

## XI-072 - REDE NEURAL ADAPTATIVA APLICADA AO CONTROLE DE PRESSÃO EM SISTEMAS DE DISTRIBUIÇÃO DE ÁGUA

**Geraldo de Araújo Moura** <sup>(1)</sup>

Engenheiro Civil, Mestre e Doutor em Engenharia Mecânica pela Universidade Federal da Paraíba (UFPB). Professor do Instituto Federal de Educação, Ciência e Tecnologia da Paraíba (IFPB).

**Heber Pimentel Gomes**

Engenheiro Civil pela Universidade Federal da Paraíba (UFPB), Mestre em Engenharia Civil pela Universidade Federal de Campina Grande (UFCG) e Doutor em Ingeniería Civil pela Universidad Politécnica de Madrid. Professor Titular da Universidade Federal da Paraíba.

**Simplicio Arnaud da Silva**

Engenheiro Elétrico, Mestre em Engenharia Elétrica e Doutor em Engenharia Mecânica pela Universidade Federal da Paraíba (UFPB). Professor Titular da Universidade Federal da Paraíba.

**Saulo de Tarso Marques Bezerra**

Engenheiro Civil pela Universidade Federal da Paraíba (UFPB), Mestre em Engenharia Civil e Ambiental pela Universidade Federal de Campina Grande (UFCG) e Doutor em Engenharia Mecânica pela Universidade Federal da Paraíba. Professor da Universidade Federal de Pernambuco (UFPE).

**José Kleber Costa de Oliveira**

Graduado em Automação Industrial pelo Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte (IFRN), Mestre em Engenharia Elétrica pela Universidade Federal do Rio Grande do Norte (UFRN) e Doutor em Engenharia Mecânica pela Universidade Federal da Paraíba (UFPB). Professor do Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte (IFRN).

E-mail<sup>(1)</sup>: [mourageraldo@hotmail.com](mailto:mourageraldo@hotmail.com).

### RESUMO

Este artigo propõe uma rede neural adaptativa para a operação de sistemas de distribuição de água. A rede neural foi treinada utilizando o algoritmo Backpropagation com o otimizador de Levenberg-Marquardt, sendo responsável pela manutenção da altura manométrica do sistema de bombeamento em um valor ótimo, eliminando qualquer excesso de pressão no ponto crítico do sistema. O controle de pressão é uma das principais opções técnicas para aumentar a eficiência dos sistemas de distribuição de água, implicando positivamente na vida útil dos sistemas, na redução dos custos operacionais e de manutenção, na redução das interrupções no abastecimento de água, na redução de vazamentos e, conseqüentemente, no aumento da credibilidade das empresas de saneamento com os consumidores. A metodologia proposta do controlador proposto é apresentada e discutida. A vantagem da abordagem proposta é que, uma vez que a rede é treinada, permite o controle automático, com baixo custo computacional, para quaisquer pontos de monitoramento de uma rede de distribuição de água. Os resultados experimentais demonstraram o desempenho do sistema de controle adaptativo e sua capacidade de controlar o processo de distribuição de água. Além disso, o sistema proposto pode ser facilmente aplicado a sistemas de abastecimento de água semelhantes, ajudando a reduzir o consumo de água e eletricidade, bem como os custos de manutenção.

**PALAVRAS-CHAVE:** Abastecimento de Água, Controle de Pressão, Rede Neural Artificial, Levenberg-Marquardt, Eficiência Energética.

### INTRODUÇÃO

O abastecimento de água potável dos centros urbanos envolvem obras de engenharia que vão desde a captação, passando pelo tratamento, até distribuição e entrega ao usuário final. As estações de bombeamento são responsáveis pela pressurização da rede de distribuição de água de maneira direta ou indireta, com auxílio de reservatórios elevados. A complexidade da operação dos sistemas de abastecimentos de água decorre, principalmente, da heterogeneidade da topologia das zonas a serem abastecidas. É exigido dos sistemas a atender, concomitantemente, com vazões e pressões adequadas, a população localizada em regiões próximas e distantes, zonas de topografia altas e baixas. Estas disparidades devem ser enfrentadas através do uso de

estratégias que promovam a adequação entre os valores de pressão e vazão ao longo de toda a rede de distribuição.

