press, 1994.