

CONTROLE AUTORREGRESSIVO PARA ESTABILIZAÇÃO DA PRESSÃO EM SISTEMAS DE BOMBEAMENTO COM DEMANDA VARIÁVEL

HUGO A. M. MOREIRA*, KAMILLA H. MENDONÇA*, HEBER P. GOMES*, JUAN M. VILLANUEVA**, ANDERSON V. S. SILVA***

*Laboratório de Eficiência Energética e Hidráulica em Saneamento - LENHS, Departamento de Engenharia Mecânica UFPB, Campus I - Lot. Cidade Universitária, PB, 58051-900, Brasil

(Tel: 55 81 989067001; e-mail: HugoMarinho93@outlook.com, Kamillapdm@hotmail.com, Heberp@uol.com.br)

** Laboratório de Eficiência Energética e Hidráulica em Saneamento - LENHS, Departamento de Engenharia Elétrica UFPB, Campus I - Lot. Cidade Universitária, PB, 58051-900, Brasil

(e-mail: Jmauricio@cear.ufpb.br)

***Instituto Federal de Pernambuco, IFPE, Campus Caruaru, PE, 55034-580, Brasil

(e-mail: Vini1708@hotmail.com)

Abstract: The control of pressures in water pumping systems is an effective energy efficiency measure. Moreover, in systems with variable demand, more robust methods should be used due to the dynamic changes inherent to the process. This work proposed an ARX controller (Autoregressive with Exogenous Input) to control the pressures of a pumping system with variable demand. The controller is responsible for regulating the motor pump set rotation speed to maintain pressure in set points. The ARX controller obtained by computational modeling, for that, a Fuzzy controller was used to build the training database. Concomitant, a method of minimizing the variability of the training data proposed, with the objective of increasing the performance of the proposed controller. The controller was tested in an experimental system, aiming of analyzing and comparing its results to other controllers (Neural and Fuzzy) on a transient, permanent basis and with respect to disturbances. The control of pressures was observed at the set points, without overshoot and with low hydraulic transient, in addition to excellent stability (**error** <5%) in severe situations of demand variation. It is concluded that the proposed control technique presents a concrete gain in the stability and control of the pumping system.

Resumo: O controle das pressões em sistemas de bombeamento de água é uma medida eficaz de eficiência energética. Além disso, em sistemas com demanda variável, métodos mais robustos devem ser utilizados devido às mudanças dinâmicas inerentes ao processo. Este trabalho propôs um controlador ARX (Autoregressivo com Entrada Exógena) para o controle das pressões de um sistema de bombeamento com demanda variável. O controlador é responsável por regular a velocidade de rotação do conjunto motobomba para manter as pressões nos *set-points*. O controlador ARX é obtido por modelagem computacional; para tanto, foi utilizado um controlador Fuzzy para a construção do banco de dados de treinamento. Concomitante, é proposto um método de minimização das variabilidades dos dados de treinamento, com o objetivo de aumentar a performance do controlador proposto. O controlador foi testado em um sistema experimental, objetivando analisar e comparar seus resultados à outros controladores (Neural e Fuzzy) em regime transitório, permanente e com relação à distúrbios. Observou-se o controle das pressões nos *set-points*, sem *overshoot* e com baixo transiente hidráulico, além de ótima estabilidade (**erro** <5%) em situações severas de variação de demanda. Conclui-se que a técnica de controle proposta apresentou um ganho concreto na estabilidade e controle do sistema de bombeamento.

Keywords: Automation; Speed control; Energy efficiency; Controller autoregressive.

Palavras-chaves: Automação; Controle de velocidade; Eficiência Energética; Controlador autoregressivo.

1. INTRODUÇÃO

Sistemas hidráulicos possuem relevância crucial na sociedade moderna, sendo extremamente importantes em processos industriais, onde são utilizados, principalmente, para o controle de processos, geração e transmissão de energia por meio de fluidos pressurizados (Diniz *et al.*, 2015). No cotidiano, os sistemas hidráulicos são utilizados para o

fornecimento de água. Os sistemas de abastecimento são o conjunto de equipamentos, obras e serviços voltados para o suprimento de água, para fins de consumo doméstico, industrial e público. A concepção e o dimensionamento dos sistemas de bombeamento e distribuição ocorrem de forma integrada, o que requer uma equipe de profissionais especializados. Devido às suas dimensões e particularidades,

estes sistemas apresentam elevada complexidade que dificultam o seu projeto e análise.

Além disso, estes sistemas consomem uma quantidade desnecessária de energia, principalmente, devido a variação de demanda, que é atribuída aos hábitos da sociedade. A variação de demanda resulta na alteração dinâmica do sistema, o que resulta no descontrole das pressões de serviço; para mitigar esses efeitos, é exigida a utilização de métodos de controle e de racionalização energética para diversos cenários de operação.

