

Modelagem e simulação de um sistema inteligente para controle de dosagem da pós-cloração em estações de tratamento de água

Modeling and simulation of an intelligent system for dosage control of post-chlorination in water treatment plants

Cleber Gustavo Dias^{1*} , André Felipe Henriques Librantz¹ , Fábio Cosme Rodrigues dos Santos^{1,2} 

RESUMO

Este artigo apresenta um modelo de rede neural para controlar a dosagem de cloro na água tratada, a fim de obter melhores resultados na estabilidade do cloro residual livre, quando comparados ao controle Proporcional-Integral-Derivativo (PID) empregado atualmente e na consequente redução do consumo de cloro no processo de tratamento de água. Entre os diferentes desinfetantes, o cloro é amplamente utilizado em estações de tratamento de água de grande porte no mundo. No Brasil, especialmente nas grandes cidades, esse produto químico é também empregado como um agente desinfetante. Nesse contexto, um modelo que utiliza redes neurais artificiais foi implementado e simulado no *software* Matlab, levando-se em conta as características operacionais de uma estação de tratamento localizada na região metropolitana de São Paulo.

Palavras-chave: cloro; controle de dosagem; redes neurais; plantas de tratamento de água.

ABSTRACT

This paper presents an approach using a neural network model to control chlorine dosage in treated water, so as to obtain better results in the stability of the free residual chlorine, when compared to the control currently used, based on the Proportional-Integral-Derivative (PID) model and the consequent reduction in chlorine consumption in the water treatment process. Among the different disinfectants, chlorine is widely used in large water treatment plants in the world. In Brazil, especially in large cities, this chemical product is also used as a disinfectant agent. In this context, a neural model was implemented and simulated in MatLab software, taking into account the operational characteristics of a treatment plant, located in the São Paulo Metropolitan Region.

Keywords: chlorine; dosage control; neural networks; water treatment plants.

INTRODUÇÃO

Sabe-se que o tratamento de água tem a função de eliminar ou diminuir a quantidade de materiais em suspensão, microrganismos e outras substâncias químicas de maneira a evitar problemas de saúde pública e atender à Portaria de Consolidação nº 5 de 2017 do Ministério da Saúde (BRASIL, 2017; CHARROIS; HRUDEY, 2007).

O tipo de tratamento de água mais utilizado é o convencional, que consiste nas etapas de pré-tratamento, coagulação, floculação, decantação, filtração e correções finais do pH e do cloro residual livre (CRL ou FRC), sendo este particularmente importante para a desinfecção da água (CHEN; HOU, 2006; GUPTA; SHRIVASTAVA, 2010; OLANREWAJU *et al.*, 2012).

A desinfecção é feita nas estações de tratamento de água (ETAs) por meio da dosagem de cloro na água, mais conhecida como processo de cloração (MOULY *et al.*, 2010). Muitas ETAs possuem esse processo automatizado, em que os equipamentos eletroeletrônicos corrigem os dosadores de maneira que se mantenha o CRL em valores pré-estabelecidos (SOYUPAK *et al.*, 2011).

A automação dos processos de uma ETA busca continuamente a qualidade da água com a otimização do consumo dos produtos químicos. Com o avanço tecnológico, a utilização de equipamentos para controle automático das dosagens está cada vez mais presente, como dosadores com acionamento eletrônico, instrumentos *on-line* de medição dos parâmetros físico-químicos da água, *Programmable Logic*

¹Universidade Nove de Julho - São Paulo (SP), Brasil.

²Companhia de Saneamento Básico do Estado de São Paulo - São Paulo (SP), Brasil.

*Autor correspondente: diascg@ig.com.br

Recebido: 28/12/2016 - Aceito: 12/02/2019 - Reg. ABES: 173961

Controllers (PLCs) e sistemas *Supervisory Control and Data Acquisition* (SCADA) (LIU *et al.*, 2013).

Com a evolução tecnológica dos equipamentos de automação, a implementação de recursos de inteligência computacional se torna favorável à aplicação de métodos que possibilitam o melhor entendimento do processo (OLSSON *et al.*, 2014).

Nesse sentido, as chamadas redes neurais artificiais são modelos pertencentes à inteligência computacional que podem contribuir para melhorias dos processos com características multivariáveis e não lineares, como os processos de tratamento de água e efluentes (BHUVANESWARI; UMA; RANGASWAMY, 2009), uma vez que tais modelos possuem a capacidade de extrair conhecimento ou informações relevantes de um processo que não esteja bem detalhado ou compreendido (NA *et al.*, 2012). Ribeiro *et al.* (2008), por exemplo, propuseram um modelo de rede neural para estimar potenciais concentrações de clorofila, ou seja, pigmentos no reservatório de uma usina hidrelétrica.

O processo de desinfecção é uma importante etapa dos processos de tratamento de água e efluentes que utiliza, na maioria das vezes, o cloro como agente químico. De acordo com o revelado em Haas (2004), a implementação de redes neurais artificiais no processo de desinfecção pode promover a previsão de inativação microbiana em função do tempo e outros parâmetros físico-químicos da água, como temperatura e pH, em relação aos métodos tradicionais de determinação, bem como em outras relações não comumente consideradas.

A dosagem de cloro resulta na existência de CRL na água tratada, garantindo a desinfecção na rede de distribuição (FISHER *et al.*, 2011). Muitos estudos estão voltados aos valores do CRL ao longo da rede de distribuição, como previsão do valor na rede após determinado período a partir de parâmetros físico-químicos de períodos anteriores apresentados durante o treinamento de redes neurais artificiais (RODRIGUEZ; SÉRODES, 1996; 1998).

Estudos alternativos referentes à medição e ao controle do CRL são feitos em sistemas de distribuição de água utilizando redes neurais artificiais, resultando em maior estabilidade do CRL e na utilização para propósitos de previsão de valores de referência (AHN *et al.*, 2004; SOYUPAK *et al.*, 2011; RIBEIRO *et al.*, 2008). Outros processos ligados à etapa de cloração em ETAs são também tema de estudos, com o emprego dos recursos de inteligência computacional, como previsão de dosagem de cal e pH por meio de controles avançados.

Além disso, as medições de pH e potencial de oxidorredução (ORP) com o emprego de redes neurais artificiais possibilitaram a criação de um controle dinâmico de cloração em ETAs de reúso (YU *et al.*, 2008). Segundo Tabesh, Azadi e Roozbahani (2011), a utilização de algoritmos genéticos possibilita o controle do processo de cloração visando à minimização do consumo de cloro em redes de distribuição de água. A utilização de algoritmos genéticos em conjunto com o *software* EPANET-MSX (Multi-Species Extension) foi proposta por Ohar e

Ostfeld (2014), tendo como objetivos o residual de cloro e a formação de trihalometanos (THMs) nas redes de distribuição de água tratada.

