

## II-125 - COMPARANDO UMA REDE NEURAL ARTIFICIAL (RNA) SUPERVISIONADA COM OS MÉTODOS TEÓRICOS (UNFCCC, CENBIO E DQO REMOVIDA) E MEDIÇÕES IN LOCO NA PREVISÃO DA PRODUÇÃO DE METANO E BIOGÁS

**Fabiano Sutter de Oliveira (M.Sc.)<sup>(1)</sup>**

Químico Industrial pela Universidade do Grande Rio e Mestre em Processos Bioquímicos pela Universidade Federal do Rio de Janeiro, Centro de Tecnologia - Escola de Química - Bloco E, Rio de Janeiro – Brasil

**Estevão Freire (D.Sc.)**

Engenheiro Químico e Doutor pelo Programa de Engenharia de Minas, Metalúrgica e de Materiais pela Universidade Federal do Rio Grande do Sul. Atualmente Professor da Escola de Química da Universidade Federal do Rio de Janeiro, Rio de Janeiro – Brasil

**Giovane Quadrelli (D.Sc.)**

Engenheiro Elétrico pela Universidade Católica de Petrópolis, pós-graduação em Informática Aplicada a Educação pela Universidade Católica de Petrópolis, mestrado em Engenharia Elétrica pela Pontifícia Universidade Católica do Rio de Janeiro e doutorado em Engenharia Elétrica pela Pontifícia Universidade Católica do Rio de Janeiro - Brasil

**Maria José de O. Cavalcanti Guimaraes (D.Sc.)**

Química e Doutora em Ciência e Tecnologia de Polímeros pela Universidade Federal do Rio de Janeiro. Atualmente Professor da Escola de Química da Universidade Federal do Rio de Janeiro, Rio de Janeiro – Brasil

**Endereço<sup>(1)</sup>:** Rua Dr. Sá Earp, 84 – Morin – Petrópolis – RJ – Cep: 25624-073 – e-mail: [fabianosutter@gmail.com](mailto:fabianosutter@gmail.com).

### RESUMO

Em uma estação de tratamento de esgoto, diversos processos inter-relacionados buscam realizar eficientemente o tratamento do esgoto, cumprindo normas e exigências legais dos órgãos ambientais fiscalizadores e evitando assim o seu lançamento indiscriminado, sem tratamento prévio. Gerada na etapa anaeróbia do tratamento, a taxa de produção do biogás é um importante indicador de desempenho e de certa forma está relacionada à eficiência do tratamento. A variação de sua produção pode determinar a causa de muitas perturbações do processo. Além disso, o metano, principal constituinte do biogás, tem importante valor econômico, podendo ser utilizado como combustível para motores de combustão interna ou turbinas a gás, ser convertido em energia elétrica, entre outros empregos. As condições econômicas de sua utilização indicarão a viabilidade de seu aproveitamento (JORDÃO, 2014). Muitas vezes, os métodos clássicos de estimativa de metano e biogás são amplamente utilizados para balizar esses investimentos do seu aproveitamento em projetos de conversão de biogás em energia elétrica e cogeração e também rotineiramente em ações operacionais. Porém essas metodologias podem supor cenários incorretos, pois os métodos reportados na literatura tipicamente superestimam as taxas de produção de biogás. Em sua maioria, os métodos estão baseados em cálculos estequiométricos ou de experimentos em laboratórios e não refletem a realidade operacional (SILVA, 2015). Além disso, essas metodologias não consideram algumas variáveis críticas do processo, como, por exemplo, a taxa de metano dissolvido que sai no efluente tratado ou a influência das chuvas na sua produção. O presente trabalho tem como objetivo empregar uma rede neural de aprendizagem do tipo supervisionada para estimar a produção de metano e biogás e compará-la com as metodologias clássicas (UNFCCC, CENBIO, DQO removida) e medições *in loco*. Isso deve-se principalmente porque a rede neural tornou-se uma ferramenta robusta, capaz de lidar com dados apresentando muitas oscilações e perturbações periódicas (MARANGONI, 2010).