O controle das pressões tem sido visto como uma medida eficaz de eficiência energética, o que é alcançado com a utilização de dispositivos atuadores, tais como inversores de frequência e válvulas redutoras de pressão, e sensores unido às técnicas de controle em malha fechada para o monitoramento da velocidade de rotação do conjunto motobomba (CMB) (Brogan *et al.*, 2016). Neste modo de operação é possível aumentar a eficiência energética do sistema de bombeamento, reduzindo a energia consumida pelo CMB, ao operar fora da velocidade nominal. Entretanto, os sistemas de abastecimento de água apresentam características de alta não-linearidade. Além de serem variantes no tempo, pois são dependentes da demanda horária de água, de falhas e manutenção. Assim, técnicas mais robustas são necessárias para o monitoramento, controle e operação afim de minimizar os custos energéticos, aumentar a eficiência e garantir as condições necessárias para atender o consumidor final em quantidade e qualidade (Babunski *et al.*, 2018).

Algumas estratégias, convencionais, para o controle das pressões de serviço remetem ao uso de controle clássico PID (Proporcional-Integral-Derivativo) (Page *et al.*, 2017 e Anjana *et al.*, 2017). Entretanto, a formulação de um modelo matemático, cuja complexidade é muitas vezes elevada, dificulta o desenvolvimento deste controlador, principalmente em situações de mudanças dinâmicas e temporais do sistema.

Há também estratégias baseadas em inteligência artificial, tais como Redes Neurais Artificiais (RNA) e lógica Fuzzy (Camboim, 2012; Carvalho, 2012; Diniz *et al.*, 2015; Mendonça, 2016; Salvino, 2016; Oliveira, 2017; Barros *et al.*, 2017; Moura *et al.*, 2018; Moreira *et al.*, 2019 e Mendonça *et al.*, 2019), todas com o objetivo de controlar as pressões da rede de abastecimento através do controle de rotação dos CMBs. Entretanto, têm-se observado que os controladores heurísticos não satisfazem o desempenho exigido pelos sistemas de abastecimento e distribuição de água em condições severas de demanda variável. Concomitante, a complexidade no projeto destes controladores, que exige a expertise de um operador do sistema a ser controlado para a construção da base de regras e formação dos conjuntos, torna o processo extremamente empírico. Usa-se então, técnicas adaptativas, como as RNA. Entretanto, essas são mais complexas e exigem elevado conhecimento em programação.

É bastante comum também o uso de controle preditivo, com o uso de modelos regressivos de sistemas de bombeamento e distribuição de água (Barcelli *et al.*, 2010; Trnka *et al.*, 2011; Martinez *et al.*, 2012; Pascual *et al.*, 2011; Sampathirao *et al.*, 2014; Puig *et al.*, 2017 e Zulkeflee *et al.*, 2017) e até para bombeamento de óleo (Binder *et al.*, 2014; Sharma *et al.*,

2013; Pavlov *et al.*, 2014 e Krishnamoorthy *et al.*, 2016) com a finalidade de regular as pressões na rede através do controle dos CMBs. Apesar de comum a representação de sistemas com modelos autoregressivos com entradas exógenas (ARX), o seu uso, especificamente, como controlador ainda não foi investigado em sistemas de bombeamento ou hidráulicos com demanda variável.

Este trabalho foi fundamentado na hipótese de que os controladores obtidos por modelagem caixa preta baseiam-se no comportamento dinâmico do controlador primário, para modelar as tendências que esses apresentam. Desta forma, mesmo utilizando dados ruidosos e algumas vezes imprecisos, para o treinamento, o modelo apresenta bom desempenho.

Neste trabalho é proposto a implementação de um controlador ARX em um sistema de bombeamento de água com demanda variável, através de uma nova abordagem para a minimização das variabilidades dos dados de treinamento, com o objetivo de aumentar a performance do controlador. O controle atua na variação da velocidade de rotação do CMB, alterando-a conforme a mudança da pressão, provocada pela variação de demanda. Como contribuição da inserção desta proposta de controle, visa-se o aumento da estabilidade do sistema de bombeamento submetido à condições críticas de variação de vazão. Como benefícios secundários, observa-se a redução do consumo energético. O sistema experimental encontra-se instalado no Laboratório de Eficiência Energética e Hidráulica em Saneamento (LENHS) da Universidade Federal da Paraíba (UFPB), Brasil.

2. SISTEMAS DE ABASTECIMENTO DE ÁGUA

Os sistemas de bombeamento e distribuição de água têm um impacto ambiental e energético significativo, pois demandam uma grande quantidade de energia elétrica na etapa de bombeamento, além de apresentar perdas em todo seu percurso. Tais sistemas são responsáveis por, aproximadamente, 3% da energia consumida no mundo, sendo o sistema de bombeamento responsável por até 90% desse montante (Gomes *et al.*, 2012). As estações de bombeamento são responsáveis por fornecer energia hidráulica, na forma de pressão e vazão, suficientes à água para vencer os desníveis geográficos, perda de carga e ainda chegar com pressão suficiente aos consumidores. A soma destas variáveis é denotada por altura manométrica total (H_{MAN}) e usualmente utiliza-se a unidade de Metros de Coluna de Água (mca).