Dados do Programa Nacional de Conservação de Energia do Setor de Saneamento (Procel Sanear) do Brasil indicam que o setor de água e esgoto consome aproximadamente 2,5% do consumo total de eletricidade, equivalente a mais de 10 bilhões de kWh/ano, dos quais cerca de 90% % dessa energia é consumida por conjuntos de motobomba (BEZERRA *et al.*, 2015). No mundo, os sistemas de bombeamento representam quase 20% do consumo de energia por motores elétricos e 25-50% do uso total de energia elétrica em instalações industriais (JAMES *et al.*, 2002).

O controle da pressão é o procedimento mais efetivo para aumentar a eficiência dos sistemas de distribuição de água (FRENI *et al.*, 2014; FECAROTTA *et al.*, 2015). As implicações incidem positivamente sobre o aumento da vida útil dos sistemas, a redução de custos com a operação e manutenção, a diminuição nas interrupções do fornecimento de água, a redução sobre os vazamentos e, consequentemente, o aumento da credibilidade das companhias de saneamento junto ao consumidor final. Tem sido amplamente demonstrado que as pressões mais elevadas levam a uma ampliação dos vazamentos e rompimentos dos tubos, além do aumento de consumo (VICENTE *et al.*, 2015).

Ao longo dos últimos anos, vários estudos têm estabelecido a influência negativa da variabilidade de pressão em novas rupturas (falhas) nas tubulações de redes (LAMBERT e THORNTON, 2011). Estudos recentes de Martínez-Codina *et al.* (2015) e Rezaei *et al.* (2015) destacaram o aumento da probabilidade de ocorrência de novas falhas em tubulações em função da variabilidade de pressão. Como consequência, o controle de pressão deve considerar, além da redução da carga hidráulica ao longo da rede hidráulica, a minimização da variabilidade da pressão ao longo do tempo.

A ferramenta mais eficiente para o controle de pressão e eficiência energética nas redes de distribuição de água são os sistemas de automação e controle (PAGE *et al.*, 2016), que tem recebido grande atenção por parte dos pesquisadores e técnicos. A automação de um sistema de abastecimento de água envolve a instrumentação com o uso dos transdutores de pressão e vazão, inversores de frequência, válvulas de controle, sensores de temperatura, controladores lógicos programáveis, além de um eficiente sistema de comunicação. Um sistema supervisor é de extrema importância no monitoramento, em tempo real, da planta, enquanto os algoritmos computacionais inteligentes cumprem o papel do controle automático dos complexos sistemas de abastecimento de água.

Com os avanços tecnológicos das últimas décadas, controladores mais modernos e eficientes estão sendo projetados para processos complexos. A Rede Neural Artificial (RNA) surgiu como uma alternativa ao controle automático de sistemas não lineares e com múltiplas entradas e saídas. Estes sistemas têm demonstrado a sua capacidade de resolver diferentes tipos de processos, que vão desde aplicações simples para controlar sofisticados processos industriais.

Tradicionalmente, os controladores utilizados para os motores são baseados em modelos matemáticos nos quais o sistema de controle é descrito utilizando uma ou mais equações diferenciais que definem a resposta do sistema às suas entradas. Tais sistemas são, frequentemente, implementados com controladores PID (proporcionais-derivativos-integrais). No entanto, essa técnica não é capaz de resolver problemas reais complexos para os quais a modelagem matemática é impraticável. Em sistemas de distribuição de água, uma descrição do modelo matemático do processo é complexa ou pode exigir uma grande quantidade de poder de processamento de computador e memória. Apesar de ser comum a aplicação de técnicas de controle PID, ressalta-se que o sistema não pode sofrer grandes mudanças, com o risco de que o controle se torne instável.

