

I-023 - ESTIMATIVA DE PARÂMETROS FÍSICO-QUÍMICOS DA ÁGUA UTILIZANDO A TÉCNICA DE REDES NEURAS ARTIFICIAIS COMO SENSOR VIRTUAL

José Rafael de Albuquerque Cavalcanti⁽¹⁾

Engenheiro Ambiental e Sanitarista pela Universidade Federal de Alagoas. Mestrando em Recursos Hídricos e Saneamento Ambiental pelo Instituto de Pesquisas Hidráulicas – Universidade Federal do Rio Grande do Sul.

Filipe Alves Coelho⁽²⁾

Graduando em Engenharia Química pela Universidade Federal de Alagoas.

Frede de Oliveira Carvalho⁽²⁾

Engenheiro Químico pela Universidade Federal de Pernambuco. Mestre em Engenharia Química pela Universidade Estadual de Campinas. Doutor em Engenharia Química pela Universidade Federal de Campinas. Professor Adjunto da Universidade Federal de Alagoas.

Ivete Vasconcelos Lopes Ferreira⁽²⁾

Engenheira Civil pela Universidade Federal da Paraíba. Mestre em Engenharia Civil pela Universidade Federal da Paraíba. Doutora em Hidráulica e Saneamento pela Universidade de São Paulo. Professora Adjunta da Universidade Federal de Alagoas.

Endereço⁽¹⁾: Av. Bento Gonçalves, 9500 - CEP 91501-970. Caixa Postal 15029 - Porto Alegre - RS – Brasil. E-mail: rafaelcavalcanti@gmail.com.

Endereço⁽²⁾: Campus A. C. Simões, av. Lourival Melo Mota, s/n, CEP: 57072-900. Cidade Universitária – Maceió – AL – Brasil. E-mail: filipec@hotmail.com, fredecarvalho@yahoo.com.br, ivetelopes@uol.com.br.

RESUMO

Neste trabalho estudou-se a aplicabilidade da técnica de Redes Neurais Artificiais (RNA's) como sensores virtuais na estimativa de parâmetros de difícil obtenção laboratorial, como a DBO de um efluente a partir de dados coletados. Para o monitoramento da bacia hidrográfica do rio Reginaldo, localizada em Maceió/AL, Brasil, dados experimentais foram recolhidos, em sete campanhas diferentes entre os meses de fevereiro de 2007 e janeiro de 2008. Os resultados obtidos se mostraram promissores no que diz respeito à utilização das RNA's como sensor virtual para estimativa de parâmetros de difícil obtenção. Nesta investigação, foram estimados os parâmetros DBO e fósforo total, por serem, respectivamente, indicador da presença de carga orgânica e indicador primário de eutrofização. Apesar dos poucos dados, na estimativa do parâmetro DBO um coeficiente de regressão de 0.830 foi encontrado, para o parâmetro fósforo total um coeficiente de regressão de 0.978 foi encontrado, demonstrando assim, a eficiência da técnica de RNA's na obtenção desses parâmetros.

PALAVRAS-CHAVE: Redes Neurais Artificiais, Qualidade da Água.

INTRODUÇÃO

A água é uma das substâncias necessárias para manter a vida e há muito se suspeita de ser a fonte de muitas doenças humanas. Não era assim há 150 anos, quando foi estabelecida uma prova definitiva da transmissão de doenças pela água. Por muitos anos seguintes, a maior preocupação era produzir um abastecimento adequado que fosse higienicamente seguro. Entretanto, fontes de água (superficiais e subterrâneas) têm se tornado contaminadas devido ao aumento da atividade industrial e agrícola. O público tem sido mais exigente nessa demanda com o passar dos tempos, e engenheiros têm a responsabilidade de produzir água que seja livre de cor, turbidez, sabor, odor, nitrato, íons de metais pesados, e uma grande variedade de organismos químicos como pesticidas e solventes a base de cloro. Problemas de saúde associados com alguns desses parâmetros incluem câncer, defeitos congênitos, desordem no sistema nervoso central e doenças no coração (Sawyer et al. (2003)).



No Brasil aproximadamente 85% dos 180 milhões de brasileiros vivem em cidades, mas menos de 5% das águas residuárias urbanas são apropriadamente coletadas e tratadas antes de atingir águas continentais ou costeiras (Costa et al. (2008)).

A qualidade da água é resultante de fenômenos naturais e da atuação do homem. De maneira geral, pode-se dizer que a qualidade de uma determinada água é função das condições naturais e do uso e da ocupação do solo na bacia hidrográfica. O estudo da qualidade da água é fundamental, tanto para se caracterizar as consequências de uma determinada atividade poluidora, quanto para se estabelecer os meios que se satisfaça determinado uso da água (Von Sperling (2005)).