**PALAVRAS-CHAVE:** Inteligência Artificial, Redes neurais artificiais, Biogás, Metano.

## INTRODUÇÃO

Os primeiros trabalhos utilizando redes neurais surgiram na década de 50 e desde o início dos anos 90 vêm sendo fortemente estudadas. A primeira publicação relacionada à neuro-computação foi elaborada por McCulloch e Pitts, em 1943, onde elaborou-se o primeiro modelo matemático que teve inspiração no neurônio biológico. Esses modelos por serem inspirados em neurônios biológicos, tentam retratar a geração e propagação de impulsos elétricos de uma membrana celular dos neurônios (SPATTI, 2010). Apesar de todo o avanço, ainda resta um longo caminho a ser percorrido, pois as aplicações e ferramentas a serem desenvolvidas são as mais variadas possíveis que vão desde a avaliação de imagens captadas por satélite até a previsão da precificação de ações na bolsa de valores, por exemplo.

As redes neurais são estudadas por uma área chamada de sistemas inteligentes. Nesta área podem ainda ser encontradas outros sistemas, tais como, sistema *fuzzy*, computação evolutiva, agentes inteligentes, entre outros. O seu emprego está baseado na possibilidade de trabalhar dados não lineares, com perturbações periódicas e muitas oscilações, partindo de informações obtidas externamente, e obter modelos que são capazes de prever uma determinada resposta. Além disso, possuem a característica de ser um sistema tolerante à falhas, ter a capacidade de aprendizado (método de treinamento) e de agrupar informações que tem particularidades em comum (clusterização). Entre as várias áreas aplicadas destacam-se o seu uso no controle de processos, reconhecimento de padrões, sistemas de previsão, otimização de sistemas e memórias associativas.

## REDE NEURAL

Um neurônio recebe dados que são advindos do meio externo e são introduzidos no sistema através de uma representação matricial. Esses dados são transformados em pesos sinápticos ( $w_i$ ), equivalentes aos impulsos elétricos que são captados pelos dendritos em um neurônio biológico.

O produto entre as entradas e os seus respectivos pesos sinápticos torna-se possível a saída do corpo celular artificial ( $u$ ), ou seja, a soma ponderada de todas as entradas dos neurônios existentes. Essa soma ponderada é subtraída pelo chamado limiar de ativação ( $\theta$ ). Se  $u \geq \theta$ , produzirá um potencial excitatório. De contrário, o potencial será inibitório. Para obter a saída  $y$ , emprega-se a chamada função de ativação  $g(u)$  que transformará a saída do neurônio. A Figura 1 ilustra a estrutura de uma rede neural artificial:

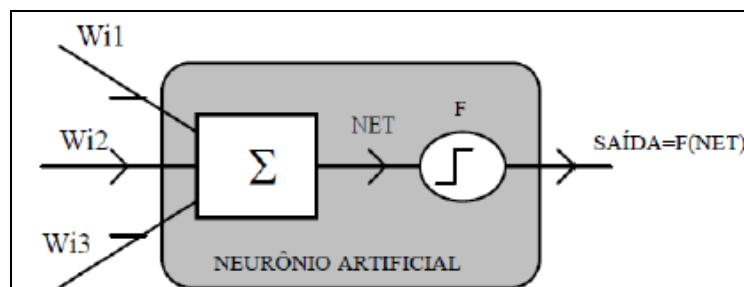


Figura 1: Estrutura de Rede Neural Artificial.

Fonte: MARANGONI, 2010.


Então, o resultado produzido pelo modelo de McCulloch e Pitts pode ser apresentado conforme as Equações 1 e 2 abaixo:

$$u = \sum_{i=1}^n w_i \cdot x_i - \theta \quad (1)$$

$$y = g(u) \quad (2)$$

As funções de ativação podem ser divididas em dois grupos: funções parcialmente diferenciáveis e funções totalmente diferenciáveis (SPATTI, 2010).

A estrutura de uma rede neural pode ser classificada ainda conforme o seu número de camadas, ou seja, da chamada arquitetura. Sendo assim, podem ser categorizados em camada única ou multicamadas com propagação para a frente (*feedforward*), sem a retroalimentação de sinais, sendo que neste caso, todos os neurônios de uma camada anterior estão conectados com os neurônios de uma cada posterior (rede totalmente conectada), que é a utilizada neste trabalho. Uma outra categoria chamada de recorrente, quando são constituídas com ou sem camadas escondidas em que há retroalimentação dos sinais dos próprios neurônios geradores dos sinais ou somente para os demais. A Figura 2 mostra um exemplo de rede com múltiplas camadas *Feedforward* totalmente conectada:



**Figura 2: Rede Múltipla Camada. Fonte: ROQUE, 2009.**

Resumidamente, a rede neural artificial pode ser explicada como sendo um sistema de neurônios ligados por conexões sinápticas e divididos em neurônios de entrada, estes recebem um estímulo do meio externo, existem ainda os neurônios ocultos (*hidden*), e os neurônios de saída, que são os que se comunicam com o meio externo (MARANGONI, 2010).