## OBJETIVO GERAL

O objetivo geral da pesquisa foi o desenvolvimento de um sistema inteligente para o controle de pressão em sistemas de distribuição de água, a fim de promover a redução do consumo de água e energia dos conjuntos motor-bomba. O controlador adotou uma Rede Neural Artificial do tipo Perceptron de Múltiplas Camadas, com treinamento por meio do método de retropropagação (*backpropagation*), do gradiente descendente e otimizado por Levenberg-Marquardt. O otimizador tem como principal característica acelerar a convergência

do treinamento por meio da minimização do erro resultante da diferença entre o valor de referência e o valor medido da pressão.

## MATERIAIS E MÉTODOS

### Descrição do sistema

No desenvolvimento do sistema de controle foi utilizada uma bancada experimental de distribuição de água, constituída por um reservatório, sistema de bombeamento, um controlador lógico programável, um inversor de frequência, transdutores de pressão e vazão, além dos acessórios hidráulicos e elétricos (Figura 1). A instalação experimental é composta por duas ramificações com saídas controladas por registros que simulam setores de uma rede de distribuição de água real com demandas distintas.

O inversor de frequência destina-se a manter a pressão no ponto mais crítico da rede hidráulica igual à pressão desejada (pressão de referência). Para estações de bombeamento onde a regulação de vazão é necessária, a melhor solução técnica e econômica é o controle da velocidade da bomba.

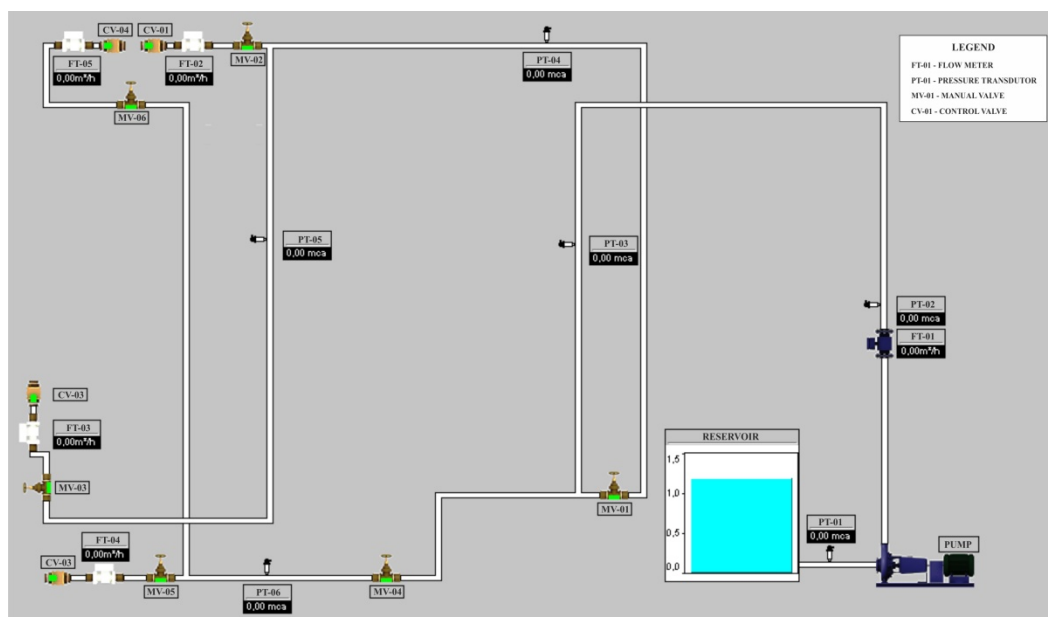


Figura 1: Sistema experimental de distribuição de água.

Um sistema supervisor de aquisição e transmissão de dados do tipo SCADA foi desenvolvido para o controle das condições de operação da rede. O supervisor permite que o desenvolvimento de rotinas de simulação e monitoramento da rede em tempo real, possibilitando que os dados coletados sejam tratados e armazenados em um banco de dados. Este sistema foi concebido em ambiente LabVIEW® com o protocolo de comunicação Modbus.