Tais sistemas apresentam duas problemáticas que surgem devido a variação horária de demanda – como ilustra a Fig. 1. Desta forma, são observadas a: (1) grande variação das pressões de serviço; (2) alto consumo energético. Isso porque, em horários de menores demandas, o sistema de bombeamento, que foi projetado para operar em sua velocidade nominal, alimentará a rede de água com uma pressão excedente, aumentando o gasto energético do sistema e a probabilidade de rompimento e vazamento das tubulações; o contrário é observado em horários de maiores demandas. Essa ciclagem faz com que a pressão do sistema flutue ao longo do dia, aumentando drasticamente o consumo energético. Existem ainda variações sazonais semanais,

mensais e anuais, o que aumenta as características dinâmicas do sistema. Para que os sistemas de controle atendam bem estes cenários, eles devem apresentar robustez objetivando a menor variação de pressão em períodos de variação de demanda.




Fig. 1 – Perfil de consumo horário (Gomes *et al.*, 2012). O coeficiente K é um vetor normalizado que indica a demanda horária.

3. MODELAGEM COMPUTACIONAL

Modelos computacionais são projetados para obter uma noção do comportamento do sistema como predição, controle, estimação do estado e simulação (Moscinski e Ogonowski; 1995; Aguirre, 2004; Bittencourt, 2007). Resumidamente, as etapas utilizadas na obtenção de um modelo computacional de um sistema dinâmico são:

- i. Planejamento experimental – determinação de como os dados serão coletados, isto é, qual o método de amostragem a ser utilizado;
- ii. Seleção da estrutura do modelo – seleção da estrutura do modelo e posterior determinação dos parâmetros passíveis de serem ajustados, chamados parâmetros livres;
- iii. Estimação de parâmetros – ajuste dos parâmetros livres usando as estatísticas obtidas dos dados;
- iv. Validação – avaliação do desempenho do modelo para os dados de teste.

3.1 Modelos paramétricos

De forma geral, os modelos paramétricos são métodos utilizados para estimar os parâmetros (θ) do modelo. Considere um modelo dado pela equação de diferenças, como em (1):

$$y(t) + ay(t - 1) = bu(t - 1) + e(t) \quad (1)$$

Em que $y(t)$ é a saída, $u(t)$ a entrada, t o tempo, e o erro, a e b são constantes do modelo.

Esse é um típico modelo discreto de primeira ordem, e seu vetor de parâmetros é definido segundo (Moscinski e Ogonowski, 1995) por (2):

$$\theta = (a; b) \quad (2)$$

Os dados utilizados para identificar modelos dinâmicos são gerados por medições da resposta $y(t)$ do sistema alimentado por uma entrada $u(t)$ pré-especificada. O sinal de entrada deve possuir espectro suficientemente amplo em amplitude e frequência para excursionar o sistema pelos regimes dinâmicos de interesse (Rodrigues, 1996).

Há algumas estruturas de modelos padrões utilizadas na identificação paramétrica, que normalmente são estruturas de modelos discretos (Bittencourt, 2007). Dentre os diferentes modelos utilizados, destacam-se: Box-Jenkins (BJ), Output Error (OE), Autoregressivo com Entrada Exógenas (ARX), Autoregressivo com Média Móvel e Entradas Exógenas (ARMAX) e estrutura de Espaço de Estados (SS). A estrutura geral de modelos paramétricos pode ser definida pela equação de diferenças, como descrito em (3) (Ljung e Glad, 2019):

$$A(q)y(t) = \frac{B(q)}{F(q)}u(t - n_k) + \frac{C(q)}{D(q)}e(t) \quad (3)$$

Na equação a diferenças - (3) - o número de intervalos de amostragem entre a saída mais atrasada e a menos atrasada é igual ao número de polos do sistema. Da mesma forma o número de intervalos de amostragem entre a entrada mais atrasada e menos atrasada é igual ao número de zeros do sistema (Ljung e Glad, 2019).

Nessa estrutura q^{-1} representa o operador de atraso, ou seja:

$$\begin{aligned} q^{-1}u(t) &= u(t - T) \\ q^{-2}u(t) &= u(t - 2T) \end{aligned} \quad (4)$$

n_k é o número de atrasos da entrada para saída, ou seja, o atraso puro de tempo Ljung (2019):

$$\begin{aligned} A(q) &= 1 + a_1q^{-1} + \dots + a_{n_a}q^{-n_a} \\ B(q) &= b_1 + b_2q^{-1} + \dots + b_{n_b}q^{-n_b+1} \\ C(q) &= 1 + c_1q^{-1} + \dots + c_{n_c}q^{-n_c} \\ D(q) &= 1 + d_1q^{-1} + \dots + d_{n_d}q^{-n_d} \\ F(q) &= 1 + f_1q^{-1} + \dots + f_{n_f}q^{-n_f} \end{aligned} \quad (5)$$

onde n_a , n_b , n_c , n_d e n_f são as ordens dos respectivos polinômios. Note que $A(q)$ corresponde aos polos comuns entre a modelagem da dinâmica do sistema e a modelagem do ruído - útil em casos que se assume que o ruído entra no sistema junto com entrada. Já $F(q)$ e $B(q)$ representam polos e zeros que afetam somente a entrada e $D(q)$ e $C(q)$ os polos e zeros que afetam somente o ruído (Ljung e Glad, 2019), como ilustra a Fig. 2.




