



# Automação inteligente em sistemas de abastecimento de água

JUAN MAURICIO MOISES VILLANUEVA  
organizador

**EJ** Editora  
UFPB

A stylized, light teal background featuring a complex network of pipes, valves, and circular components, resembling a water supply system. The pipes are thick and solid, with various fittings, elbows, and circular tanks or reservoirs integrated into the network. The overall aesthetic is clean and modern, with a focus on the infrastructure of water supply.

**Automação inteligente  
em sistemas  
de abastecimento  
de água**



## UNIVERSIDADE FEDERAL DA PARAÍBA

**Valdiney Veloso Gouveia**  
Reitor

**Liana Filgueira Albuquerque**  
Vice-Reitora



**Natanael Antônio dos Santos**  
Diretor Geral da Editora UFPB

**Everton Silva do Nascimento**  
Coordenador do Setor de Administração

**Gregório Ataíde Pereira Vasconcelos**  
Coordenador do Setor de Editoração

### CONSELHO EDITORIAL

**Cristiano das Neves Almeida** (Ciências Exatas e da Natureza)  
**José Humberto Vilar da Silva** (Ciências Agrárias)  
**Julio Afonso Sá de Pinho Neto** (Ciências Sociais e Aplicadas)  
**Márcio André Veras Machado** (Ciências Sociais e Aplicadas)  
**Maria de Fátima Alcântara Barros** (Ciências da Saúde)  
**Maria Patrícia Lopes Goldfarb** (Ciências Humanas)  
**Elaine Cristina Cintra** (Linguística e das Letras)  
**Regina Celi Mendes Pereira da Silva** (Linguística e das Letras)  
**Ulrich Vasconcelos da Rocha Gomes** (Ciências Biológicas)  
**Raphael Abrahão** (Engenharias)

Editora filiada à



Juan Mauricio Moises Villanueva  
(organizador)

# **AUTOMAÇÃO INTELIGENTE EM SISTEMAS DE ABASTECIMENTO DE ÁGUA**

João Pessoa  
Editora UFPB  
2024

**1ª Edição – 2024**

E-book aprovado para publicação – Editora UFPB.

É proibida a reprodução total ou parcial desta obra, de qualquer forma ou por qualquer meio.  
A violação dos direitos autorais (Lei nº 9.610/1998) é crime estabelecido no artigo 184 do código penal.

O CONTEÚDO DESTA PUBLICAÇÃO, SEU TEOR, SUA REVISÃO E SUA NORMALIZAÇÃO  
SÃO DE INTEIRA RESPONSABILIDADE DO(S) AUTOR(ES).

Projeto gráfico · **Editora UFPB**  
Editoração eletrônica e design de capa · **Rildo Coelho**

Catologação na fonte: **Biblioteca Central da Universidade Federal da Paraíba**

---

A939      Automação inteligente em sistemas de abastecimento de  
              água [recurso eletrônico] / Juan Mauricio Villanueva  
              (organizador). – Dados eletrônicos - João Pessoa : Editora  
              UFPB, 2024.

E-book.

Modo de acesso : <http://www.editora.ufpb.br/sistema/press/>

ISBN: 978-65-5942-251-7

1. Abastecimento de água. 2. Inteligência artificial. 3.  
Automação – Abastecimento de água. 4. Controladores fuzzy  
– Distribuição de água. 5. Redes neurais artificiais. I. Villanueva,  
Juan Mauricio. II. Título.

UFPB/BC

CDU 628.1

---

**OS DIREITOS DE PROPRIEDADE DESTA EDIÇÃO SÃO RESERVADOS À:**



Cidade Universitária, Campus I – Prédio da Editora Universitária, s/n  
João Pessoa – PB CEP 58.051-970

<http://www.editora.ufpb.br> E-mail: [editora@ufpb.br](mailto:editora@ufpb.br) Fone: (83) 3216.7147

## APRESENTAÇÃO

É com satisfação que eu, Juan Moises Villanueva, membro do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal da Paraíba (UFPB), apresento esta coletânea no formato de e-book sobre aplicações de tecnologias de inteligência artificial aos sistemas de abastecimento de água, o qual organizei com o auxílio dos autores. Os capítulos que fazem parte da coletânea foram desenvolvidos a partir de trabalhos de conclusão de curso, dissertações e teses de alunos que foram orientados ou co-orientados por mim. Os dois primeiros capítulos apresentam alguns conceitos fundamentais de sistemas de abastecimento de água e sua automação (Capítulo 1) e de inteligência artificial (Capítulo 2). Os quatro capítulos seguintes tratam do uso de controladores fuzzy para otimizar o desempenho dos sistemas de abastecimento de água (Capítulos 3, 4 e 5) e o uso de redes neurais artificiais para realizar a medição indireta da vazão no sistema, por meio de sensores virtuais (soft sensors)

Vale ressaltar que as pesquisas usadas como base para este livro foram desenvolvidas em parceria com o Programa de Pós-Graduação em Engenharia Mecânica, seja por meio de colaborações dadas por alguns de seus membros, ou pelo uso da infraestrutura do LENHS/UFPB (Laboratório de Eficiência Energética e Hidráulica em Saneamento) nos experimentos.

O objetivo deste livro é apresentar, com certo nível de detalhamento, os usos que têm sido dados, no âmbito do Departamento de Engenharia Elétrica, à tecnologia de inteligência artificial para o aprimoramento do setor de abastecimento.

# SUMÁRIO

<b>1. Técnicas Modernas de Automação e Controle em Sistemas de Abastecimento de Água</b>	<b>09</b>
1.1 Controle em Sistemas de Abastecimento de Água	09
1.2 O Sistema de Abastecimento de Água	11
1.2.1 Conjunto Motobomba	18
1.2.2 Inversores de Frequência	21
<b>2. Sistemas de Abastecimento de Água e Inteligência Artificial</b>	<b>23</b>
2.1 Introdução	23
2.2 Sistemas de Controle	23
2.3 Sistemas de Supervisão e Monitoramento	26
2.4 Inteligência Artificial	28
2.4.1 Critérios de Erro	29
2.4.2 Redes Neurais Artificiais	31
2.4.3 Lógica Fuzzy	36
2.4.3.1 Inferência Mamdani	39
2.4.3.2 Inferência do Tipo Sugeno	40

<b>3. Aplicação do Controle Fuzzy em Sistemas de Bombeamento Série-Paralelo</b>	<b>47</b>
3.1 Operação de Bombas em Série-Paralelo	47
3.2 Controle Fuzzy	50
3.3 Exemplo de Aplicação a Sistemas com Bombas em Série e em Paralelo	51
3.3.1 Bancada Experimental	51
3.3.2 Controlador Fuzzy	57
3.3.3 Análise e Resultados	65
3.3.3.1 Experimento I	65
3.3.3.2 Experimento II	68
3.3.3.3 Considerações Finais	78
<b>4. Controladores Neuro-Fuzzy Aplicados ao Ajuste de Pressão em Sistemas de Distribuição de Água</b>	<b>82</b>
4.1 O Controlador Neuro-Fuzzy e Identificação de Sistemas	82
4.1.1 Análise e Validação do Modelo	85
4.1.2 Controle Neuro-fuzzy	89
4.2 Aplicação do Controle Neuro-fuzzy aos Sistemas de Distribuição de Água	95
4.2.1 Bancada Experimental	95
4.2.1.1 Identificação da Bancada Experimental	98
4.2.2 Projeto do Controlador	104
4.3 Análise e Resultados	110
4.3.1 Critérios de Análises Hidroenergéticas	110
4.3.2 Desenvolvimento do Banco de Dados	111

<b>4.3.3 Dados de Treinamento</b>	<b>115</b>
4.3.3.1 Resposta do Modelo SIMO (1 input - 2 output)	116
4.3.3.2 Resposta do Modelo MIMO (2 input - 2 output)	120
4.3.3.3 Caracterização do Rendimento do CMB	124
4.3.3.4 Análises e Modelos	128
4.3.3.5 Análise do Controlador	129
4.3.3.6 Variação do Valor de Referência do Sistema	137
4.3.3.7 Variação Contínua da VC	139
4.3.3.8 Variação Pausada da VC	142
4.3.3.9 Considerações Finais	150

## **5. Controle de Pressão Fuzzy em Sistemas de Abastecimento de Água Baseada em Modelos de Sistemas com Redes Neurais Artificiais**

**153**

<b>5.1 Contexto e Problemas dos Sistemas de Abastecimento de Água</b>	<b>153</b>
<b>5.2 Controle de Pressão em Sistemas de Abastecimento do Tipo Estrela</b>	<b>156</b>
<b>5.2.1 Componentes da Solução de Monitoramento e do Sistema de Distribuição</b>	<b>158</b>
5.2.1.1 ScadaLTS	167
5.2.1.2 Modelagem do Processo com Redes Neurais Artificiais	170
5.2.1.3 Controle Fuzzy Baseado em Python	174
<b>5.2.2 Funcionamento da Solução IoT sobre a Rede Estrela</b>	<b>183</b>
5.2.2.1 Funcionamento do Modelo RNA	183
5.2.2.2 Resultados da Operação na Rede Estrela	195

<b>6. Desenvolvimento de um Sensor Virtual para a Estimação de Fluxo em Sistemas de Abastecimento de Água</b>	<b>206</b>
6.1 Medição Indireta de Grandezas Físicas	206
6.2 Sensores Virtuais	211
6.3 Desenvolvimento do Sensor Virtual	213
6.3.1 Bancada Experimental	213
6.3.2 Metodologia de Desenvolvimento	223
6.3.2.1 Bloco de Reconstrução Direta da Medida de Pressão	224
6.3.2.2 Bloco Associado ao Soft Sensor (Reconstrução Indireta de Vazão)	227
6.3.2.3 Implementação do Soft Sensor usando Redes Neurais Artificiais	230
6.4 Experimentos e Análises	233
6.4.1 Ensaio A	234
6.4.2 Ensaio B	238
6.4.3 Validação do Soft Sensor	242
6.4.3.1 Validação do Soft Sensor sem Ação do Controlador	243
6.4.3.1.1 Validação A	243
6.4.3.1.2 Validação B	247
6.4.3.2 Verificação da Eficiência do Soft Sensor com Atuação do Controlador	252
6.4.3.2.1 Atuação do Soft Sensor para Diferentes Setpoint de Pressão	253
6.4.3.2.2 Atuação do Soft Sensor para Variações Bruscas de Demanda de Consumo	256
6.4.3.2.2 Atuação do Soft Sensor para Sinais Espúrios em PT-3	260
6.4.4 Considerações Finais	265
Sobre os(as) autores(as)	267

# Capítulo 1: Técnicas Modernas de Automação e Controle em Sistemas de Abastecimento de Água

*José Vinícius Santos de Araújo,  
Rafael Moura Duarte e  
Juan Mauricio Moises Villanueva*

## 1.1 Controle em Sistemas de Abastecimento de Água

A busca por formas de usar recursos energéticos de forma mais racional tem impactado pesquisas em diversos campos da tecnologia. Com sistemas de distribuição de água (SDA), que são responsáveis por um consumo intenso não só de água, mas também de energia, não poderia ser diferente.

Na prática, os setores hídrico e energético são bastante interdependentes, como é fácil de observar nas indústrias de produção de combustíveis, nos sistemas de resfriamento de termelétricas (baseados em água) e na necessidade de energia para o bombeamento, tratamento e distribuição de água. No

Brasil, os prestadores de serviços de água estão entre os maiores consumidores das empresas de distribuição de energia elétrica.

Além dos custos de pessoal, outro grande custo das indústrias e prestadores de serviço são os custos com energia elétrica. Por esse motivo, faz-se necessária a busca por formas de reduzir a quantidade de energia necessária para viabilizar a prestação de serviços por parte das companhias do setor hídrico.

O uso de técnicas de automação em sistemas de distribuição de água é uma possível alternativa para elevar a sua eficiência energética. Existem várias formas de realizar esse controle, mas alguns elementos, tais como transdutores de nível, pressão e vazão, válvulas de controle, inversores de frequência e sistemas de comunicação são elementos recorrentes nesse tipo de esquema.

O uso da automatização clássica na operação de sistemas de distribuição de água se baseia em métodos de controle clássicos, os quais se fundamentam em algoritmos matemáticos desenvolvidos com base no modelo matemático do sistema e que atuam diretamente nos dispositivos e atuadores sem a intervenção do operador, de acordo com as condições operacionais do sistema.

Tradicionalmente, faz-se o uso de válvulas redutoras de pressão e bombas de velocidade variável como atuadores no controle da pressão e da vazão.

O uso de controladores nos SDA não garante apenas a operação satisfatória do fornecimento de água, mas também permite a redução do consumo hidroenergético, isto é, das perdas de água e energia. No entanto, com a aplicação de técnicas de automação inteligente, melhores resultados podem ser alcança-

dos no controle de pressão(Mendonça, 2022). Algumas dessas técnicas serãoexploradas nas aplicações descritas nos próximos capítulos.A operação dos sistemas de distribuição de água não operam de forma linear, ou mesmo previsível. A demanda e as pressões na rede variam ao longo do tempo, o que faz com que algum tipo de controle de pressão seja necessário para aumentar a eficiência energética e hidráulica dos sistemas de distribuição de água.

## **1.2 O SISTEMA DE ABASTECIMENTO DE ÁGUA**

O sistema de abastecimento de água (SAA) é composto por estruturas, equipamentos e dispositivos que, juntos, viabilizam o fornecimento de água em quantidade, qualidade e com regularidade adequadas ao consumo humano.

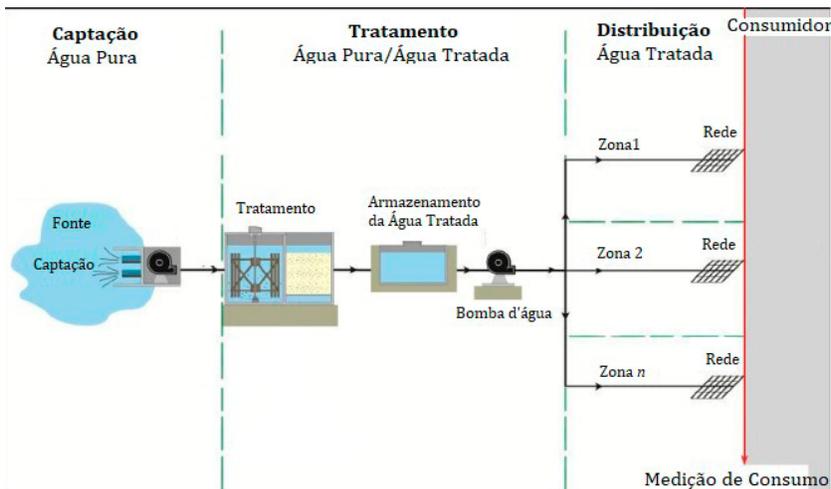


Figura 1.1: Setores de um sistema de abastecimento de água.

Fonte: adaptado de Araújo et al. (2023).

Antes de chegar aos consumidores, a água passa pelas etapas de captação, processamento e transporte. A obtenção da água é feita em mananciais (rios, lagos ou fontes subterrâneas de água doce). Nas unidades de processamento, a água passa pela captura, elevação, adução da água pura. Nas unidades de processamento, a água é tratada para satisfazer as necessidades de cada tipo de consumidor, seja ele residencial, industrial ou de qualquer outro tipo. Em seguida, a água é entregue ao departamento responsável por sua distribuição. Essas três etapas estão representadas na Figura 1.1.

Em especial, o setor de distribuição de água é composto por uma estação de bombeamento de água tratada, reservatórios (elevados ou não) e rede de distribuição. Os reservatórios subterrâneos têm a função de prover água para distribuição, atuando como uma reserva extra de água tratada e sendo

essencial quando o volume de água demandado pela rede é maior que o volume que entra nela.

Nas estações de bombeamento, as bombas são capazes de bombear água desde os reservatórios subterrâneos até os elevados, os quais provêm água às unidades consumidoras. Entretanto, em algumas situações, a água é bombeada diretamente para as unidades consumidoras, o que faz com que o desempenho hidroenergético do sistema precise ser analisado com atenção.

Parte do sucesso e eficiência do sistema de abastecimento de água depende do conhecimento prévio das características da rede de distribuição e dos conjuntos motobombas, os quais devem estar de acordo com as pressões estabelecidas nos padrões vigentes. No Brasil, o padrão adotado é o ABNT NBR 12218/1994, em que ficou estabelecido que a rede deve ter pressões mínimas de pelo menos 10 mca e máxima de 50 mca.

Normalmente, quando se considera que um sistema é formado por uma ou várias tubulações, é usado como referência de desempenho um gráfico de variação da perda de carga em função da vazão, dominando esse gráfico de curva do sistema. Essa curva está ilustrada na Figura 2.2 e é dada pelo somatório das perdas de carga estáticas e dinâmicas, as quais variam de acordo com certas circunstâncias, tais como a diferença de cota entre o ponto de fornecimento e o de consumo de água e de características da tubulação (presença de estreitamentos, válvulas, mudanças de direção etc.)

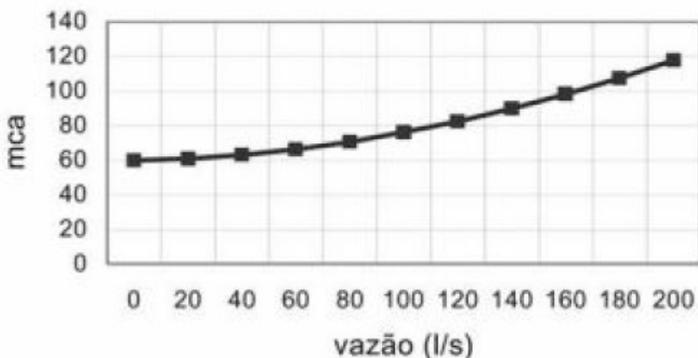


Figura 1.2: Curva do sistema.

Fonte: (Araújo, 2021).

As perdas de cargas estáticas dependem da altura geométrica em que a água deve ser bombeada, a fim de superar a diferença de cota de um ponto A para um ponto B. Por independência da vazão, a altura geométrica pode ser considerada valor constante, o que motiva o uso, também, do nome altura estática para se referir a ela.

As perdas de cargas dinâmicas podem ser classificadas em perdas de carga distribuídas e perdas de carga localizadas. A primeira classe engloba as perdas que ocorrem ao longo das tubulações e de forma contínua; já a segunda classe diz respeito às perdas que ocorrem devido aos pontos que apresentam discontinuidades na perda distribuída, ou seja, em pontos em que há um atrito significativamente maior do que o provocado por um escoamento contínuo.

Juntando as perdas de carga dinâmicas e a perda de carga estática, tem-se a Equação (1.1), para modelagem da curva do sistema citada anteriormente,

$$H_{MT} = H_G + h_p + h_L. \quad (1.1)$$

em  $H_{MT}$  é a altura manométrica total,  $H_G$  é a altura geométrica,  $h_p$  é a perda de carga distribuída e  $h_L$  é a perda de carga localizada.

Pelo fato de as características quadráticas das cargas dinâmicas e das perdas de carga distribuídas, em geral, excederem às perdas de cargas localizadas, é comum a simplificação da Equação (1.1), em que se desprezam as perdas de carga localizada, o que leva a

$$H_{MT} = H_G + \alpha \cdot Q^2, \quad (1.2)$$

em que a vazão volumétrica é representada por  $Q$  e  $\alpha$  é determinado a partir da equação de carga distribuída de Darcy-Weisbach,

$$h_p = \frac{8 \cdot f \cdot L}{p^2 \cdot g \cdot D^5} Q^2 = \alpha \cdot Q^2, \quad (1.3)$$

A curva de sistema reflete o comportamento típico do sistema. Ao longo do dia, o ponto de operação varia de acordo com a dinâmica do consumo, variando consideravelmente entre os horários de pico e os de baixo consumo, conforme está ilustrado na Figura 1.3.

Da volatilidade do comportamento do sistema decorre a necessidade de se regular as ações do abastecimento, a fim de evitar o excesso ou a falta de volume de água que percorre as tubulações, diminuindo, respectivamente, rompimentos e interrupções do abastecimento. Algumas ações que alteram o comportamento do sistema podem ser tomadas por meio do uso de válvulas redutoras de pressão (VRP), as quais aumentam a pressão manométrica total do sistema. O efeito da atuação da VRP sobre a curva do sistema pode ser observado na Figura 1.4.

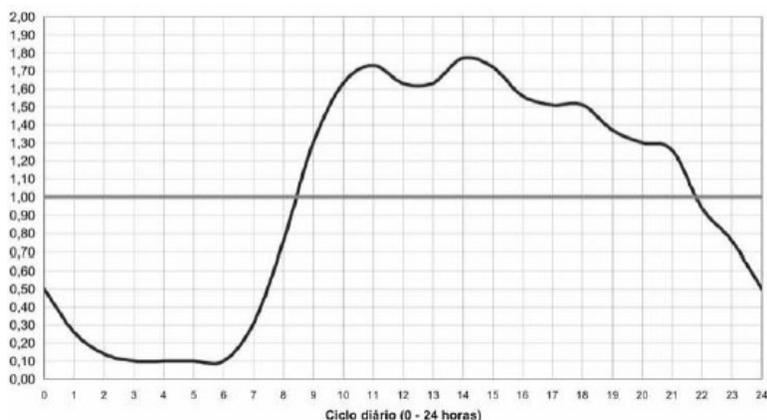


Figura 1.3: Perfil de consumo ao longo do dia.

Fonte: (Araújo, 2021).

A utilização de válvulas deve ser feita de forma moderada, pois, apesar de possibilitar a adequação da pressão na rede, o aumento da altura manométrica total da rede tem potencial para diminuir a eficiência energética do processo de abastecimento. Uma alternativa para atender a demanda variável sem comprometer a eficiência energética consiste na variação da

rotação da bomba, de modo a promover aumento ou diminuição no fornecimento de água sem elevar a altura manométrica total do sistema.

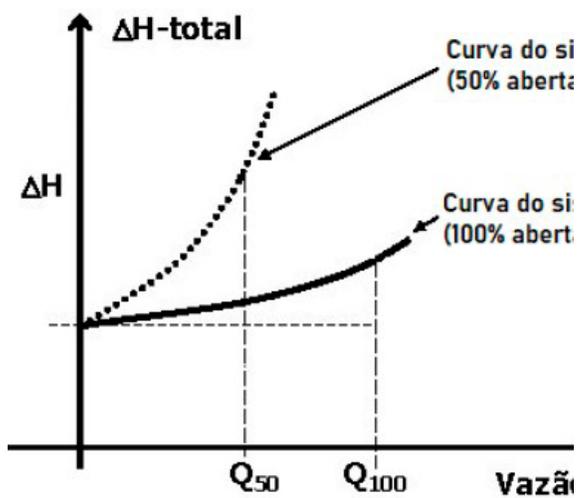


Figura 1.4: Ação da válvula sobre a curva do sistema.

Fonte: (Araújo, 2021).

## 1.2.1 CONJUNTO MOTOBOMBA

A escolha de um conjunto motobomba, isto é, um par composto por motor e bomba, que será usada para que o sistema de abastecimento atenda à demanda dos consumidores deve ser feita com base nas suas especificações. Em especial, deve-se atentar para a curva de pressão versus vazão do sistema, a qual deve interceptar a curva de sistema no ponto de operação desejado, para que o sistema opere de forma harmoniosa.

Conhecendo-se a altura manométrica total entre dois pontos, a vazão e o peso específico da água ( $\gamma$ )

$$P = \gamma \cdot Q \cdot H_{MT}, \quad (1.4)$$

O funcionamento ótimo (do ponto de vista elétrico) do sistema é alcançado quando a bomba opera no seu ponto de máximo rendimento. É nesse ponto que, idealmente, deve ocorrer o cruzamento entre as curvas do sistema, conforme está ilustrado na Figura 1.5.

Além de buscar a operação da bomba em seu ponto máximo, é importante determinar a potência de saída do conjunto motobomba, considerando tanto o rendimento da bomba quanto do motor. Sendo  $\eta_b$  e  $\eta_m$  as eficiências da bomba e do motor, a potência de saída do conjunto motobomba é dada por

$$P = \gamma \cdot Q \cdot H_{MT} / \eta_b \cdot \eta_m \quad (1.5)$$

Com a equação acima, é possível determinar a potência consumida pelo conjunto motobomba. Entretanto, nos momentos em que o sistema necessita de um volume de água menor, há o desperdício de energia elétrica pela bomba que opera em máxima velocidade. Assim, o uso de um sistema variador de frequência possibilita a economia de energia fazendo o conjunto motobomba operar a uma velocidade inferior sem prejuízo para a qualidade do abastecimento.