Durante as últimas décadas, tem havido uma demanda crescente para monitorar a qualidade da água de vários rios por meio de medições regulares de vários parâmetros de qualidade da água. Os resultados são o acúmulo gradual de dados confiáveis de qualidade da água (Antonopoulos e Papamichail (1991); Antonopoulos et al. (2001)), apesar de que a determinação de alguns desses parâmetros exigem uma grande demanda econômica e de tempo.

Diamantopoulou et al. (2005) utilizaram modelos baseados em RNA's do tipo multilayer perceptron feedforward, como sensores virtuais, e demonstraram possuir a habilidade apropriada para a predição de parâmetros de qualidade da água. Isto mostra uma ferramenta muito útil para preenchimento de valores falhos, que é um problema sério na maioria das estações de monitoramento do mundo.

Apesar da existência de vários tipos de RNA's, tais como MLP (Multilayer Perceptron) feedforward, RBF (Radial Basis Function), GDMH (Group Method of Data Handling), a rede MLP tem sido muito aplicada por razão de estar facilmente disponível e ser facilmente implementada através de softwares comerciais tais como: MATLAB®, STATISTICA® e NEUROSOLUTIONS®.

Os parâmetros utilizados neste trabalho para inferência através de sensores virtuais têm sua importância para o monitoramento da qualidade da água, pois a DBO tem relação com a quantidade de matéria orgânica presente no corpo d'água e o fósforo total é um indicador primário de eutrofização.

Deve-se ressaltar que o teste de DBO é de baixa reprodutibilidade de resultados e longo tempo de resposta, (Sawyer et al. (2003); Von Sperling (2005)). Sua obtenção por meio de outros parâmetros seria importante ao passo que diminui a necessidade da realização do experimento no laboratório, auxiliando o preenchimento de possíveis falhas nas análises.

OBJETIVO DO TRABALHO

O trabalho teve como objetivo o monitoramento da qualidade da água da bacia hidrográfica do Rio Reginaldo, e também, o estudo da aplicabilidade da técnica de Redes Neuras Artificiais como sensores virtuais na estimativa de parâmetros de baixa reprodutibilidade de resultados e longo tempo de resposta em laboratório (DBO e fósforo total). A proposta para o sensor virtual foi a obtenção de teores de DBO e fósforo total em função de temperatura, pH, turbidez, cor aparente, oxigênio dissolvido, cloretos, N – amoniacal, sólidos suspensos e DQO.

MATERIAL E MÉTODOS

A DBO é definida como a quantidade de oxigênio necessária para oxidar a matéria orgânica biodegradável sob condições aeróbicas. Portanto, indica a quantidade de oxigênio dissolvido, em mg/L, que será consumida pelos organismos aeróbios ao degradarem a matéria orgânica. O teste padrão é realizado num período de tempo de 5 dias e temperatura de incubação de 20°C (DBO_{5,20°C}). Os maiores aumentos em termos de DBO, num corpo d'água, são provocados por despejos de origem orgânica. Elevadas concentrações de carga orgânica podem levar à completa extinção do oxigênio dissolvido no corpo hídrico, provocando o desaparecimento de peixes e outras formas de vida aquática. Um elevado valor da DBO pode indicar um incremento da microflora presente e interferir no equilíbrio da vida aquática, além de produzir sabor e odor desagradáveis e, ainda, pode obstruir os filtros de areia utilizados nas estações de tratamento de água (Senna Jr. (2005)).

O fósforo na água apresenta-se principalmente nas formas de ortofosfato, polifosfato e fósforo orgânico. Os ortofosfatos são diretamente disponíveis para o metabolismo biológico sem necessidade de conversões a formas mais simples. O fósforo não apresenta problemas de ordem sanitária nas águas de abastecimento, porém, é um elemento indispensável para o crescimento de algas e, quando em elevadas concentrações em lagos e represas, pode conduzir a um crescimento exagerado desses organismos (eutrofização). Além disso, o fósforo é um nutriente essencial para o crescimento dos microorganismos responsáveis pela estabilização da matéria orgânica (Von Sperling (2005)).

Redes Neurais Artificiais (RNA's)

As redes neurais artificiais são modelos que vêm sendo desenvolvidos nos últimos anos, e que, de uma maneira geral, procuram imitar o funcionamento do cérebro humano (Valença (2005)).

Ainda segundo Valença (2005), embora o conceito de neurônio artificial fosse introduzido primeiramente por McCulloch e Pitts em 1943, a pesquisa em aplicações de RNA's teve um grande avanço com o advento do algoritmo de treinamento conhecido como Backpropagation para as redes do tipo Feedforward. Logo, as RNA's podem ser consideradas uma ferramenta relativamente nova no campo da previsão e classificação.

Os modelos de RNA's manipulam informações pela interação de um grande número de unidades básicas de processamento. O sistema recebe sinais externos que são processados, produzindo saídas. As unidades básicas do sistema enviam sinais entre si, fazendo com que a informação seja distribuída por meio da rede. Essas unidades básicas são denominadas neurônios artificiais (Oliveira Jr. et al. (2007)).