Nesse contexto, o objetivo deste trabalho foi propor um controle multivariável para o sistema de dosagem da pós-cloração de uma ETA, visando diminuir as variações do CRL da água tratada no reservatório de água tratada e, conseqüentemente, na adutora de distribuição. Esse reservatório recebe água tratada da ETA, que está na mesma localidade, e de outro sistema produtor com a finalidade de complementar a vazão de água de distribuição.

Dessa forma, com a estabilização do CRL, espera-se obter a redução no consumo de cloro e um sistema de controle mais autônomo, capaz, ainda, de reduzir a interferência humana no processo.

As redes neurais artificiais

As técnicas de inteligência artificial têm como finalidade primordial o desenvolvimento de soluções computacionais, ou algoritmos, capazes de realizar as chamadas tarefas cognitivas (HAYKIN, 1999). Em outras palavras, pode-se afirmar que os sistemas inteligentes são atualmente empregados em diversas aplicações nas quais o conhecimento humano está presente.

Atualmente, as técnicas neurais são aplicadas especialmente em problemas complexos e não lineares, uma vez que as soluções matemáticas convencionais apresentam alto custo computacional, particularmente no que se refere ao tempo de processamento da máquina.

A Figura 1 ilustra uma estrutura típica de um neurônio artificial, ou um modelo não linear do referido neurônio. Essa arquitetura foi utilizada no presente trabalho com a finalidade de estimar a dosagem de cloro em uma planta de tratamento de água, como será melhor descrita a seguir.

As equações que compõem o neurônio artificial da Figura 1 são as Equações 1 e 2:

$$uk = \sum_{j=1}^n (wkj \times xj) + bk \quad (1)$$

$$yk = \phi(uk) \quad (2)$$

Em que:

uk = estado de ativação do neurônio artificial;

n = número total de entradas do neurônio artificial;

j = índice de uma entrada do neurônio artificial;




Figura 1 - Representação de um neurônio artificial.

wkj = peso sináptico de uma entrada do neurônio;

xj = entrada do neurônio;

bk = sinal de bias do neurônio artificial;

yk = saída do neurônio artificial;

ϕ = função de ativação do neurônio artificial.

O desempenho da rede neural artificial é medido por meio do erro médio quadrático (MSE) e do erro médio absoluto (MAE), conforme mostrado nas Equações 3 e 4, respectivamente (MAY *et al.*, 2008):

$$MSE = \frac{1}{N} \sum_{i=1}^N (t_i - y_i)^2 \quad (3)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |t_i - y_i| \quad (4)$$

Em que:

t_i = valor desejado;

y_i = valor obtido na saída da rede neural artificial (ANN ou RNA);

N = número de amostras existente.

A dosagem de cloro e o processo de desinfecção

A finalidade da desinfecção é reduzir ou incapacitar microrganismos que possam causar doenças aos seres humanos. Ao processo de eliminação completa, dá-se o nome de esterilização. Os agentes químicos utilizados para desinfecção em um tratamento de água devem conter algumas características, como: tempo de redução aceitável em relação à quantidade de microrganismos presentes; produzir residuais de cloro livre para garantir a desinfecção ao longo do sistema de abastecimento (CHARROIS; HRUDEY, 2007).

A quantidade de cloro a ser aplicada no processo está diretamente relacionada com a qualidade da água bruta e do valor de residual livre que se deve apresentar na água, utilizando-se do método clássico do *breakpoint* da cloração (KIM *et al.*, 2006). Da mesma forma, a demanda de cloro para alcance do *breakpoint* da cloração está relacionada com a concentração de amônia e com pontos de controle de ORP.

Na pré-cloração, o cloro aplicado tem a finalidade de eliminar os microrganismos patogênicos, além de oxidar substâncias como amônia, compostos orgânicos e inorgânicos, como o manganês e o ferro (WARTON *et al.*, 2006). Nessa etapa, parte do cloro aplicado na água será consumido pela oxidação e pela desinfecção. A pós-cloração tem a finalidade apenas de complementar o CRL na água tratada para envio à população. Isso evitará possíveis contaminações no percurso da distribuição (RODRIGUEZ; SÉRODES, 1996).

A presença do CRL na água se inicia após concluir o processo de oxidação e desinfecção, pela reação do gás cloro com a água, conforme as Equações 5 e 6 a seguir (HUI *et al.*, 2013):



Dessa reação, formam-se o ácido hipocloroso (HOCl) e o ácido clorídrico (HCl). O HOCl sofre dissociação para formar o íon hidrogênio (H^+) e o íon hipoclorito (OCl^-). Os agentes desinfetantes para água tratada são formados por HOCl e OCl^- , os quais são chamados de CRL. Vale mencionar que a proporção do HOCl e do OCl^- presente na água depende do pH e da temperatura do meio.

O sistema de dosagem na estação de tratamento de água em estudo e o controle da pós-cloração

A ETA em estudo está localizada na região metropolitana de São Paulo e tem a vazão nominal de produção de aproximadamente $0,9 \text{ m}^3 \cdot \text{s}^{-1}$. Esse valor pode ser reduzido em casos de manutenções periódicas dos equipamentos ou variações na demanda de consumo da população. Pelo fato de a água bruta do manancial ter origem em um rio, os seus parâmetros físico-químicos alteram-se naturalmente, especialmente nas épocas de chuva, gerando oscilações no valor do CRL ao longo do tratamento, chegando à etapa da pós-cloração. A Figura 2 ilustra a configuração do processo que envolve a pós-cloração na ETA em estudo.

Nessa figura, pode-se observar a existência do sistema de compensação de água, que tem a finalidade de complementar o reservatório de água tratada da ETA com água de outro sistema produtor, localizado em outra cidade da região metropolitana de São Paulo, a fim de atender à vazão de bombeamento da elevatória de água tratada 2. A vazão de água tratada do sistema de compensação varia de 0 a $0,4 \text{ m}^3 \cdot \text{s}^{-1}$ e possui CRL de $1,1 \text{ mg} \cdot \text{L}^{-1}$. A medição do CRL na saída do reservatório tem o objetivo de controlar a dosagem da pós-cloração de modo que a água seja distribuída com CRL em torno de $2,5 \pm 0,2 \text{ mg} \cdot \text{L}^{-1}$ (*set-point*). A vazão de água filtrada pode variar de 0 a $0,9 \text{ m}^3 \cdot \text{s}^{-1}$ de acordo com a vazão de produção da ETA, com CRL de aproximadamente $1,5 \text{ mg} \cdot \text{L}^{-1}$.