Conforme o aprendizado (aprimoramento dos pesos sinápticos visando melhorar o desempenho da Rede Neural, reduzindo a função custo), as redes se dividem em supervisionadas, aprendizado por reforço e não supervisionadas. Neste trabalho será utilizado o aprendizado supervisionado, onde toda entrada corresponderá a uma saída desejada no treinamento. Já na segunda categoria, o sistema aprende mediante a iteração contínua com o ambiente até que o seu desempenho seja aceitável pelo operador. Na terceira, existe o aprendizado através de regras competitivas entre os neurônios na codificação das entradas (GAMBOGI, 2013).

Destacam-se três conceitos fundamentais no processo de aprendizagem (MARANGONI, 2010):

- Algoritmo de treinamento: conjunto de procedimentos que são empregados para ajustar os parâmetros das redes;
- Número de épocas: trata-se do número de vezes que os padrões de treinamento serão apresentados às redes, em outras palavras, trata-se da atualização dos pesos e na busca do erro aceitável;
- Taxa de aprendizado: essa taxa controla a intensidade das alterações dos pesos. Uma alta taxa acelera o processo, mas isso pode implicar na perda da capacidade de generalização da rede neural.

No final da década de 40, surgiu a primeira metodologia de treinamento denominada de regra de aprendizagem de Hebb. Para o correto desempenho da rede neural é necessário escolher corretamente a arquitetura de rede que mais se adequa aos dados de entrada e objetivos a serem alcançados. Após a escolha ideal da arquitetura, ainda é necessário definir o número de conexões entre os neurônios.

## O EMPREGO DAS REDES NEURAIS ARTIFICIAIS EM PROCESSOS BIOQUÍMICOS

A construção de modelos matemáticos para processos de tratamentos biológicos apresenta várias dificuldades no que diz respeito à complexa abordagem cinética e ao seu comportamento não linear. Apesar disso, a

literatura apresenta diversos modelos matemáticos de sistemas de tratamento anaeróbio. Tais modelos apresentam natureza específica e muitas vezes possuem baixa aplicabilidade em plantas reais.

As vias metabólicas são tão variadas quanto ao número de microrganismos envolvidos, tornando o conhecimento em detalhes destes processos muito complexo (BRITO, 2006). A atividade enzimática das bactérias produz, entre outros produtos, o biogás, composto basicamente por metano. Trata-se de uma mistura gasosa comburente de grande importância energética. Porém, muitos fatores podem interferir na sua formação e assim, quanto maior a quantidade de impurezas ou ineficiência de tratamento, menor será a produção ou o biogás produzido terá baixo poder calorífico. Em contrapartida, quanto maior o controle nas variáveis críticas do processo, maiores as chances de obter eficiência no tratamento e um biogás de elevado valor energético. No Brasil, a tecnologia do digestor anaeróbio de fluxo ascendente (DAFA), conhecida pela sigla em inglês *Upflow anaerobic sludge blanket - UASB*, é a mais utilizada e difundida no tratamento dos esgotos sanitários. Porém, muitos fatores podem alterar o meio reacional e com isso refletir na qualidade do efluente final. Temperaturas baixas, pH, toxicidade, elevadas flutuações de carga hidráulica e carga orgânica entre outros fatores são fatores geradores de diversos problemas operacionais. Modelos que predizem certas variáveis dos processos envolvidos no tratamento são importantes, pois possibilitam ao operador praticar uma ação corretiva.

As redes neurais tem sido bastante empregadas para a previsão de modelos e sistemas de controle. O uso de ferramentas mais inteligentes para auxiliar a tomada de decisão em processos bioquímicos, exemplo das rotas da digestão anaeróbia, estão cada vez mais sendo utilizados em plantas de tratamento de água e esgoto. As redes neurais artificiais já foram aplicadas em sistemas de controle para o tratamento de água, onde podem ser encontrados processos físico e químicos não-lineares e que são de difíceis compreensão através de sistemas convencionais (SPATTI, 2010).