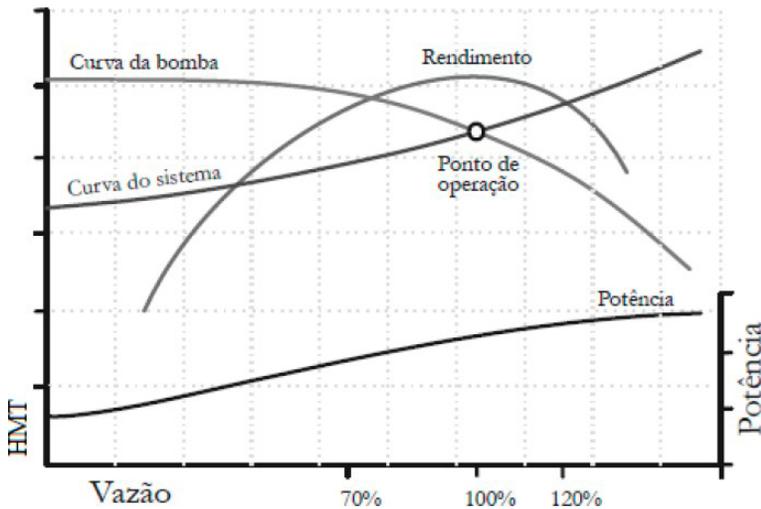


Figura 1.5: Operação eficiente de um sistema hidráulico Vazão x  $H_{MT}$

Fonte: (Bezerra et al, 2010).

De forma resumida, a mudança na velocidade de rotação da bomba provoca um deslocamento na curva de vazão versus pressão da bomba, de forma a adaptá-la às necessidades da rede, evitando excessos no fornecimento e diminuindo as interrupções no abastecimento devido a vazamentos. Na Figura 1.6, encontra-se ilustrado o comportamento da curva da bomba com regulação na velocidade de rotação do motor ( $n_1$ ,  $n_2$  e  $n_3$ ).

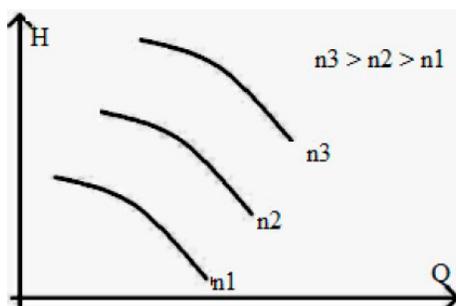


Figura 1.6: Influência da velocidade de rotação sobre a curva da bomba.

Fonte: (Araújo, 2021).

## 1.2.2 INVERSORES DE FREQUÊNCIA

Uma das formas de controlar a velocidade de rotação de um motobomba e, por consequência, o volume de água injetado na rede consiste em usar inversores de frequência. Além da função de controlar a velocidade de rotação dos motores, esses equipamentos também atuam como proteção contra problemas como o desbalanceamento entre fases, sobrecarga e quedas de tensão. Outro uso dos inversores também possibilitam o controle do torque do motor, proporcionando uma inicialização suave (soft start) e reduzindo o consumo de potência reativa por meio da filtragem harmônica.

Os inversores também proporcionam melhorias relacionadas à economia de eletricidade, por terem a capacidade de controlar a potência injetada nos conjuntos motobomba e o balanço do fator de potência fornecido pela rede através de circuitos retificadores.

## REFERÊNCIAS

ABNT – Associação Brasileira de Normas Técnicas. **NBR 12218. Projeto de rede de distribuição de água para abastecimento público.** 1994.

ARAÚJO, J.V.S.; VILLANUEVA, J.M.M; CORDULA, M.M.; CARDOSO, A.A.; GOMES, H.P. **Fuzzy Control of Pressure in a Water Supply Network Based on Neural Network System Modeling and IoT Measurements.** Sensors, 22, 9130, 2022. <https://doi.org/10.3390/s22239130>.

ARAÚJO, J.V.S. **Monitoramento e Controle de Pressão de Redes de Abastecimento de Água Utilizando IoT e Controle Fuzzy.** Trabalho de Conclusão de Curso (TCC), Departamento de Engenharia Elétrica, Universidade Federal da Paraíba (UFPB), 2021.

BEZERRA, S. T. M.; SILVA, S. A.; GOMES, H. P. **Operational optimisation of water supply networks using a fuzzy system.** Water SA, vol. 38, n. 4, p. 565-572, 2012.

MENDONÇA, C.H.; GOMES, H.P.; BEZERRA, .T.M.; VILLANUEVA, J.M.M. **Aplicação de Sistemas de Controle Fuzzy para Sistemas de Distribuição de Água.** Revista DAE, n. 236, 2022.

# Capítulo 2: Sistemas de Abastecimento de Água e Inteligência Artificial

*Robson Pacífico Guimarães Lima,  
José Vinícius Santos de Araújo,  
Hugo Augusto Marinho Moreira,  
Rafael Moura Duarte  
e Juan Mauricio Moises Villanueva.*

## 2.1 INTRODUÇÃO

As aplicações de controle e automação aos sistemas de abastecimento de água apresentadas neste livro empregam técnicas baseadas em inteligência artificial. Portanto, acreditamos ser conveniente que o leitor se familiarize ou relembre alguns conceitos, antes de seguir para os próximos capítulos. Eles estão expostos nas próximas seções.

## 2.2 SISTEMAS DE CONTROLE

Segundo Nise (2017) “um sistema de controle consiste em subsistemas e processos (ou plantas) construídos com o objetivo de obter uma saída desejada com um desempenho desejado, dada

uma entrada especificada". Nesse caso, o desempenho desejado possui dois parâmetros de qualidade: a resposta transitória e o erro em regime permanente.

Para perceber o conceito desses dois parâmetros pode-se pensar em um dos controles mais simples presentes no cotidiano: o carro. Ao dirigir um carro, por exemplo, pode-se desejar que ele se desloque mais rápido ou mais devagar, com maior ou menor aceleração,

tudo isso comandado pelo ser humano através da marcha e dos pedais. Essa velocidade que desejamos alcançar é chamada na literatura de *setpoint*; a diferença entre a velocidade atual (constante) e o *setpoint* é o erro em regime permanente e período em que se está acelerando até atingir a velocidade desejada é a resposta transitória.

Esse é um típico sistema que opera em malha aberta uma vez que possui imprecisão, nenhuma adaptação a variações externas (perturbações) e dependência do julgamento e da estimativa humana. Esses sistemas são representados na literatura diagramas de blocos similares ao da Figura 2.1.

Para um sistema operar com mais precisão e controle, é fundamental que ele seja realimentado com o sinal de saída para que um controlador comande os atuadores e os ajustem para que a saída obtenha o desempenho desejado. Com a informação da referência desejada e o valor atual da saída, é possível saber a diferença entre esses dois valores, ou seja, o erro e utilizar alguma rotina de controle específica para alcançar a resposta ideal. Essa maneira de interagir com o processo é compatível com um sistema em malha fechada, conforme está ilustrado na Figura 2.2.

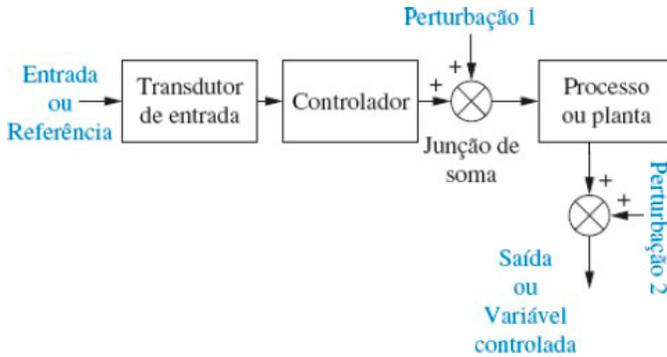


Figura 2.1: Sistema de Controle em Malha Aberta.

Fonte: Adaptado de Nise (2017).

Entre as ações de controle disponíveis na literatura para solucionar o problema de controle de pressão em redes de abastecimento de água, existem, por exemplo, o uso da família PID (proporcional-integral-diferencial) em duas válvulas redutoras de pressão, para controlar as pressões mínimas e máximas de uma área e reduzir as perdas, o uso de redes neurais adaptativas para manutenção da altura manométrica ótima do sistema e o uso de controle fuzzy para ajustar a pressão de acordo com as medições disponíveis de vazão e pressão.

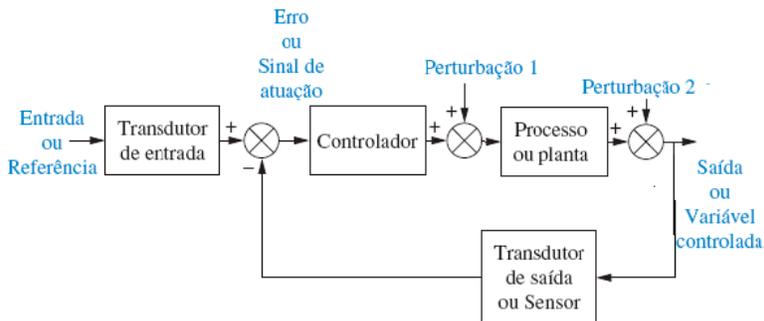


Figura 2.2: Sistema de Controle em Malha Fechada.

Fonte: Adaptado de Nise (2017).

## 2.3 SISTEMAS DE MONITORAMENTO E SUPERVISÃO

Comuns em ambientes industriais, os sistemas supervi-sórios permitem a coleta de dados obtidos por dispositivos de aquisição de dados e, conseqüentemente, o monitoramento e o rastreamento do estado de instalações físicas.

Os elementos básicos de um sistema de monitoramento e supervisão são:

(1) Sistema SCADA (*Supervisory Control and Data Acquisition*): conseguem agrupar dados coletados de diferentes equipamentos de campo, inclusive aqueles obtidos remotamente, e apresentá-los de maneira amigável para o operador por meio de recursos gráficos e conteúdo multimídia;

(2) Dispositivos de aquisição (DAQ) são responsáveis por extrair os dados dos equipamentos de campo e enviar estes dados para o sistema SCADA;

(3) equipamentos de campo que mensuram e atuam sobre as variáveis do processo.

O ScadaLTS é um sistema supervisor derivado do do supervisor brasileiro de código aberto ScadaBR, com o objetivo de servir como solução para aplicações de processos de automação. Ele foi desenvolvido com base na linguagem de programação Java e é capaz de rodar em qualquer sistema operacional, com interface 100% web que permite acesso e controle de dispositivos e processos através de computadores, *tablets e smartphones* (Araújo, 2021)

Entre os recursos disponíveis em um ScadaLTS, há: *Engine* de alarmes e eventos parametrizáveis; alarmes sonoros; sistema de permissões por usuários; relatórios de variáveis, alarmes e eventos; *Engine* de “*scripts*” para controle e automação; aquisição de dados em mais de 20 protocolos como: Modbus TCP/IP e Serial, OPC, DNP3, IEC, Serial ASCII, HTTP; variáveis calculadas (com funções matemáticas, estatísticas, e lógica em geral); visualização de dados (variáveis ou “*tags*”) em tempo-real; registro contínuo das variáveis em Banco de Dados (*Datalogger*); construção de telas gráficas (HMI ou Sinóticos).

Um recurso do ScadaLTS que merece destaque é a possibilidade de interação com os dados via API REST. De maneira simplista, uma API (tradução literal para Interface de Programação de Aplicativos) é um meio pelo qual dois sistemas (ou *softwares*)

diferentes podem se comunicar, sendo um protocolo de troca de dados entre sistemas. Com o API REST do ScadaLTS, é mais fácil extrair e enviar informações do supervisão por meio de diversas linguagens de programação que possuem suporte para HTTP, como Python, C++ e Matlab. Assim, é possível explorar os dados usufruindo de tecnologias de inteligência artificial.

## 2.4 INTELIGÊNCIA ARTIFICIAL

Muitas tarefas que costumavam ser desempenhadas de forma manual passaram a ser realizadas de forma automática com o passar do tempo. Inicialmente, essa automatização era realizada usando técnicas de controle clássicas, as quais exigiam algum tipo de modelagem matemática do sistema a ser controlado. No entanto, o projeto do controle de sistemas cuja descrição matemática seja demasiadamente complexa ou não linear pode exigir muitos estudos, apresentar imperfeições ou mesmo ser inviável. Nesse contexto, uma solução que tem sido muito adotada consiste no uso das técnicas de inteligência artificial, cujas principais vertentes são as Redes Neurais Artificiais (RNA), os Sistemas Nebulosos (lógica *fuzzy*) e suas hibridizações (Ballini, 2000). Novas aplicações de tais técnicas surgem todos os dias, devido à sua capacidade de criar sistemas computacionais que emulem características inerentes aos seres humanos, como aprendizado, intuição, raciocínio lógico aproximado, capacidade de generalização, entre outras (Moreira, 2020). A seguir, serão apresentados os critérios de erro utilizados para analisar o desempenho dessas técnicas, bem como as próprias técnicas, para que o leitor consiga compreender os métodos de controle

inteligente e de estimação empregados nos problemas dos próximos capítulos.

## 2.4.1 CRITÉRIOS DE ERRO

Os critérios de avaliação de erros mais usados no contexto de sistemas de controle inteligente são os seguintes (Lima, 2022):

(1) Seja  $x$  um número real e  $\bar{x}$ , sua aproximação. O **erro absoluto** da aproximação  $\bar{x}$  é definido por

$$E = |x - \bar{x}|. \quad (2.1)$$

(2) O **erro relativo** da aproximação  $\bar{x}$  é definido por

$$E = |x - \bar{x}|/|x|, \quad (2.2)$$

com  $x \neq 0$ .

(3) O **MAPE** (*Mean Absolute Percentage Error*) ou **Erro Absoluto Percentual Médio** corresponde a uma medida que exprime o tamanho do erro em termos percentuais. Em outras palavras, o MAPE é a média de todos os erros absolutos percentuais fornecendo uma indicação do tamanho médio do erro, expresso como uma porcentagem do valor observado, independentemente de o erro ser positivo ou negativo.

Seja  $x_r$  o valor real de uma medida e  $x_p$  seu valor previsto. Assim, o MAPE percentual pode ser expresso matematicamente por

$$MAPE(\%) = \frac{1}{n} \sum \frac{|x_r - x_p|}{|x_r|} \cdot 100 \quad (2.3)$$

em que  $n$  corresponde a uma determinada quantidade de dados.

(4) O critério utilizado para verificação do erro de rastreamento relativo aos resultados obtidos nessa pesquisa foi o Erro Médio Quadrático (EMQ) ou MSE (mean squared error). Erro Médio Quadrático é uma medida do desvio dos valores calculados em relação aos valores originais. Ele é estimado tomando uma amostra dos valores calculados e comparando-a com seus valores reais. As diferenças entre elas são então elevadas ao quadrado e adicionadas. A soma é então dividida pelo número de medidas, para que se obtenha o EMQ.

O Erro Médio Quadrático mensura a média dos quadrados do erro, ou seja, a diferença quadrática média entre os parâmetros estimados  $x_e$  e o parâmetro referencial  $x_s$  de uma amostra de dados  $n$ . Assim, o EMQ pode ser definido por

$$EMQ = \sum_{i=1}^n (x_e - x_s)^2 / n \quad (2.4)$$

em que  $i$  varia de 1 até a  $n$ -ésima amostra de dados.

## 2.4.2 REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais (RNAs) podem ser definidas como técnicas computacionais que representam um modelo matemático cuja inspiração vem da estrutura neural dos seres vivos. Sua estrutura é semelhante à de um neurônio biológico, com corpo e linhas de transmissão, e o seu funcionamento se resume em coletar os sinais de entrada e agrupá-los de acordo com sua função operacional para fornecer uma saída. Para gerar a resposta, é levada em consideração a função de ativação presente no processo. Na Figura 2.3, ilustra-se a estrutura do neurônio artificial.

Uma RNA é composta por uma rede variada de neurônios organizados em camadas e interligados entre si por meio de entrada(s) e saída(s), as quais possuem pesos e estes podem assumir diferentes valores até atingir determinada(s) saída(s). Cada camada pode possuir um número diferente de neurônios. As unidades (neurônios) fazem operações apenas sobre seus dados locais, que são as entradas recebidas pelas suas conexões.

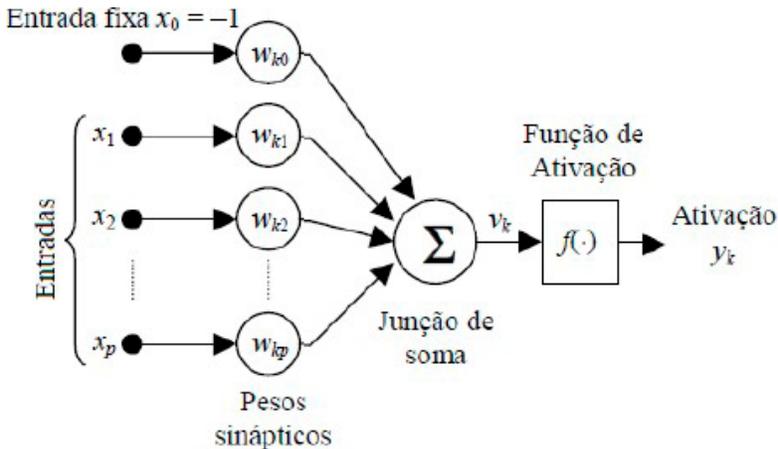


Figura 2.3: Elementos constitutivos de um neurônio artificial.

Fonte: Adaptado de Ballini (2000).

As operações básicas de tratamento típico de uma RNA são:

- Sinais são apresentados à(s) entrada(s);
- Cada sinal (ou sinapse) é multiplicado por um peso sináptico (aleatório)  $w_j$ , que indica a sua influência na saída da unidade. Sendo assim, um sinal  $x_j$  na entrada da sinapse  $j$  conectada ao neurônio  $k$  é multiplicado pelo peso sináptico  $w_{kj}$ .
- Uma junção de soma, responsável pela combinação aditiva dos sinais de entrada é responsável por produzir um nível de atividade; Uma função de ativação representando um efeito de saturação na ativação de saída  $y$  do neurônio. Tipicamente a excursão da ativação dos neurônios é confinada ao intervalo  $(0, 1)$  ou  $(-1, 1)$ .

A estrutura típica de uma RNA é descrita da seguinte maneira:

- Camada de entrada: entrada do sinal;
- Camada intermediária: onde é realizado o tratamento, os pesos ( $w$ ) são ponderados, também podendo ser consideradas de extratora de regras;
- Camada de saída: conclusão do resultado e envio do sinal novamente à entrada em um processo iterativo para reduzir o erro ( $e$ ); o truncamento se dá por intermédio de algum critério como o número de interações ou o erro final admissível.

Existem diversos algoritmos que determinam a forma de treinamento de uma Rede Neural. A mais importante propriedade de uma rede neural artificial é sua capacidade de aprendizado baseado no treinamento. Uma rede neural aprende por meio de um processo iterativo de ajustes aplicados aos seus pesos sinápticos e limiares, o qual pode ser expresso na forma de um algoritmo computacional.

Assim, de acordo com as características dos dados de treinamento, um método de aprendizagem utilizado normalmente é o *backpropagation* (retropropagação do erro) com um método de minimização, como os mínimos quadrados. De maneira conceitual, o algoritmo de retropropagação consiste em dois passos de computação: o tratamento direto e o tratamento reverso. No tratamento direto, uma entrada é aplicada à rede neural e seu efeito é propagado pela rede, camada a camada. Durante esse tipo de tratamento, os pesos da rede permanecem fixos. No tratamento reverso, um sinal de erro calculado na saída da rede é propagado no sentido reverso, camada a camada, e ao final deste processo os

pesos são ajustados de acordo com uma regra de correção de erro. O treinamento de uma rede por intermédio de retropropagação, é realizado de forma supervisionada, ou seja, é apresentada à rede uma determinada entrada (exemplo) e é disponibilizada a resposta desejada para aquela entrada.

Entre as recomendações propostas por (Silva e Oliveira, 2001) para se obter os melhores parâmetros para as RNAs, algumas merecem destaque:

**(1) Número de camadas ocultas:** a utilização de muitas camadas ocultas não é recomendada. Cada vez que o erro médio durante o treinamento é utilizado para atualizar os pesos das sinapses da camada imediatamente anterior, ele se torna menos útil ou preciso. A única camada que possui uma noção precisa do erro cometido pela rede é a camada de saída. A última camada oculta recebe uma estimativa sobre o erro. A penúltima camada oculta recebe uma estimativa da estimativa, e assim por diante. Testes empíricos com a rede neural MLP *backpropagation* não demonstram vantagem significativa no uso de duas camadas ocultas ao invés de uma para problemas menores. Para a resolução de problemas de classificação, uma rede neural com uma camada oculta é suficiente. Os problemas de estimação de função também podem ser resolvidos utilizando-se apenas uma camada. Entretanto, pode ser necessário a utilização de duas camadas ocultas;

**(2) Número de neurônios na camada oculta:** com relação ao número de neurônios nas camadas ocultas, este é geralmente definido empiricamente. Deve-se ter cuidado para não utilizar nem

unidades demais, o que pode levar a rede a memorizar os dados de treinamento (*overfitting*), ao invés de extrair as características gerais que permitirão a generalização, nem um número muito pequeno, que pode forçar a rede a gastar tempo em excesso tentando encontrar uma representação ótima. Devido a estas dificuldades, recomenda-se que seja mantido baixo o número de neurônios ocultos, mas não tão baixo quanto o estritamente necessário;

**(3) Taxa de aprendizado:** o parâmetro taxa de aprendizado possui grande influência durante o processo de treinamento da rede neural. Uma taxa de aprendizado muito baixa torna o aprendizado da rede muito lento, ao passo que uma taxa de aprendizado muito alta provoca oscilações no treinamento e impede a convergência do processo de aprendizado. Geralmente seu valor varia de 0,1 a 1,0. Alguns softwares disponíveis no mercado possuem este parâmetro adaptativo, por isso a escolha de um valor inicial não constitui um grande problema;

**(4) Dinâmica de treinamento por interação (*epoch*):** os pesos são atualizados após todos os exemplos de treinamento terem sido apresentados. Esta técnica é geralmente mais estável e o treinamento é menos influenciado pela ordem de apresentação dos padrões, mas ela pode ser lenta se o conjunto de treinamento for grande e redundante. O Matlab (versão 2020b) utiliza essa técnica como padrão;

**(5) Critérios de parada de treinamento:** existem vários métodos para a determinação do momento em que o treinamento de uma rede neural deve ser encerrado. Uma boa determinação destes critérios é fundamental para um bom treinamento e

consequentemente uma boa generalização. Os critérios de parada mais utilizados são por número de ciclos em que define o número de vezes em que o conjunto de treinamento é apresentado à rede. Um número excessivo de ciclos pode levar a rede à perda do poder de generalização (*overfitting*). Por outro lado, com um pequeno número de ciclos a rede pode não chegar ao seu melhor desempenho (*underfitting*). Sugere-se um valor entre 500 e 3.000 ciclos de treinamento.

Outro critério de parada de treinamento é o do erro. Isso consiste em encerrar o treinamento após o erro médio quadrático ficar abaixo de um valor pré-definido. Uma sugestão é estabelecer um valor de 0,01 no primeiro treinamento e depois ajustá-lo em função do resultado.

### 2.4.3 LÓGICA FUZZY

Reconhecida como a melhor ferramenta para se trabalhar com sistemas caixa preta; a lógica *fuzzy* é muito eficiente em situações nas quais é preciso modelar o raciocínio humano. É utilizada em sistemas ou situações cuja complexidade de desenvolver um modelo matemático é alta. O modelamento do sistema via técnicas *fuzzy* é realizado através da inter-relação das variáveis de entrada com as variáveis de saída.

Um sistema baseado em regras *fuzzy* contém até quatro componentes:

(1) Dicionário, que define os conjuntos *fuzzy* sobre as variáveis: etapa de fuzzificação;

- (2) Base de regras, que estabelece uma relação entre as variáveis de entrada e de saída;
- (3) Método de inferência, usado para determinar a saída, dada uma certa entrada;
- (4) Defuzzificação: transforma uma saída *fuzzy* em um número real ou um conjunto clássico. Na Figura 2.4, ilustra-se um sistema de inferência do tipo Mamdani, comumente utilizado em aplicações de controle.

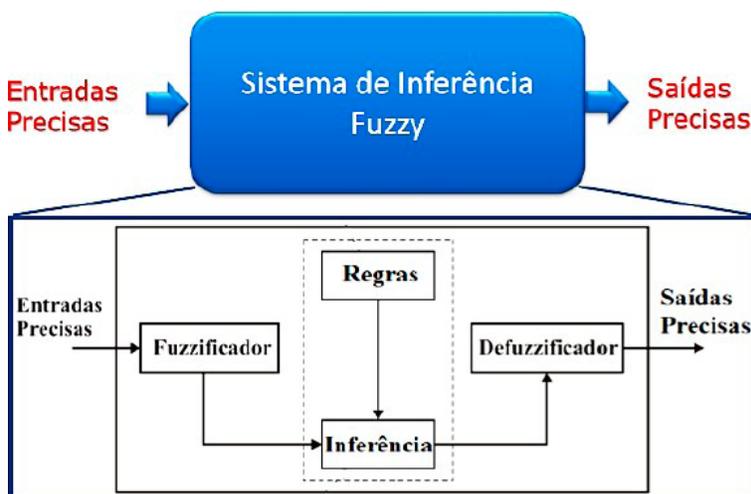


Figura 2.4: Arquitetura fuzzy Mamdani.

Fonte: (Villanueva, 2019).