Uma RNA consiste em um alto número de simples e altamente interconectados processadores, também chamados de neurônios artificiais, que são análogos aos neurônios biológicos no cérebro. Os neurônios são conectados por ligações ponderadas, passando sinais de um neurônio para o outro. Cada neurônio recebe um grande número de sinais de entrada pelas suas conexões; entretanto ele nunca produz mais do que um sinal de saída. O sinal de saída é transmitido pela conexão externa do neurônio (correspondendo ao axônio biológico). A conexão externa, por sua vez, se divide em vários ramos que transmitem o mesmo sinal (o sinal não é dividido entre os ramos de forma alguma). O ramo externo tem seu fim nas ligações que vem de outros neurônios na rede (Negnevitsky, (2005)).

Redes Perceptron Multicamadas (*Multilayer Perceptron* - MLP)

Uma rede MLP é uma RNA do tipo feedforward com uma ou mais camadas escondidas. Tipicamente, a rede consiste de uma camada de entrada vinda dos neurônios de entrada, ao menos uma camada intermediária ou escondida de neurônios computacionais (artificiais), e uma camada de saída de neurônios computacionais. Os sinais de entrada são propagados na direção progressiva num passo camada a camada (Negnevitsky, (2005)). Uma rede MLP com duas camadas escondidas é mostrada na figura 1.




Figura 1 - Configuração de uma rede MLP usual com duas camadas escondidas.

Na Figura 2 estão representados os principais elementos de uma “típica” RNA do tipo MLP feedforward onde x e y representam entrada e saída, respectivamente; w representa os pesos e $f(x)$, a função de ativação (logística) (Garcia et al. (2004)).

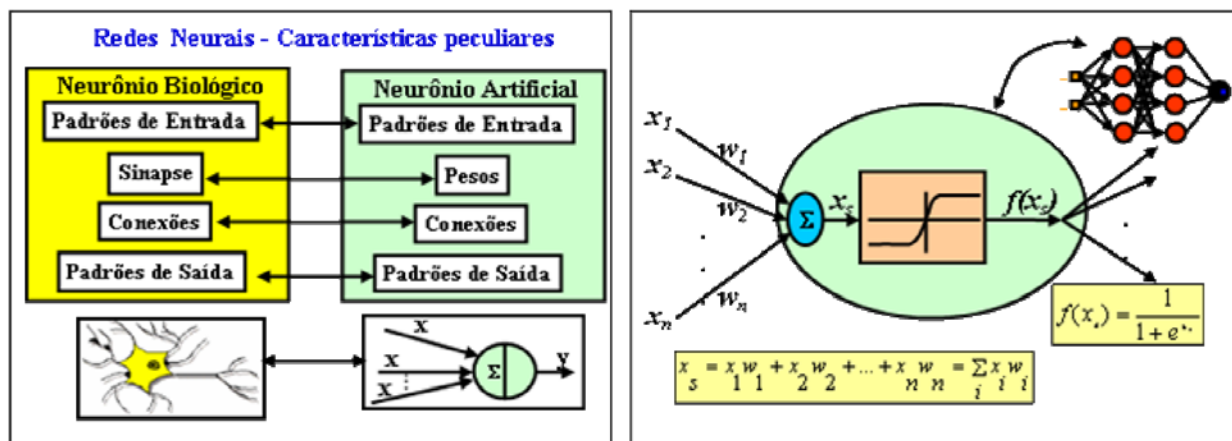


Figura 2 - Rede Neural *feedforward*.

A mais importante propriedade das redes MLP é a capacidade de aproximar qualquer função contínua arbitrária com uma única camada escondida e função de ativação logística (Garcia et al. (2004)).

Treinamento da RNA do tipo MLP

O treinamento ou aprendizado supervisionado de uma RNA visa à obtenção dos pesos das conexões que minimizam uma função erro dada pela diferença entre saída calculada pela rede e um valor de saída conhecido. Este processo de aprendizado ocorre através dos ajustes sucessivos dos pesos e, em alguns algoritmos, por meio dos resíduos de ativação, de forma a se obter dados de saída o mais próximo possível dos desejados (Oliveira Jr. et al. (2007); Carvalho et al. (2007)). Esta é a etapa que exige maior demanda computacional. Um dos algoritmos de treinamento mais utilizados é o backpropagation, apesar da literatura trazer vários outros (Carvalho et al. (2007)).

A Figura 3 ilustra a fase de treinamento de uma RNA onde x é o vetor de entrada de dados; y_d e y_c são os vetores de saída desejados e calculados, respectivamente; w é o vetor de pesos e n é o número da iteração (Carvalho et al. (2007)).