Fig. 2 – Modelo geral para a identificação paramétrica.

Modelo ARX

Esse modelo é definido através da simplificação do modelo geral, descrito por (3), considerando $C=D=F=1$, obtém-se (6), que representa o modelo ARX.

$$A(q)y(t) = B(q)u(t - nk) + e(t) \quad (6)$$

O modelo ARX é considerado o modelo mais simples de ser estimado. Entretanto, tem a desvantagem do polinômio $A(q)$ representar tanto a dinâmica do sistema quanto as propriedades do ruído. Assim, torna-se fácil de estimar incorretamente a dinâmica do sistema e talvez sejam necessárias ordens mais altas dos polinômios $A(q)$ e $B(q)$. Se a relação sinal/ruído for boa, essa desvantagem não tem muita importância (Ljung e Glad, 1994). A estimativa do modelo ARX é, também, o mais eficiente dos métodos de estimação polinomiais porque é o resultado de resolução de equações de regressão linear em forma analítica. Além disso, a solução é única. Em outras palavras, a solução sempre satisfaz o mínimo global de perda de função. Por conseguinte, o modelo ARX é preferível, especialmente quando a ordem do modelo é alta (National Instrument, 2020).

4. MATERIAIS E MÉTODOS

4.1 Sistema Experimental

Este trabalho foi desenvolvido em uma bancada instrumentalizada ilustrada na Fig. 3. A bancada foi construída com o objetivo de emular sistemas reais de bombeamento e abastecimento de água com demanda variável com a finalidade de realizar ensaios experimentais de sistemas de controle. Entre as variáveis de entrada estão a frequência do inversor e o ângulo da Válvula Redutora de Pressão (VRP). A VRP é responsável por deslocar verticalmente a curva da tubulação e alterar a demanda de água, fazendo com que o controlador atue encontrando um novo ponto de equilíbrio através do controle de velocidade das bombas. Entre as variáveis de saída estão a pressão de três pontos (sucção, recalque e a jusante), a vazão e a potência ativa do CMB.

A bancada é equipada com um Sistema de Supervisão e Aquisição de Dados (SCADA) da National Instruments (NI USB-6229) que é utilizado na aquisição de dados da planta e no controle do conversor de frequência e da VRP. Um conversor de frequência (Schneider Electric - ALTIVAR 31) é responsável por ajustar a velocidade do CMB (DANCOR - CAM W10 com 3 HP). A VRP (ARB24-SR) é comandada através do supervisório desenvolvido na plataforma

LABVIEW; ela tem como função variar o consumo de água e, conseqüentemente, as pressões para que o controlador atue mantendo as pressões nos set-points. O sensoramento fica a cargo de três transdutores de pressão (Druck PTX 7217) e um transdutor de vazão eletromagnético (VMS Pro 038), bem como, de um sinal enviado pelo inversor de frequência para a leitura da potência ativa do CMB e um enviado pela VRP para indicar o seu ângulo de abertura.




Fig. 3 – Esquemático da bancada experimental.

4.2 Sistema de controle

Controlador Primário

Neste trabalho é proposta a utilização de um controlador primário (Fuzzy Mandani) – com superfície de controle ilustrada na Fig. 4 – para controlar o sistema e gerar a paridade de dados de treinamento. Este mesmo controlador é utilizado na análise comparativa na seção de resultados. Sua escolha foi motivada devido ao seu uso recente no trabalho de Moreira *et al.* (2019). O controlador fuzzy foi projetado com funções de pertinência gaussianas e um total de 9 regras, o método de defuzzificação adotado é o do centro de área.




Fig. 4 – Superfície de resposta do controlador Fuzzy Gaussiano.

O procedimento experimental para a aquisição dos dados de treinamento consistiu de testes realizados, com o controlador primário, variando-se o *set-point* e as condições de operação.

Aquisição dos dados

O banco de dados é formado pela paridade de dados de duas variáveis de entrada (Erro: $e(k)$ e Variação do erro: $de(k)/dt$) e uma variável de saída (Delta de frequência: $df(k)/dt$) – como ilustrado na Fig. 5. Erro é o desvio do valor do set-point (valor medido - valor do set-point); variação do erro é a diferença entre o erro no instante (k) e o erro no instante ($k-1$); delta de frequência é definida com a diferença da frequência no instante (k) e ($k-1$); D_{VRP} é o distúrbio inserido pela VRP no instante (k). A planta é representada como um sistema caixa preta e sua dinâmica é alterada pelo ângulo de abertura da VRP.