Para expressar as variáveis e o seu valor, os aspectos quantitativos dão lugar aos qualitativos. Elementos típicos nestes sistemas são alto, médio e baixo; deste modo, a variável numérica cede lugar à variável linguística e a este processo de conversão de valor numérico para linguístico dá-se o nome de

Fuzzificação. Toma-se como exemplo a altura de um elevador; em determinado momento ela pode ter um conjunto de diferentes distâncias em relação ao solo, como {baixa, média, alta}, cada conjunto representa um intervalo numérico da altura, como pode ser visto na Figura 2.5.

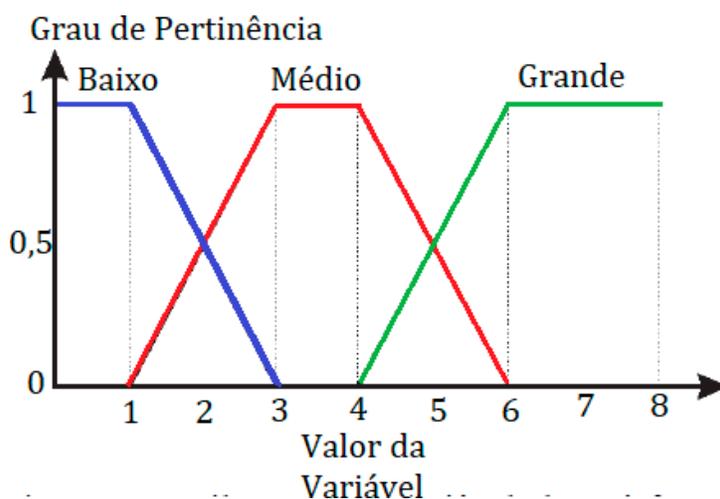


Figura 2.5: Conjunto Fuzzy ilustrando a variável altura à função de pertinência.

Fonte: Autores.

Para definir o comportamento do sistema *fuzzy*, uma base de regras deve ser elaborada. Nas palavras de Ortega (2001), “as regras descrevem situações específicas que podem ser submetidas à análise de especialistas, e cuja inferência conduz a algum resultado desejado”. A base de regras representa, não somente, o conjunto de regras que através de um antecedente são programadas para gerarem um consequente através de

proposições condicionais do tipo “Se – Então”, mas também o processo que determina o

conjunto de saída e conseqüentemente, o valor numérico da saída.

O método ou algoritmo de inferência define a forma operacional do modelo *fuzzy*, mapeando o processo de transformação de valores de entrada em uma saída. As relações entre as variáveis de entrada e as de saída são feitas de, pelo menos, dois modos, onde o processo de inferência do conseqüente varia de acordo com o modelo utilizado. São os modelos de inferência mais utilizados o Mamdani e o Takagi-Sugeno-Kang (TSK).

### 2.4.3.1 INFERÊNCIA DO TIPO MAMDANI

No modelo de inferência Mamdani (1977) as saídas são construídas pela superposição dos conseqüentes das regras individuais do tipo: Regra  $i$ : Se  $x$  é  $A_i$  então  $y$  é  $B_i$ , onde  $i = 1, 2, \dots, n$  e  $n$  é o número de regras,  $x$  é a variável linguística de entrada,  $y$  é a variável linguística de saída e  $A_i$  e  $B_i$  são subconjuntos *fuzzy*, respectivamente, dos universos de discursos  $U$  e  $V$ .

De acordo com o algoritmo de Mamdani, a inferência *fuzzy* é executada utilizando a base difusa de conhecimento, expressa por meio da Equação (2.5) e ilustrada na Figura 2.6.

se  $(X_1 \text{ é } a_{1,1})$  e  $(X_2 \text{ é } a_{1,2})$  e ... e  $(X_n \text{ é } a_{1,n})$   
então  $(Y_1 \text{ é } d_1) (W_1)$

se  $(X_1 \text{ é } a_{2,1})$  e  $(X_2 \text{ é } a_{2,2})$  e ... e  $(X_n \text{ é } a_{2,n})$  (2.5)  
então  $(Y \text{ é } d_2) (W_2)$

se  $(X_1 \text{ é } a_{m,1})$  e  $(X_2 \text{ é } a_{m,2})$  e ... e  $(X_n \text{ é } a_{m,n})$   
então  $(Y \text{ é } d_m) (W_m)$

Na etapa de inferência de um conjunto *fuzzy*, o conjunto selecionado depende do operador de composição, *and* ou *or*. Para *and* (S-norma) se seleciona o conjunto com maior valor de pertinência e para *or* (T-norma) se seleciona o conjunto com o menor valor de pertinência. Os métodos de defuzificação mais utilizados são: centro de área e área média.

### 2.4.3.2 INFERÊNCIA DO TIPO SUGENO

O controlador de Sugeno, ou TSK (Takagi, Sugeno e Kang, 1983), consiste em uma simplificação do controlador de Mamdani, onde o consequente de cada regra é definido como uma função das variáveis linguísticas de entrada. No modelo de Sugeno, as regras são também da forma "Se – Então", onde o consequente pode ser uma constante ou uma função linear, tal como em

se  $X_1$  é  $A_{1,i}$  e  $X_2$  é  $A_{2,i}$  e ... e  $X_n$  é  $A_{n,i}$

então,  $y = f_i (X_1 , X_2 , \dots , X_n)$  (2.6)

em que  $A_{1,i}, A_{2,i}, \dots, A_{n,i}$  são conjuntos *fuzzy* dos antecedentes, enquanto que o conseqüente é uma função das variáveis de entrada, que pode ser linear ou uma constante a ser definida pelos requisitos do projeto. Quando for linear, o conseqüente se tratará de uma representação em forma de uma função de primeiro grau. Quando o conseqüente for constante, a saída será um valor fixo e não dinâmico.

Um exemplo para o sistema de inferência Sugeno está ilustrado na Figura 2.7, em que duas variáveis de entrada tem os seus valores apresentados; atribuído um valor de pertinência a cada conjunto, são atreladas uma função linear definida no projeto e que posteriormente são ponderadas por meio de uma média, em que  $w_i$  é o peso da função de inferência em função do valor de pertinência do conjunto *fuzzy*.

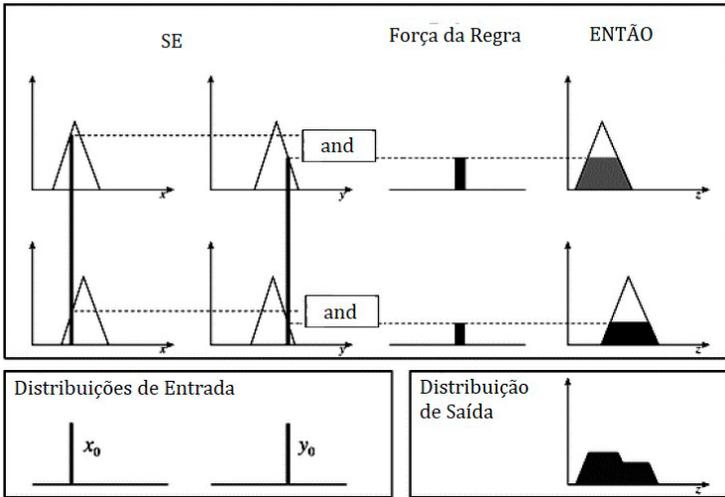


Figura 2.6: Sistema de inferência Mamdani.

Fonte: Adaptado de Moreira (2021).

Dada uma entrada  $(X_1, X_2, \dots, X_n)$ , a saída com um número  $k$  de regras “Se-Então” é dada pela média ponderada das Funções de pertinência ativadas pelo antecedente, que pode ser resumida por

$$y = \sum_{i=1}^k w_i f_i(x_1, x_2, \dots, x_n) \tag{2.7}$$

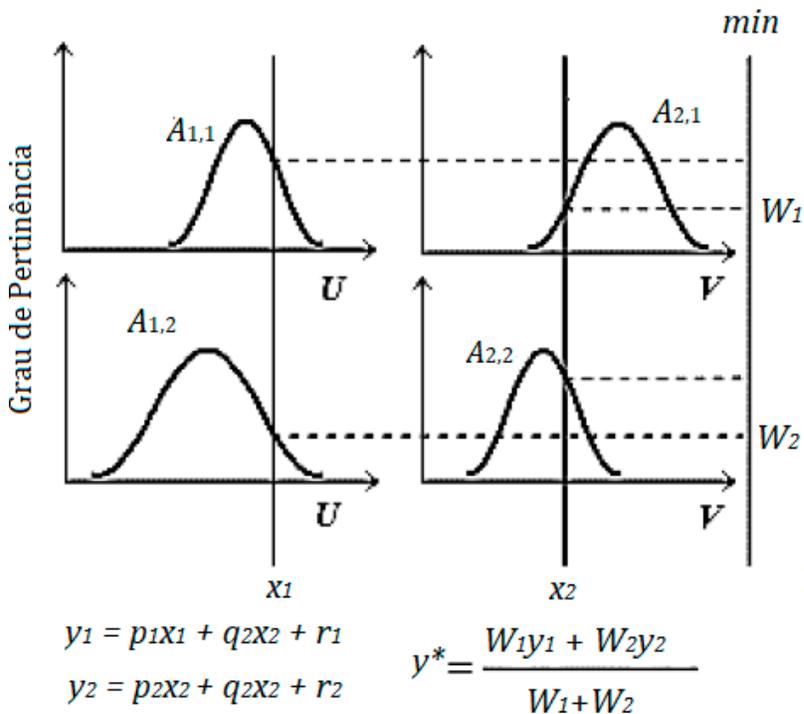


Figura 2.7: Sistema de inferência Sugeno para um consequente linear.

Fonte: Adaptado e Jang (1993).

Outra aplicação prática de sua saída é como interpolador não-linear para funções lineares. A estrutura dos modelos TSK é intrinsecamente adequada para a representação de sistemas dinâmicos complexos, não-lineares e multivariáveis.

O consequente *fuzzy* TSK possui uma saída dinâmica representada por funções cuja complexidade dependem da região de saída. Caso a saída seja trivial pode-se utilizar funções mais simples de forma a reduzir o número de regras. Caso a região precise representar uma não-linearidade, funções mais complexas

podem ser utilizadas em um número maior na região de saída. Neste tipo de modelo de inferência utiliza-se o conceito de linearidade ou não-linearidade locais. Assim, o modelo *fuzzy* TSK é capaz de aproximar um sistema não-linear com uma combinação de vários sistemas lineares, através da decomposição de todo o espaço de entrada em vários espaços parciais. Algumas das vantagens desse método frente ao de Mamdani residem em sua:

- maior eficiência computacional;
- capacidade de trabalhar com técnicas adaptativas;
- garantia de continuidade da superfície de controle;
- maior facilidade para se realizar análises matemáticas;
- capacidade de trabalhar com outros controladores, como PID;
- capacidade de trabalhar com modelos não-lineares através do conceito de linearidade local;
- não-linearidade através do conceito de linearidade local.

## REFERÊNCIAS

- ARAÚJO, J.V.S. **Monitoramento e Controle de Pressão de Redes de Abastecimento de Água Utilizando IoT e Controle Fuzzy**. Trabalho de Conclusão de Curso (TCC), Departamento de Engenharia Elétrica, Universidade Federal da Paraíba (UFPB), 2021.
- BALLINI, R. **Análise e Previsões de Vazões Utilizando Modelos de Séries Temporais, Redes Neurais e Redes Neurais Nebulosas**. Tese de Doutorado, - UNESP, Campinas, SP, Brasil, 2000.
- JANG, J.S.R. **ANFIS: Adaptive-Network-Based Fuzzy Inference System**. IEEE Trans. Syst. Man. Cybern. Vol.23, n.3, 1993, pp.665- 685.
- LIMA, R.P.G.; VILLANUEVA, J.M.M.; GOMES, H.P. FLORES, T.K.S. **Development of a Soft Sensor for Flow Estimation in Water Supply Systems Using Artificial Neural Networks**. Sensors, vol.22, Ano: 2022.
- MAMDANI, E. H. **Application of fuzzy algorithms for control of simple dynamic plant**. Proceedings of the Institution of Electrical Engineers. IET, p. 1585-1588, 1974.
- MOREIRA, H.A.M. **Controle Neuro-Fuzzy para Eficiência Energética de Sistemas de Abastecimento de Água com Demanda Variável**. Dissertação de Mestrado, Departamento de Engenharia Mecânica, Universidade Federal da Paraíba, João Pessoa, Brasil, 2020.
- NISE, N.S. **Engenharia de Sistemas de Controle**. 7ª ed., Ed. GEN (Grupo Editorial Nacional), 2017.
- ORTEGA, N.R.S. **Aplicação da Teoria da Lógica Fuzzy a Problemas de Biomedicina**. Tese de doutorado, IF-USP. São Paulo, Brasil, 2001.
- SUGENO, M.; TAKAGI, T. **A new approach to design of fuzzy controller**. In: Advances in Fuzzy Sets, Possibility Theory, and Applications. Springer,

Boston, Massa, 1983. p. 325-334. [https://doi.org/10.1007/978-1-4613-3754-6\\_20](https://doi.org/10.1007/978-1-4613-3754-6_20).

TAKAGI, T.; SUGENO, M. **Fuzzy identifications of systems and its applications to modeling and control**. IEEE Transactions on Systems, MAN and Cybernetics 15(1), pp.116-132, 1985.

VILLANUEVA, J.M.M. **Sistemas de inferência Fuzzy**. João Pessoa, Brasil, 2019. Disponível em: <http://www.cear.ufpb.br/juan/>. Acesso em 21 de maio de 2020.

# Capítulo 3: Aplicação de Controle Fuzzy em Sistemas de Bombeamento Série-Paralelo

*Thommas Kevin Sales Flores,  
Juan Moises Mauricio Villanueva  
e Heber Pimentel Gomes*

## **3.1 OPERAÇÃO DE BOMBAS EM SÉRIE E EM PARALELO**

A associação de duas ou mais bombas em série faz com o que elas possuam o mesmo fluxo, ou seja, a descarga da primeira bomba está diretamente ligada à sucção da segunda por meio de um ducto, conforme está mostrado na Figura 3.1. Nesse caso, cada uma das bombas contribui com uma parcela da altura manométrica total fornecida ao sistema elevatório.

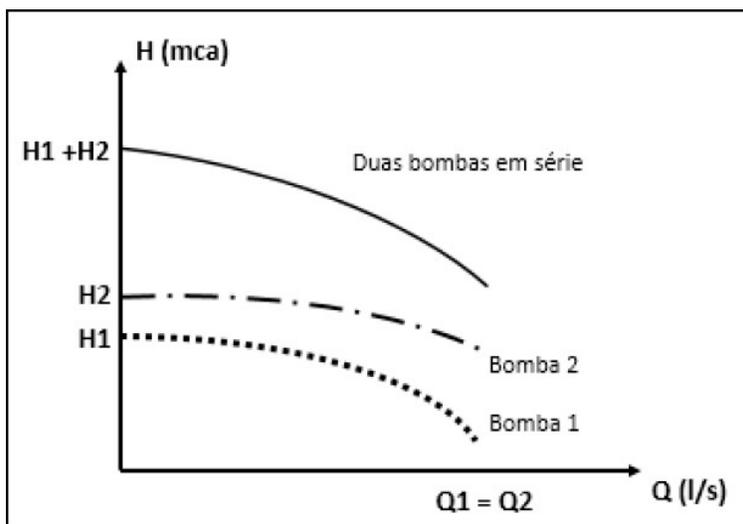


Figura 3.1: Esquema hidráulico de duas bombas ligadas em série.

Fonte: (Flores, 2018).

A curva gerada a partir desta combinação está ilustrada Figura 3.2, onde H1 e H2 correspondem a altura manométrica referente às motobombas 1 e 2, respectivamente. Já (H1+H2), refere-se à altura manométrica total decorrente desta combinação.

A associação em paralelo faz com que duas ou mais bombas operem em conjunto descarregando água numa mesma linha de recalque, conforme está ilustrado na Figura 3.3.

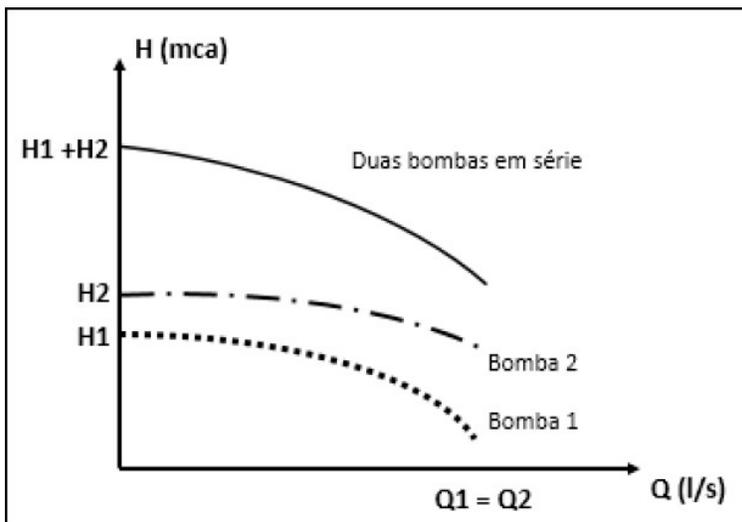


Figura 3.2: Curva característica resultante da associação de duas bombas em série. Fonte: (Flores, 2018).

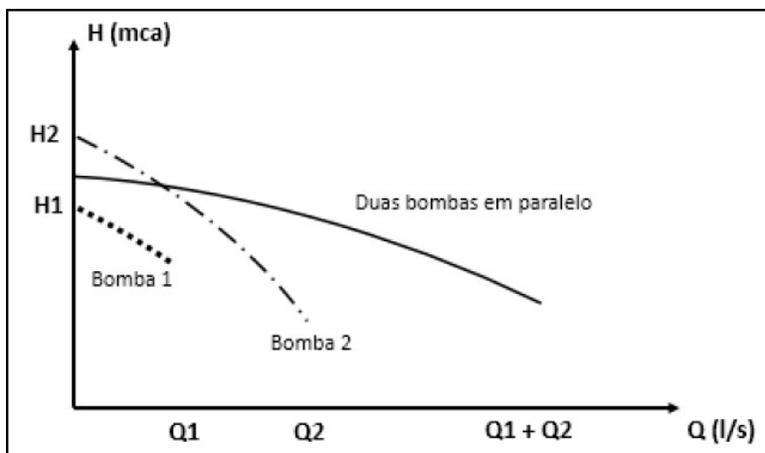


Figura 3.3: Curva característica resultante da associação de duas bombas em paralelo. Fonte: (Flores, 2018).

## 3.2 CONTROLADOR FUZZY

O controlador baseado em lógica *fuzzy* diferencia-se dos controladores clássicos pelo fato de os do segundo tipo serem descritos através de equações algébricas ou diferenciais, através de um modelo matemático, enquanto os controladores *fuzzy* se baseiam na linguagem natural, fruto da experiência humana, com a finalidade de controlar um processo.

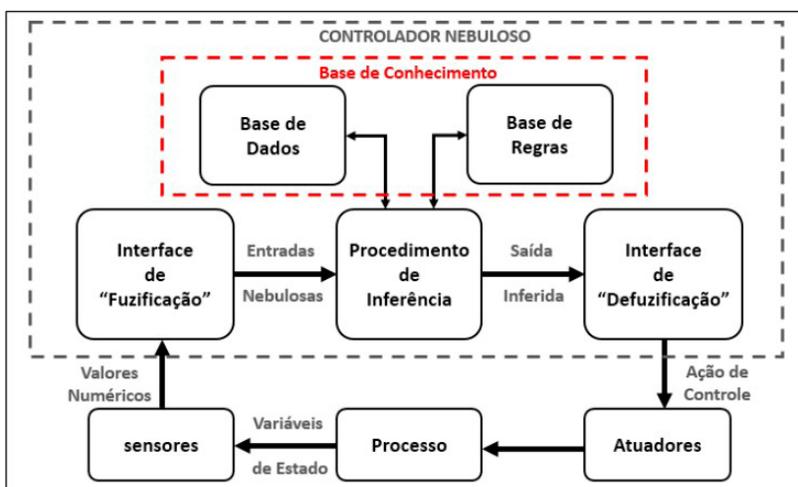


Figura 3.4: Estrutura de um controlador fuzzy.

Fonte: (Flores, 2018).

A estrutura básica para um controlador nebuloso está representada pelo diagrama de bloco da Figura 3.4. Nota-se, que os valores obtidos medidos pelos sensores são transformados em variáveis linguísticas através do processo de fuzificação. Em seguida, estas variáveis fuzificadas passam pelo processo de

inferência, isto é, onde através das bases de dados e de regras o sistema toma a decisão.

Em seguida, por se tratar de um sistema de inferência do tipo Mamdani, necessita-se de uma interface de defuzzificação, cuja função é transformar a variável linguística obtida no sistema de inferência em um valor numérico que será aplicado ao atuador do processo.

## **3.3 EXEMPLO DE A SISTEMAS COM BOMBAS EM SÉRIE E EM PARALELO**

### **3.3.1 BANCADA EXPERIMENTAL**

O sistema o qual foi realizado o experimento, ilustrado na Figura 3.5, é constituído por dois conjuntos motobomba (BOMBA), cinco transdutores de pressão (PT), dois transdutores de vazão (FT), dois inversores de frequência, uma válvula de controle (CV), cinco registros manuais (REG) e por fim um reservatório circular de volume igual a  $7,64 \text{ m}^3$ .

Ademais, há instalação elétrica, uma placa de condicionamento dos sinais provenientes dos sensores, instalação hidráulicas através de tubos e conexões de PVC e para processar os dados, foram usados um computador portátil e uma interface de aquisição de dados.

Sendo assim, o fluxo advindo do reservatório circular é sugado pelas duas motobombas, que em seguida retorna para o mesmo reservatório, tudo isto através de canos. Além disso, a presença de registros no sistema experimental, permite

a configuração em série ou em paralelo das motobombas, possibilitando a criação de diferentes topologias de sistemas hidráulicos.

Na Figura 3.6, estão representados os fluxos da água quando sistema está ligado em série (a) e em paralelo (b).

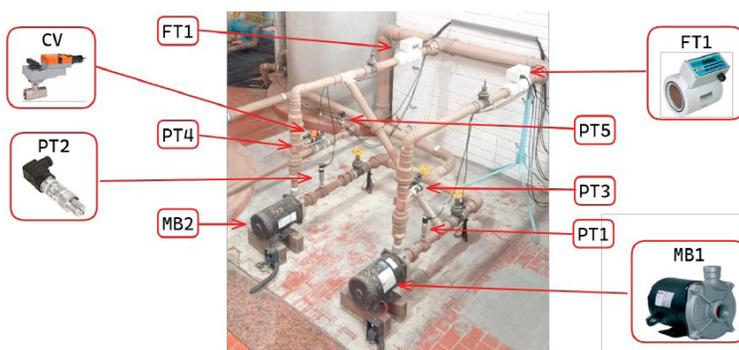


Figura 3.5: Plataforma experimental usada no exemplo.

Fonte: (Flores, 2018).

Os conjuntos motobombas usados são monoblocos composto por um motor de indução trifásico acoplado a uma bomba Dancor, modelo CAM-W10. Estas foram instaladas abaixo do nível de água do reservatório (“afogada”).

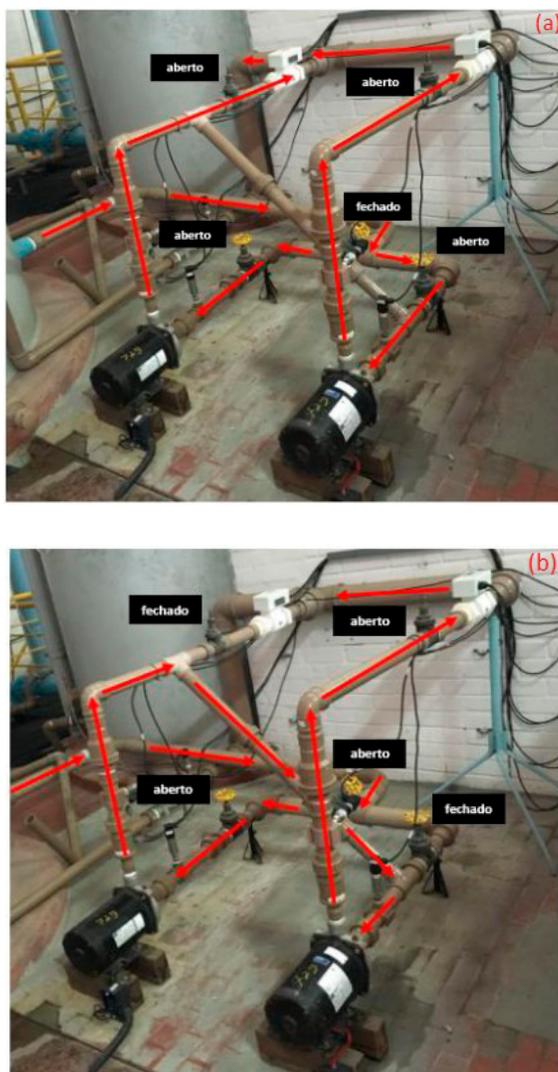


Figura 3.6: Fluxo de água nas ligações (a) série e (b) paralelo.  
Fonte: Flores (2018).