### Rede Neural Adaptativa

O desenvolvimento do sistema de controle adaptativo foi antecedido pela definição das características da Rede Neural Artificial - RNA. A arquitetura considerada mais adequada para a rede dispõe de uma única camada oculta. Este fato não resultou em perda de qualidade ou mesmo capacidade de aprendizado, pois está é capaz de identificar um sistema com a mesma precisão que teria uma RNA com múltiplas camadas ocultas.

Foi adotado o treinamento *off-line* assistido, em que são apresentados os dados de entrada e saída desejados. Nesta pesquisa, o valor da pressão mínima no(s) ponto(s) de monitoramento e a frequência de acionamento do conjunto motor-bomba correspondem aos dados de entrada e saída, respectivamente. Foi percebido, ao longo das primeiras tentativas de treinamento, que o número de dados era um limitante ao aprendizado. Portanto foi necessária a multiplicação dos dados até valores que garantisse um treinamento satisfatório

O RNA adota o algoritmo de *Backpropagation* para executar o treinamento paralelo e melhorar a eficiência da rede Perceptron com múltiplas camadas, sendo esse o modelo mais popular, eficaz e fácil de aprender para este tipo de RNA (SAPNA *et al.*, 2012). A *Backpropagation* é uma técnica de aprendizagem supervisionada que se baseia no método Gradiente Descendente, que busca a minimização do erro.

Concluída as fases de aquisição e tratamento dos dados, treinamento supervisionado e validação, partiu-se para o desenvolvimento do controlador neural adaptativo usando o Algoritmo Levenberg-Marquardt Backpropagation, que possui como principal característica a atualização dos pesos da RNA em tempo real (Figura 2). A vantagem da abordagem proposta é que, uma vez que a rede é treinada, permite a avaliação instantânea da solução com um custo computacional insignificante.



**Figura 2: Diagrama de blocos do Sistema de Controle Neural Adaptativo.**

Onde:  $P_{REF}$  – valor de referência da pressão no ponto de medição;  $P_{NET}$  – pressão no ponto de monitoramento;  $F_r$  – Frequência de acionamento do conjunto motor-bomba;  $E$  – Erro que corresponde à diferença entre  $P_{REF}$  e  $P_{NET}$ ;  $W$  – Pesos sinápticos entre as camadas de entrada e intermediária.

O Módulo 1 é iniciado com base no valor de referência da pressão e pelos pesos sinápticos. A conclusão deste módulo acontece com o cálculo da frequência de acionamento do conjunto motor-bomba. Esta etapa diz respeito à fase *forward* da RNA. Em seguida, será calculado o Erro, que corresponde à diferença entre o *set-point* da pressão e o valor medido. Na sequência, o Módulo 2 será executado, dando início a aplicação do método *Backpropagation*. O Algoritmo Levenberg-Marquardt finaliza o Módulo 2, que responderá com novos valores dos pesos sinápticos à serem alimentados no Módulo 1. Este procedimento será repetido enquanto o controlador estiver atuando sobre a planta.

### Levenberg-Marquardt Aplicado Ao Controle Neural Adaptativo

Este tópico apresenta um breve desenvolvimento do Algoritmo Levenberg-Marquardt (LM) e o tratamento matemático pertinente. O Algoritmo LM é especificamente direcionado para a minimização de funções de erros quadráticas. Nessa pesquisa, o algoritmo foi aplicado na minimização do erro resultante da diferença entre o valor de referência da pressão e a pressão medida na rede (Eq. 1).

$$E = \sum (P_{REF} - P_{NET})^2 \quad \text{equação (1)}$$

Onde  $E$  é o erro quando todos os padrões de treinamento são introduzidos;  $P_{REF}$  é o valor de referência da pressão;  $P_{NET}$  é a pressão no ponto de monitoramento.