Fig. 5 – Estrutura de treinamento do controlador ARX.

Para a aquisição dos dados de treinamento foi utilizada uma frequência de amostragem igual a 100 amostras/s. Para minimizar as variabilidades dos dados de treinamento, ocasionadas por erros na mensuração da Pressão, foi proposto um estimador para o valor médio a cada 10 amostras, conforme mostra a Tabela I.

Ao total foram utilizados 5900 conjuntos de dados para o treinamento do controlador ARX. Estes dados também foram utilizados para o treinamento do controlador Neural, baseado em Redes Neurais Artificiais perceptron multicamadas (MPL) com algoritmo de treinamento *backpropagation*.

Tabela I. Formato do conjunto de dados

Instante de amostragem	Erro	Variação do erro	Variação da frequência	Estimação
k-1
k	$e(k)$	$e(k)-e(k-1)$	$f(k)-f(k-1)$	Estimação do valor médio do e , de e df a cada 10 amostras
k+1	$e(k+1)$	$e(k+1)-e(k)$	$f(k+1)-f(k)$	
k+2	$e(k+2)$	$e(k+2)-e(k+1)$	$f(k+2)-f(k+1)$	
...	
k+9	$e(k+9)$	$e(k+9)-e(k+8)$	$f(k+9)-f(k+8)$	
k+10

Desenvolvimento do controlador

O projeto do controlador ocorreu de forma semelhante ao procedimento utilizado para a identificação de sistemas dinâmicos. Para tanto, foi desenvolvido um código na

plataforma computacional MATLAB; a ordem dos modelos paramétricos foi definida através de uma função custo proposta por Ljung e Glad (1994), relacionando a ordem do modelo à variância (R^2).

A Fig. 6 ilustra a estrutura do sistema de controle em malha fechada para o controlador ARX. As variáveis de entrada são o Erro e a Variação do Erro, enquanto que a variável de saída é o Delta de frequência.




Fig. 6 – Estrutura do sistema de controle autoregressivo.

5. RESULTADOS

5.1 Desenvolvimento do Controlador

Os critérios utilizados para definir os procedimentos experimentais para o desenvolvimento do banco de dados foram a simplicidade (representadas pelas respostas degrau e variação do *set-point*) e as condições de operação do sistema de bombeamento de água (representadas pela variação de demanda e pressões de serviço). A Fig. 7 ilustra os dados de treinamento utilizados para o desenvolvimento dos controladores ARX e Neural. Os dados foram obtidos de um controlador Fuzzy.

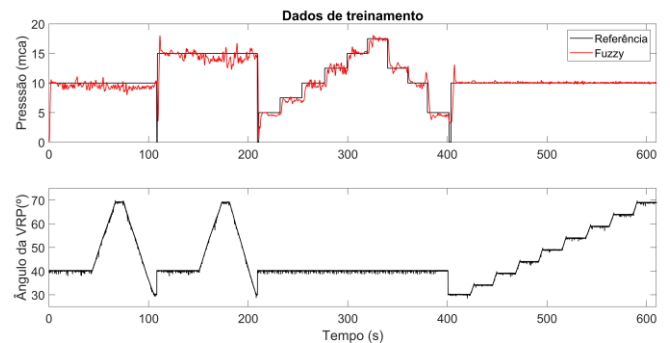


Fig. 7 – Dados de treinamento.

Os polinômios do modelo ARX obtido consiste em (7) que representa o polinômio de saída, (8) e (9) representam os polinômios da variáveis de entrada, aplicados à (6). O modelo tem ordem [$n_a=3; n_b=3; n_{k1}=0; n_{k2}=0$], correspondente a três polos, três zeros e atraso nulo para as duas variáveis de entrada. O ajuste (R^2) na etapa de treinamento foi de 89%.

$$A(z) = 1 + 0,529z^{-1} + 0,4119z^{-2} + 0,09446z^{-3} \quad (7)$$

$$B_1(z) = 0,4842 + 0,2244z^{-1} + 0,3269z^{-2} \quad (8)$$

$$B_2(z) = -2,149 - 1,459z^{-1} - 0,5995z^{-2} \quad (9)$$

5.2 Análise do controlador ARX

Um sistema de controle é considerado robusto quando é capaz de manter a estabilidade do sistema quando sujeito a mudanças severas na planta. Para tanto, foram realizados quatro ensaios experimentais; os dois primeiros – ilustrados nas Fig. 8 e 9 – foram realizados aumentando drasticamente a demanda de água na rede; o terceiro ensaio - ilustrado na Fig. 10 - para proporcionar uma variação mais branda da demanda; o quarto - ilustrado na Fig. 11 – para avaliar a resposta dos controladores às mudanças dinâmicas do *set-point*.