Este modelo CAM-W10 apresenta as seguintes características: são centrífugas, mono-estágio, diâmetro do rotor de 162 mm de altura manométrica máxima de 44 mca, vazão máxima de 14,5 m<sup>3</sup>/h. Na Tabela 3.1, apresentam-se as principais características do modelo das motobombas usadas neste trabalho. Já na Figura 3.7, está ilustrado o modelo deste mesmo dispositivo.

Tabela 3.1: Característica da motobomba.

Fabricante	WEG
Potência	3 CV
Tensão de alimentação	230/380 V
Frequência de alimentação	60 Hz
Índice de proteção	IP 21
Velocidade de rotação nominal	3450 rpm

Fonte: Catálogo do fabricante.

O desempenho da bomba centrífuga citada está demonstrado por um conjunto de curvas características, indicadas na Figura 3.7. Nelas estão contidas as informações acerca da variação da altura manométrica, potência e rendimento em função da vazão.

Em termos práticos, a pressão recebe a unidade de metros de coluna d'água (mca), ou seja, é a altura em que um fluido consegue atingir escoando em uma tubulação, operando em uma vazão desejada. Com isso, o projetista pode, a partir das curvas características da bomba, escolher o melhor dispositivo que se encaixe em seu projeto, bem como analisar a eficiência para o ponto de operação escolhido.

Um conversor de frequência controla a velocidade de rotação da bomba. Na saída do sistema, encontra-se uma válvula proporcional automática (VRP CV-1) que estimula uma demanda variável de água por meio do controle da abertura da seção transversal através da qual a água flui pelo duto.

As tensões oriundas dos sensores são convertidas em sinais digitais por um sistema de aquisição de dados (DAQ) de modelo NI-USB 6229 com frequência de amostragem de 10 amostras/s. O algoritmo de controle foi então aplicado e um sinal de atuação foi gerado e enviado do computador para o inversor via DAQ.

Nesse ponto é necessário ressaltar que os sinais advindos dos diversos sensores distribuídos no sistema são de 4 a 20 mA, porém o sistema de aquisição de dados utilizado, suporta apenas leitura de valores de tensão, com faixa de operação de -10 a 10V. Levando em consideração este aspecto, foi necessário elaborar um circuito de condicionamento destes sinais, o qual transforma o sinal em corrente para tensão.

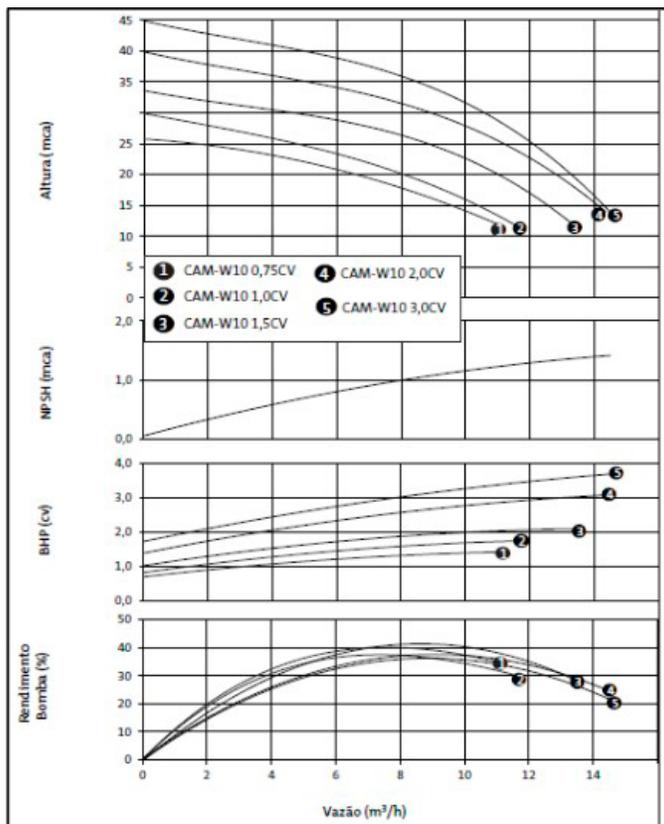


Figura 3.7: Curva característica da bomba CAM-W10.

Fonte: Flores (2018).

Para gerenciar o sistema, o *software* computacional utilizado foi o LabVIEW – Laboratory Virtual Instruments Engineering Workbench, da empresa National Instruments. A programação é feita de acordo com o modelo de fluxo de dados.

Os programas desenvolvidos no LabVIEW são chamados de instrumentos virtuais (IVs). Sua composição consiste em um painel frontal, que contém a interface, e pelo diagrama de blocos, que contém o diagrama de blocos do programa. Esta linguagem é processada por um compilador, e sua performance é de alto nível, recebendo o nome de “linguagem G”.

Neste exemplo, a linguagem G foi escolhida devido à sua compatibilidade com o sistema de aquisição de dados escolhido e às diversas ferramentas oferecidas: sinóticos, gráficos, blocos de lógicas de controle, armazenamento, processamento e análise dos dados

### 3.3.2 CONTROLADOR FUZZY

A estrutura do controlador *fuzzy* (ilustrada na Figura 3.8) cujo objetivo é gerar ações de controle para modificar o valor da resposta de pressão na saída do sistema. O controle de tipo SIMO (*single-input multiple-output*), com P representando a variável de controle (pressão). O erro de pressão está representado por  $e = SP - P$ , em que SP é o valor de referência; De é a variação do erro dado por  $De = e[k] - e[k - 1]$ ; Df é o incremento ou decremento do sinal de atuação (velocidade da rotação do conjunto motobomba). O último valor de frequência usado para atuação é  $f[k - 1]$  e o valor atualizado da frequência do inversor, que é usado como

uma variável de atuação do motobomba é  $f[k]$ . Um saturador foi usado nesse esquema para evitar que o motobomba opere fora da sua faixa de operação.

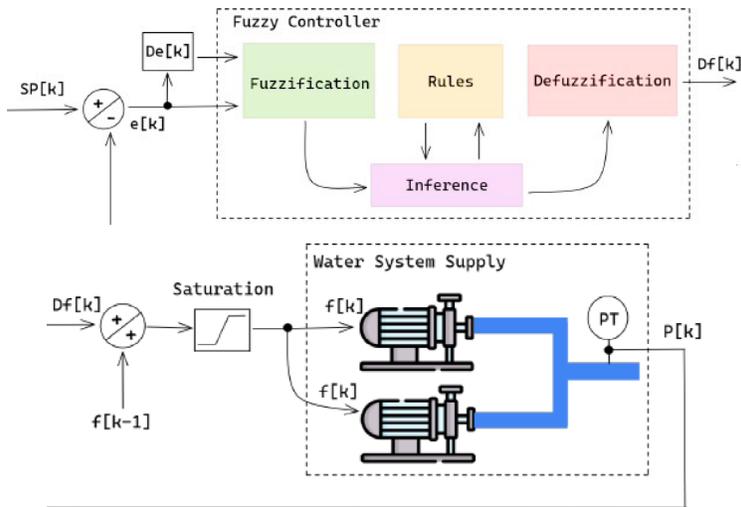


Figura 3.8: Sistema de controle de pressão fuzzy.

Fonte: Adaptado de Flores et al. (2023).

O controle proposto tem como objetivo manter a estabilidade da pressão na saída do sistema, representada pelo sensor PT-5 na Figura 3.5. Neste sistema, também é possível emular a demanda por meio da regulação do ângulo de abertura da válvula de controle na saída do sistema.

Para implementar o controlador *fuzzy*, o primeiro passo consiste em fuzzificar as variáveis de entrada, como foi dito anteriormente. As faixas das variáveis pressão, erro de pressão, variação do erro de pressão e variação de frequência estão dispostas na Tabela 3.2.

Tabela 3.2: Faixas relacionadas a cada variável.

Variáveis	Faixa (Range)
Pressão ( mca )	0 → 42.21
Erro de Pressão ( mca )	-20 → 20
Variação do Erro de Pressão ( mca )	-5 → 5
Variação de Frequência (Hz)	0 → 10

Fonte: Adaptado de Flores et al. (2023)

Os limites das funções de pertencimento das variáveis foram determinados após a análise da resposta do sistema quando a bomba opera com velocidade nominal (60 Hz), a qual revelou que a pressão máxima obtida é de 18 mca e a maior variação do erro é de 4 mca.

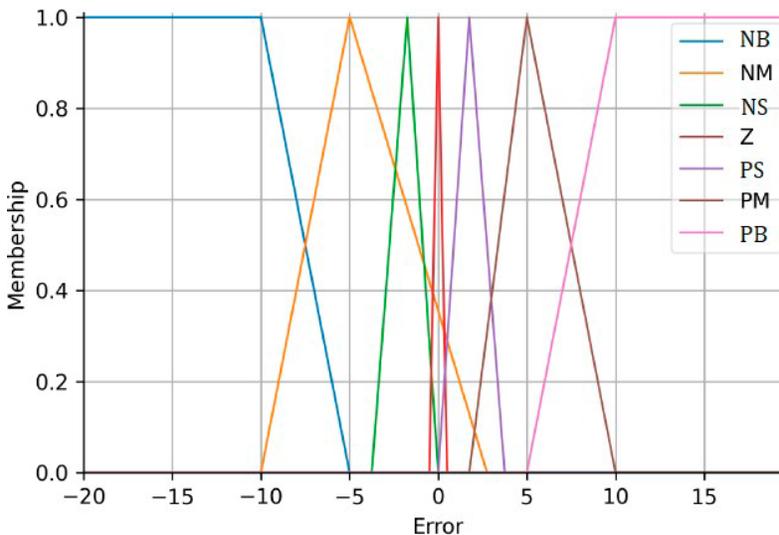


Figura 3.8: Funções de pertencimento do erro (variável de entrada).

Fonte: Flores et al. (2023).

As funções de pertencimento das variáveis de entrada do controlador estão mostradas nas Figuras 4.8 e 4.9. As variáveis linguísticas poderiam ter sete diferentes valores: *negative big* (NB), *negative medium* (NM), *negative small* (NS), *zero* (Z), *positive small* (PS), *positive medium* (PM) e *positive big* (PB). Os contornos numéricos para cada categoria foram definidos considerando conhecimento prévio acerca do comportamento da plataforma. Foram escolhidas para as funções de pertencimento as formas triangular e trapezoidal.

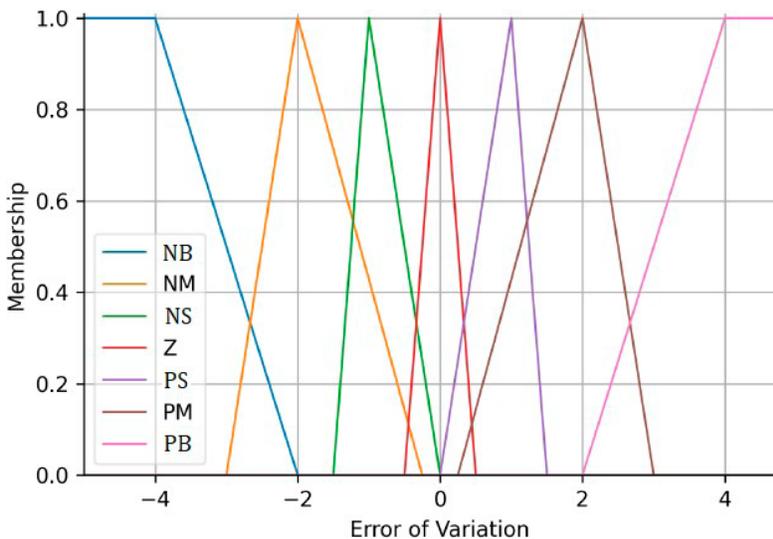


Figura 3.9: Funções de pertencimento da variação do erro (variável de entrada).

Fonte: Flores *et al.* (2023)

As funções de pertencimento da variável de saída do controle *fuzzy* estão ilustradas na Figura 3.10. A determinação dessas funções é baseada na rampa de aceleração do inversor de frequência usado para alimentar o motobomba, cuja frequência máxima de rotação é de 4 Hz. Essas regras, ou variáveis linguísticas de saída, são *decrease small* (DS), *decrease medium* (DM), *decrease big* (DB), zero (Z), *increase big* (IB), *increase medium* (IM), and *increase small* (IS).

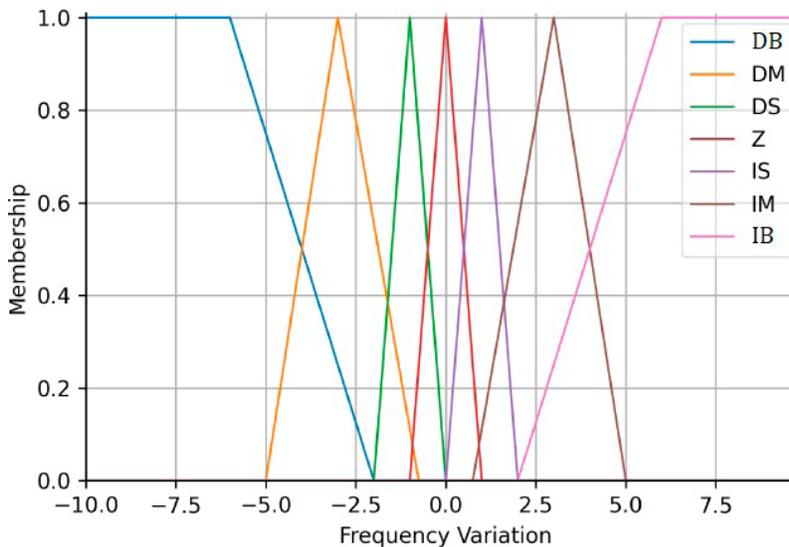


Figura 3.10: Funções de pertencimento da variação da frequência (variável de saída). Fonte: Flores *et al.* (2023)

Para a determinação das regras, tentou-se obter respostas de primeira ordem com erro próximo a zero. Essas propriedades decorrem do estudo do sistema. Por exemplo, a presença de aumentos abruptos no sinal de atuação causa rotação excessiva,

o que resulta na ruptura de canais e danos ao maquinário auxiliar, devido a ocorrências sazonais de sobrecorrentes.

O sinal hipotético ilustrado na Figura 3.11 pode ser usado para deixar mais clara a metodologia aplicada para a elaboração das regras e dos conjuntos *fuzzy* enumerou-se os pontos de 1 a 7, onde a curva tracejada é a resposta do sistema para um dado referencial  $P^*$ .

Observa-se que no ponto 1 o erro é “grande” e positivo, pois este ponto é o mais distante do referencial e está abaixo do mesmo, além disso, a derivada da pressão é nula, pois não há ponto anterior a ele. Este fato justifica um “incremento grande” na frequência de giro do conjunto motobomba (CMB).

Complementarmente, analisando o ponto 3, tem-se que o erro continua positivo, porém menor que o erro do ponto 2 e 1. Por conseguinte, a derivada da pressão é positiva, ou seja, a curva da pressão está em ascensão, logo aplica-se um incremento pequeno da frequência, pois a curva da pressão já está convergindo para o valor desejado. Já o ponto 4 está sobre o valor desejado, ou seja, apresenta erro e derivada da pressão nulos, então o controlador não deve aplicar nenhuma alteração no valor já existente da pressão atuante.

Por outro lado, ao diminuir o valor desejado, nota-se o declínio da curva da pressão do sistema, ao observar o ponto 5 e o comparar ao valor desejado, tem-se um erro “negativo médio”. Além disso, ao comparar o ponto 5 ao

ponto 4, fica evidente que a derivada do erro é “negativo grande”, então justifica-se o controlador atuar no sistema experimental aplicando ao conjunto MB um “zero” da frequência.

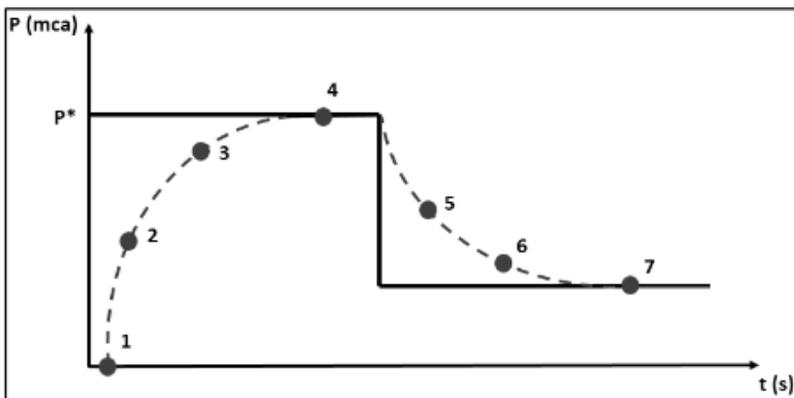


Figura 3.11: Sinal hipotético com todos os estados considerados na elaboração das funções de pertinência.

Fonte: (Flores, 2018).

Na Tabela 3.3 constam 49 regras criadas empiricamente por um especialista, com o objetivo de estabilizar o sistema no regime permanente e de fazê-lo exibir uma relação de resposta suave entre as regras de entrada e as de saída. Para lidar com as regras linguísticas, o procedimento de inferência Mamdani foi utilizado. Já a etapa de defuzzificação foi baseada no método do centróide.

Tabela 3.3: Regras de controle fuzzy.

		Variation of Error (Variação do Erro)						
		NB	NM	NS	Z	PS	PM	PB
Error (Erro)	NB	DS	DS	DS	DM	DM	DB	DB
	NM	Z	DS	DM	DM	DM	DB	DB
	NS	Z	Z	DS	DS	DS	DS	DM
	Z	IS	Z	Z	Z	Z	Z	DS
	PS	IS	IS	IS	Z	IS	Z	Z
	PM	IB	IB	IM	IM	IM	IM	IS
	PB	IB	IB	IB	IB	IM	IM	IM

Fonte: Adaptado de Flores *et al.* (2023)

A partir das regras, o processo de defuzzificação pode ser realizado por meio do método da média dos máximos. Na Figura 3.12, ilustra-se a superfície em que erro e variação do erro são entradas e a variação de frequência é a saída.

Vale ressaltar que a superfície ilustrada na Figura 3.12 pode ser dividida em três sub-regiões:

– Saturação: com valores iguais a  $\pm 6$  Hz, a superfície tem duas regiões de saturação: saturação negativa em azul e saturação positiva em amarelo. Quando o erro e/ou a variação de frequência estão muito distantes do zero, a saída do sistema alcança esses valores;

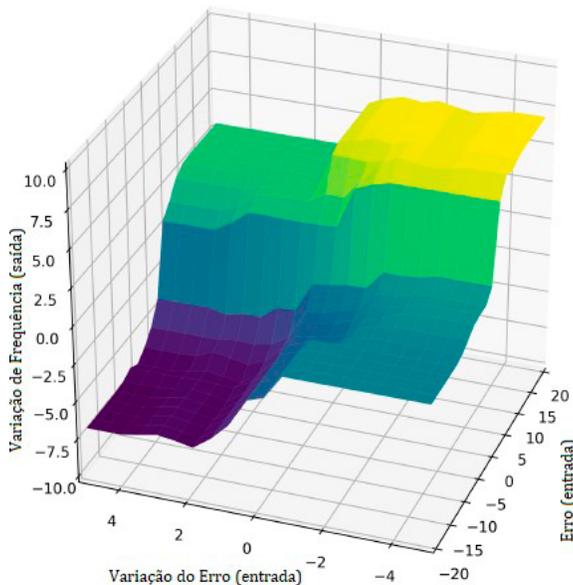


Figura 4.12: Relacionamento entre entradas e saída.

Fonte: Adaptado de Flores *et al.* (2023)

- Regime: é a região de cor verde clara e representa o estado em que a variação de frequência quase inexistente. Isso ocorre quando o erro é muito pequeno ou relativamente grande, mas a sua variação já é grande o suficiente;
- Convergência: essa área representa os outros casos que ocorrem quando o sistema está operando em regiões intermediárias, de modo a alcançar o centro da superfície.

### 3.3.3 EXPERIMENTOS E RESULTADOS

A fim de demonstrar a validade da metodologia descrita acima, dois experimentos podem ser realizados:

- Experimento I: teste com malha fechada do controle *fuzzy* aplicado a uma única bomba, em que as características da resposta decorrente da mudança do setpoint e da demanda de água foram avaliadas;
- Experimento II: teste com malha fechada do controle *fuzzy* aplicado a dois conjuntos de bombas conectados em série e em paralelo, em que as características da resposta diante da variação do setpoint e da demanda de água são avaliadas.

#### 3.3.3.1 EXPERIMENTO I

No Experimento I, o primeiro teste foi feito com um conjunto motobomba (MB 1) iniciado a partir do repouso, ou seja, frequência zero e ângulo da válvula de controle VRP igual

a 35°, um valor que corresponde à menor demanda. O valor de pressão de 10 mca foi aplicado. Neste procedimento, o sistema de controle foi avaliado nos seguintes aspectos: tempo de subida, sobrevalor percentual, tempo de assentamento e erro em regime permanente. A resposta do controlador está ilustrada na Figura 3.13 e as suas características estão expostas na Tabela 3.4.

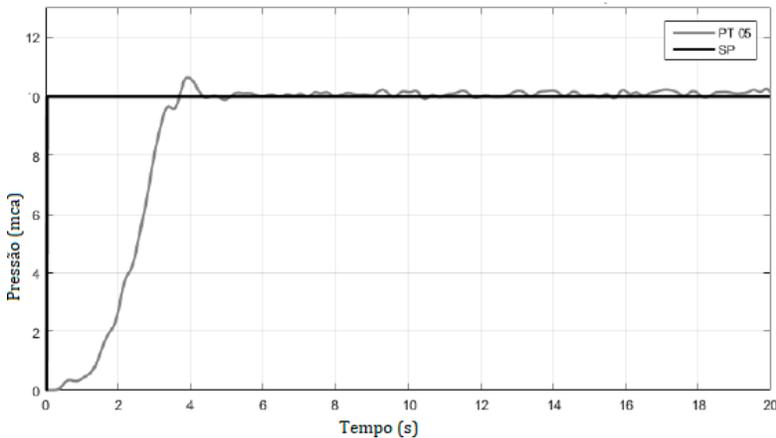


Figura 3.12: Relacionamento entre o setpoint e a pressão para a resposta ao degrau do controlador *fuzzy* proposto.

Fonte: Flores *et al.* (2023)

Tabela 3.4: Características da resposta do controlador *fuzzy* proposto quando aplicado a uma motobomba.

Setpoint	Tempo de Subida	Tempo de Assentamento	Sobrevalor Percentual	Erro de Regime Permanente
10 mca	1.76 s	4.35	5.66%	0.79%

Fonte: Adaptado de Flores *et al.* (2023)

Nesse mesmo experimento, também é possível calcular a eficiência energética do conjunto motobomba para diferentes setpoints. Para isso, a equação

$$\eta = \gamma \cdot Q \cdot H \cdot 100 / P, \quad (1)$$

em que  $\eta$  é a eficiência,  $\gamma$  é o peso específico do fluido,  $Q$  é o fluxo,  $H$  é a pressão e  $P$  é a potência elétrica (em kW).

O valor inicial desejado para o setpoint foi de 8 mca, tendo sido incrementado a um passo de 2 mca, até o limite de 14 mca. Em seguida, foi decrementado até 8 mca, com o mesmo passo. Os resultados estão sumarizados na Tabela 3.5.

Tabela 3.5: Eficiência energética do sistema com controle *fuzzy* e um CMB.

Setpoint	Eficiência
8 mca	30.11%
10 mca	26.08%
12 mca	23.74%
14 mca	23.20%
12 mca	23.41%
10 mca	25.61%
8 mca	29.28%

Fonte: Flores *et al.* (2023).

A análise dos valores expostos na Tabela 3.5 revela que o fluxo diminui à medida que a pressão aumenta. Isso

ocorre porque a bomba opera perto da rotação nominal, necessitando da potência máxima, o que significa exceder o ponto de operação ideal do sistema.

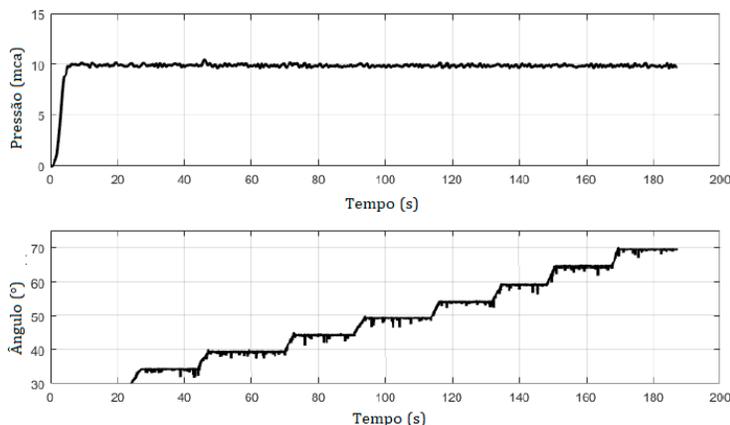


Figura 3.14: Resposta do sistema controlado e com um único motobomba diante da variação da demanda de água.