De posse do valor do erro  $E$ , e aplicado o método *backpropagation*, que permite a determinação dos gradientes relativos aos seus respectivos pesos. Sem distinção entre os pesos entre as camadas de entrada e intermediária e entre as camadas intermediária e a camada de saída, temos que os gradientes (incremento/decremento) relativos aos seus respectivos pesos serão calculados pela Eq. 2.

$$\Delta W_t = \Delta W_{t+1} - \Delta W_t \quad \text{equação (2)}$$

Onde  $\Delta W_t$  é o gradiente relativo ao respectivo peso sináptico;  $W_{t+1}$  é o peso no instante  $t+1$ ; e  $W_t$  é o peso no instante  $t$ .

O Algoritmo LM é uma variação do Método de Newton descrito pelas Equações 3, 4 e 5.

$$\Delta \mathbf{W}_t = [\mathbf{H}(\mathbf{W})]^{-1} \mathbf{J}(\mathbf{W}) \cdot \mathbf{E}(\mathbf{W}) \quad \text{equação (3)}$$

$$\mathbf{H}(\mathbf{W}) = \nabla^2 \mathbf{E}(\mathbf{W}) \quad \text{equação (4)}$$

$$\mathbf{J}(\mathbf{W}) = \nabla \mathbf{E}(\mathbf{W}) \quad \text{equação (5)}$$

Onde  $\mathbf{J}(\mathbf{W})$  é a Matriz Jacobiana, descrita pela Eq. 6;  $\mathbf{H}(\mathbf{W})$  é a Matriz Hessiana.

$$\mathbf{J}(\mathbf{W}) = \nabla \mathbf{I}_d(\mathbf{W}) = \begin{bmatrix} \frac{\partial \mathbf{I}_d(\mathbf{W}_{1,1}^{ei})}{\partial (\mathbf{W}_{1,1}^{ei})} & \frac{\partial \mathbf{I}_d(\mathbf{W}_{1,1}^{ei})}{\partial (\mathbf{W}_{1,1}^{ei})} & \dots & \frac{\partial \mathbf{I}_d(\mathbf{W}_{1,j}^{ei})}{\partial (\mathbf{W}_{1,j}^{ei})} \\ \frac{\partial \mathbf{I}_d(\mathbf{W}_{1,1}^{is})}{\partial (\mathbf{W}_{1,1}^{is})} & \frac{\partial \mathbf{I}_d(\mathbf{W}_{1,2}^{is})}{\partial (\mathbf{W}_{1,2}^{is})} & \dots & \frac{\partial \mathbf{I}_d(\mathbf{W}_{1,j}^{is})}{\partial (\mathbf{W}_{1,j}^{is})} \end{bmatrix} \quad \text{equação (6)}$$

Onde  $\frac{\partial \mathbf{I}_d(\mathbf{W}_{1,1}^{is})}{\partial (\mathbf{W}_{1,1}^{is})}$  e  $\frac{\partial \mathbf{I}_d(\mathbf{W}_{1,1}^{ei})}{\partial (\mathbf{W}_{1,1}^{ei})}$  são parâmetros da Matriz Jacobiana são calculados pelas Equações 7 e 8.

$$\frac{\partial \mathbf{I}_d(\mathbf{W}_{k,m}^{is})}{\partial (\mathbf{W}_{k,m}^{is})} = (\mathbf{E} \times \mathbf{Y}_k^i)_{(t)} \quad \text{equação (7)}$$

$$\frac{\partial \mathbf{I}_d(\mathbf{W}_{j,k}^{ei})}{\partial (\mathbf{W}_{j,k}^{ei})} = \left( \mathbf{E} \cdot \mathbf{W}_{k,m}^{is} \frac{\beta_k^i}{2} [1 - (\mathbf{Y})^2] \mathbf{X}_j^e \right)_{(t)} \quad \text{equação (8)}$$

A matriz Hessiana (Eq. 8) envolve derivadas de segunda ordem, o que implica em um custo computacional elevado. Diante disto, técnicas alternativas estão sendo desenvolvidas com o objetivo de otimizar o processo de cálculo. É o caso do método de Gauss-Newton, que propõe uma aproximação para a matriz Hessiana como o produto da transposta da matriz Jacobiana por ela própria, Eq. 10.