Como exposto, a concepção do sistema necessita de um controle multivariável que possibilite prever as alterações das vazões da ETA e do sistema de compensação, além do complemento dos CRL da água filtrada e do sistema de compensação, para que se alcance o valor de *set-point* na saída do reservatório de água tratada.

Metodologia empregada na modelagem matemática e na implementação da rede neural artificial

Um controle proporcional-integral-derivativo (PID) monovariável de dosagem de cloro foi proposto em Dieu *et al.* (1995) com todos os dispositivos necessários, como analisador em tempo real de CRL, PLCs e dosadores de cloro, demonstrando malha de controle similar à utilizada na ETA em estudo atualmente. A dosagem da pós-cloração na ETA possui diversas variáveis que impactam diretamente no valor do

CRL na água tratada, e por esse motivo restringem a utilização com o controle clássico PID, como mencionado em Shariiff *et al.* (2004).

O emprego de recursos de inteligência computacional se torna favorável, uma vez que abarca os sinais de vazão dos processos que impactam diretamente na dosagem e no *set-point*, bem como os pontos críticos de medição do CRL.

Desse modo, a modelagem do sistema proposto contempla seis variáveis de entrada:

- *Set-point*, ou valor desejado, da saída do reservatório (SPFRC), em mg.L⁻¹;
- CRL da saída do reservatório de água tratada (FRCRES), em mg.L⁻¹;
- CRL da saída da ETA (FRCWTP), em mg.L⁻¹;
- Vazão da produção da ETA (VAZAOWTP), em m³.s⁻¹;
- Vazão do sistema de compensação (VAZAOSC), em m³.s⁻¹;
- Erro de dosagem.

A modelagem contempla ainda duas variáveis de saída, o valor do *set-point* de referência da pós-cloração (SPWTP), em mg.L⁻¹, e a dosagem de cloro (dosagem), em kg.s⁻¹.

Os dados referentes às vazões são coletados em medidores instalados nas tubulações de transferência de água da ETA. Os sinais de CRL são obtidos a partir de analisadores *on-line*.

O *set-point* é definido manualmente pela operação da ETA, referenciando o CRL na água tratada que será enviada à rede de distribuição. O erro é calculado durante o controle para compensar quaisquer desvios no processo.

O valor de SPWTP na saída da rede neural artificial tem a finalidade apenas de fornecer a referência que será adotada no controle, para que se tenha o CRL necessário na água tratada da saída da ETA e, conseqüentemente, alcançar os limites definidos pelo SPFRC de água tratada. A saída “dosagem” corresponde ao valor efetivo da massa de cloro que os dosadores de cloro aplicam no ponto da pós-cloração.

A Figura 3 mostra a arquitetura da rede neural com as variáveis de entrada e saída, modelada para a realização das simulações.

O conjunto de dados foi normalizado com limites de -1 a 1 para utilização com a função de ativação tangente hiperbólica. Os critérios de parada para treinamento das redes neurais foram o MSE desejado e/ou o número máximo de 150 épocas. O algoritmo de treinamento utilizado foi o *Levenberg-Marquardt* (LM), e a quantidade de neurônios na camada intermediária variou entre dez e 16 neurônios. Como descrito por Hagan e Menhaj (1994), o algoritmo LM é uma aproximação do método de Gauss-Newton, e muito embora tal algoritmo ofereça maior custo computacional a cada iteração, o seu uso se justifica na medida em que o treinamento da rede neural alcança maior eficiência, quando comparado a outros métodos. A base de dados para treinamento e validação das redes neurais contou, respectivamente, com 15.625 e 2.700 registros. Essa base de dados foi gerada a partir da experiência operacional da ETA e suas características construtivas.

O controle baseado em redes neurais artificiais foi desenvolvido e simulado com todas as variáveis que compõem o sistema da pós-cloração da ETA em estudo, de maneira que as perturbações sejam evidenciadas e corrigidas pelo controle. A Figura 4 ilustra o modelo implementado no ambiente computacional MATLAB/Simulink e utilizado nas simulações. Tal modelo foi executado usando o método numérico de Runge-Kutta 4ª ordem, com passo fixo de 1s e erro absoluto da ordem de 1e⁻⁵.

O cálculo do bloco CRL, também ilustrado na Figura 4, é demonstrado na Equação 7, e o cálculo do erro referente à entrada “Erro de Dosagem” é mostrado na Equação 8.

$$CRL_{DOS(t)} = \frac{D_{(t-1)} \times 1000}{Q_{FIL(t-1)}} \tag{7}$$

Em que:

CRL_{DOS} = CRL dosado pelo controle, em mg.L⁻¹;

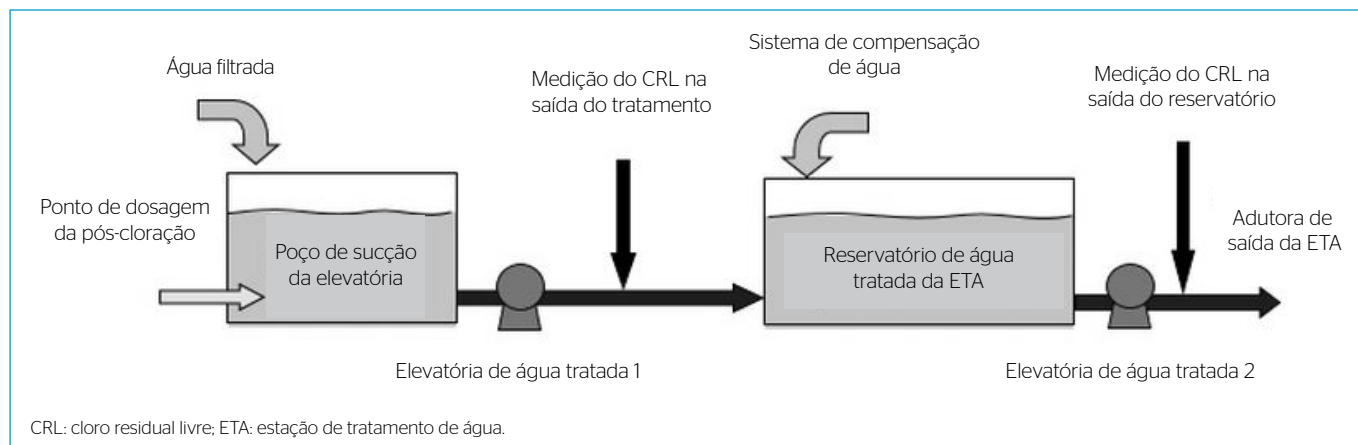


Figura 2 - Concepção da dosagem e controle da pós-cloração.