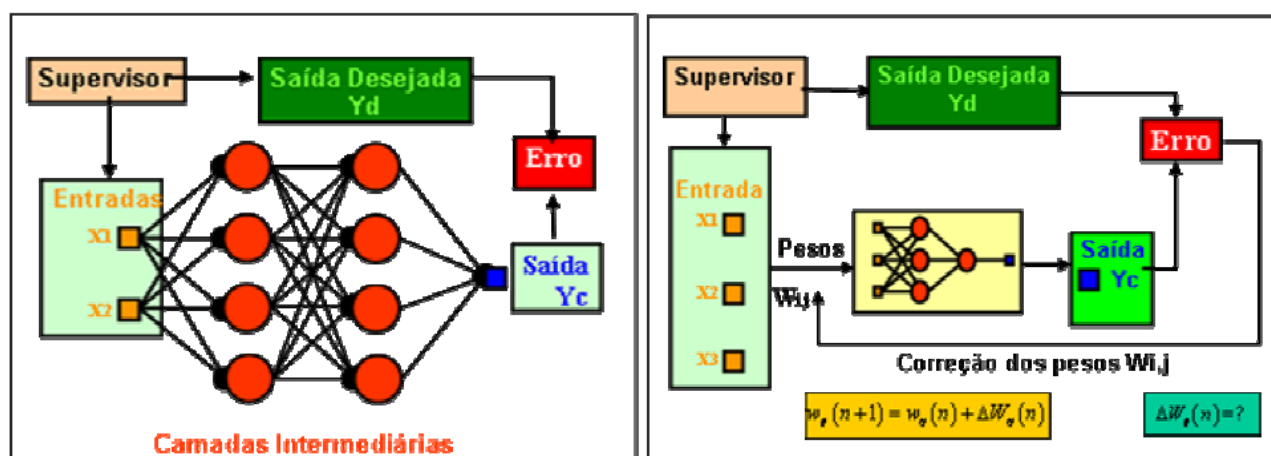


Figura 3. Fase de treinamento de uma RNA.

O ajuste dos pesos feito pelo algoritmo backpropagation é baseado na regra delta proposta por Widrow e Hoff utilizada para o treinamento de redes Adaline (Widrow e Hoff (1960)). A generalização desse algoritmo para redes de múltiplas camadas é conhecido como regra delta generalizada ou backpropagation (Braga et al. (2007)).

A maior parte dos algoritmos de treinamento é baseada nos métodos de gradientes descendentes e de Newton. As abordagens baseadas nos métodos de Newton apresentam, em geral, melhores resultados pelo fato de serem métodos de segunda ordem, apresentando uma convergência quadrática próxima ao mínimo. Um método simplificado para o treinamento de RNA é o algoritmo de Lavenberd-Marquart, desenvolvido para se obter uma rápida velocidade de treinamento onde é utilizada a Equação-1, para atualização do vetor de pesos e baias (Carvalho et al. (2007)).

$$w_{k+1} = w_k - [j^t j = \mu i]^{-1} j^t e$$

(1)

onde w_k é o vetor de pesos e baias na iteração k ; J é a matriz Jacobiana, a qual contem as primeiras derivadas dos erros obtidos pela rede em relação aos pesos e baias; e é o vetor de erros da rede; e μ é um escalar.

Área de estudo

A área de estudo para coleta de dados de qualidade de água foi a bacia do Rio Reginaldo, que drena a área urbana da cidade de Maceió e desemboca na Praia da Avenida, próxima à região portuária, como mostrado na figura 4. Sua área é de 12 km², encontra-se intensamente ocupada pelo uso urbano, restando nas áreas altas um mínimo de vegetação nativa. O vale do Rio Reginaldo é em grande parte habitado por população de baixa renda, que também ocupa as encostas do bairro do tabuleiro dos martins.

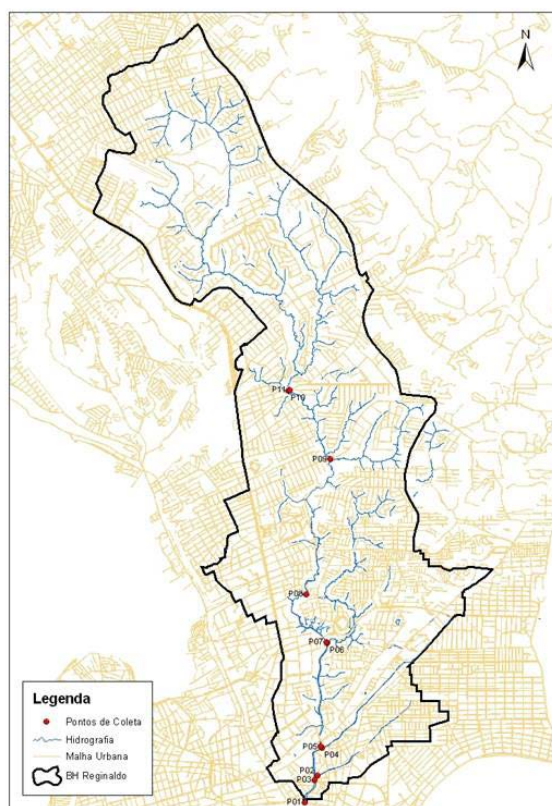


Figura 4 – Pontos de coleta utilizados ao longo do rio.