$$\mathbf{H}(\mathbf{W}) = \nabla^2 \mathbf{I}_d(\mathbf{W}) = \begin{bmatrix} \frac{\partial^2 \mathbf{I}_d(\mathbf{W}_{1,1}^{ei})}{\partial \mathbf{W}_{1,1}^{ei 2}} & \frac{\partial^2 \mathbf{I}_d(\mathbf{W}_{1,1}^{ei})}{\partial \mathbf{W}_{1,1}^{ei 2}} & \dots & \frac{\partial^2 \mathbf{I}_d(\mathbf{W}_{1,j}^{ei})}{\partial \mathbf{W}_{1,j}^{ei 2}} \\ \frac{\partial^2 \mathbf{I}_d(\mathbf{W}_{1,1}^{is})}{\partial \mathbf{W}_{1,1}^{is 2}} & \frac{\partial^2 \mathbf{I}_d(\mathbf{W}_{1,2}^{is})}{\partial \mathbf{W}_{1,2}^{is 2}} & \dots & \frac{\partial^2 \mathbf{I}_d(\mathbf{W}_{1,j}^{is})}{\partial \mathbf{W}_{1,j}^{is 2}} \end{bmatrix} \quad \text{equação (9)}$$

$$\mathbf{H}(\mathbf{W}) \cong \mathbf{J}^T(\mathbf{W}) \cdot \mathbf{J}(\mathbf{W}) \quad \text{equação (10)}$$

Apesar das considerações, a aplicação do Método Gauss-Newton ainda é complexa. Quando os valores de  $\mathbf{W}$  encontram-se distante do valor ótimo esperado, o processo iterativo resultará dispendioso devido ao comprimento do passo ser pequeno, provocando uma lenta convergência do método. Para alguma aproximação de  $\mathbf{W}$ , durante o processo iterativo, a aproximação da Matriz Hessiana pode tornar-se negativa, o que invalida o método por não admitir a respectiva matriz inversa. Para contornar esses impedimentos, Levenberg e em seguida Marquardt propuseram a Eq. 11.

$$\Delta \mathbf{W}_t \cong [\mathbf{J}^T(\mathbf{W}) \cdot \mathbf{J}(\mathbf{W}) + \lambda \mathbf{I}]^{-1} \mathbf{J}(\mathbf{W}) \cdot \mathbf{E}(\mathbf{W}) \quad \text{equação (11)}$$

Onde  $\mathbf{I}$  é a matriz identidade de mesma ordem da aproximação da Matriz Hessiana e  $\lambda$  é o parâmetro de Levenberg-Marquardt.

O parâmetro de Levenberg-Marquardt usado nesta pesquisa foi proporcional ao erro quadrático, Eq. 12. Isto promoverá a diminuição do custo computacional e, consequentemente, a aceleração do processo de convergência. O parâmetro  $\lambda$  multiplicado pela matriz identidade  $I$  ( $\lambda \cdot I$ ) somado a aproximação da matriz Hessiana,  $J^T(W) \cdot J(W)$ , cumprirá o papel de garantir que o resultado da soma,  $[J^T(W) \cdot J(W) + \lambda \cdot I]$ , que será sempre positiva e consequentemente admitirá o cálculo da sua inversa. Os valores de  $\Delta W_{t-1}$  calculados a cada iteração serão propagados à frente (*forward*), a fim de determinar os novos valores dos pesos  $\Delta W_t$ . Ao término deste processo o algoritmo de retropropagação (*backpropagation*), os novos valores de  $\Delta W_t$  serão usados na nova matriz Jacobiana. Essas etapas são repetidas até que o erro quadrático atenda ao critério pré-estabelecido no projeto.

$$\lambda = \sum (P_{REF(t)} - P_{NET(t)})^2 \quad \text{equação (12)}$$

Destaca-se que a eficiência do Método de LM despertou na comunidade científica um grande interesse sobre a determinação de parâmetro  $\lambda$ . Atualmente, inúmeros estudos são realizados com o objetivo de propor melhores técnicas de ajuste deste parâmetro.