D = dosagem de cloro, em $\text{kg}\cdot\text{s}^{-1}$;

Q_{FLL} = vazão da água filtrada da WTP, em $\text{m}^3\cdot\text{s}^{-1}$.

$$Error_{(t)} = (SP_{WTP(t)} - FRC_{WTP(t)}) \times K \quad (8)$$

Em que:

$Error$ = erro calculado, em $\text{mg}\cdot\text{L}^{-1}$;

SP_{WTP} = *set-point* de FRC na água tratada da saída da ETA;

FRC_{WTP} = FRC na água tratada da saída da ETA;

K = constante.

Para realizar a simulação computacional do modelo construído foram previstas três situações operacionais que podem ocorrer na ETA em questão e no sistema de compensação de água no reservatório de água tratada:

- Cenário 1: Vazão de água filtrada (da ETA em estudo) de $0,9 \text{ m}^3\cdot\text{s}^{-1}$ com variações de $\pm 0,05 \text{ m}^3\cdot\text{s}^{-1}$; CRL da água filtrada de $1,5 \text{ mg}\cdot\text{L}^{-1}$ com variações de $\pm 0,35 \text{ mg}\cdot\text{L}^{-1}$ e sem a utilização do sistema de compensação de água;

- Cenário 2: Vazão de água filtrada (da ETA em estudo) de $0,9 \text{ m}^3\cdot\text{s}^{-1}$ com variações de $\pm 0,05 \text{ m}^3\cdot\text{s}^{-1}$; CRL da água filtrada de $1,5 \text{ mg}\cdot\text{L}^{-1}$ com variações de $\pm 0,35 \text{ mg}\cdot\text{L}^{-1}$; e a vazão do sistema de compensação de água com $0,10 \text{ m}^3\cdot\text{s}^{-1}$ e variação de $\pm 0,10 \text{ m}^3\cdot\text{s}^{-1}$;
- Cenário 3: Vazão de água filtrada (da ETA em estudo) de $0,5 \text{ m}^3\cdot\text{s}^{-1}$ com variações de $\pm 0,05 \text{ m}^3\cdot\text{s}^{-1}$; CRL da água filtrada de $1,5 \text{ mg}\cdot\text{L}^{-1}$ com variações de $\pm 0,35 \text{ mg}\cdot\text{L}^{-1}$; e a vazão do sistema de compensação de água com $0,10 \text{ m}^3\cdot\text{s}^{-1}$ e variação de $\pm 0,10 \text{ m}^3\cdot\text{s}^{-1}$.

RESULTADOS E DISCUSSÃO

Os treinamentos com a rede neural foram realizados com as topologias de 10 a 16 neurônios na camada intermediária, a fim de verificar qual delas apresentou melhor *performance*. A Tabela 1 mostra os MSE das topologias previstas, calculados conforme a Equação 3.

De acordo com a Tabela 1, a topologia com 15 neurônios na camada intermediária apresentou menor MSE entre todas as