O Rio Reginaldo é um curso d'água perene embora sua vazão durante o período de estiagem seja, praticamente, resultante do despejo de esgotos domésticos. Os seus afluentes são pequenos, como os riachos do Sapo e o Gulandim na planície litorânea, onde o Rio Reginaldo passa a ser chamado de riacho Salgadinho. A região é carente de serviços de saneamento (abastecimento de água, esgotamento sanitário, resíduos sólidos e drenagem urbana), o que contribui para o alto grau de degradação da qualidade ambiental, sobretudo da qualidade das águas, situação típica de regiões de ocupação desordenada (Ferreira et al., 2008; Pimentel et al., 2008).

Período e pontos de amostragem

Foram efetuadas sete campanhas de amostragem no período de fevereiro de 2007 a janeiro de 2008. Para a caracterização das águas do rio Reginaldo, em cada campanha foram coletadas amostras em sete pontos, desde sua foz, até o bairro da Gruta. Além desses pontos foram incluídos mais três pontos de amostragem correspondentes aos afluentes conhecidos como Riacho Gulandim, Riacho do Sapo e Riacho Pau d'Arco. Também foi caracterizado um ponto de lançamento de esgotos que contribui com significativa vazão para o rio Reginaldo.

Na Tabela 1 estão indicados os pontos de coleta com respectivas descrições e georeferenciamentos.

Tabela 1 – Pontos de amostragem

Ponto de coleta	Descrição	Localização GPS	
		Latitude	Longitude
P1	Foz do Riacho Salgadinho	200339	8929954
P2	Riacho Gulandim	200515	8930334
P3	Ponte no Salgadinho próximo ao Gulandim	200492	8930272
P4	Riacho do Sapo	200589	8930746
P5	Salgadinho próximo ao Riacho do Sapo	200574	8930764
P6	Riacho Pau d'Arco. Contribui com vazão considerável para o Reginaldo, abaixo da ponte da rodoviária	200681	8932302
P7	Rio Reginaldo abaixo da ponte da rodoviária	200677	8932290
P8	Moenda	200370	8933006
P9	Rotary	200727	8934986
P10	Gruta - Esgoto com grande vazão de contribuição para o Rio Reginaldo	200165	8935982
P11	Gruta – Rio Reginaldo antes do lançamento do esgoto	200157	8935980

Parâmetros físico-químicos de qualidade de água

As análises para caracterização físico-química das águas do Rio Reginaldo e seus afluentes foram realizadas no Laboratório de Saneamento Ambiental – UFAL (LSA/UFAL) do Centro de Tecnologia da UFAL, conforme os procedimentos descritos no Standard Methods for the Examination of Water and Wastewater (APHA (1998)).

Na Tabela 2 estão indicados os métodos analíticos e equipamentos utilizados na caracterização físico-química das amostras coletadas.

Tabela 2 – Análises físico-químicas, métodos analíticos e equipamentos.

Parâmetro	Método analítico e equipamento utilizado
pH (-)	Potenciométrico – peagômetro com eletrodo combinado ANALION
Temperatura (°C)	Leitura direta – Sonda LUTRON – DO-5510
OD (mg O ₂ /L)	Sonda com membrana seletiva de oxigênio – LUTRON – DO-5510
Cor aparente (uC)	Espectrofotometria – $\lambda = 455 \text{ nm}$ – DR 2500 – HACH
Cor verdadeira (uC)	Espectrofotometria – $\lambda = 455 \text{ nm}$ – DR 2500 – HACH. Filtração em membrana com diâmetro de poro 0,45 μm
Turbidez (uT)	Nefelométrico – Turbidímetro PoliControl AP 2000
SST (mg/L)	Gravimétrico – Filtração em membrana de fibra de vidro com diâmetro de poro = 1,2 μm
SSF(mg/L)	Gravimétrico – Filtração em membrana de fibra de vidro com diâmetro de poro = 1,2 μm
SSV(mg/L)	Gravimétrico – Filtração em membrana de fibra de vidro com diâmetro de poro = 1,2 μm
SDT (mg/L)	Gravimétrico – Filtração em membrana de fibra de vidro com diâmetro de poro = 1,2 μm
Sólidos sedimentáveis (mL/L)	Método Volumétrico - Cone Imhoff
Cloretos (mg Cl ⁻ /L)	Método Argentométrico (Método de Mohr)
Nitrogênio amoniacal (mg NH ₄ ⁺ /L)	Destilação seguida de titulação volumétrica com ácido sulfúrico – Destilador de nitrogênio TECNAL TE-036/1
Nitrito (mg N-NO ₂ ⁻ /L)	Método Colorimétrico da Diazotização. $\lambda = 543 \text{ nm}$ – Espectrofotômetro QUIMIS Q-108U2M
Fósforo total (mg P/L)	Método Espectrofotométrico – Método do Ácido Ascórbico após digestão com persulfato - $\lambda = 880 \text{ nm}$ - Espectrofotômetro QUIMIS Q-108U2M
DQO (mg/L)	Colorimétrico - Espectrofotômetro QUIMIS Q-108U2M
DBO ₅ (mg/L)	Frascos padrões

Embora considerado um importante parâmetro para avaliação da qualidade de águas, não foram realizadas análises de nitrato por limitações do laboratório.