Fonte: Adaptado de Flores *et al.* (2023)

Em um terceiro teste, com o motobomba (MB1) iniciado com frequência zero e a VRP com ângulo de  $30^\circ$ , a abertura da válvula foi variada remotamente, por meio de um instrumento virtual desenvolvido em LabVIEW, a fim de emular a demanda de água ao longo do tempo. Na Figura 3.14, observa-se que a resposta do controlador permanece constante ao longo do teste. Para determinar o erro de regime permanente, todos os valores no intervalo de tempo de 10 a 180 s foram usados para calcular uma média, a qual foi subtraída do valor desejado, o que levou a uma estimativa de 0,47% de erro.

### 3.3.3.2 EXPERIMENTO II

No experimento II, o objetivo é avaliar a aplicação de controle fuzzy às configurações de motobombas em série e em

paralelo em um sistema de abastecimento de água em termos de eficiência energética.

Antes de aplicar o controlador proposto, as curvas características dos arranjos de motobombas foram obtidas, com o objetivo de comparar as suas faixas de eficiência e operação para as seguintes situações: uma única motobomba, duas motobombas em série e duas em paralelo.

Inicialmente, considerou-se que a bomba tinha frequência de rotação igual a zero e ângulo da válvula de controle de  $90^\circ$ . Em seguida, as frequências de 30, 40 e 50 Hz foram aplicadas, e, para cada frequência, a válvula foi posicionada nos seguintes ângulos:  $90^\circ$ ,  $60^\circ$ ,  $50^\circ$ ,  $40^\circ$ ,  $30^\circ$ ,  $20^\circ$ ,  $10^\circ$  e  $0^\circ$ , a fim de emular o decaimento da altura manométrica em um sistema de descarga.

Nas Figura 3.15, observa-se que a operação em sériedas bombas atinge a soma das pressões individuais e o valor do fluxo se aproxima daquele em que há uma única bomba. A conexão em paralelo leva às pressões individuais e aproximadamente à soma dos fluxos das duas bombas.

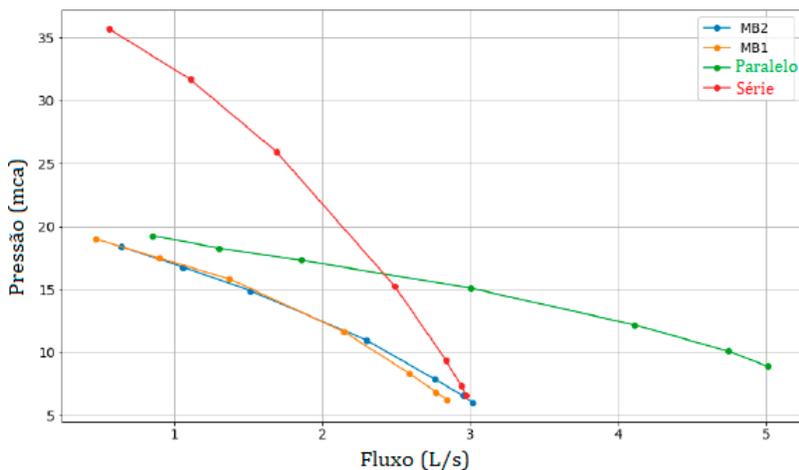


Figura 3.15: Curvas características de operação em série/paralelo do CMB usado, comparativamente a CMB individuais para frequência de 30 Hz.

Fonte: Adaptado de Flores *et al.* (2023)

Adicionalmente, na Figura 3.16 estão mostradas as curvas de eficiência energética que relevam qual configuração de operação é mais viável, ou seja, quando o uso de arranjos em série e paralelo são mais viáveis que o uso de bombas isoladas.

O processo de escolha e configuração com maior eficiência para um dado ponto de operação consiste em usar as curvas da Figura 3.15 como ábaco, observando os valores de fluxo para a pressão de 10 mca, que é o valor de interesse. Esse procedimento pode ser feito com o uso de uma linha paralela ao eixo x, que passe pelas curvas das quatro configurações, interceptando os fluxos 1 L/s (MB 1), 0.9 L/s (MB 2), 1.5 L/s (paralelo), and 1.8 L/s (série).

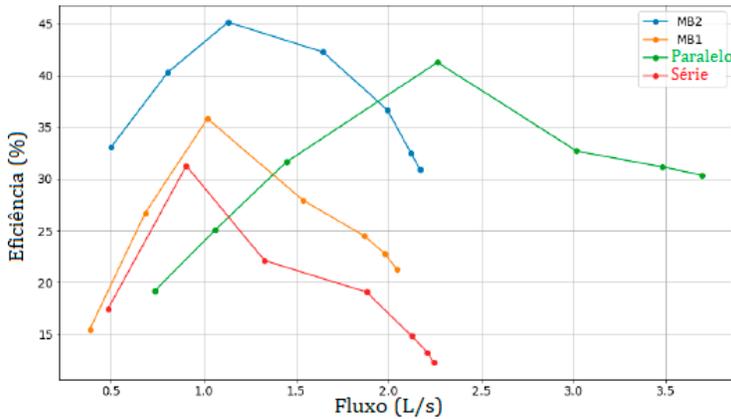


Figura 3.16: Eficiência dos arranjos em série e em paralelo do CMB usado, comparativamente a CMB individuais, com frequência de 30 Hz.

Fonte: Adaptado de Flores *et al.* (2023)

Os valores de fluxo interceptados a uma pressão de 10 mca podem ser usados para consultar as curvas da Figura 3.16, levando aos seguintes valores de eficiência: 35% (MB 1), 42,5% (MB 2), 23% (paralelo) and 30,5% (série). A eficiência do motobomba 2 é o mais alto, de modo que o sistema operará com essa configuração.

Considerando o arranjo em série dos motobombas 1 e 2, iniciando com velocidade de rotação zero, ângulo da válvula de controle de 35° e valor de potência de 10 mca, a resposta ao degrau está ilustrada na Figura 3.17 e as suas características estão dispostas na Tabela 3.6.

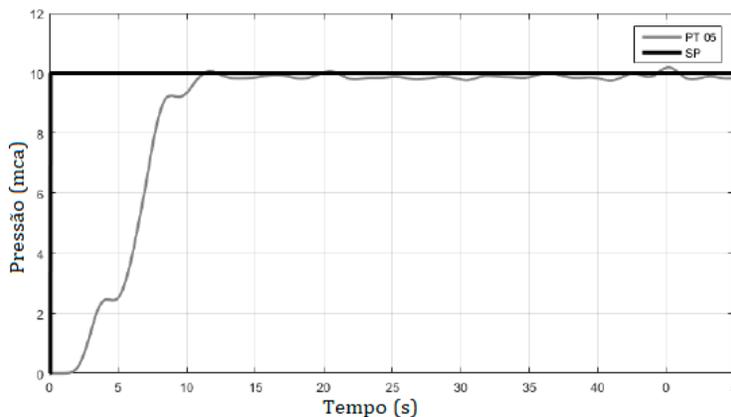


Figura 3.17: Resposta ao degrau do sistema com controle *fuzzy* com arranjo de motobombas em série.

Fonte: Adaptado de Flores *et al.* (2023)

A robustez do sistema de controle *fuzzy* diante da mudança da demanda de água também pode ser verificada.

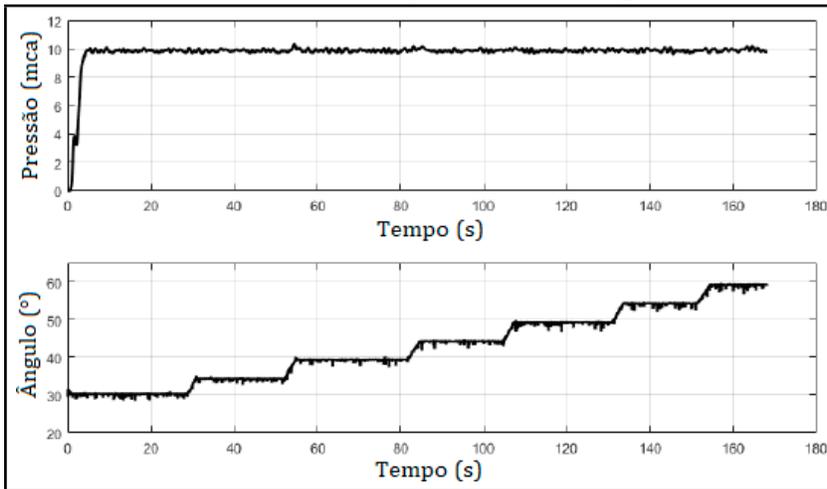
Para emular esse cenário, a válvula proporcional foi acionada remotamente ao longo do tempo e com diferentes valores, a começar por 30°. O ângulo de abertura foi incrementado até 60°. Os resultados ilustrados na Figura 3.18 revelam que o controlador consegue manter a pressão do sistema estável e com erro de regime permanente próximo a zero.

Tabela 3.6: Características temporais do arranjo em série com controlador *fuzzy*.

Setpoint	Tempo de Subida	Tempo de Assentamento	Sobrevalor Percentual	Erro de Regime Permanente
10 mca	2.21 s	4.54 s	–	0.49%

Fonte: Adaptado de Flores *et al.* (2023)

Figura 3.18: Resposta do sistema controlado e com um par de motobombas em série diante da variação da demanda de água.



Fonte: Adaptado de Flores *et al.* (2023)

A eficiência energética do sistema controlado para diferentes setpoints também pode ser analisada. Para tanto, considera-se que a velocidade inicial de rotação do motobomba é zero, o valor inicial do ângulo da VRP é de 35° e a pressão é de 8 mca. O valor da pressão foi incrementado com passo de 2 mca até o limite de 14 mca, a partir do qual a pressão foi decrementada

com passo de 2 mca até retornar ao valor inicial de 8 mca. Esses resultados estão expostos na Tabela 3.7.

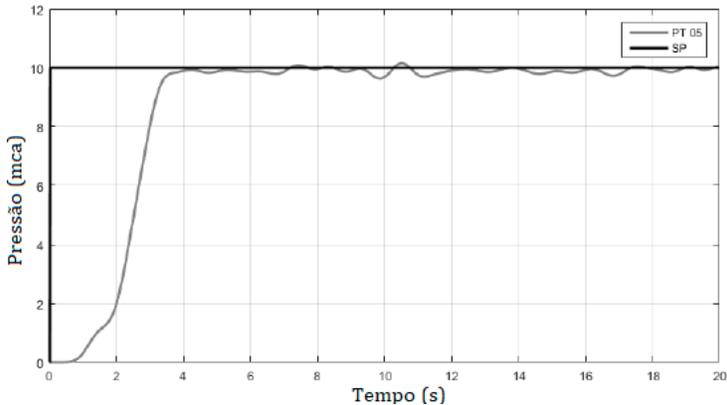
Tabela 3.7: Eficiência energética do sistema com controle *fuzzy* e um arranjo de motobombas em série.

<b>Setpoint (mca)</b>	<b>Eficiência</b>
8:	21.94%
10	23.30%
12	19.89%
14	19.69%
12	20.16%
10	23.51%
8:	22.15%

Fonte: Adaptado de Flores et al. (2023)

Os testes com a configuração em paralelo foram realizados com o ângulo da VRP inicialmente em 35°. Considera-se o valor do setpoint de 10 mca. As características temporais da resposta estão expostas na Tabela 3.8 e a curva de resposta ao degrau está ilustrada na Figura 3.19.

Figura 3.19: Resposta ao degrau do sistema com controle fuzzy com arranjo de CMB em paralelo.



Fonte: Flores *et al.* (2023)

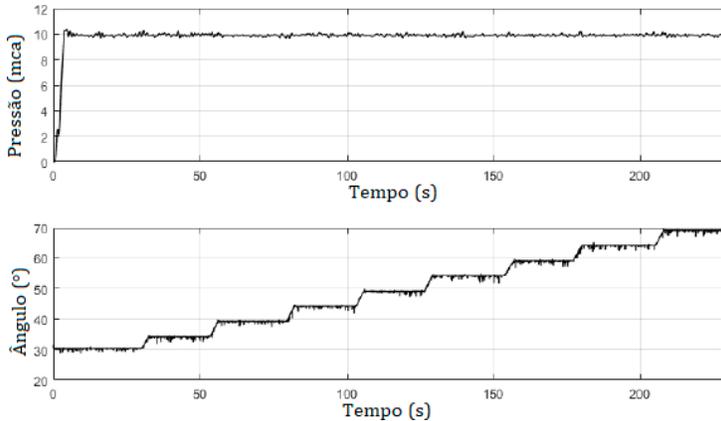
Tabela 4.8: Características temporais do arranjo em paralelo com controlador fuzzy.

Setpoint	Tempo de Subida	Tempo de Assentamento	Sobrevalor Percentual	Erro de Regime Permanente
10 mca	1.78 s	4 s	–	0.56%

Fonte: Flores *et al.* (2023).

Para verificar a robustez do controlador fuzzy em um sistema que opera com duas bombas em paralelo e com demanda variável, a válvula proporcional foi inicializada com ângulo de 30°, variando de forma gradual e discreta até o limite de 60°. O resultado está exposto na Figura 3.20. Novamente, o controlador se mostrou capaz de estabilizar a pressão do sistema, com erro de regime permanente próximo a zero.

Figura 3.20: Resposta do sistema controlado e com um par de motobombas em paralelo diante da variação da demanda de água.



Fonte: Flores *et al.* (2023)

A eficiência energética dessa configuração com controle fuzzy foi avaliada para diferentes valores desejados. Para tanto, considera-se  $35^\circ$  como ângulo de abertura inicial da VRP e valor desejado inicial de pressão de 8 mca, variando até 14 mca com passo de 2 mca, para depois voltar ao valor inicial de 8 mca. Os dados de eficiência energética estão dispostos na Tabela 3.9.

Tabela 3.9: Eficiência energética do sistema com controle *fuzzy* e um arranjo de motobombas em paralelo.

<b>Setpoint (mca)</b>	<b>Eficiência</b>
8	39.20%
10	33.18%
12	33.74%
14	29.92%
12	34.56%
10	32.77%
8	34.86%

Fonte: Flores *et al.* (2023)

A comparação entre as eficiências alcançadas com os três tipos de configurações consideradas aqui pode ser vista na Tabela 3.10, onde estão dispostas as médias para os valores desejados de pressão.

Tabela 3.10: Eficiência energética de diferentes configurações com controle *fuzzy*.

<b>Configuração de Operação</b>	<b>Eficiência</b>
Uma única motobomba	25.84%
Duas motobombas em paralelo	33.74%
Duas motobombas em série	23.4%

Fonte: Flores *et al.* (2023).

### 3.3.3.3. CONSIDERAÇÕES FINAIS

Considerando o valor de operação com uma única motobomba como referência, a operação do sistema com bombas em paralelo apresenta um aumento de 23,41% em eficiência quando comparado ao de uma única motobomba. Por outro lado, quando se deseja operar em série, há uma redução da ordem de 10,42% no valor da eficiência energética de operação com uma única motobomba. Portanto, o controle *fuzzy*, devido à sua capacidade de lidar com incertezas e imprecisões, flexibilidade e capacidade de mimetizar o processo decisório humano, proporciona uma abordagem mais eficiente que os métodos de controle tradicionais, tais como o controle PID (proporcional-integral-derivativo), o controle baseado em modelos ou o controle baseado em regras em sistemas de distribuição de água. No contexto de sistemas de bombeamento, controladores *fuzzy* oferecem várias vantagens e características únicas:

- Robustez: devido à capacidade de lidar com incertezas e imprecisões do sistema, o que torna esse controle adequado a aplicações em que os parâmetros do sistema são desconhecidos;
- Flexibilidade: eles podem ser facilmente modificados para lidar com mudanças no sistema, ou para incorporar novas estratégias de controle;
- Simplicidade: não necessitam de modelos matemáticos do sistema complexos, o que simplifica o seu projeto;

- Processo decisório quase humano: os torna adequados a aplicações em que o julgamento humano é necessário para melhorar o desempenho;
- Lida com não linearidades;
- Lida com múltiplas entradas e saídas: permite a aplicação em sistemas complexos (com muitas variáveis);
- Lida com múltiplos setpoints;
- Lida com setpoint variável no tempo;
- Lida com grandes variações nas variáveis de processo.

Em resumo, este capítulo fala sobre uma metodologia de controle baseada em lógica *fuzzy* e a sua aplicação a sistemas que contêm entre seus componentes pares de motobombas arranjadas em série ou em paralelo. Recebem destaque alguns dos principais parâmetros da resposta do sistema, tais como tempo de assentamento,

tempo de subida, sobrevalor percentual e erro de regime permanente, além da eficiência energética. Os resultados do exemplo revelam que a metodologia *fuzzy* proporciona a estabilização da pressão hidráulica em menos de 5 s, com erro de regime permanente próximo a zero, independentemente da topologia considerada. O sistema de controle também se mostrou robusto a variações de demanda emuladas por uma válvula proporcional. O uso de bombas em série ou em paralelo permitem o aumento da pressão total do sistema e do fluxo

total, respectivamente. A associação de motobombas, apesar de depender de certos critérios, é uma alternativa mais barata e energeticamente mais eficiente ao uso de bombas mais potentes. O uso do controlador *fuzzy* para fazer o balanço entre as duas bombas do arranjo de forma heurística possibilita o seu uso e barateia o sistema sem que seja preciso recorrer a controladores cujo projeto seria muito mais complexo.

## REFERÊNCIAS

FLORES, T.K.S. **Sistema Fuzzy para Controle de Pressão Aplicado a Sistemas de Bombeamento Série-Paralelo Visando a Eficiência Energética**. Trabalho de Conclusão de Curso (TCC), Departamento de Engenharia Elétrica, Universidade Federal da Paraíba (UFPB), 2018.

FLORES, T.K.S.; VILLANUEVA, J.M.M.; GOMES, H.P. **Fuzzy Pressure Control: A Novel Approach to Optimizing Energy Efficiency in Series-Parallel Pumping Systems**. *Sensors*, n.4, pp. 11-28, 2023.

# Capítulo 4: Controladores Neuro-fuzzy Aplicados ao Ajuste de Pressão em Sistemas de Distribuição de Água

*Hugo Augusto Marinho Moreira,  
Heber Pimentel Gomes,  
Juan Moises Mauricio Villanueva  
e Saulo de Tarso Marques Bezerra*

## **4.1 O CONTROLADOR NEURO-FUZZY E IDENTIFICAÇÃO DE SISTEMAS**

A técnica Neuro-Fuzzy (NF) foi proposta por Jang (1993), inicialmente com o nome *Artificial Neural Fuzzy Inference System* (ANFIS). Esse tipo de sistema fornece inúmeras vantagens ao combinar as propriedades das Redes Neurais Artificiais (RNA) e da Lógica *Fuzzy* (LF), tais como permitir a modelagem de sistemas não-lineares e multivariáveis, características difíceis de serem modeladas por modelos fenomenológicos e até por lógica *Fuzzy*. Nesta técnica o modelo matemático do sistema a ser controlado não é necessário. A expertise do projetista, para

o desenvolvimento da base de regras e formação dos conjuntos *Fuzzy*, é também dispensada.

A obtenção do modelo do sistema está associada a sua importância para o estudo, otimização, análise e projeto de algoritmos de sistemas controle (malha aberta, adaptativos, dentre outros). As técnicas de identificação de sistemas consistem na construção de modelos dinâmicos baseados em dados medidos. As técnicas computacionais progrediram muito nos últimos anos e estão tomando o lugar da matemática clássica na modelagem e no projeto de muitos sistemas dinâmicos. De certo, sistemas muito complexos e com não-linearidades severas são melhores representados por modelos computacionais, principalmente por modelos inteligentes, como as redes neurais, os sistemas *Fuzzy* (SF) e Neuro-Fuzzy.

Observam-se ineficiências acentuadas dos métodos convencionais de identificação de sistemas - paramétricos e fenomenológicos -, principalmente quando há não-lineares ou multivariáveis envolvidas. A busca por métodos mais eficientes resultou no desenvolvimento de modelos robustos baseados em inteligência artificial, como as Redes Neurais e os sistemas Neuro-Fuzzy. Desta forma, a utilização de métodos inteligentes têm garantido um maior desempenho das técnicas de identificação.

A identificação de sistemas permite obter um modelo, que é uma representação computacional ou numérica do sistema. "O modelo obtido pode ser usado para obter uma noção do comportamento do sistema, como predição, controle, estimação do estado, simulação, etc." Modelos matemáticos constituem um eficiente mecanismo para resumir o conhecimento acerca de um

processo ou sistema. Entretanto, a complexidade do sistema, por vezes, impede a obtenção do modelo matemático.

Um sistema pode ser identificado através da excitação de suas entradas em observância com a resposta obtida nas suas saídas; a partir dos pares de dados obtidos, o modelo computacional pode ser obtido. Normalmente são adotados diversos modelos computacionais e, através de comparação, um ou mais modelos podem ser escolhidos. O passo final trata da validação do modelo através da comparação experimental e simulada, em observância com o erro medido, que no geral podem ser a Raiz do Erro Quadrático Médio (RMSE), Raiz do Erro Médio Quadrático Normalizado (NRMSE), o Erro Final de Predição (FPE) e percentual de Ajuste. “Os modelos assim gerados podem ser utilizados para inferir propriedades dinâmicas e estatísticas do sistema original” (Rodrigues, 1996).

As etapas para a obtenção de um modelo computacional são:

- Planejamento experimental: determinação de como os dados serão coletados, isto é, qual o método de amostragem a ser utilizado;
- Seleção da estrutura do modelo: seleção da estrutura do modelo e posterior determinação dos parâmetros passíveis de serem ajustados, chamados parâmetros livres.

A identificação de sistemas por modelos computacionais é possível devido às diversas ferramentas computacionais oferecidas atualmente, como o system identification do Matlab. A ampla

oferta destes pacotes permite a modelagem em mais de uma técnica, permitindo a comparação e a seleção do modelo mais eficiente. Entretanto, para a realização deste tipo de modelagem é necessário uma grande disponibilidade de dados amostrais de toda região de operação do sistema, que devem ser obtidos através de ensaios experimentais da planta. Dentre os modelos mais utilizados estão os paramétricos e os inteligentes. Segundo Bittencourt (2007) há algumas estruturas de modelos padrões utilizadas na identificação paramétrica, que normalmente são estruturas de modelos discretos. Dentre os diferentes modelos utilizados, destacam-se: Box-Jenkins (BJ), Output Error (OE), Auto Regressivo com Entradas Exógenas (ARX), Auto Regressivo com Média Móvel e Entradas Exógenas (ARMAX) e estrutura de Espaço de Estados (SS).

Técnicas de inteligência artificial, como as redes neurais, são também utilizadas para a identificação de sistemas, devido a sua capacidade de relacionar variáveis de entrada para saídas com características não-lineares.

### **4.1.1 ANÁLISE E VALIDAÇÃO DE MODELO**

Obtido o modelo computacional, é necessário utilizar indicadores ou métodos para avaliá-lo quantitativamente, e validá-lo. A validação de um modelo é mais um princípio quantitativo do que qualitativo, pois depende fortemente da aplicação. Um método de estimação de parâmetros bastante comum e geral é o método de Erro Final de Predição (FPE), onde os parâmetros do

modelo são escolhidos de forma a minimizar a diferença entre a saída do modelo (predição) e a saída medida. Para cada valor do vetor de parâmetros ( $\theta$ ), o modelo é capaz de prever qual será a saída  $y(t)$  – como mostrado na Equação (4.1) –, baseado nas medidas de entrada e saída,  $u(s)$  e  $y(s)$ , respectivamente, para  $s \leq t - 1$ , ou seja, entradas e saídas anteriores.

$$y(t) = Q(q)u(t) + H(q)e(t) \quad (4.1)$$

No caso geral, a Equação (4.2) pode ser utilizada para obter o FPE, a predição pode ser deduzida da seguinte forma:

$$H^{-1}(\theta, q)y(t) = H^{-1}(\theta, q)Q(\theta, q)u(t) + e(t) \quad (4.2)$$

Segundo Bittencourt (2007), a Equação (4.3) é uma expressão geral de como os modelos realizam a predição do próximo valor da saída, dados os valores antigos de entrada e saída. Assim, pode-se verificar quão boa é essa predição calculando o erro de predição:

$$\epsilon(t, \theta) = y(t) - \hat{y}(t|\theta) \quad (5.3)$$

onde  $\epsilon$  é o erro de predição e  $\hat{y}$  é a saída simulada.

Além disso, é possível confrontar a saída do modelo com uma nova sequência de dados de validação. Em termos estatísticos esse método é chamado de validação cruzada e é um método natural de comparação, pois se um modelo é capaz de prever uma sequência de dados melhor que outro, ele deve ser tratado como o melhor modelo encontrado. O problema da validação cruzada é que quanto maior for a ordem do modelo menor será a função de custo. Se os valores dessa função forem plotados como uma função da ordem do modelo, será obtida uma função decrescente. Assim, mesmo depois que a ordem “correta” do modelo tiver passado, a função de custo continuará diminuindo. A razão é que parâmetros extras (e não necessários) são usados para ajustar o modelo às perturbações específicas dos dados usados. Isso é chamado de sobre ajuste e não tem nenhum benefício se o modelo for usado quando outras perturbações afetarem o sistema. Pelo contrário, o modelo será na verdade pior por causa do sobre ajuste.