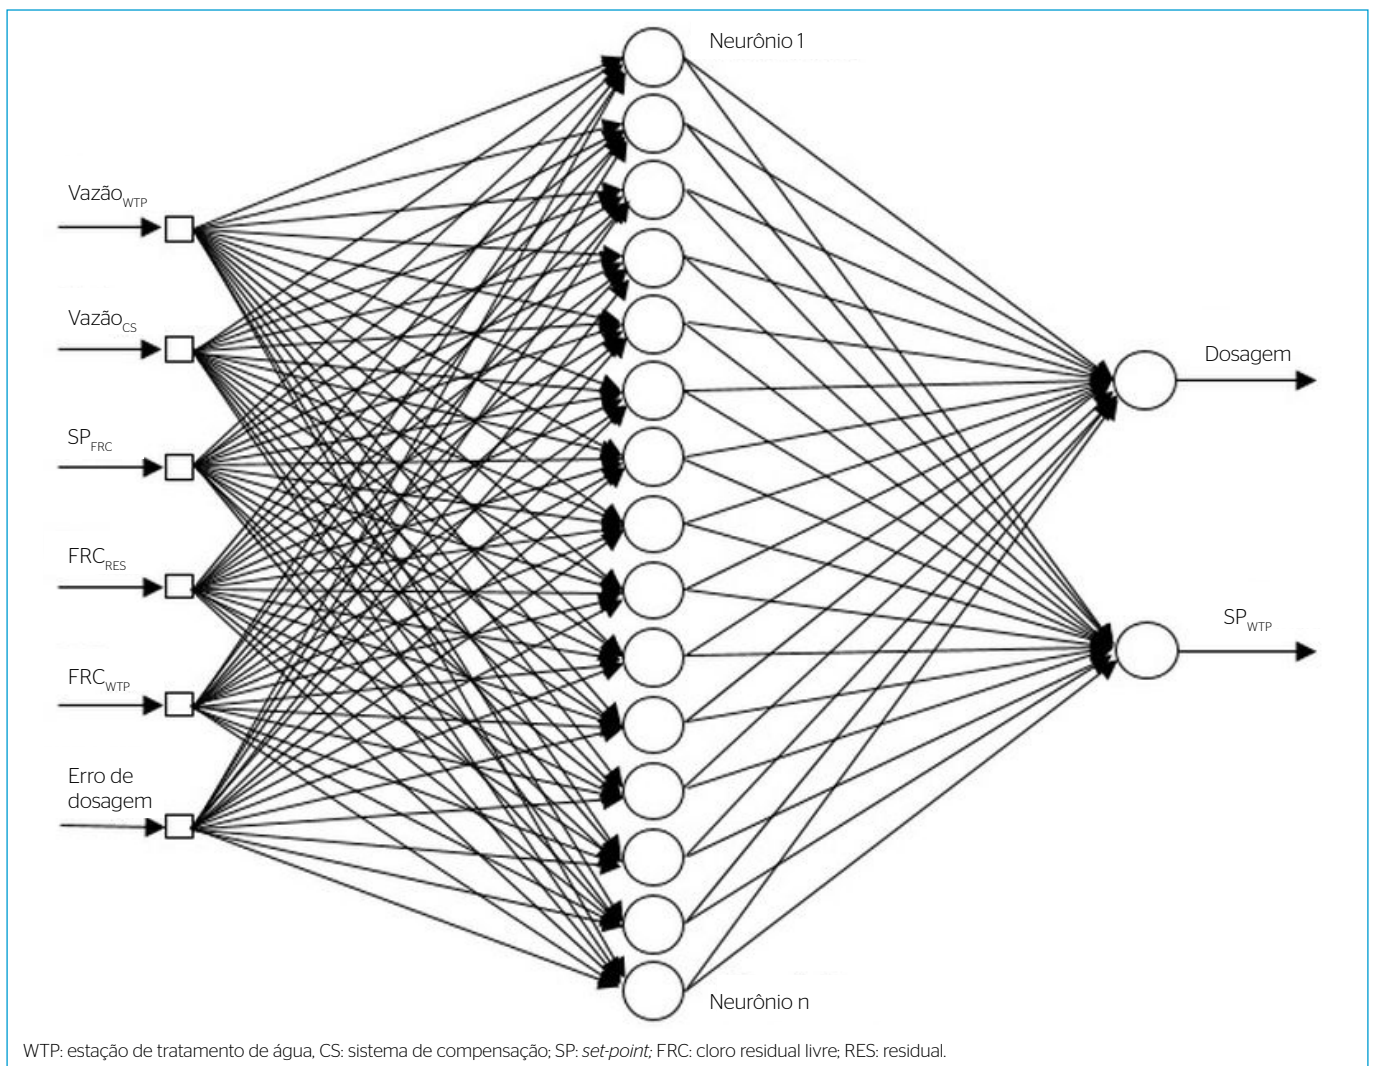


Figura 3 - Arquitetura da rede neural modelada.

simuladas, com 96 iterações ao final dos testes. A Figura 5 ilustra a evolução do MSE durante o treinamento com 15 neurônios na camada intermediária.

Na etapa de validação foram verificadas as generalizações da rede neural artificial em relação ao valor desejado ou necessário ao controle da dosagem de cloro, e viu-se que a etapa de treinamento e os dados selecionados foram adequados dadas as similaridades encontradas.

Na etapa de simulação foram observados os valores de CRL na saída da ETA em estudo e o correspondente *set-point* (SPWTP) para esse ponto, de maneira que quaisquer alterações na vazão do sistema de compensação de água possam ser compensadas com a finalidade de manter o CRL na saída do reservatório de água tratada dentro dos limites estabelecidos operacionalmente.

As Figuras 6A e 6B ilustram os comportamentos da simulação com os parâmetros do cenário 1.

Sem a utilização do sistema de compensação nessa simulação, não há a necessidade de alteração do *set-point* (SPWTP), o qual permanece a valores próximos ao *set-point* (SPRES). Na Figura 6A, podem-se constatar a estabilidade do referido *set-point* (SPWTP) e pequenas variações do CRL da água tratada na saída da ETA, em função da ação do controle ante as variações

submetidas da etapa de dosagem de cloro anterior, ou seja, CRL da água filtrada de $1,5 \text{ mg.L}^{-1}$ com variações de $\pm 0,35 \text{ mg.L}^{-1}$ utilizado na simulação.

A Figura 6B ilustra o erro absoluto entre o *set-point* (SPWTP) e o CRL na saída da ETA, mantendo-se entre $0,015$ e $0,025 \text{ mg.L}^{-1}$. Os valores máximos e mínimos observados são inferiores ao limite operacional existente, de $\pm 0,20 \text{ mg.L}^{-1}$ aplicado ao *set-point*.

Os resultados da simulação para o cenário 2 são mostrados nas Figuras 7A e 7B. O diferencial nessa simulação é a utilização do sistema de compensação de água no sistema de dosagem da pós-cloração.

Tabela 1 - Valores dos erros com diferentes números de neurônios.

Número de neurônios na camada intermediária	MSE
10	0,000159
11	0,000155
12	0,000128
13	0,000120
14	0,000113
15	0,000099
16	0,000128

MSE: erro quadrático médio.