Várias metodologias dentro do campo da Inteligência Artificial vêm sendo empregadas no diagnóstico operacional de plantas de tratamento de águas residuárias. Modelos *fuzzy* foram desenvolvidos para fornecer diagnósticos de uma planta de tratamento anaeróbio de uma fábrica de placas de fibra. Outros modelos, também do tipo *fuzzy*, foram aplicados em modelagens de reatores anaeróbios de leito fixo e fluxo ascendente para o tratamento de efluentes de uma vinícola (BORGES, 2005).

A produção e emissão de metano como gás do efeito estufa de fontes naturais e antropogênicas tem sido amplamente estudadas. Segundo o IPCC, a concentração de metano aumentou em 1060 ppb (partes por bilhão) desde 1750. Esse número representa um aumento de 151 % do total de emissões de metano no mundo. Mais da metade de origem antropogênica. A produção de metano gerado no tratamento de esgotos sob condições anaeróbias varia entre 30 e 40 Tg<sup>1</sup>/ano, representando de 8 a 11% do total global de emissões antropogênicas de metano, estimado em 360 Tg/ano (LINS, 2010).

## OBJETIVO

O presente artigo tem como objetivo a comparação de saídas de uma rede neural com as demais metodologias clássicas de estimativa de biogás e metano citadas na literatura. O uso de redes neurais artificiais, bem como de outras ferramentas mais inteligentes, tem como objetivo fornecer subsídios para a resolução de problemas com alto grau de incertezas, combinando a imprecisão das variáveis empregadas e a busca por sistemas mais robustos com respostas mais inteligentes e utilizando o poder computacional das máquinas (JANÉ, 2004).

## METODOLOGIA

Através de amostragens realizadas em uma planta operacional de tratamento de esgoto foram coletados dados de Demanda Química de Oxigênio (entrada e saída), RNFT (entrada e saída), temperatura do reator, vazão operacional da unidade e volume de biogás produzido. As determinações analíticas seguiram procedimentos descritos no *Standard Methods of Water and Wastewater*, 22<sup>a</sup> ed. (Washington, APHA/AWWA/WEF, 2012).

---

<sup>1</sup> 1 Tg = 1 teragrama = 10<sup>12</sup> g

Após tratamento estatístico do grupo de dados, utilizando o desvio padrão e coeficiente de variação, foram escolhidos parâmetros com maior influência na produção de biogás. Esses grupos de dados foram modelados no *toolbox Neural Network* do Matlab® e de posse de suas saídas (*outputs*), esses resultados foram comparados com os resultados das metodologias clássicas: UNFCCC, CENBIO e DQO removida.

Foram escolhida três metodologias:

1. A Convenção-Quadro das Nações Unidas sobre a mudança do clima (UNFCCC – *United Nations Framework Convention on Climate Change*) desenvolveu uma ferramenta que avalia a linha-base de emissão de dióxido de carbono para projetos de recuperação e utilização do metano, conforme preconizado pelo Mecanismo de Desenvolvimento Limpo. Essa metodologia considera o poder de aquecimento global (GWP) do metano. Considerando o metano de GWP igual a 21, cada tonelada deste gás tem o poder de aquecimento global equivalente a 21 toneladas de dióxido de carbono.
2. Já a metodologia CENBIO trata-se metodologia desenvolvida pelo Centro Nacional de Referência em Biomassa (CENBIO) que pertence ao Instituto de Eletrotécnica e Energia da Universidade de São Paulo (USP), referência nacional na pesquisa de produção de energia a partir da biomassa e baseia-se na determinação da Demanda Bioquímica de Oxigênio produzida por cada habitante produtor de carga orgânica;
3. E por último, o método de DQO removida foi desenvolvido por Chernicharo e utiliza a estequiometria dos reagentes do processo anaeróbio.

Para a rede neural utilizou-se inicialmente a seguinte parametrização: *script* gerado pelo *Neural Fitting app* – Matlab®; algoritmo de aprendizagem: *backpropagation* com variação através do algoritmo de Levenberg-Marquardt<sup>2</sup>; número de variáveis (*inputs*): 2 a 6 parâmetros; combinações matriciais de 3500:2, 3500:6, 5000:2 e 5000:6; cenários de 5 a 10 neurônios na camada escondida; processo de treinamento do tipo supervisionado; função Custo (para medida desempenho): erro quadrático médio ou “*mean squared error*”; divisão utilizada de 70% dos valores para treinamento, 15% para validação e 15% para testes.