Outras métricas são utilizadas para avaliar o desempenho de cada modelo, Raiz do Erro Médio Quadrático (RMSE), Raiz do Erro Médio Quadrático Normalizado (NRMSE) e percentual de Ajuste, mostradas nas Equações (4.4) à (4.6), respectivamente.

$$RMSE = \sqrt{\frac{\sum_{k=1}^P (y^k - \hat{y}^k)^2}{n}} \quad (4.4)$$

$$NRMSE = \frac{1}{y_{max} - y_{min}} * RMSE \quad (4.5)$$

$$AJUSTE = \left(1 - \frac{1}{P} \sum_{k=1}^P |y^k - \hat{y}^k|\right) * 100/\hat{y}^k \quad (4.6)$$

onde  $y^k$  ou  $y$  e  $\hat{y}^k$  ou  $\hat{y}$  são respectivamente a saída desejada e a saída obtida pelo modelo para a k-ésima entrada e P é o número total de pares de treinamento, ou de validação, considerados.

Em geral, as características referentes a qualidade do modelo devem ser sempre em base quantitativa, predizer que um modelo realmente é bom, depende da sua aproximação numérica com o sistema real. Na prática, nem sempre se tem uma descrição exata disponível, e a qualidade do modelo deve, sempre que possível, ser julgada em diferentes aspectos:

- A qualidade do modelo relacionada com seu uso: o modelo pode ser excelente para controle, porém inadequado para simulação;
- A qualidade do modelo relacionada com habilidade de reproduzir o comportamento do sistema: a simulação do modelo ou sua predição da saída é bem próxima da saída produzida pelo sistema;
- A qualidade do modelo está relacionada à estabilidade do modelo: para diferentes dados medidos sobre diversas condições o modelo consegue reproduzir bem o sistema.

Outro ponto que deve ser abordado é o *overfit*, principalmente quando se utilizam modelos com entradas autorregressivas exógenas. Sendo definido como a capacidade do modelo de prever com exatidão a saída quando um novo conjunto de dados é utilizado para validação ou teste. Desta forma, na validação parte-se sempre de um novo conjunto de dados, como forma de evitar que o modelo computacional seja ineficiente.

## 4.1.2 CONTROLE NEURO-FUZZY

Os sistemas de controle baseados na lógica *fuzzy* apresentam uma metodologia mais intuitiva, quando comparado aos controles convencionais, exigindo para sua implantação um conhecimento detalhado da planta ou processo. Isto porque sua base de regras e suas funções de pertinência devem ser baseadas no conhecimento do projetista (*expertise*) sobre a planta ou processo a ser controlador.

Em especial, a integração entre as RNA e os sistemasnebulosos tem se mostrado “eficientes quando os problemas exigem soluções robustas, intolerantes a falhas, de dinâmica adaptativa e capazes de considerar dados de natureza vaga ou imprecisa” (Pedrycz e Gomide, 2007). O sistema Neuro-Fuzzy é o resultado da integração entre as RNA e a LF, na qual as principais vantagens de cada técnica são aproveitadas.

O modelo Neuro-Fuzzy, também nomeado de ANFIS, é o resultado da hibridização de dois métodos inteligentes. Neste tipo de técnica é aproveitada a capacidade da lógica Fuzzy com a

utilização dos termos linguísticos e sua modelagem, juntamente com a capacidade de aprendizado e generalização das Redes Neurais Artificiais. As vantagens das Redes Neurais sobre os sistemas convencionais são a sua performance para o mapeamento de entradas e saídas não-lineares, generalização, adaptabilidade e a baixa tolerância. Entretanto, a sua interpretabilidade é de difícil compreensão, dificultando o seu uso. Para solucionar esse problema técnicas *Fuzzy* podem ser utilizadas com o objetivo de expressar – através dos seus conjuntos e da sua base de regras – o conhecimento humano e a ambiguidade das informações. A grande desvantagem das técnicas *Fuzzy* é que elas não fornecem a capacidade de aprendizagem para a construção da base de regras e das MF, sendo definidas pela expertise humana, o que resulta em certo grau de incertezas no projeto de controladores. Desta forma, a lógica *Fuzzy* e as Redes Neurais Artificiais são tecnologias complementares no projeto de controladores inteligentes. Devido a sua versatilidade, há diversas aplicações para o seu uso, como modelagem, identificação e controle de sistemas dinâmicos não-lineares.

O uso do ANFIS é justificado pela facilidade em obter modelos apenas com dados amostrais, sem que haja a necessidade de um especialista sobre o processo ou uso de modelagem matemática fenomenológica. Devido a estas características, a técnica NF vem sendo amplamente utilizada em sistemas caixa cinza e preta.

De forma geral, as RNA são utilizadas para ajustar o intervalo das funções de pertinência e criar a base de regras com o objetivo de atender o critério de saída através da manipulação das constantes de Sugeno. As constantes também podem ser obtidas

por outros métodos como, por exemplo, através da solução do problema de Desigualdade

Linear Matricial (LMI) ou também por modelagem matemática através de Equações de Espaço de Estado acopladas do sistema. A determinação dos parâmetros do modelo de Sugeno dependem da forma da função de pertinência (MF – *membership function*) utilizada e das mudanças dos valores da entrada e saída. Basicamente o algoritmo cria MF para cada regra observando a inter-relação entre os dados de entrada e saída, de forma a ajustar cada parâmetro da MF (antecedente) e das funções de saída (consequente), também chamadas de constantes de Sugeno, o que condiz com a condição de aprendizagem das RNA. Existem diversos tipos as MF (triangulares, trapezoidais, gaussianas...) e que são escolhidas de acordo com os parâmetros do sistema. Em muitas situações não se pode discernir qual a MF olhando apenas para os dados, tal que a escolha da MF é, às vezes, arbitrária.

O algoritmo do ANFIS é composto por cinco camadas, utilizadas no processo de aprendizagem e que alteram continuamente os parâmetros finais do FIS. Os parâmetros (pesos) são alterados de acordo com o erro de cada interação que é obtido através do método dos mínimos quadráticos. Sua estrutura pode ser resumida como ilustrado na Figura 4.1, onde  $A_{ij}$  são os conjuntos *Fuzzy*.

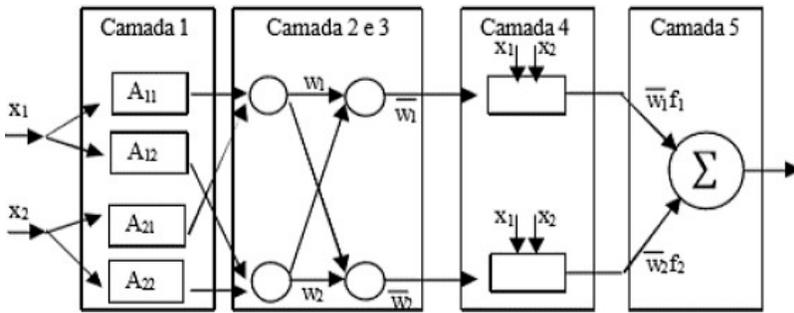


Figura 4.1: Estrutura do controlador ANFIS.  
 Fonte: Moreira (2020).

A função de cada camada mostrada na Figura 4.1 é:

1º Camada – Calcula o grau de pertinência com que as entradas satisfazem os valores ou termos linguísticos associados a estes nós.

$$w_i = m_{A_i}(x_1)m_{B_i}(x_2), \quad i = 1, 2, \dots, n. \quad (4.7)$$

2º Camada – Cada nó desta camada corresponde a uma regra e calcula com que grau o consequente da regra está sendo atendido, ou seja, são as implicações das premissas.

$$y = w_i f_i(x_1, x_2, \dots, x_n) = \frac{w_1 f_1 + w_2 f_2 + \dots + w_n f_n}{w_1 + w_2 + \dots + w_n}. \quad (4.8)$$

3º Camada – Esta camada realiza a normalização dos valores da camada anterior.

$$\bar{w}_{1,2,\dots,n} = \frac{w_{1,2,\dots,n}}{w_1 + w_2 + \dots + w_n} \quad (4.9)$$

4º Camada – Nesta camada, as saídas dos neurônios são calculadas pelo produto dos valores dos consequentes da regra.

5º Camada – Os nós desta última camada calculam a saída do ANFIS. Podendo ser rescrito como:

$$f = \bar{w}_1 f_1 + \bar{w}_2 f_2 + \dots + \bar{w}_n f_n \quad (4.10)$$

Onde  $n$  representa o número de variáveis.

O procedimento metodológico para a modelagem destes sistemas pode ser resumido em quatro passos:

- (1) Agrupamento dos dados, relacionando suas saídas com as entradas;
- (2) Seleção da MF e da quantidade de funções para cada variável de entrada;
- (3) Escolha do tipo de truncamento e o critério de erro ( $e$ );
- (4) Teste com os dados de validação, independentes dos de treinamento, para certificar que o critério de *over-fitting* foi atendido.

Em resumo, o ANFIS é utilizado para obter um modelo dinâmico de controlador TSK baseado na Lógica Fuzzy. Na Figura 4.2, ilustra-se um fluxograma metodológico para a obtenção de controladores inteligentes baseados na Lógica Fuzzy. O controlador *Fuzzy* tradicional (Mandani) é obtido, geralmente, por expertise de um operador/projetista. Já para obter um controlador TSK existem três caminhos prováveis: Modelagem matemática através de Equações de Espaço de Estado acopladas, desigualdades matriciais lineares (LMI - *Linear Matrix Inequality*) ou Modelagem Computacional. As RNA são utilizadas para realizar o mapeamento das Funções de Pertinência dos conjuntos *Fuzzy* de entrada e saída; para tanto, é necessário um banco de dados, que em geral é obtido do sistema experimental através de um controlador primário.

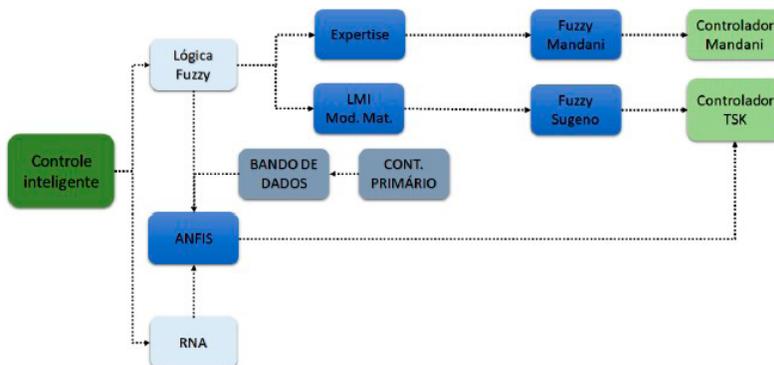


Figura 4.2: Fluxograma para obtenção de ANFIS.

Fonte: Moreira (2020).

## 4.2 APLICAÇÃO DO CONTROLE NEURO-FUZZY AOS SISTEMAS DE DISTRIBUIÇÃO DE ÁGUA

### 4.2.1 BANCADA EXPERIMENTAL

Para realizar este experimento, foi utilizada a bancada experimental apresentada na Figura 4.3, a qual é composta de um reservatório circular com  $7,64 \text{ m}^3$ , dois conjuntos motobombas (CMBs), dois inversores de frequência, uma válvula de controle eletrônico (VC), cinco transdutores de pressão (PT), dois transdutores de vazão (FT), uma fonte de alimentação, além das instalações elétricas e eletrônicas, conexões e tubos de PVC (DN 50, DN 75 e DN 100) da rede hidráulica.



Figura 4.3: Bancada Experimental usada no exemplo.

Fonte: Moreira et al. (2020).

Os CMB utilizados são monoblocos constituídos por um motor de indução trifásico e uma bomba DANCOR, modelo CAM-W10, instalados em uma cota inferior ao nível do reservatório (“afogada”); a altura manométrica do reservatório é sempre mantida constante.

As bombas são centrífugas, de um estágio, com NPSH máximo de 6 metros, diâmetro do rotor de 162 mm, altura manométrica máxima de 45 mca e vazão máxima de 12 m<sup>3</sup>/h. As especificações do motor estão descritas na Tabela 4.1.

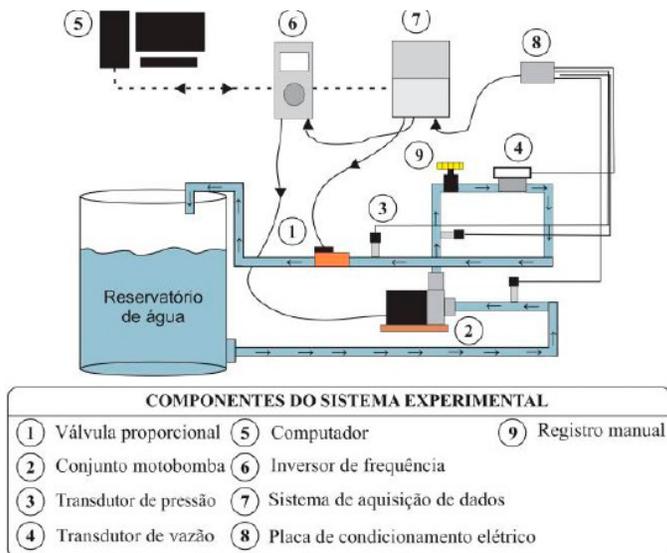


Figura 4.3:Esquema da bancada experimental.

Fonte: Moreira (2020).

Tabela 4.1: Especificações do motor do CMB.

Fabricante	WEG
Potência	3 cv
Tensão de alimentação	220/380 V
Frequência de alimentação	60 Hz
Índice de proteção	IP 21
Velocidade de rotação nominal	3450 RPM

Fonte: Moreira (2020).

### 4.2.1.1 IDENTIFICAÇÃO DA BANCADA EXPERIMENTAL

Para estudar o comportamento dinâmico, o sistema experimental deve ser identificado. Isso possibilita a realização de simulações, análises e o desenvolvimento de algoritmos de controle (malha aberta e adaptativo). Para realizar a identificação neste exemplo, foi construído um banco de dados a partir de ensaios experimentais para o treinamento do modelo. O procedimento experimental consiste na manipulação das variáveis de entrada em observância com as variáveis de saída.

São desenvolvidos cinco modelos mediante a utilização de duas técnicas inteligentes (RNA e ANFIS) - como está ilustrado na Figura 4.4 - são dois modelos com demanda fixa (SISO), dois modelos com demanda variável (MIMO) e um modelo da caracterização rendimento do CMB com demanda variável (MISO). Ambas foram desenvolvidas em linguagem de código C no MATLAB/2018. Tendo em vista a importância de comparar os modelos obtidos e utilizar o mais eficiente para cada caso, é realizado um estudo comparativo utilizando os indicadores descritos anteriormente.

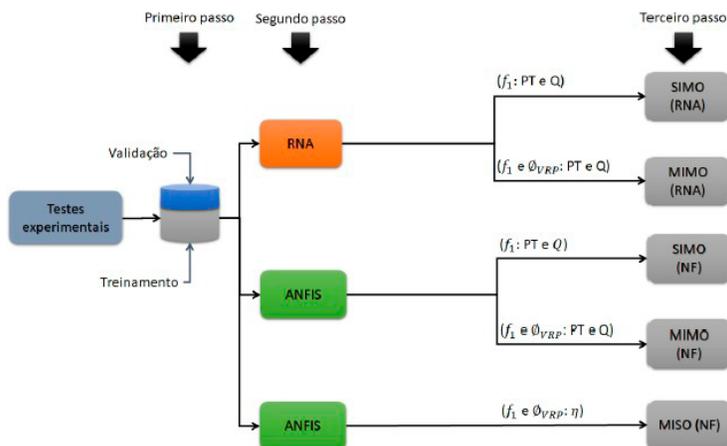


Figura 4.4: Diagrama dos modelos inteligentes desenvolvidos.

Fonte: Moreira (2020).

O sistema experimental possui cinco variáveis de interesse, sendo duas de entrada e três de saída; um modelo de múltiplas entradas e múltiplas saídas (MIMO) é necessário para descrever o seu comportamento. As variáveis de entrada são a Frequência do inversor ( $f_1$ ) e o Ângulo da VC ( $\phi_{VRC}$ ), como saída têm-se a Pressão (PT), a Vazão (Q) e a Potência ativa (W) do CMB. Estas variáveis foram selecionadas devido às correlações que formam; a pressão possui uma correlação direta com a frequência do inversor e o ângulo da VC; a vazão possui relação direta com a frequência e inversa com o ângulo da VC; a potência possui correlação direta com a frequência do inversor e correlação direta e não-linear com o ângulo da VC. A Tabela 4.3 resume as variáveis modeladas, o intervalo global e o intervalo de variação utilizado nos experimentos para o desenvolvimento do banco de dados para treinamento e validação do modelo.

Segundo Ljung (2017), a escolha da frequência “ideal” de amostragem pode ser definida como, aproximadamente, 10 vezes a largura de banda do sistema (ou a largura de banda de interesse), o que resultará em aproximadamente 5-8 amostras no tempo de subida da resposta ao degrau do sistema. Assim, para evitar o efeito aliasing, utilizou-se uma frequência de amostragem igual a 20 Hz. Além disso, é preferível uma amostragem considerada rápida a uma amostragem considerada lenta.

O treinamento dos modelos Neural e Neuro-Fuzzy ocorre de forma semelhante e envolve a utilização do algoritmo de treinamento *Backpropagation* em um processo iterativo para redução do erro final. Na Figura 4.5 é ilustrada a arquitetura inicial da RNA desenvolvida neste exemplo. Ela está organizada em três camadas: i) entrada; ii) intermediária; iii) saída. A camada de entrada é responsável por receber os sinais de entrada. Na camada intermediária é realizado o processamento, ou seja, os pesos ( $W$ ) são ajustados para reduzir o erro e atender a saída, também é considerada de extratora de regras. Por fim, na camada de saída ocorre a conclusão do resultado final e a realimentação do sinal na entrada, em um processo iterativo, para reduzir o erro ( $e$ ). O truncamento dá-se através do número de iterações ou o erro final ( $e_F$ ) admissível. O número de camadas intermediárias e de neurônios por camada pode ser definido por meio de uma tentativa inicial, aumentando-se o valor deles até que os resultados sejam satisfatórios.

Na Figura 4.6, está ilustrada a arquitetura inicial do sistema Neuro-Fuzzy desenvolvido neste exemplo. O algoritmo do ANFIS é composto por cinco camadas que fazem parte do processo de treinamento. A primeira camada calcula o grau de pertinência

( $w_1$  e  $w_2$ ) com que as entradas  $x_1$  e  $x_2$  satisfazem os valores ou termos linguísticos associados a estes nós. Na segunda camada, cada nó corresponde a uma regra e calcula com que grau ( $A_{i,j}$ ) o conseqüente da regra está sendo atendido, ou seja, são as implicações das premissas. A terceira camada é responsável pela normalização do vetor ( $w_1$  e  $w_2$ ). Na quarta camada as saídas dos neurônios (Pressão e Vazão) são calculadas pelo produto dos valores dos conseqüentes da regra. Na última camada é calculada a respectiva saída. O *backpropagation* é utilizado juntamente com a retropropagação do erro quadrático para o treinamento.

Um importante aspecto é a escolha das funções de membesia, que podem ser triangulares, gaussianas etc. Neste exemplo, por se tratar de um sistema não-linear, resolveu-se adotar MF gaussianas, as quais representam melhor não-linearidades, o que permite reduzir o número de neurônios da camada intermediária.

Tabela 4.3: Descrição das variáveis usadas no ensaio.

Dados	Descrição
Variáveis de entrada	$f_1 \in \emptyset_{VRP}$
Variáveis de saída	PT-5, $Q_1$ e $W_1$
Intervalo global de operação das variáveis de entrada	$20 < f_1 < 50 \text{ Hz}$ $0 < \emptyset_{VRP} < 90^\circ$
Delta de variação das variáveis de entrada	$3 < \Delta f_1 < 5 \text{ Hz}^*$ $\Delta \emptyset_{VRP} = 5^\circ$
Frequência de amostragem	20 Hz

Fonte: Moreira (2020).

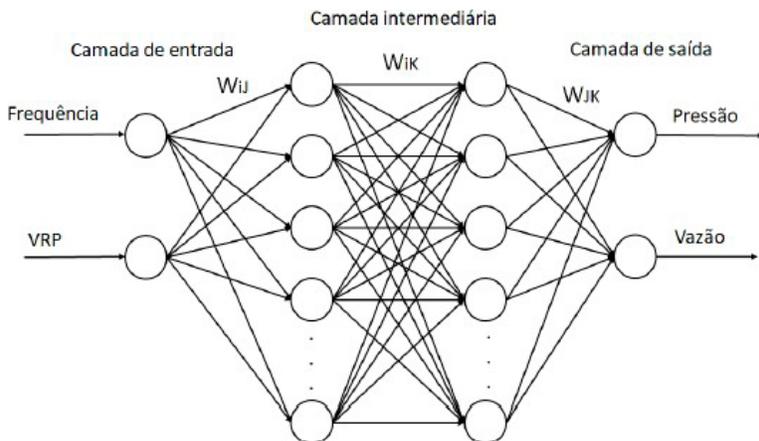


Figura 4.5: Arquitetura MIMO da rede neural.

Fonte: Moreira (2020).

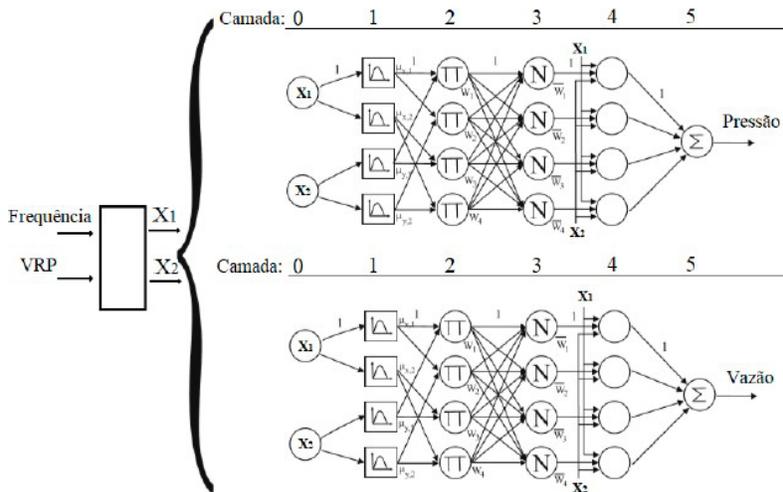


Figura 4.6: Arquitetura MIMO do sistema Neuro-Fuzzy.

Fonte: Moreira (2020).

A metodologia utilizada para a identificação do sistema pode ser descrita na forma de fluxograma, conforme está ilustrado na Figura 4.7. No projeto, definem-se as variáveis de interesse do sistema e como elas são manipuladas para produzir as paridades de dados necessárias para o treinamento, para em seguida coletar dados para o desenvolvimento do banco de dados.

A determinação da estrutura do sistema é feita com base no conhecimento preliminar sobre o sistema e, geralmente, através de um estudo paramétrico. A validação ocorre a partir da simulação e comparação do modelo com dados experimentais (processo de validação cruzada). O método de estimação trata dos indicadores utilizados para determinar o desempenho quantitativo do modelo. Quanto menor o erro, dado pela Equação (4.3), mais próximo do desejado se torna o modelo computacional; além disso, as Equações (4.4), (4.5) e (4.6) são utilizadas para analisar o erro relativo do modelo. Dá-se especial atenção ao ajuste percentual que o modelo tem em relação aos dados experimentais.

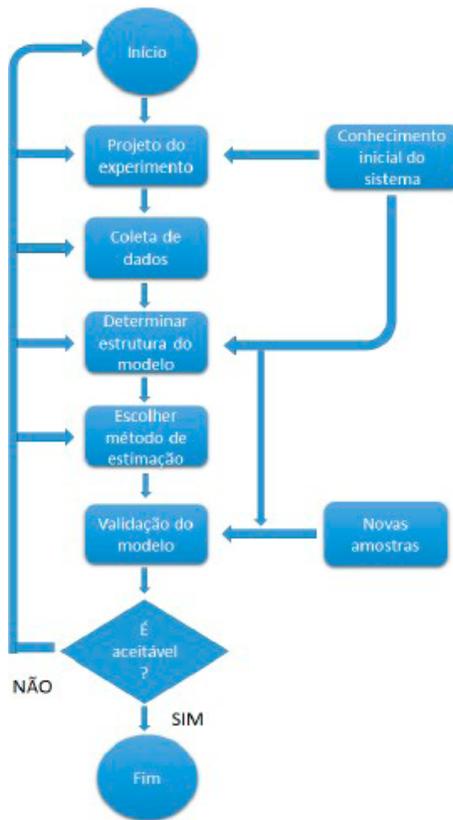


Figura 4.7: Fluxograma metodológico para modelagem computacional de sistemas. Fonte: Moreira (2020).

## 4.2.2 PROJETO DO CONTROLADOR

O método de treinamento adotado no algoritmo do ANFIS é o supervisionado; assim, a elaboração deste controlador envolve o desenvolvimento de um banco de dados robusto, com a paridade de dados do sistema controlado por um controlador pré-

existente (primário). Um controlador primário pode ser baseado em qualquer técnica de controle. Normalmente, são controladores mais simples, convencionais e que, em geral, não possuem desempenho tão bom quanto os ajustáveis, compensadores e PID. Um diferencial deste exemplo é o uso de um controlador primário heurístico do tipo *Fuzzy Mamdani* para controlar o sistema e construir a paridade de dados. Este mesmo controlador primário é utilizado na análise comparativa dos resultados.