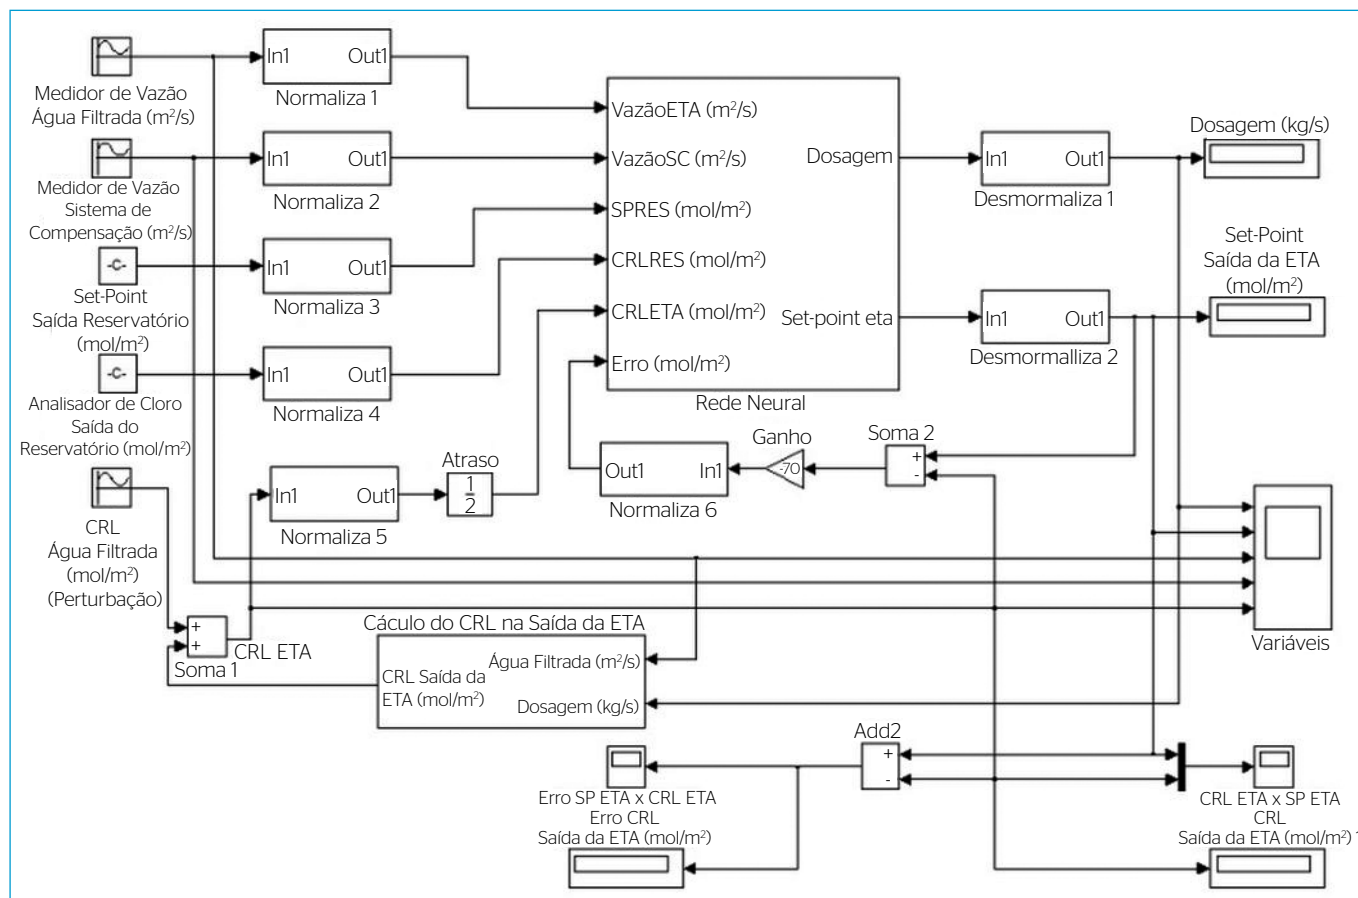


Figura 4 - Diagrama do processo para simulação com rede neural no ambiente Simulink.

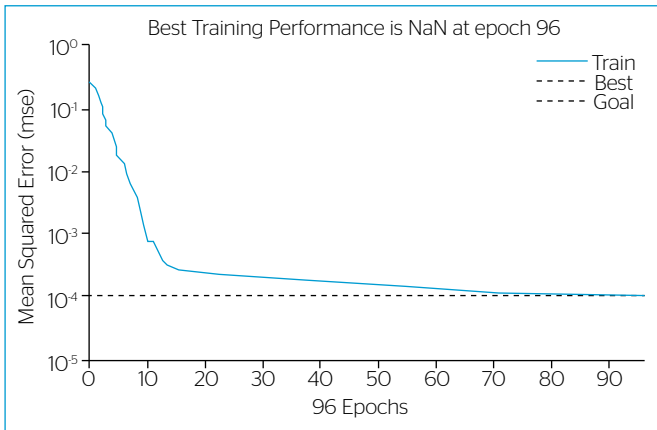


Figura 5 - Evolução do erro quadrático médio durante o treinamento obtido via simulação no MATLAB.

Nessa simulação são consideradas as mesmas características da ETA no cenário 1, mas com a utilização do sistema de compensação de água no reservatório de água tratada. Sendo assim, tem-se a variação do *set-point* (SPWTP) com a finalidade de manter o CRL na saída dentro dos limites operacionais.

O cenário 2 impôs ao controle da dosagem de cloro a necessidade de ajuste da dosagem, em virtude das variações dos processos anteriores de dosagem de cloro e das alterações necessárias no *set-point* (SPWTP).

No entanto, o CRL na saída da ETA acompanhou o *set-point* (SPWTP) de maneira satisfatória diante das perturbações em que o modelo foi submetido. O erro absoluto entre essas duas grandezas se manteve entre 0,015 e 0,029 mg.L⁻¹, tendo o limite máximo superior aproximadamente 15% maior em relação ao cenário 1. A variação do erro absoluto é ilustrada na Figura 7B.




Figura 6 - Comportamento do controle submetido ao cenário 1.

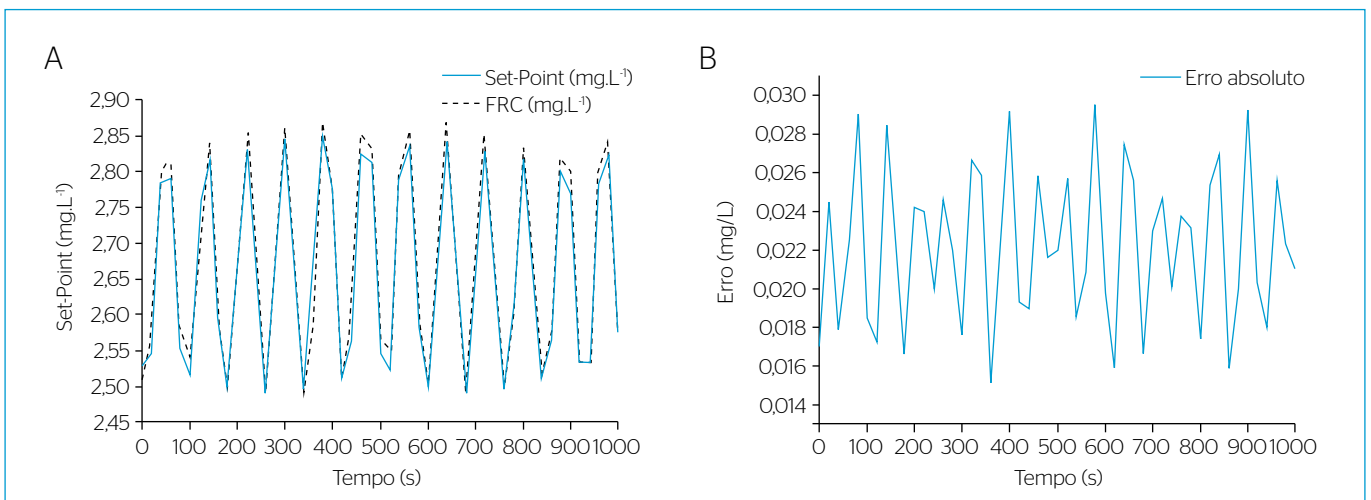


Figura 7 - Comportamento do controle submetido ao cenário 2.

O cenário 3 tem seus resultados ilustrados nas Figuras 8A e 8B, correspondentes ao comportamento do controle com a vazão de produção da ETA reduzida.

Os resultados mostraram a alteração do *set-point* (SPWTP) da mesma forma que o cenário 2, comparando-se as Figuras 7A e 8A. No entanto, podem-se observar maior amplitude nessa simulação ocasionada pela redução da vazão da ETA e a permanência da mesma vazão no sistema de compensação de água, que é necessária para manter o CRL na saída do reservatório dentro do estabelecido.

Como no cenário 2, o controle alterou a dosagem de cloro de forma que o CRL na saída da ETA se mantivesse próximo ao *set-point* (SPWTP) no determinado instante. A Figura 8B mostra a variação do erro entre as duas grandezas, mantendo-se entre 0,015 e 0,036 mg.L⁻¹.