Na Figura 8 ilustra-se a resposta dinâmica do sistema considerando-se um *set-point* de 10 mca. Observa-se, que o controlador Fuzzy possui a maior velocidade; e que o controlador ARX e Neural apresentam velocidades muito próximas e *overshoot* nulo. Analisando o tempo de acomodação e a estabilidade (erro de regime permanente) do controlador ARX, nota-se, graficamente, que os seus resultados são superiores. Entretanto, o controlador Fuzzy não se estabiliza em tempo hábil. Após a resposta ao degrau, a dinâmica de operação foi alterada ($t=60$ s), através do fechamento e da abertura da VRP, o que faz a demanda do sistema variar. É possível notar que o controlador ARX e o Neural possuem boa estabilidade, adaptando-se às mudanças do sistema com baixo erro de regime permanente, mesmo em situações severas de mudança dinâmica.




Fig. 8 – Degrau em 10 mca com variação contínua da VRP.

A Tabela II resume o desempenho numérico dos controladores em regime transiente e permanente para um degrau de 10 mca. Em sistemas de abastecimento a importância do erro de regime permanente e a estabilidade em relação a distúrbios se sobrepõe, em importância, ao tempo de subida. Sendo assim, os resultados obtidos pelo controlador ARX e Neural mostraram superioridade em relação ao Fuzzy.

Tabela II. Análise do desempenho dos controladores.

Controlador	Tempo de subida [s]	Máxima ultrapassagem [%]	Tempo de acomodação [s]	Erro estacionário [%]
ARX	5.3	0	11.2	0.9
Neural	6.1	0	14.2	1.2
Fuzzy	4.4	5.7	-	11.8

A mesma análise é realizada em relação ao ensaio anterior, configurando, desta vez, um *set-point* de 15 mca. Os controladores Neural e Fuzzy apresentam *overshoot's* elevados, de 21,3 e 16,6%, respectivamente; já o ARX apresentou baixo *overshoot*, se aproximando de nulo, e o melhor desempenho em relação ao erro de regime permanente, tempo de acomodação e à variação de demanda.




Fig. 9 – Degrau em 15 mca com variação contínua da VRP.

Para sistemas de abastecimento o erro de regime permanente não é um fator extremamente crítico, principalmente, em situações de variação de demanda. Dessa forma, são toleráveis erros da ordem de 2 a 5%. A análise do desempenho dos controladores ao variar pausadamente a demanda - uma condição mais branda que a observada nas Fig. 8 e 9 - permite observar que o controlador ARX mantém a pressão de serviço com baixo percentual de erro (<1.3%), como ilustra-se na Fig. 10. Também é ilustrada a potência ativa do CMB, estável e apresentando ausência de pico para o caso dos controladores ARX e Neural - aspecto importante para a proteção dos equipamentos eletromecânicos e eletrônicos.

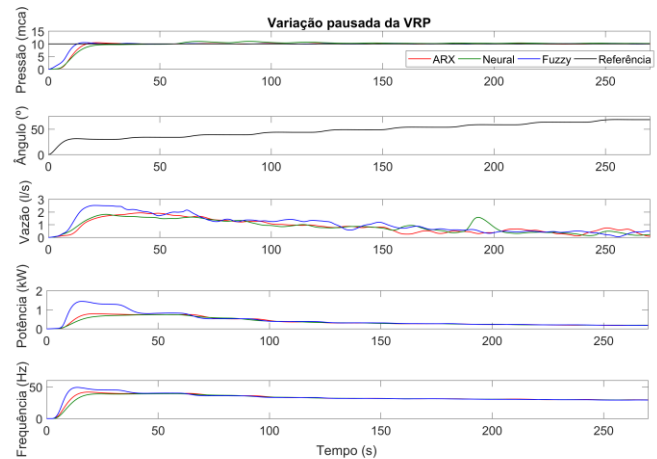


Fig. 10 – Degrau em 10 mca com variabilidade pausada da VRP.

Com o objetivo de demonstrar a efetividade do controlador, foi realizado um ensaio experimental com diferentes valores de *set-points*. A Fig. 11 apresenta o resultado da operação dos controladores com a mudança progressiva dos valores de pressão do sistema com VRP em demanda média (40°). É possível observar que devido a mudança repetitiva do *set-point*

somente o controlador ARX atinge um baixo erro de regime permanente. Avaliando, graficamente, o tempo de subida e a estabilidade, os controladores ARX e Neural apresentam resultados semelhantes, entre si, e superiores ao controlador Fuzzy.