Os pares de dados são obtidos através de procedimentos experimentais com o controlador *Fuzzy* implementado. Os critérios utilizados para definir os procedimentos experimentais para os ensaios e o desenvolvimento do banco de dados foram as simplicidades, representadas pelas respostas degrau e variação do valor de referência, e as condições de operação do sistema de bombeamento de água, representadas pela variação de demanda e pressões de serviço.

O banco de dados é formado pela paridade de dados de duas variáveis de entrada (Erro e Variação do erro) e uma variável de saída (Variação de frequência) – como ilustrado na Figura 4.8. A planta é representada por um sistema caixa preta e sua dinâmica é alterada pelo ângulo de abertura da VC.

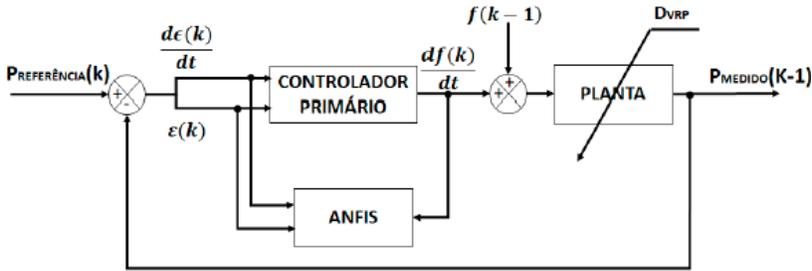


Figura 4.8: Estrutura de treinamento do controlador ANFIS.

Fonte: Moreira (2020).

Neste exemplo, a aquisição dos dados de treinamento foi feita com uma frequência de amostragem igual a 100 amostras/s, estimando um valor médio a cada 10 amostras para reduzir as variabilidades durante a aquisição dos dados. Ao total foram utilizados 5.900 conjuntos de dados para o treinamento do controlador Neuro-Fuzzy (NF). Estes dados também foram utilizados para o treinamento do controlador Neural. A Tabela 4.4 contém o formato dos dados adquiridos, usados para o treinamento dos controladores.

Tabela 4.4: Formato do conjunto de dados.

Instante de amostragem	Erro	Varição do erro	Varição 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	...	...	...	...

Fonte: Moreira (2020).

A estrutura do algoritmo do ANFIS utilizado neste exemplo está ilustrada na Figura 4.9. O processo de treinamento é o mesmo exemplificado na Figura 4.6. A primeira camada calcula o grau de pertinência ( $w_1$  e  $w_2$ ) com que as entradas (Erro  $x_1$  e Variação do erro  $x_2$ ) satisfazem os valores ou termos linguísticos associados a estes nós. Na segunda camada, cada nó corresponde a uma regra e calcula com que grau ( $A_{i,j}$ ) o consequente da regra está sendo atendido, ou seja, são as implicações das premissas. A terceira camada é responsável por realizar a normalização do vetor ( $w_1$  e  $w_2$ ). Na quarta camada, as saídas dos neurônios são calculadas através do produto dos consequentes da regra. Na última camada, calcula-se a respectiva saída (Delta de frequência:  $Y_1$ ).

Na Figura 4.9, ilustra-se a estrutura do sistema de controle em malha fechada para o controlador NF. As variáveis de entrada são o Erro e a Variação do Erro, enquanto que a variável de saída é o Delta de frequência.

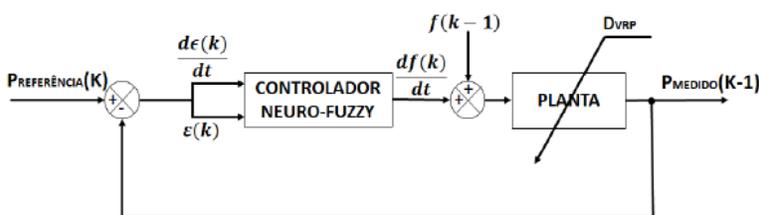


Figura 4.9: Sistema de controle em malha fechada.

Fonte: Moreira (2021).

O controlador primário, utilizado para gerar a paridade de dados de treinamento do controlador Neuro-Fuzzy, têm suas funções de pertinência e superfície de controle ilustradas nas

Figuras 4.10 e 4.11, respectivamente e sua base de regras na Tabela 4.5. A motivação para a escolha das MF gaussianas é atribuída a suas melhores características em representar conjuntos de dados não-lineares.

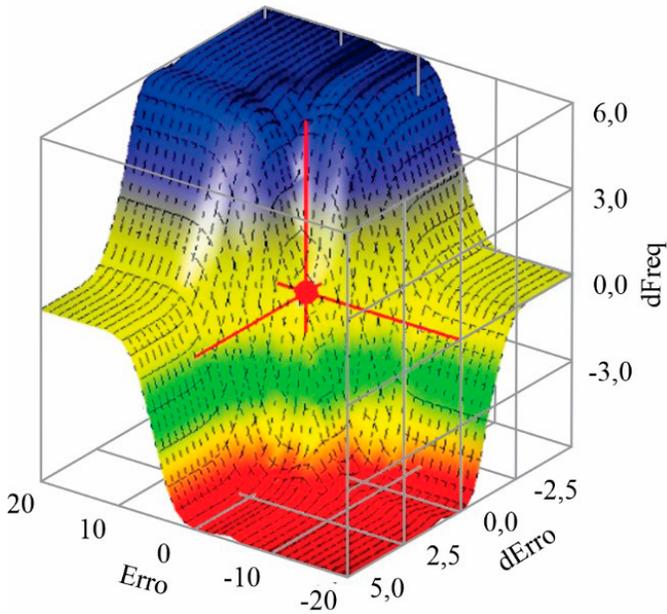


Figura 4.10: Superfície da resposta do controlador fuzzy.

Fonte: Moreira et al. (2021).

Tabela 4.5: Regras do controlador fuzzy.

		Variação do erro		
		NG	Z	PG
Erro	NG	IG	IG	Z
	Z	IG	Z	DG
	PG	Z	DG	DG

Fonte: Moreira (2021).

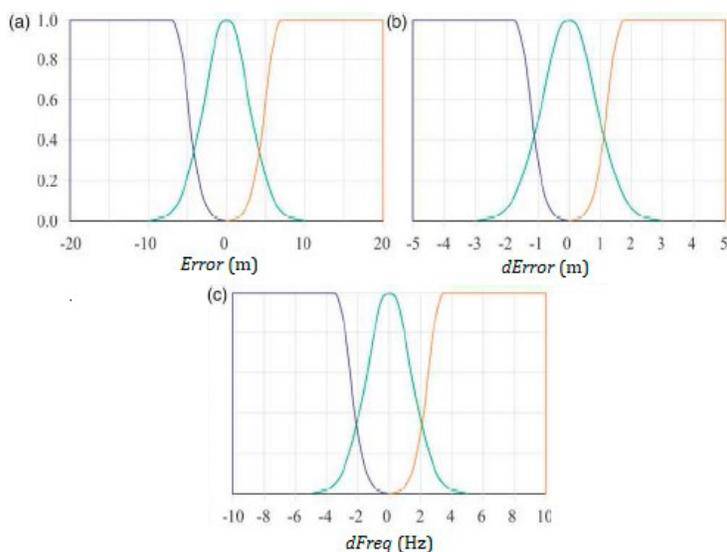


Figura 4.11: Funções de pertencimento do controlador fuzzy: (a) variável linguística de entrada Error, (b) variável linguística de entrada  $dError$  e (c) variável linguística de saída  $dFreq$ .

Fonte: Moreira et al. (2020).

## 4.3 ANÁLISES E RESULTADOS

### 4.3.1 CRITÉRIOS DE ANÁLISE HIDROENERGÉTICA

As análises hidroenergéticas são medidas de eficiência e eficácia utilizadas para fins comparativos entre as atividades desenvolvidas. Os dois indicadores de desempenho mais usuais em sistemas de bombeamento são o da: energia fornecida ao fluido pelo rotor da bomba – Equação (4.11) – e o da razão de energia gasta por volume bombeado (CE) – Equação (4.12) – este índice é utilizado, geralmente, para medir comparar a eficiência energética de um mesmo sistema de bombeamento sob diferentes condições de operação.

– Rendimento do conjunto motobomba ( $\eta$ ), em decimais:

$$\eta = \frac{\gamma H_{man} Q}{P}, \quad (4.11)$$

em que  $\gamma$  é o peso específico do fluido,  $Q$  é a vazão volumétrica (em  $\text{m}^3/\text{s}$ ),  $P$  é a potência elétrica (em W) e  $H_{man}$  é a altura manométrica (em mca).

– Consumo específico de energia (CE), em  $\text{kWh}/\text{m}^3$ :

$$CE = \frac{P'}{V}. \quad (4.12)$$

em que  $P'$  é a energia consumida (em kWh) e  $V$  é o volume bombeado (em  $\text{m}^3$ ).

### 4.3.2 DESENVOLVIMENTO DO BANCO DE DADOS

O procedimento experimental para o desenvolvimento do banco de dados de treinamento e validação dos modelos (1 entrada – 2 saídas), consiste na variação, conforme a Tabela 4.3, da frequência do conversor do CMB com a observação das variáveis de saída, pressão e vazão. Inicialmente, foram inseridos degraus crescentes de frequência até o limite da variável; posteriormente foram inseridos degraus decrescentes. O ângulo da VC foi mantido constante em 30°. Os dados experimentais para o treinamento são ilustrados na Figura 4.12, com um total de 5.700 pares sequenciais. Para validação foram utilizados 3.120 novos pares sequenciais.

Há certas complexidades no modelo MIMO, ocasionadas devido ao número de variáveis e as não-linearidades da variação de demanda. A variação do ângulo da VC tem como objetivo alterar a demanda do sistema, o que resulta no deslocamento vertical da curva da tubulação e adiciona uma variável e não-linearidades severas ao modelo, principalmente, devido às características hidráulicas e mecânicas da válvula. O procedimento experimental realizado neste ensaio é semelhante ao anterior, variando a frequência em degraus crescentes até o limite da variável, seguida da variação gradual do ângulo da VC conforme a Tabela 4.3. Na Figura 4.13(a) e(b), ilustra-se a relação entre as variáveis de saída e entrada dos dados de treinamento com 61.850 pares sequenciais. Para a validação foram utilizados 19.700 pares sequenciais.

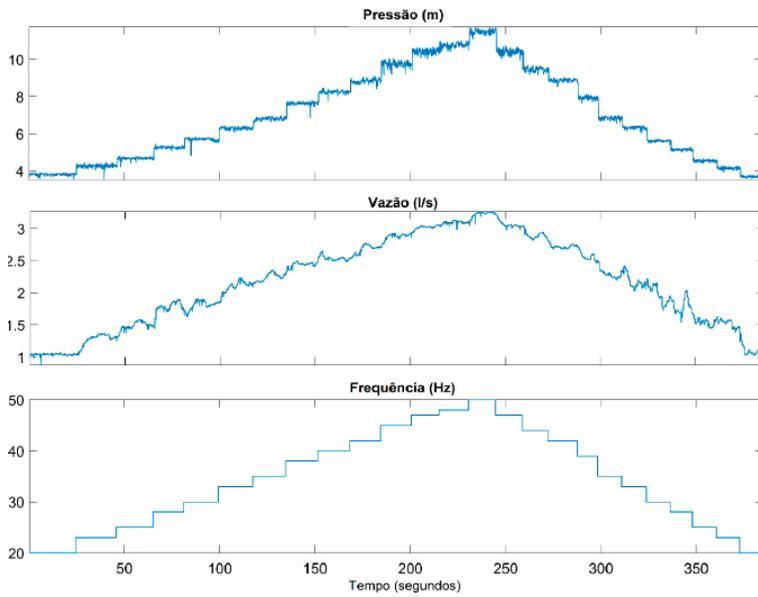


Figura 4.12: Relação dos dados de treinamento do modelo SIMO.

Fonte: Moreira (2020).

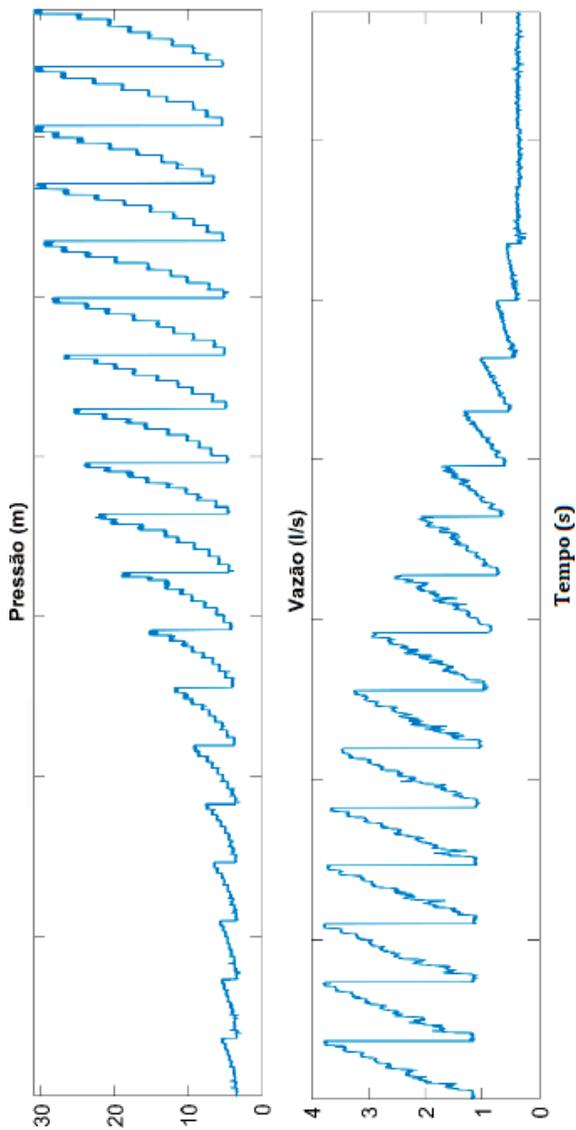


Figura 4.13(a): Relação dos dados de treinamento do modelo MIMO.  
Fonte: Moreira (2020).

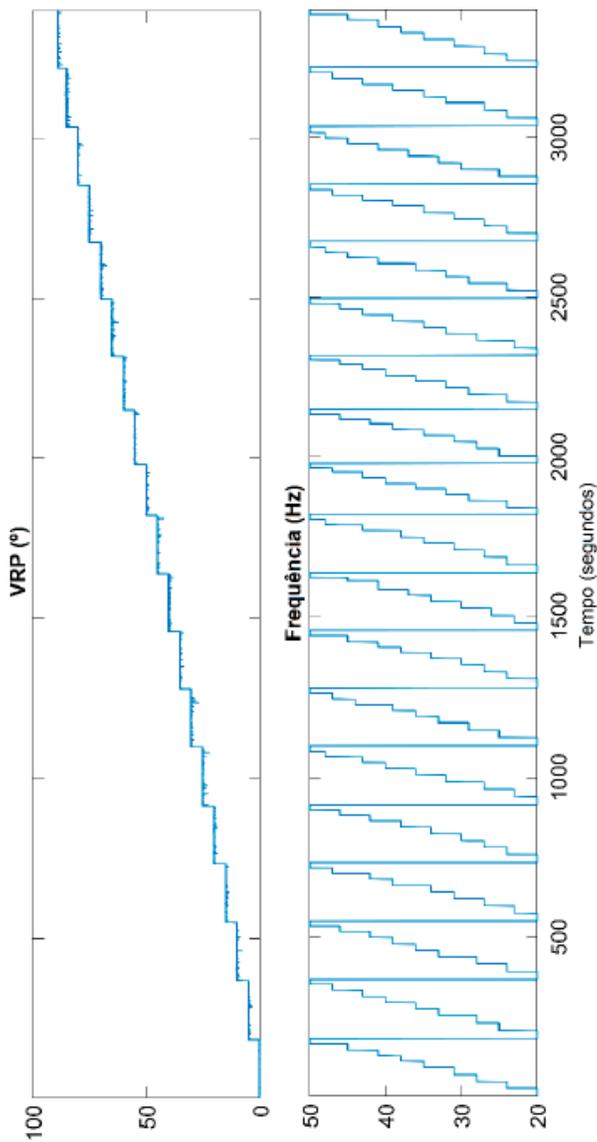


Figura 4.13(b): Relação dos dados de treinamento do modelo MIMO.  
 Fonte: Moreira (2020).

### 4.3.3 TREINAMENTO

Encontrar a configuração ideal da Rede Neural e do Neuro-Fuzzy é um exercício paramétrico. Neste exemplo, realizou-se um processo interativo de treinamento para encontrar a configuração estrutural (número de camadas e neurônios) com o maior percentual de ajuste. Na Figura 4.14, está ilustrada a superfície gerada variando-se o número de neurônios por camadas para o modelo MIMO (2 entradas – 2 saídas).

A análise gráfica da Figura 4.14 revela que o modelo Neural obteve melhores resultados com um número baixo de neurônios na primeira camada e elevados na segunda. Os resultados do modelo Neuro-Fuzzy não apresentam tendência comum nas duas saídas analisadas. Observando a resposta do modelo para a pressão, prefere-se um elevado número de MF para o ângulo da VC. Para a vazão prefere-se um baixo número de MF para o ângulo. Em geral, os modelos apresentam ajustes superiores a 96%, sendo excelentes valores para as simulações e desenvolvimento de algoritmos de controle.

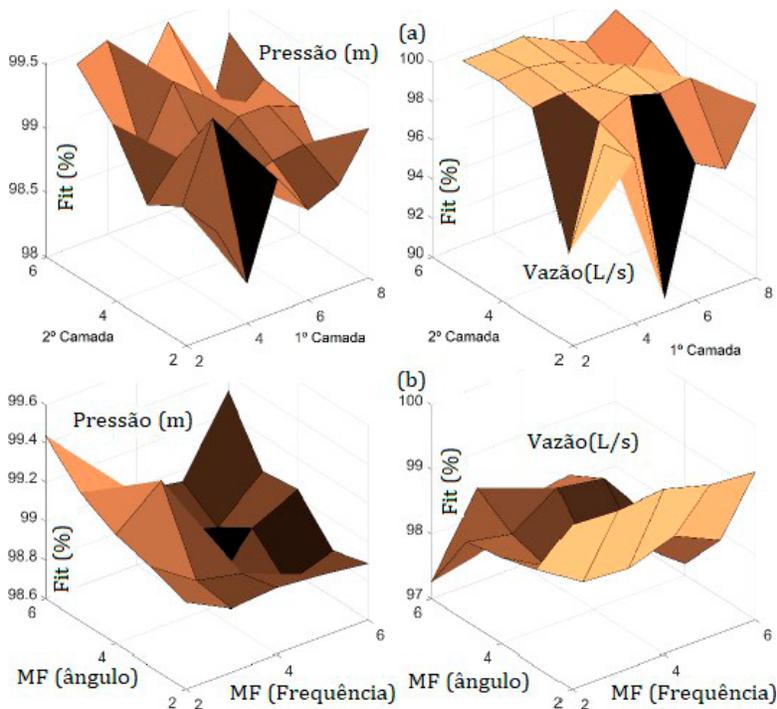


Figura 4.14: Gráfico de convergência do modelo MIMO (a) Neural e (b) Neuro-Fuzzy.

Fonte: Moreira (2020).

### 4.3.3.1 RESPOSTA DO MODELO SIMO (1 INPUT - 2 OUTPUT)

Modelos paramétricos possuem relevância crucial na identificação de sistemas lineares, sendo preferíveis por sua fácil obtenção. Na Tabela 4.6 é possível observar que

nem todos os modelos apresentaram ajustes satisfatórios, como o de Espaço de Estados ( $n_a=3$ ,  $n_b=4$  e  $n_c=3$ ) e o ARX ( $n_a=[4\ 6]$ ;  $n_b=[4\ 6]$  e  $n_k=0$ ), principalmente para simular as pressões

de serviço. O não-overfit é uma característica bastante comum em modelos paramétricos, ocorrendo quando o modelo não consegue manter ajustes satisfatórios quando testado com novos dados. O modelo ARMAX ( $n_a=[6 \ 6]$ ;  $n_b=[6 \ 6]$ ;  $n_c=3$  e  $n_k=1$ ) e a Função de Transferência ( $n_b=3$ ;  $n_f=3$  e  $n_k=0$ ) apresentaram bom ajuste e baixo RMSE. Há forma de elevar o desempenho desses modelos; a mais trivial é aumentar as suas ordens, o que ocasiona também o aumento do custo computacional. Desta forma, limitou-se a ordem do modelo atribuindo uma função custo proposta por Ljung e Glad (1996).

A Função de Transferência, modelo que apresentou o maior ajuste, é exposta nas Equações (4.13) e (4.14), sendo a resposta da pressão e vazão, respectivamente.

$$G(s) = \frac{0,4443s^2 + 0,0003168s + 8,402e^{-5}}{s^3 + 1,284s^2 + 0,0003167s + 8,402e^{-5}} \quad (5.13)$$

$$G(s) = \frac{0,02368s^2 + 0,0004096s + 3,021e^{-5}}{s^3 + 0,5191s^2 + 0,005583s + 5,328e^{-5}} \quad (5.14)$$

Tabela 4.6: Dados de performance dos modelos computacionais testados com dados de validação.

Model	RMSE	NRMSE	FPE	Ajuste [%]
SS	1.107 (0.798)	6.3e-5 (21.0e-5)	636.7e-5 (21.1e-5)	72.25 (84.35)
TF	0.365 (0.211)	178.3e-5 (41.2e-5)	179e-5 (413.6e-5)	94.40 (90.33)
ARX	0.748 (0.068)	666.7e-5 (21.5e-5)	669.5e-5 (21.6e-5)	73.01 (84.42)
ARMAX	0.607 (0.079)	628.9e-5 (21.21e-5)	633.5e-5 (21.3e-5)	88.01 (89.84)
<b>ANFIS</b>	<b>0.026</b> <b>(0.008)</b>	<b>17.8e-5</b> <b>(19.5e-5)</b>	<b>843.5e-5</b> <b>(191e-5)</b>	<b>99.95</b> <b>(99.72)</b>
RNA	0.0260 (0.008)	18.1e-5 (19.9e-5)	844.9e-5 (190.7e-5)	99.94 (99.20)

Fonte: Moreira (2020).

Por outro lado, os modelos inteligentes apresentaram ajustes superiores a 99% com dados de validação. Na Figura 4.15, estão ilustradas as respostas dos modelos inteligentes testados com dados de treinamento e de validação para o ANFIS (com 5 MF gaussianas) e para a Neural (com 8 e 5 neurônios na primeira e segunda camada, respectivamente).

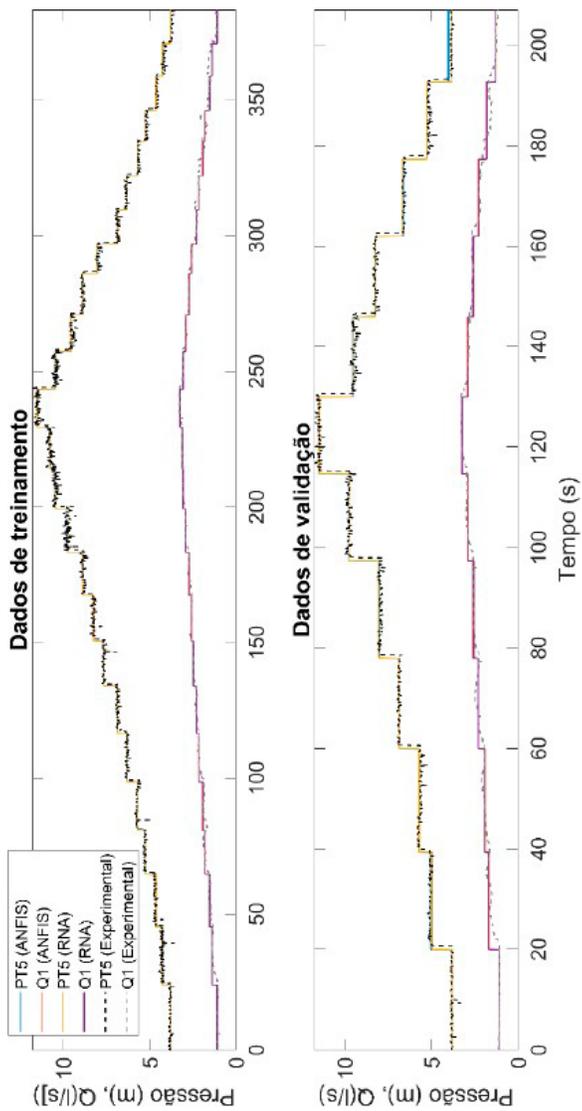


Figura 4.15: Resposta dos modelos inteligentes com dados de treinamento e validação.

Fonte: Moreira (2020).

De modo geral, o custo computacional do ANFIS é maior; desta forma, é conveniente reduzir o número de neurônios da camada intermediária para valores inferiores aos encontrados nos modelos desenvolvidos por RNA, mantendo resultados, muitas vezes, superiores.