Não foi possível realizar algumas análises para todos os pontos de coleta, para a utilização na Rede Neural, apenas os parâmetros existentes em todos os pontos de coletas foram utilizados.

Os parâmetros escolhidos como entradas para o sensor virtual (dados de treinamento para RNA) foram: temperatura da água, pH, turbidez, cor aparente, oxigênio dissolvido, sólidos suspensos totais, nitrogênio amoniacal, cloretos e Demanda Química de Oxigênio (DQO). A rede neural artificial será construída com nove neurônios de entrada e um neurônio de saída por vez.

Todos os dados descritos foram agrupados como variáveis de entrada do sistema, conforme mostra a topologia da rede representada na figura 5, enquanto que os dados de DBO e fósforo total foram definidos como parâmetro de saída.

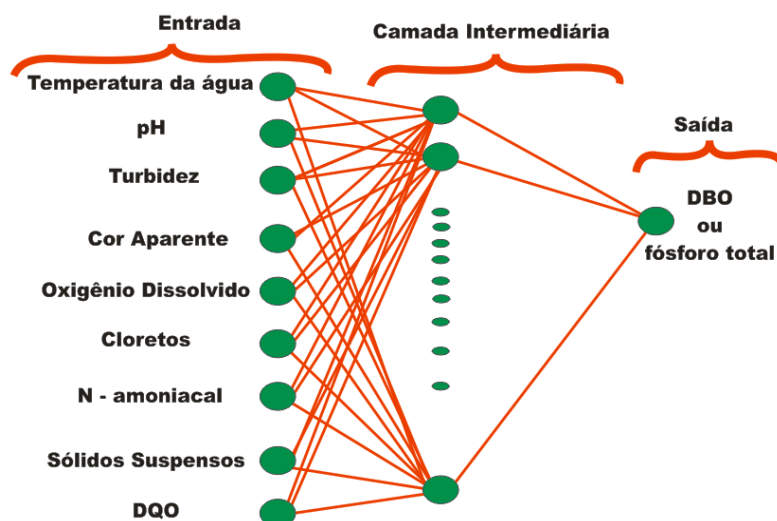


Figura 5 – Topologia da Rede Neural utilizada.

O software MATLAB® possui uma biblioteca específica para utilização das RNA's do tipo MLP que pode ser utilizada. Pela facilidade de obtenção e conhecimento da linguagem de programação pelos autores esta rede foi escolhida como forma de estimar os parâmetros.

RESULTADOS E DISCUSSÃO

Na tabela 3 se encontra um exemplo dos parâmetros físico-químicos para qualidade da água, encontrados pela análise da água em uma das campanhas realizadas. Deve-se salientar que houve falhas na obtenção dos parâmetros, causando dificuldades na utilização das redes.

Tabela 3 - Resultados das análises físico-químicas das amostras coletadas em 13.06.2007.

Parâmetros	Pontos de coleta									
	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10
Temperatura (°C)	29	28	28	28	29	28	28	28	28	29
OD (mg/L)	4,3	6,2	3,6	7,5	3,0	5,4	0,9	0,8	0,6	2,4
pH	7,29	7,51	7,18	7,45	7,20	7,50	7,17	7,29	7,63	7,30
Cor aparente (uC)	332	485	377	486	407	325	258	555	735	870
Turbidez (uT)	19	29	34	30	30	24	17	59	58	60
SST (mg/L)	152	70	57	8	54	28	12	30	58	88
SSF (mg/L)	60	47	45	5	44	16	7	13	37	47
SSV (mg/L)	92	23	12	3	10	12	5	17	21	41
SSed (mL/L)	0	1,2	0	1,1	0	0,6	0,3	1,0	1,1	1,5
DQO (mg/L)	790,1	174,2	>800	152,3	675,7	159,6	166,9	86,6	198,5	415,2
Cloretos (mg Cl-/L)	9568,7	169,3	8096,6	279,7	51,5	88,3	51,5	29,4	73,6	81,0
Amônia (mg NH4+/L)	7,73	11,59	9,66	18,35	8,69	17,39	5,80	3,86	31,88	22,22
Nitrito (mg N/L)	0	0	0	0	0	0	0,446	0,060	0	0
Fósforo Total (mg P/L)	0,792	1,458	1,075	1,640	1,236	1,317	0,570	0,550	3,860	3,133

Pelos dados obtidos nas análises de todas as coletas, foi possível verificar a baixa qualidade das águas do Rio Reginaldo. A ocupação desordenada do solo e a precariedade dos serviços de saneamento na região contribuem para a degradação ambiental da bacia hidrográfica. Conforme ilustrado na Figura 6, a descarga de esgotos sanitários (figura 6 (a)) e de lixo urbano no leito dos rios (figura 6 (b)) é comum na região.