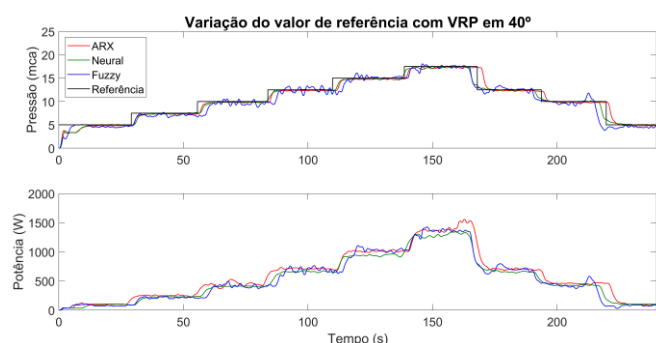


Fig. 11 – Variação do *set-point* com VRP em 40°.

6. CONCLUSÕES

Este trabalho teve como objetivo implementar uma técnica de controle inovadora em sistemas de abastecimento de água, visando a estabilização das pressões de serviço. O controlador ARX foi desenvolvido por modelagem caixa preta, a partir de um banco de dados construído com um controlador primário Fuzzy; foi também projetado um controlador Neural, para fins de comparação, com os mesmos dados de treinamento. Esses três controladores foram comparados e os resultados demonstraram que o controlador ARX apresentou o melhor desempenho para este tipo de aplicação. A hipótese introduzida no início deste trabalho, de que os controladores obtidos por modelagem computacional baseiam-se no comportamento dinâmico do controlador primário para modelar as tendências que esses apresentam e que mesmo utilizando dados ruidosos e algumas vezes imprecisos, para o treinamento, apresentam bom desempenho, foi comprovada.

Os controladores obtidos por modelagem computacional, como o ARX e o Neural, baseiam-se no comportamento dos dados obtidos com o controlador primário, captando as tendências que esse apresenta. Essa é uma das grandes vantagens desse tipo de controle, permitindo que controladores mais eficientes sejam projetados a partir de controladores não tão eficientes assim.

AGRADECIMENTOS

Ao laboratório de Eficiência Energética e Hidráulica em Saneamento (LENHS) e ao programa de Pós-Graduação em Engenharia Mecânica (PPGEM) da Universidade Federal da Paraíba (UFPB) e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

REFERÊNCIAS

Aguirre, L. A., “Introdução a identificação de sistemas”, Editora UFMG, 2004.

Anjana, G., Kumar, M., Amrutur, B. Comparison of Different Controllers for Equitable Water Supply in Water Networks. *Computing and Control for the Water Industry*, 2017.

D. Barcelli, C. Ocampo-Martinez, V. Puig, and A. Bemporad. Decentralized Model Predictive Control of Drinking Water Networks using an Automatic Subsystem Decomposition Approach. *12th IFAC Symposium on Large-Scale Systems: Theory and Applications (LSS)*, pages 572– 577, 2010.

Babunski, D., ZaeV, E., Tuneski, A., Bozovic, D. Optimization methods for water supply SCADA system. In *2018 7th Mediterranean Conference on Embedded Computing (MECO)*, pages 1–4, June 2018.

Barros, E. G. F., Salvino, L. R., Bezerra, S. T. M., Salvino, M. M., Gomes, H. P. Intelligent system for control of water distribution networks. *Water science & technology: water supply*, p. 1-12, 2017.

Bittencourt, M. C. Identificação de sistemas dinâmicos lineares – métodos paramétricos e não paramétricos. Trabalho de conclusão de curso de Engenharia Elétrica. Universidade de Brasília, Brasília, Distrito Federal, Brasil, 2007.

Binder, B., Kufoalor, D.K.M., Pavlov, A., Johansen, T. (2014). Embedded model predictive control for an electric submersible pump on a programmable logic controller. In *2014 IEEE Conf. on Control Applications (CCA)*, 579–585. IEEE.

Brogan, A., Gopalakrishnan, V., Sturtevant, K., Valigosky, Z., Kissock, K. Improving Variable-Speed Pumping Control to Maximize Savings. *ASHRAE Transactions*, volume 122, n. 2, 2016.

Camboim, W. L. L. Aplicações de técnicas de controle Fuzzy em sistemas de abastecimento de água visando melhoria no rendimento energético e hidráulico, 2012. Tese (Doutorado em Engenharia Mecânica) – Programa de Pós Graduação em Engenharia Mecânica, UFPB, João Pessoa, PB, 2012.

Carvalho, P. S. O. Controle para bombeamento distribuído com vistas à minimização dos custos energéticos aplicado a sistemas de abastecimento de água, 2012. Tese (Doutorado em Engenharia Mecânica) – Programa de Pós Graduação em Engenharia Mecânica, UFPB, João Pessoa, PB, 2012.

Diniz, A. M. F., Fontes, C. H. O., Costa, C. A., Ferreira, A. M. S., Santos, P. I. D. Improvements In Water Supply Systems Based On Optimization And Recognition Of Consumption Patterns. *Journal of Engineering Science and Technology*, volume 10, n. 5, pages 571–590, 2015.

Gomes, H. P., Carvalho, P. D. Manual de Sistema de Bombeamento - Eficiência Energética. João Pessoa: Editora da UFPB, 2012.