## RESULTADOS E DISCUSSÃO


O treinamento e validação da RNA do sistema de controle resultaram em uma arquitetura composta por um neurônio na camada de entrada, 13 (onze) neurônios na camada intermediária e um neurônio na camada de saída. A função de ativação utilizada nos neurônios da camada intermediária foi a tangente hiperbólica, com valor constante de 0,18 para o parâmetro  $\beta$  da função. O limiar de ativação (bias) da camada intermediária foi definido “por tentativa e erro” e foi -1,0. Este valor é adotado com frequência na literatura. A Tabela 1 mostra os parâmetros do Sistema de Controle Neural Adaptativo.

**Tabela 1: Parâmetros do Sistema de Controle Neural Adaptativo.**

Pesos entre as camadas de entrada e intermediária												
$W_{1,1}^{ei}$	$W_{1,2}^{ei}$	$W_{1,3}^{ei}$	$W_{1,4}^{ei}$	$W_{1,5}^{ei}$	$W_{1,6}^{ei}$	$W_{1,7}^{ei}$	$W_{1,8}^{ei}$	$W_{1,9}^{ei}$	$W_{1,10}^{ei}$	$W_{1,11}^{ei}$	$W_{1,12}^{ei}$	$W_{1,13}^{ei}$
-0,32	1,77	0,58	1,23	0,71	-0,05	-0,02	0,64	1,23	1,33	0,19	-0,003	0,17
Pesos entre as camadas intermediária e saída												
$W_{1,1}^{is}$	$W_{2,1}^{is}$	$W_{3,1}^{is}$	$W_{4,1}^{is}$	$W_{5,1}^{is}$	$W_{6,1}^{is}$	$W_{7,1}^{is}$	$W_{8,1}^{is}$	$W_{9,1}^{is}$	$W_{10,1}^{is}$	$W_{11,1}^{is}$	$W_{12,1}^{is}$	$W_{13,1}^{is}$
-0,94	0,24	-0,42	-0,15	-0,38	-0,80	-0,74	-0,48	-0,15	0,007	-0,66	-0,75	-0,71

Finalizada as etapas de treinamento e validação da RNA, deu-se prosseguimento a aplicação do sistema de controle neural adaptativo com otimizador de Levenberg-Marquardt. Três tipos de experimentos foram realizados para avaliar a eficiência do sistema de controle desenvolvido.


O Experimento 1 foi realizado para o valor de referência de 12,5 mca para o ponto de medição de pressão. Com este procedimento, foram obtidos os indicadores de desempenho do sistema de controle (sobressinal, tempo de assentamento e erro de estado estacionário). O tempo de assentamento foi de 19 segundos, o erro máximo foi de 1,52% (0,19 mca) e não houve sobressinal (*overshoot*). A Figura 3 mostra a curva de resposta do Sistema de Controle Neural Adaptativo.



**Figura 3: Curva de resposta do Sistema de Controle Neural Adaptativo.**




A fim de verificar a eficiência da RNA Adaptativa às diferentes valores de referência (*set-point*), o sistema de controle foi submetido ao Experimento 2, que impôs uma sequência de valores de referência para a pressão. A Figura 4 mostra o comportamento da pressão ao longo deste experimento. Inicialmente, a pressão de referência foi 12,5 mca; em seguida, o controlador foi submetido a um *set-point* de 8,0 mca. Esta transição foi realizada de maneira suave. A mudança para a pressão referência de 9,0 mca foi satisfatória. Finalmente, o sistema atinge a pressão de referência de 14,0 mca com eficiência. Os resultados foram satisfatórios e observou-se a ausência de sobressinal (*overshoot*).