Figura 6 (a)



Figura 6 (b)

Figura 6 – Lançamento de esgoto doméstico no Riacho Gulandim, afluente do Rio Reginaldo (a) e Lançamento de resíduos sólidos no leito do Rio Reginaldo (b).

Com os dados referentes às análises, foi possível treinar uma RNA do tipo MLP, cuja topologia utilizada para a RNA foi apresentada na figura 5. Sabe-se que o baixo número de pontos de coleta pode afetar a qualidade da estimativa da RNA.

No estudo realizado sobre a estimativa do parâmetro de DBO (Figura 7), os dados apresentados a RNA possibilitaram um ajuste com coeficiente de regressão igual a 0,83. Embora estes resultados não sejam significativos mediante a quantidade de dados utilizados. Pode-se perceber o potencial da utilização desta técnica como sensor virtual.

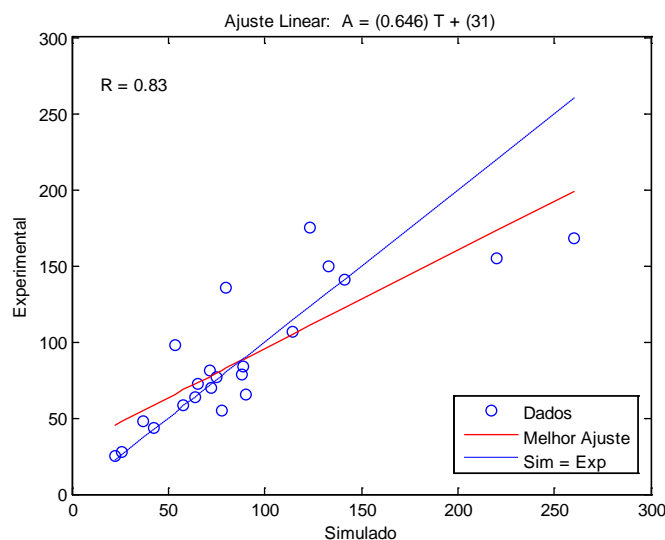


Figura 7 – Desempenho do RNA utilizada para estimar a DBO a partir de parâmetros obtidos.

No estudo realizado sobre a estimativa do parâmetro fósforo total, a Figura 8 mostra o desempenho da RNA para os dados apresentados. Foi possível um ajuste do coeficiente de regressão igual a 0,978. No caso do fósforo total, o número de dados disponíveis foram quarenta e sete, indicando melhor os dados referentes à DBO a potencialidade desta técnica como analisador virtual.




Figura 8 – Desempenho da RNA para estimativa do parâmetro fósforo total.

Apesar da quantidade de dados não ter sido representativa para o treinamento e validação das redes, foi possível alcançar resultados que geram boas perspectivas para a utilização de RNA's na estimativa de parâmetros de baixa representatividade em laboratório, a partir de parâmetros que podem ser obtidos de maneira simplificada. O resultado corrobora com os resultados encontrados por Fogelman et al. (2006), que estimou teores de DQO em efluentes a partir de RNA's do tipo MLP e quantidade de dados semelhantes.

Vale salientar que houve um significativo progresso do grupo de pesquisa do LSA/UFAL no entendimento da utilização das RNA's.

CONCLUSÕES

Apesar dos poucos dados disponíveis, uma vez que o monitoramento da bacia do Reginaldo teve início somente em fevereiro de 2007 e se estendeu até janeiro de 2008, os resultados mostram que a RNA do tipo MLP poderá se estabelecer como um sensor virtual para estimativa de parâmetros ambientais. Sendo assim, o trabalho mostra que os valores de um parâmetro de baixa reprodutibilidade, como a DBO, podem ser estimados a partir de outras propriedades medidas mais facilmente. O LSA/UFAL obteve um conhecimento na utilização das RNA's como sensores virtuais aplicadas ao monitoramento da qualidade da água. Os resultados obtidos estão em conformidade com o trabalho de Garcia et al. (2004), Carvalho et al. (2007) e Fogelman et al. (2006).

AGRADECIMENTOS

Ao CNPq, pelo apoio material e pela concessão de bolsas de Apoio Técnico e Iniciação Científica.