De forma geral, o controle conseguiu estabelecer a dosagem de cloro na pós-cloração adequada aos diferentes valores de *set-point* (SPWTP) requeridos durante as simulações. Pode-se perceber que o limite máximo do erro absoluto aumenta a cada cenário simulado, mostrando que o sistema de compensação é uma perturbação importante ao sistema, tornando-se mais crítico em casos de redução da vazão da ETA.

Para os três cenários propostos foram calculados o MAE entre *set-point* (SPWTP) e o CRL da saída da ETA, conforme a Equação 4. Os MAEs são mostrados na Tabela 2. Comparando-se o MAE dos cenários simulados com o atual da ETA em estudo, de 0,083 mg.L⁻¹, é possível obter uma redução da ordem de três vezes com a utilização do controle proposto. Como benefício, pode-se obter a redução no consumo de cloro utilizado na pós-cloração entre a situação atual e a proposta de 2.400 kg do produto químico no período de um ano.

O trabalho realizado em Pastre *et al.* (2002), por exemplo, procurou manter o CRL na saída do reservatório entre 0,8 e 1,2 mg.L⁻¹, ou

seja, de maneira semelhante a determinado valor de *set-point* e os limites operacionais de $\pm 0,20$ mg.L⁻¹, como o utilizado na ETA em estudo, diferenciando apenas o *set-point* em cada localidade.

No entanto, o modelo proposto no presente artigo resultou em menor amplitude, o que favorece a redução dos limites operacionais utilizados atualmente na ETA, tal como sugerido em Pastre *et al.* (2002). Além disso, o sistema proposto reduz a interferência manual em casos de variações bruscas nas vazões, visando manter o CRL dentro dos limites operacionais.

CONCLUSÃO

Neste estudo foi proposto um modelo de rede neural em substituição ao controle convencional do tipo PID, no controle de dosagem de cloro na água tratada. Para os três cenários operacionais estudados, foi possível obter redução da ordem de três vezes com a utilização do controle ora proposto, e um MAE de 0,01 entre os valores esperados para a planta real e aqueles simulados com o presente modelo.

Como benefício, pode-se obter a redução no consumo de cloro utilizado no processo de pós-cloração de aproximadamente 2.400 kg do produto químico no período de um ano, quando comparado ao controle hoje utilizado.

Tabela 2 - Erro médio absoluto para cada cenário.

Cenário	MAE (mg.L ⁻¹)
1	0,019
2	0,022
3	0,026
Valor atual da planta	0,083

MAE: erro médio absoluto.




Figura 8 - Comportamento do controle submetido ao cenário 3.

Como benefício extra, deve-se destacar que não há restrições tecnológicas importantes para a implementação do controle proposto em tempo real, dada a automação já existente na ETA em estudo.

Como continuação deste trabalho, pode-se incluir no modelo implementado os parâmetros de tempo de detenção no reservatório e temperatura, de maneira que contribuam com as perdas e as oscilações possíveis no CRL da água tratada na saída do reservatório.

REFERÊNCIAS

- AHN, J.C.; KIM, Y.W.; LEE, K.S.; KOO, J.Y. (2004) Residual chlorine management in water distribution systems using network modelling techniques: case study in Seoul City. *Water Science and Technology: Water Supply*, v. 4, n. 5-6, p. 421-429. <https://doi.org/10.2166/ws.2004.0134>
- BHUVANESWARI, N.S.; UMA, G.; RANGASWAMY, T.R. (2009) Adaptive and optimal control of a non-linear process using intelligent controllers. *Applied Soft Computing*, v. 9, n. 1, p. 182-190. <https://doi.org/10.1016/j.asoc.2008.04.003>
- BRASIL. (2017) Ministério do Estado da Saúde. Portaria de Consolidação nº 5, de 28 de setembro de 2017. Consolidação das normas sobre as ações e os serviços de saúde do Sistema Único de Saúde. *Diário Oficial [da] República Federativa do Brasil*, Brasília. Disponível em: <ftp://ftp.saude.sp.gov.br/ftpssesp/bibliote/informe_eletronico/2017/iels.out.17/iels194/U_PRC-MS-GM-5_280917.pdf>. Acesso em: 9 out. 2018.
- CHARROIS, J.W.A.; HRUDEY, S.E. (2007) Breakpoint chlorination and free-chlorine contact time: Implications for drinking water N-nitrosodimethylamine concentrations. *Water Research*, v. 41, n. 3, p. 674-682. <https://doi.org/10.1016/j.watres.2006.07.031>
- CHEN, C.-L.; HOU, P.-L. (2006) Fuzzy model identification and control system design for coagulation chemical dosing of potable water. *Water Science & Technology: Water Supply*, v. 6, n. 3, p. 97-104. <https://doi.org/10.2166/ws.2006.782>
- DIEU, B.; GARRETT JR., M.T.; AHMAD, Z.; YOUNG, S. (1995) Applications of automatic control systems for chlorination and dechlorination processes in wastewater treatment plants. *ISA Transactions*, v. 34, n. 1, p. 21-28. [https://doi.org/10.1016/0019-0578\(94\)00041-J](https://doi.org/10.1016/0019-0578(94)00041-J)
- FISHER, I.; KASTL, G.; SATHASIVAN, A.; JEGATHEESAN, V. (2011) Suitability of Chlorine Bulk Decay Models for Planning and Management of Water Distribution Systems. *Critical Reviews in Environmental Science and Technology*, v. 41, n. 20, p. 1843-1882. <https://doi.org/10.1080/10643389.2010.495639>
- GUPTA, A.K.; SHRIVASTAVA, R.K. (2010) Reliability-constrained Optimization of Water Treatment Plant Design Using Genetic Algorithm. *Journal of Environmental Engineering*, v. 136, n. 3, p. 326-334. [https://doi.org/10.1061/\(ASCE\)EE.1943-7870.0000150](https://doi.org/10.1061/(ASCE)EE.1943-7870.0000150)
- HAAS, C. N. (2004) Neural networks provide superior description of Giardia lamblia inactivation by free chlorine. *Water Research*, v. 38, n. 14-15, p. 3449-3457. <https://doi.org/10.1016/j.watres.2004.05.001>
- HAGAN, M.T.; MENHAJ, M.B. (1994). Training Feedforward Networks with Marquardt Algorithm. *IEEE Transactions on Neural Networks*, v. 5, n. 6, p. 989-993. <https://doi.org/10.1109/72.329697>
- HAYKIN, S. (1999) *Neural networks: a comprehensive foundation*. 2. ed. Patparganj: Prentice-Hall, Inc.
- HUI, T.; FENG, X.; WEI, C.; MIN, S.; LIANG, C.; BO, F. (2013) The Effects of Glycine on Breakpoint Chlorination and Chlorine Dosage Control Methods for Chlorination and Chloramination Processes in Drinking Water. *Water, Air & Soil Pollution*, v. 224, p. 1-10. <https://doi.org/10.1007/s11270-013-1686-y>
- KIM, H.; KWON, S.; HAN, S.; YU, M.; KIM, J.; GONG, S.; COLOSIMO, M.F. (2006) New ORP/pH based control strategy for chlorination and dechlorination of wastewater: pilot scale application. *Water Science and Technology*, v. 53, n. 6, p. 145-151. <https://doi.org/10.2166/wst.2006.188>
- LIU, H.; RONG, Q.; XU, L.; ZHANG, Y. (2013) Application of Automatic Control System in Water Plant in China. *Journal of Convergence Information Technology*, v. 8, n. 5, p. 243-250. <https://doi.org/10.4156/jcit.vol8.issue5.29>
- MAY, R.J.; DANDY, G.C.; MAIER, H.R.; NIXON, J.B. (2008) Application of partial mutual information variable selection to ANN forecasting of water quality in water distribution systems. *Environmental Modelling & Software*, v. 23, n. 10-11, p. 1289-1299. <https://doi.org/10.1016/j.envsoft.2008.03.008>
- MOULY, D.; JOULIN, E.; ROSIN, C.; BEAUDEAU, P.; ZEGHNOUN, A.; OLSZEWSKI-ORTAR, A.; MUNOZ, J.F.; WELTÉ, B.; JOYEUX, M.; SEUX, R.; MONTIEL, A.; RODRIGUEZ, M.J. (2010) Variations in trihalomethane levels in three French water distribution systems and the development of a predictive model. *Water Research*, v. 44, n. 18, p. 5168-5179. <https://doi.org/10.1016/j.watres.2010.06.028>
- NA, J.; REN, X.; SHANG, C.; GUO, Y. (2012) Adaptive neural network predictive control for nonlinear pure feedback systems with input delay. *Journal of Process Control*, v. 22, n. 1, p. 194-206. <https://doi.org/10.1016/j.jprocont.2011.09.003>
- OHAR, Z.; OSTFELD, A. (2014) Optimal design and operation of booster chlorination stations layout in water distribution systems. *Water Research*, v. 58, p. 209-220. <https://doi.org/10.1016/j.watres.2014.03.070>
- OLANREWaju, R.F.; MUYIBI, S.A.; SALAWUDEEN, T.O.; AIBINU, A.M. (2012) An Intelligent Modeling of Coagulant Dosing System for Water Treatment Plants based on Artificial Neural Network. *Australian Journal of basic and Applied Sciences*, v. 6, n. 1, p. 93-99.