Ljung, L., Glad, T., 1993. Modeling of dynamic systems, 1ª ed., Prentice Hall International, United Kingdom, 1994.

- Ljung, L., 2019. "System Identification Toolbox User's Guide", Disponível em: <http://www.mathworks.com>. Acesso em 18 de maio de 2020.
- Krishnamoorthy, D., Bergheim, E.M., Pavlov, A., Fredriksen, M., Fjalestad, K. (2016). Modelling and robustness analysis of model predictive control for electrical submersible pump lifted heavy oil wells. *IFAC PapersOnLine*, 49(7), 544–549.
- Mendonça, K. H., Gomes, H. P., Villanueva, J., Bezerra, S. T. M., Silva, S. A. (2019). Análise energética do controle de pressões com o uso de inversores de frequência. XVI Seminário Ibero-Americano sobre Sistemas de Abastecimento e Drenagem, Lisboa, Portugal.
- Moreira, H. A. M., Gomes, H. P., Villanueva, J., Silva, A. Fuzzy - Mandani controller for a supply system. In: 25th International Congress of Mechanical Engineering, 2019. Proceedings of the 25th International Congress of Mechanical Engineering. doi.org/10.26678/ABCM.COBEM2019.COB2019-0508
- Moscinski, J., Ogonowski, Z., "Advanced control with Matlab & Simulink", 1ª ed., Ellis Horwood, United Kingdom, 1995.
- Moura, G. de A., Bezerra, S. de T. M., Gomes, H. P., Silva, S. A. da. (2018). Neural network using the Levenberg–Marquardt algorithm for optimal real-time operation of water distribution systems. *Urban Water Journal*, 1–8. doi:10.1080/1573062x.2018.1539503.
- Oliveira, J. K. C. Lógica fuzzy aplicada na otimização operacional de rede setorizada de distribuição de água. 2017. 147f. Tese (Doutorado em Engenharia Mecânica) – Programa de Pós Graduação em Engenharia Mecânica, UFPB, João Pessoa, PB, 2017.
- Pavlov, A., Krishnamoorthy, D., Fjalestad, K., Aske, E., Fredriksen, M. (2014). Modelling and model predictive control of oil wells with electric submersible pumps. In 2014 IEEE Conf. on Control Applications (CCA), 586–592. IEEE.
- Page, P. R., Abu-Mahfouz, A. M., Mothetha, M. L. Pressure management of water distribution systems via the remote real-time control of variable speed pumps. *Journal of Water Resources Planning and Management*, volume 143, n. 8, page 04017045, 2017.
- J. Pascual, J. Romera, V. Puig, R. Creus, M. Minoves. Operational predictive optimal control of barcelona water transport network. 18th IFAC World Congress, pages 10571–10578, 2011.
- Puig, V., Ocampo-Martínez, C., Pérez, R., Cembrano, G., Quevedo, J., Escobet, T. (Eds.). (2017). Real-time Monitoring and Operational Control of Drinking-Water Systems. *Advances in Industrial Control*. doi:10.1007/978-3-319-50751-4.
- Rodrigues, G. G. Identificação de sistemas dinâmicos não-lineares utilizando modelos NARMAX polinomiais – Aplicação a sistemas reais. Dissertação de mestrado do PPGE, Universidade Federal de Minas Gerais, Belo Horizonte, Brasil, junho de 1996.
- Salvino, L. R. Eficiência energética em sistemas pressurizados de distribuição de água com o uso de Redes Neurais Artificiais, 2018. Tese (Doutorado em Engenharia Mecânica) – Programa de Pós Graduação em Engenharia Mecânica, UFPB, João Pessoa, PB, 2018.
- Sampathirao, A. K., Grosso, J. M., Sopasakis, P., Ocampo-Martínez, C., Bemporad, A., Puig V. Water demand forecasting for the optimal operation of large-scale drinking water networks: The Barcelona Case Study. 19th IFAC World Congress, pages 10457–10462, 2014.
- Sharma, R., Glemmestad, B. (2013). Nonlinear optimization and control of an electric submersible pump lifted oil field. In *Modelling, Identification & Control (ICMIC)*, 2013 Proc. of Int. Conf. on, 26–31. IEEE.
- Ocampo-Martínez, C., Barcelli, D., Puig, V., Bemporad, A. Hierarchical and decentralized model predictive control of drinking water networks: application to Barcelona case study. *IET Control Theory and Applications* Vol. 6, Issue 1, pages 62–71, 2012.
- Trnka, P., Pekar, J., Havlena, V. Application of Distributed MPC to Barcelona Water Distribution Network. 18th IFAC World Congress, pages 9139–9144, 2011.
- Zulkeflee, A., Sata, S., Aziz, N. (2017). Auto-Regressive with Exogenous Input Model Predictive Controller for Water Activity in Esterification. *Chemical Engineering Transactions*, 56, 217-222. <https://doi.org/10.3303/CET1756037>