REFERÊNCIAS BIBLIOGRÁFICAS

1. ANTONOPOULOS, V. Z.; PAPAMICHAIL, D. M. (1991). Stochastic analysis of water quality parameters in streams. In: DIAMANTOPOULOU, M. J.; PAPAMICHAIL, D. M.; ANTONOPOULOS, V. Z. The use of a neural network technique for the prediction of water quality parameters. Operation Research. An International Journal, Vol. 5, Nº 1 (2005), pp. 115-125.
2. ANTONOPOULOS V. Z.; PAPAMICHAIL D. M.; MITSIOU K. A. (2001). Statistical and trend analysis of water quality and quantity data for the Strymon River in Greece. In: DIAMANTOPOULOU, M. J.; PAPAMICHAIL, D. M.; ANTONOPOULOS, V. Z. The use of a neural network technique for the prediction of water quality parameters. Operation Research. An International Journal, Vol. 5, Nº 1 (2005), pp. 115-125.
3. APHA, AWWA, WPCF. (1998). Standard Methods for the Examination of Water and Waste Water, 20th edition. Washington.
4. BRAGA, A. P.; CARVALHO, A. C. P. L. F.; TERESA B. L. (2007). Redes Neurais Artificiais: teoria e aplicações. 2ª Ed. Rio de Janeiro: LTC, 226.
5. CARVALHO, F. O.; GARCIA, C. A. B.; GARCIA, H. L.; PIMENTEL, W. R. O.; ALVES, J. P. H.; SILVA, J. L. (2007). Modelagem do processo de eutrofização no reservatório Jacarecica II – Sergipe/Brasil utilizando redes neurais artificiais e estatística multivariada. In: Anais do CILAMCE 2007, Porto, POR, Jul, 2007. CD – ROM.
6. COSTA, A. O. S.; SILVA, P. F.; SABARÁ, M. G.; COSTA JÚNIOR, E. F. (2008). Use of neural networks for monitoring surface water quality changes in a neotropical urban stream, Environ Monit Assess, DOI 10.1007/s10661-008-0453-9.
7. DIAMANTOPOULOU, M. J.; PAPAMICHAIL, D. M.; ANTONOPOULOS, V. Z. The use of a neural network technique for the prediction of water quality parameters. Operation Research. An International Journal, Vol. 5, Nº 1 (2005), pp. 115-125.
8. FERREIRA, I. V. L.; BARBOZA, M. G.; MENDES, A. G. A.; MELO, M. C. (2008). Water quality of the hydrous basin of Reginaldo River in Maceió, AL – Brazil. In: XXXI CONGRESO INTERAMERICANO DE INGENIERÍA SANITARIA Y AMBIENTAL – AIDIS, Santiago, Chile, Out, 2008.
9. FOGELMAN, S.; BLUMENSTEIN, M.; ZHAO, H. (2006). Estimation of chemical oxygen demand by ultraviolet spectroscopic profiling and artificial neural networks. Neural Comput & Applic (2006) 15: 197–203.
10. GARCIA H.L.; ALVES J. P. H.; CARVALHO F. O. (2004). Modelagem de processos de eutrofização em reservatórios usando a técnica de redes neurais. In: XV Congresso Brasileiro de Engenharia Química, Curitiba, Set, 2004. CD-ROM.
11. NEGNEVITSKY, M. (2005). Artificial intelligence: A guide to intelligent systems. 2 nd Edition. Pearson, 415 p.
12. OLIVEIRA JUNIOR, H. A.; CALDEIRA, A. M.; MACHADO, M. A. S.; SOUZA, R. C.; TANSCHKEIT, R. (2007). Inteligência Computacional aplicada à Administração, Economia e Engenharia em MATLAB®. São Paulo: Thomson Learning.
13. PIMENTEL, I. M. C.; HOLZ, J.; SOUZA, V. C. B.; BARBOZA, M. G.; FERREIRA, I. V. L. (2008). Avaliação Ambiental da Bacia do Riacho Reginaldo em Maceió/AL. In: IX Simpósio de Recursos Hídricos do Nordeste, Salvador, BA, Nov, 2008. CD-ROM.
14. SAWYER, C. N.; McCARTY, P. L.; PARKIN, G. F. (2003). Chemistry for Environmental Engineering and Science. 5 th Edition. McGraw-Hill, 752p.
15. SENNA JR, V. A. (2005). Saneamento e Saúde: Malha Hidrográfica de Leopoldina e Impacto das Doenças de Veiculação Hídrica no Município do Rio de Janeiro. 104p. Dissertação (Mestrado) – Escola Nacional de Saúde Pública Sérgio Arouca. Departamento de Saneamento e Saúde Ambiental.
16. VALENÇA, M.J.S. (2005). Aplicando Redes Neurais: Um Guia Completo. Ed. Do Autor. Olinda-PE, 284p.
17. VON SPERLING, M. (2005). Introdução à Qualidade das Águas e ao Tratamento de Esgotos. v.1. Departamento de Engenharia Sanitária e Ambiental; UFMG, 452p.
18. WIDROW, B.; HOFF, M.E. (1960). Adaptive switching circuits. In: BRAGA, A. P.; CARVALHO, A. C. P. L. F.; TERESA B. L. (2007). Redes Neurais Artificiais: teoria e aplicações. 2ª Ed. Rio de Janeiro: LTC, 226.