- OLSSON, G.; CARLSSON, B.; COMAS, J.; COPP, J.; GERNAEY, K.V.; INGILDSEN, P.; JEPPSSON, U.; KIM, C.; RIEGER, L.; RODRÍGUEZ-RODA, I.; STEYER, J.-P.; TAKÁCS, I.; VANROLLEGHEM, P.A.; VARGAS, A.; YUAN, Z.; ÁMAND, L. (2014) Instrumentation, control and automation in wastewater - from London 1973 to Narbonne. *Water Science & Technology*, v. 69, n. 7, p. 1373-1385. <https://doi.org/10.2166/wst.2014.057>
- PASTRE, A.; MULHOLLAND, M.; BROUCKAERT, C.J.; BUCKLEY, C.A.; LE LANN, M.-V.; ROUSTAN, M.; NAIDOO, D.; MABEER, V. (2002) Modelling and control of potable water chlorination. *Water Science and Technology*, v. 46, n. 9, p. 103-108. <https://doi.org/10.2166/wst.2002.0216>
- RIBEIRO, H.M.C.; ALMEIDA, A.C.; ROCHA, B.R.P.; KRUSCHE, A.V. (2008) Water quality monitoring in large reservoirs using remote sensing and neural networks. *IEEE Latin America Transactions*, v. 6, n. 5, p. 419-423. <https://doi.org/10.1109/TLA.2008.4839111>
- RODRIGUEZ, M.J.; SÉRODES, J.B. (1996) Neural network-based modelling of the adequate chlorine dosage for drinking water disinfection. *Canadian Journal of Civil Engineering*, v. 23, n. 3, p. 621-631. <https://doi.org/10.1139/196-871>
- RODRIGUEZ, M.J.; SÉRODES, J.B. (1998) Assessing empirical linear and non-linear modelling of residual chlorine in urban drinking water systems. *Environmental Modelling & Software*, v. 14, n. 1, p. 93-102. [https://doi.org/10.1016/S1364-8152\(98\)00061-9](https://doi.org/10.1016/S1364-8152(98)00061-9)
- SHARIFF, R.; CUDRAK, A.; ZHANG, Q.; STANLEY, S.J. (2004) Advanced process control techniques for water treatment using artificial neural networks. *Journal of Environmental Engineering and Science*, v. 3, supl. 1, p. S61-S67. <https://doi.org/10.1139/s04-005>
- SOYUPAK, S.; KILIC, H.; KARADIREK, I.E.; MUHAMMETOGLU, H. (2011) On the usage of artificial neural networks in chlorine control applications for water distribution networks with high quality water. *Journal of Water Supply: Research and Technology—AQUA*, v. 60, n. 1, p. 51-60. <https://doi.org/10.2166/aqua.2011.086>
- TABESH, M.; AZADI, B.; ROOZBAHANI, A. (2011) Quality Management of Water Distribution Networks by Optimizing Dosage and Location of Chlorine Injection. *International Journal of Environmental Research*, v. 5, n. 2, p. 321-332. <https://dx.doi.org/10.22059/ijer.2011.317>
- WARTON, B.; HEITZ, A.; JOLL, C.; KAGI, R. (2006) A new method for calculation of the chlorine demand of natural and treated waters. *Water Research*, v. 40, n. 15, p. 2877-2884. <https://doi.org/10.1016/j.watres.2006.05.020>
- YU, R.-F.; CHEN, H.-W.; CHENG, W.-P.; SHEN, Y.-C. (2008) Dynamic control of disinfection for wastewater reuse applying ORP/pH monitoring and artificial neural networks. *Resources, Conservation and Recycling*, v. 52, n. 8-9, p. 1015-1021. <https://doi.org/10.1016/j.resconrec.2008.03.007>