## RESULTADOS ESPERADOS

Os resultados do referido estudo ainda encontram-se no estágio inicial, pois são parte integrante de uma tese de doutorado em andamento. Porém, mesmo em estágio inicial já indica que o uso de metodologias mais inteligentes, como redes neurais, torna-se indispensável para monitorar processos, exemplo da digestão anaeróbia, que possuem inúmeras variáveis e que sofrem forte influência de fatores externos.

A Figura 3 apresenta os valores inicialmente obtidos após o tratamento estatístico dos dados e a correlação com as saídas das redes neurais estudadas.

---

<sup>2</sup> Levenberg-Marquardt – é um método gradiente de segunda ordem, baseado no método dos mínimos quadrados para modelos não-lineares, podendo ser incorporado ao algoritmo *backpropagation*, potencializando assim a eficiência do processo de treinamento.



**Figura 3: Comparação das saídas da rede neural.**

**Fonte: Autor, 2016.**

## CONCLUSÕES E RECOMENDAÇÕES

Com base no trabalho realizado, até o momento, verificou-se que os resultados calculados de vazão de biogás, utilizando as metodologias clássicas, apresentaram-se bem acima dos valores reais. Tomando alguns parâmetros relevantes na produção de biogás, várias estruturas de redes neurais foram implementadas para correlacionar as suas saídas com os resultados das metodologias clássicas. Muitas metodologias superestimam a produção de biogás e devem ser utilizadas com cautela, como é o caso da metodologia DQO removida. Buscando avaliar a precisão das quatro metodologias empregadas, observou-se que todas apresentaram homogeneidade nos dados de saída ficando todos os resultados dentro dos limites aceitáveis. Importante destacar que a metodologia rede neural artificial foi a que apresentou menor variação em seus dados.

Até o momento, todos os valores apresentados para o desvio padrão das redes neurais ficaram abaixo de 1, demonstrando baixa ou quase nenhuma variabilidade em relação à sua média. Quando utilizado o mesmo critério de análise para as metodologias clássicas, observou-se este resultado apenas para o grupo de saídas referente à metodologia UNFCCC.

Esse estudo faz parte de uma tese de doutorado e encontra-se em seu estágio inicial e outros cenários e ajustes nas redes neurais serão estudados.

## REFERÊNCIAS BIBLIOGRÁFICAS

1. BORGES, R. M. Desenvolvimento e aplicação de um sistema de diagnóstico *fuzzy* baseado em modelos para reatores UASB tratando esgoto sanitário. Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro Tecnológico. Universidade Federal do Espírito Santo, 2005.
2. BRITO, M. F. Determinação das frações orgânicas de efluentes de reatores de UASB. Dissertação apresentada à Escola Politécnica da Universidade de São Paulo, 2006.
3. GAMBOGI, J. A. Aplicação de redes neurais na tomada de decisão no mercado de ações. Dissertação apresentada ao Departamento de Engenharia de Telecomunicações e Controle. Universidade de São Paulo, 2013.
4. JANÉ, D. A. Uma introdução ao estudo da lógica *Fuzzy*. Revista da Humanidade e Ciências Sociais Aplicadas, Num. 02, Ourinhos, São Paulo, 2004.
5. LINS, G. A. Impactos ambientais em estações de tratamentos de esgotos (ETEs). Dissertação de Mestrado Profissional. Programa de Pós Graduação em Engenharia Ambiental. Universidade Federal do Rio de Janeiro, 2010.
6. MARANGONI, P. H. Redes neurais artificiais para previsão de séries temporais no mercado acionário. Monografia apresentada ao Curso de Graduação em Ciências Econômicas. Universidade Federal de Santa Catarina, 2010.





7. ROQUE, R. C. Estudo sobre a empregabilidade da previsão do índice BOVESPA usando redes neurais artificiais. Departamento de Eletrônica e de Computação. Escola Politécnica da Universidade Federal do Rio de Janeiro, 2009.
8. SPATTI, D. H.; SILVA, I. N.; FLAUZINO, R. A. Redes Neurais Artificiais para Engenharia e Ciências Aplicadas. Curso Prático. Editora Artliber, 2010.