**Figura 4: Comportamento da pressão com o do Sistema de Controle Neural Adaptativo submetido a vários set-points.**

Um sistema de controle é considerado robusto quando é capaz de manter a estabilidade do sistema quando submetido a mudanças brutais na planta. A fim de promover distúrbios na instalação experimental, duas válvulas localizadas na saída dos tubos foram abertas simultaneamente. Este procedimento foi projetado para alterar drasticamente as vazões ao longo da rede hidráulica – o que poderia ser comparado a um aumento da demanda em uma rede de distribuição de água real. A Figura 5 mostra que o controlador respondeu satisfatoriamente às condições causadas pela perturbação, restabelecendo a pressão no valor desejado.



**Figura 5: Curva de resposta do Sistema de Controle Neural Adaptativo quando submetido a um distúrbio.**

## CONCLUSÕES

Este artigo apresenta um sistema inteligente para controlar a pressão de redes de distribuição de água. O objetivo do estudo foi projetar um controlador robusto para quaisquer valores de referência (*set-point*) de pressão. Não há limite para o número de pontos monitorados a serem controlados; além disso, os valores de referência de pressão nestes pontos podem mudar ao longo do tempo.

O sistema de controle neural adaptativo com um otimizador de Levenberg-Marquardt mostrou-se satisfatório na configuração experimental. As principais vantagens do sistema de controle são a ausência de necessidade de modelagem da planta, sua adaptabilidade a diferentes condições de operação e sua aplicabilidade para sistemas dinâmicos complexos. Assim, espera-se que o sistema de controle desenvolvido possa ser facilmente implementado em redes de distribuição de água semelhantes.

## REFERÊNCIAS BIBLIOGRÁFICAS

1. BEZERRA, S.T.M., SILVA, S.A., GOMES, H.P., SALVINO, M.M. *Energy savings in pumping systems: application of a Fuzzy system. Ciência & Engenharia*, v.24, n.1, p.71-78, 2015.
2. FECAROTTA, O., ARICÒ, C., CARRAVETTA, A., MARTINO, R., RAMOS, H.M. *Hydropower potential in water distribution networks: Pressure control by PATs. Water Resources Management*, v.29, n.3, p.699-714, 2015.
3. FRENI, G., DE MARCHIS, M., NAPOLI, E. *Implementation of pressure reduction valves in a dynamic water distribution numerical model to control the inequality in water supply. Journal Hydroinformatics*, v.16, n.1, p.207-217, 2014.
4. JAMES, K., CAMPBELL, S.L., GODLOVE, C.E. *Água e Energia: Aproveitando as oportunidades de eficiência de água e energia não exploradas nos sistemas municipais. Washington - USA, Alliance to Save Energy*, 2002.
5. LAMBERT, A., THORNTON, J. *The relationships between pressure and bursts 'state-of-the-art' update. Water*, v.21, p.37-38, 2011.
6. MARTÍNEZ-CODINA, Á., CUETO-FELGUEROSO, L., CASTILLO, M., GARROTE, L. *Use of pressure management to reduce the probability of pipe breaks: a Bayesian approach. Journal of Water Resources Planning and Management*, v.141, n.9, p.04015010, 2015.
7. PAGE, P.R., ABU-MAHFOUZ, A.M., YOYO, S. *Real-time adjustment of pressure to demand in water distribution systems: parameter-less P-controller algorithm. Procedia Engineering*, v.154, p.391-397, 2016.
8. REZAEI, H., RYAN, B., STOIANOV, I. *Pipe failure analysis and impact of dynamic hydraulic conditions in water supply networks. Procedia Engineering*, v.119, p.253-262, 2015.
9. SAPNA, S., TAMILARASI, A., KUMAR, M.P. *Backpropagation learning algorithm based on Levenberg Marquardt Algorithm. Journal of Computer Science and Information Technology*, v.2, p.393-398, 2012.
10. VICENTE, D.J., GARROTE, L., SÁNCHEZ, R., SANTILLÁN, D. *Pressure management in water distribution systems: Current status, proposals, and future trends. Journal of Water Resources Planning and Management*, v.142, n.2, p.04015061, 2015.