A Tabela 4.6 resume os resultados dos indicadores de performance dos modelos, sendo as saídas Pressão e Vazão ( $Q$ ). É notável os ajustes superiores dos modelos inteligentes. Entretanto, a predição não é um ponto positivo destes modelos, indicado pelo menor FPE apresentado pelos modelos paramétricos. Desta forma, é possível afirmar que os modelos paramétricos apresentaram melhores resultados quando aplicados na predição do comportamento linear de sistemas de bombeamento. Os modelos inteligentes são recomendados para simulações de sistemas de bombeamento. Entretanto, em situações práticas, com a alta complexidade, não-linearidades e multivariáveis, pertencentes a muitos sistemas industriais, os modelos inteligentes apresentaram superioridade, frente aos paramétricos em qualquer situação, como predição, simulação e análise.

#### **4.3.3.2 RESPOSTA DO MODELO MIMO (2 INPUT - 2 OUTPUT)**

Apesar dos modelos paramétricos apresentarem boas vantagens na modelagem de sistemas lineares, estes possuem limitações para a modelagem de sistemas não-lineares. Foi observado um problema de não-overfit quando os modelos são testados com dados de validação, não conseguindo obter valores razoáveis de ajustes. Apesar do modelo ARX ( $n_a=3$ ;  $n_b=3$

3] e  $nk=[0\ 0]$ ) e TF ( $nb=[3\ 3; 3\ 3]$ ;  $nf=[3\ 3; 3\ 3]$  e  $nk=[0\ 0; 0\ 0]$ ) apresentarem dinâmica de comportamento próxima à resposta do sistema real, estes modelos foram descartados quando seu uso visar à simulação. Entretanto, como é observado na Tabela 5.2, o seu uso pode se justificar para predição, por apresentar baixo FPE. Os modelos ARMAX ( $na=4$ ;  $nb=[4\ 4]$ ;  $nc=2$  e  $nk=[1\ 1]$ ) e SS ( $na=[3\ 0; 0\ 3]$ ;  $nb=[4\ 4; 4\ 4]$ ;  $nc=[3; 3]$  e

$nk=[0\ 0; 0\ 0]$ ) não apresentaram desempenho suficiente para serem utilizados para simulação ou predição. Devido às não-linearidades inseridas pela VC, nenhum modelo paramétrico apresentou ajuste suficiente para justificar sua aplicação em simulação.

Para a representação de sistemas não-lineares, as técnicas inteligentes têm sido utilizadas com sucesso em muitas aplicações. Como alternativa às deficiências dos modelos paramétricos em modelar sistemas com não-linearidades, é proposto a utilização de métodos mais robustos para identificar o sistema com estas condições.

Na Figura 4.16, ilustra-se a resposta dos modelos inteligentes com dados de treinamento e validação. O ANFIS (com 3 MF gaussianas) e a RNA (com 8 e 5 neurônios na primeira e segunda camada, respectivamente). É possível notar o excelente ajuste das respostas, não havendo problemas relacionados ao *overfit*.

Na Tabela 4.7, apresenta-se a comparação dos dados de performance dos modelos obtidos para o caso. É notável a superioridade dos modelos inteligentes em qualquer indicador de desempenho, principalmente no ajuste e no RMSE. Estes

resultados demonstram que a utilização dos modelos baseados em inteligência artificial visam suprimir as deficiências encontradas nos modelos tradicionais de identificação de sistemas, quando o objetivo é a simulação e predição de sistemas dinâmicos multivariáveis e não-lineares de bombeamento com demanda variável de água.

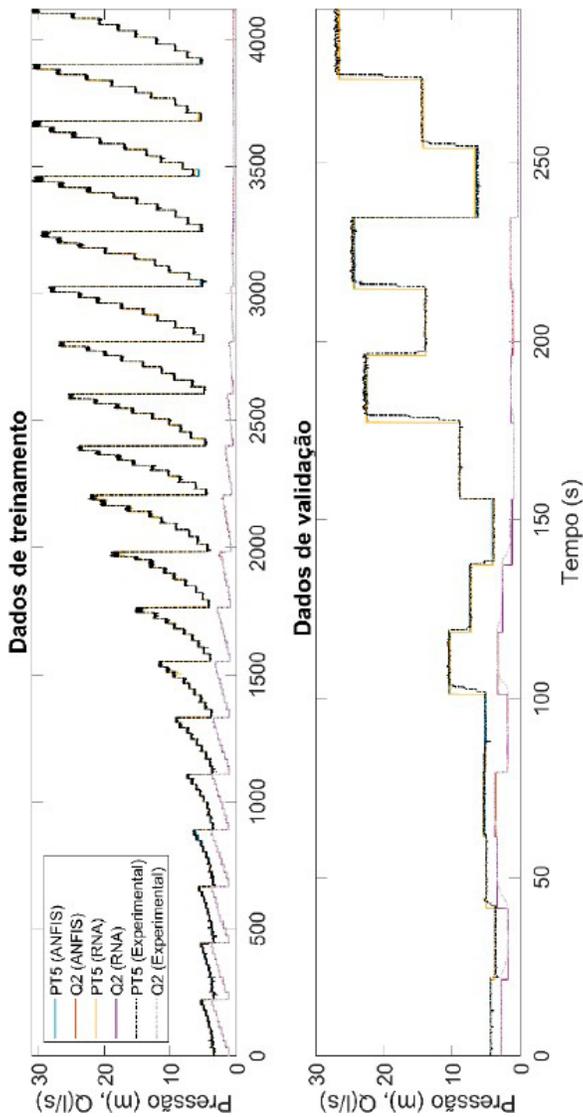


Figura 4.16: Resposta dos modelos inteligentes com dados de treinamento e validação.

Fonte: Moreira (2020).

Figura 4.7: Dados de performance dos modelos testados com dados de validação.

Model	RMSE	NRMSE	FPE	Ajuste (%)
SS	0.698 (0.549)	9647e-5 (9647e-5)	8.4e-05 (8.4e-05)	37.48 (30.70)
TF	1.744 (4.966)	13.4 (13.4)	89040e-5 (89040e-5)	16.97 (-52.3)
ARX	1.113 (0.469)	4762e-5 (44.8e-5)	0.04764e-5 (44.8e-5)	22.18 (53.06)
ARMAX	0.9122 (0.499)	9600e-5 (98.7e-5)	96040e-5 (98.8e-5)	19.00 (39.43)
ANFIS	<b>0.1360</b> <b>(0.0049)</b>	<b>0.11e-5</b> <b>(0.10e-5)</b>	<b>333.6e-5</b> <b>(183e-5)</b>	<b>99.86</b> <b>(99.99)</b>
RNA	0.1280 (0.0054)	0.11e-5 (0.09e-5)	343.1e-5 (192.6e-5)	99.87 (99.99)

Fonte: Moreira (2020).

### 4.3.3.3 CARACTERIZAÇÃO DO RENDIMENTO DO CMB

O desenvolvimento de modelos computacionais que possam prever a performance, localizar o Ponto de Máxima Eficiência Energética (PMEE) ou encontrar o Ponto de Máxima Potência (MPPT), é uma importante ferramenta para analisar cenários de operação com o objetivo de aumentar a eficiência energética de muitos sistemas. O rendimento de CMBs é um importante aspecto técnico e energético para o projeto de sistemas de bombeamento.

Em sistemas de bombeamento é possível relacionar a altura manométrica, vazão e a potência ativa do CMB, através da Equação (4.11), para obter o rendimento do CMB. Foi investigada

a possibilidade de obter a curva de rendimento com demanda fixa, variando-se a rotação do CMB; e com demanda variável mantendo-se fixa a rotação do CMB. Sendo possível obter modelos matemáticos para cada caso.

A análise polinomial da frequência sob o rendimento expõe as características do regime de operação do sistema de bombeamento. Na Figura 4.17, encontram-se ilustradas as curvas de rendimento para três condições de demanda de água - VC com ângulo de 30°, 40° e 50° -, com a variação da frequência. É possível observar que os modelos polinomiais obtidos apresentam variância (R2) superior a 0,97. A análise da Figura 4.17 revela que, nestes casos, os pontos de máxima eficiência estão em baixas frequências de operação. Por fim, é observável que ao mudar qualquer parâmetro do sistema, um novo modelo polinomial é exigido.

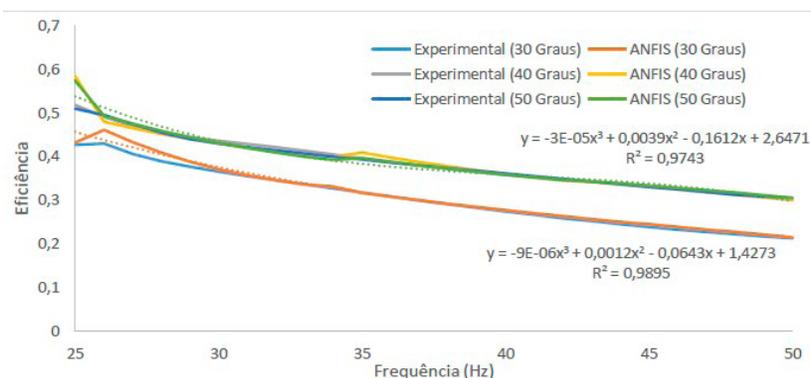


Figura 4.17: Influência da frequência no rendimento do CMB.

Fonte: Moreira (2021).

Sistemas de abastecimento de água operam sob demanda variável, surge, diante disso, a necessidade em controlar o acionamento ou a rotação dos CMBs. Como forma de avaliar o rendimento em uma condição real de operação, foi realizado um estudo em que a abertura da VC era controlada de forma a simular a variação de demanda com pressão constante em 10 m. A curva de rendimento do CMB com a variação de demanda está ilustrada na Figura 4.18. Novamente, é ressaltado o ótimo ajuste fornecido pelos modelos polinomiais locais. É possível observar que a condição de máxima eficiência do sistema ocorre com demandas médias de água.

Entretanto, obter uma função matemática para cada condição, ou região, de operação torna-se uma atividade estafante. A menor mudança nos parâmetros, seja de frequência ou demanda, torna a função matemática obtida inútil. A utilização de técnicas inteligentes, como a Neuro-Fuzzy, torna possível a modelagem de sistemas não-lineares e multivariáveis com exatidão adequada.

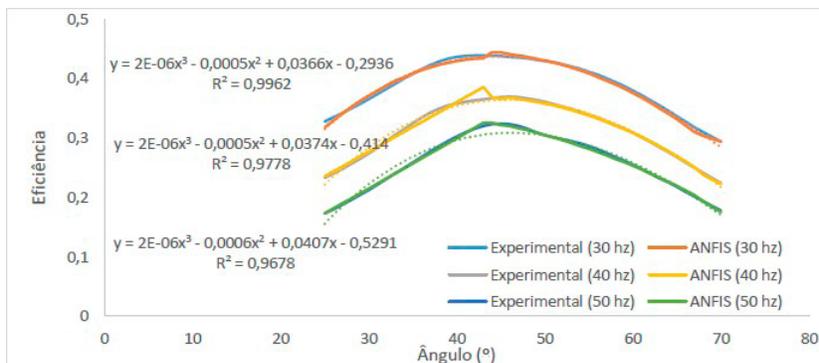


Figura 4.18: Influência da demanda no rendimento do CMB.

Fonte: Moreira (2021).

Na Figura 4.19, ilustra-se a superfície do modelo global do rendimento do sistema de bombeamento, obtida com o ANFIS. É possível observar a inter-relação das variáveis de importância do sistema (variáveis de entrada: VC e Frequência; variáveis de saída: Eficiência). É mostrado graficamente que o rendimento máximo do sistema ocorre em baixas rotações e com demandas médias de água. Há

ainda regiões onde a eficiência do sistema apresenta máximos locais, como quando opera com altas demandas e baixas rotações. Em geral, o sistema pode operar, em algumas regiões, com eficiência 305% superior com relação à operação com demandas máximas; por exemplo, em sua frequência nominal, com 50 Hz, a variação de demanda pode proporcionar um ganho de 112% no rendimento.

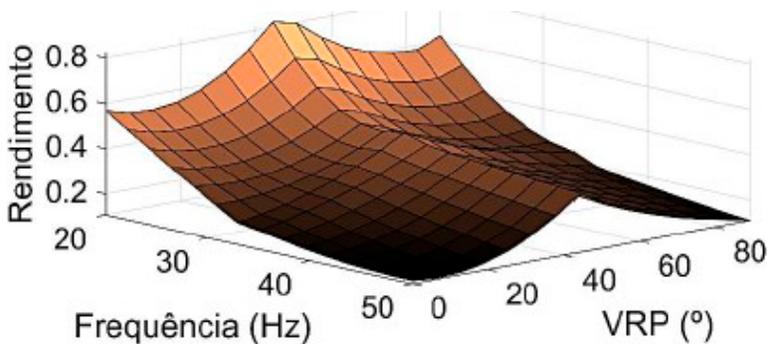


Figura 4.19: Superfície da caracterização da eficiência do sistema de bombeamento.

Fonte: Moreira (2020).

A análise da Figura 4.19 permite a melhor interpretação das condições de operação do sistema de bombeamento, mostrando que é conveniente manter um determinado número de CMBs, em arranjo série/paralelo, operando com capacidades médias de vazão. Essa estratégia deve resultar em economia de energia elétrica.

### 4.3.3.4 ANÁLISE DE MODELOS

Elementos gráficos permitem uma grande interpretação de sistemas dinâmicos. Em hidráulica, variáveis como pressão, vazão e demanda são constantemente avaliadas para o suprimento de energia ou controle de processos.

Na Figura 4.20, ilustra-se a superfície de comportamento do sistema de bombeamento obtida com a utilização da técnica NF. É ilustrado a inter-relação das variáveis de entrada e saída. Através desta superfície é possível analisar o comportamento gráfico do sistema mediante a mudança de cenário e determinar limites seguros de operação.

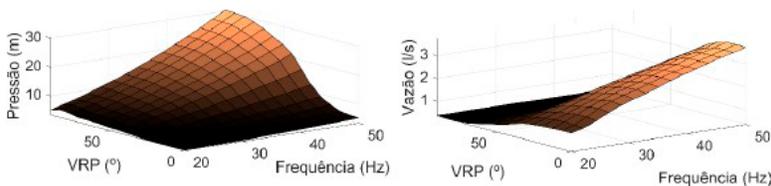


Figura 4.20: Superfície de comportamento do sistema de abastecimento Neuro-Fuzzy.

Fonte: Moreira (2021).

O desenvolvimento de modelos computacionais tem

por finalidade a análise e simulação com o objetivo de desenvolver estratégias e algoritmos de controle que resultem na maior eficiência operacional, reduzindo consideravelmente o consumo energético do sistema de bombeamento. Além disso, o desenvolvimento de um modelo que relacione os parâmetros de operação à eficiência energética do sistema resulta em uma ferramenta eficaz para a análise energética.

### 4.3.3.5 ANÁLISE DE CONTROLADOR

O controlador Neuro-Fuzzy do exemplo pode ser analisado nos regimes transiente e permanente e com relação aos distúrbios inseridos no sistema através da VC, comparativamente aos controladores Neural (RNA) e Heurístico (*Fuzzy*). Para avaliar e comparar o desempenho dos controladores foram realizados ensaios experimentais na bancada experimental. Os ensaios consistiram em:

- Respostas ao degrau com ângulo de abertura da VC em 30° e 40°;
- Variação do valor de referência do sistema com ângulo de abertura da VC em 40°;
- Variação contínua da VC de 30° à 70° e de volta à 30° com valor de referência em 10 m;
- Variação pausada da VC de 30° à 70° com valor de referência em 10 m.

Inicialmente, o controlador proporcional-derivativo (PD;  $K_P=0,5$  e  $K_D=1$ ) foi cotado para a posição de controlador primário. Entretanto, ensaios realizados com ele, demonstraram que a qualidade dos dados de treinamento eram inviáveis, devido a presença de elevados picos, pouca estabilidade em situações de variação de demanda e mudança de valor de referência, como ilustrado na Figura 4.21; assim, o seu uso foi descartado.

A soma das respostas do controlador primário (*Fuzzy*) representam os dados de treinamento utilizados para o desenvolvimento dos controladores Neuro-Fuzzy (NFC) e Neural (NC) - como ilustrado na Figura 5.22. Os critérios utilizados para definir os procedimentos experimentais para o desenvolvimento do banco de dados são a simplicidade representada pelas respostas ao degrau e variação do valor de referência e as condições de operação do sistema de bombeamento de água, representadas pela variação de demanda e pressão de serviço.

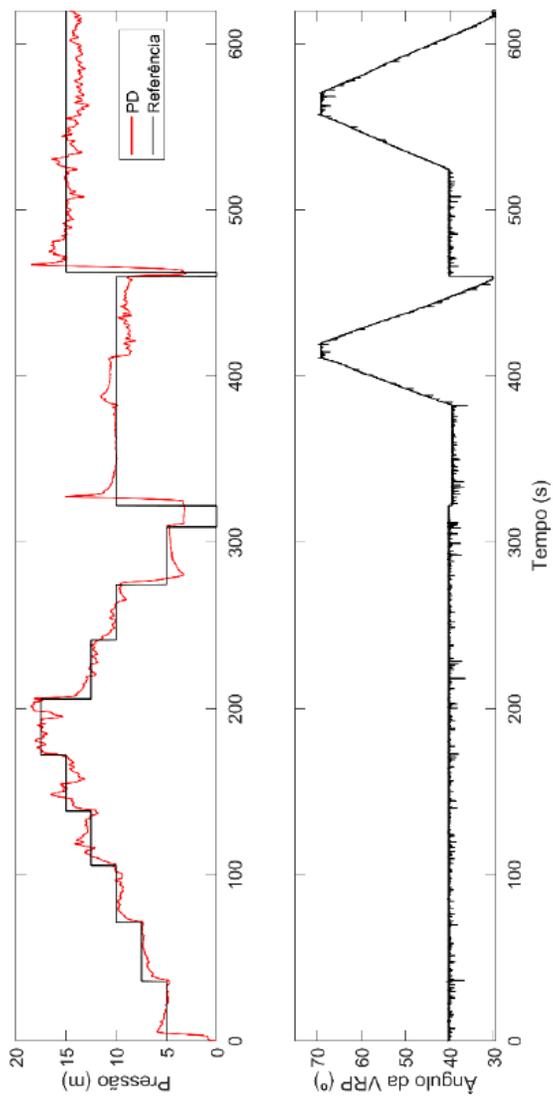


Figura 4.21: Dados de treinamento do controlador primário PD.

Fonte: Moreira (2020).

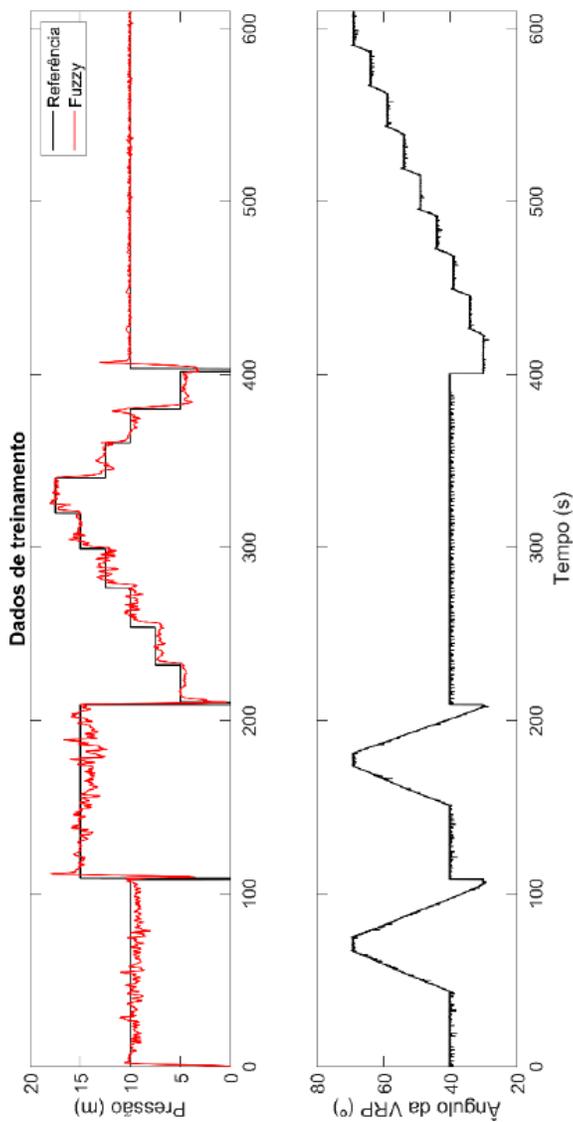


Figura 4.22: Dados de treinamento do controlador primário Fuzzy.  
 Fonte: Moreira (2020).

A superfície de resposta do controlador Neuro-Fuzzy (NFC) está ilustrada na Figura 4.23; comparando-a com a Figura 4.10, que representa a superfície de resposta do controlador *Fuzzy*, as superfícies não apresentam nenhuma relação de semelhança, mesmo assim, ambas deverão controlar o sistema de bombeamento, em menor ou maior desempenho.

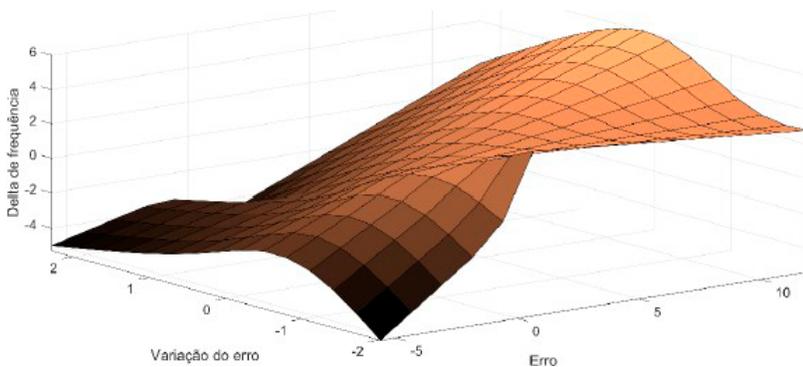


Figura 4.23: Superfície de resposta do controlador NF.

Fonte: Moreira (2020).

A resposta ao degrau é um método bastante comum para analisar o desempenho de controladores quando aplicados em sistemas que partem do repouso. Na Figura 4.24, encontra-se ilustrada a resposta ao degrau com os controladores NF, *Fuzzy* e Neural. A partir de uma análise comparativa, é observado que o *Fuzzy* apresenta a maior

velocidade e o controlador Neural apresenta o menor valor de máxima ultrapassagem. Tendo o NFC características híbridas, ele apresenta velocidade intermediária e alguma ultrapassagem. Analisando o tempo de acomodação e a sua estabilidade (erro

de regime permanente) do NFC é notável que os seus resultados são superiores.

A Tabela 4.8 resume o desempenho do controlador em relação à análise transiente e permanente para um degrau de 10 m. Em sistemas de abastecimento, o erro de regime permanente se sobrepõe, em importância, ao tempo de subida. Desta forma, pode-se considerar os resultados obtidos pelo NFC superiores aos demais.

Uma análise semelhante pode ser realizada com um degrau de 15 mca para verificar a influência da mudança de valor de referência. Na Figura 4.25, encontra-se ilustrada a resposta dos controladores; ambos os controladores apresentam ultrapassagem, entretanto o NF apresenta o melhor desempenho em relação ao erro de regime permanente e ao tempo de acomodação.

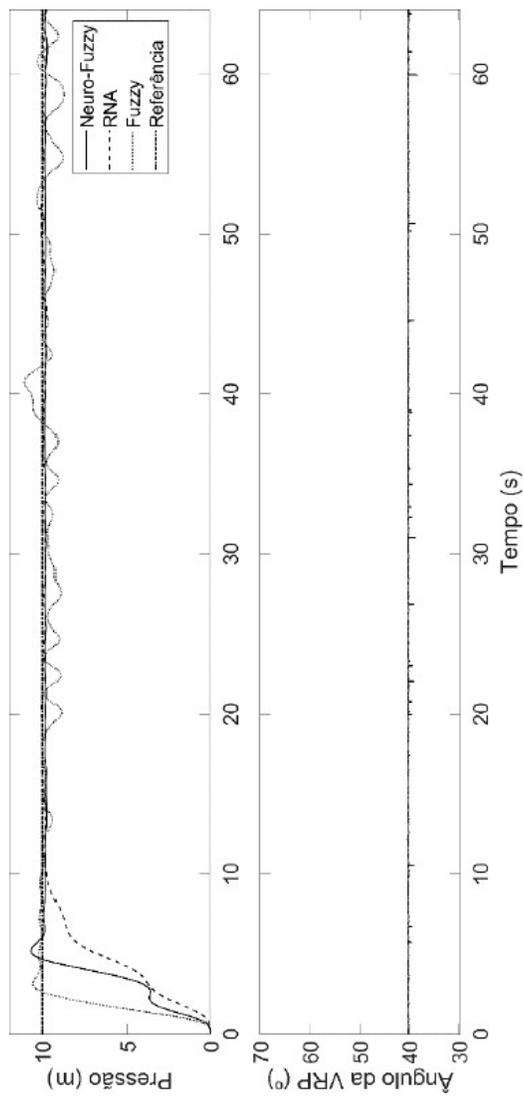


Figura 4.24: Resposta ao Degrau 10 mca.

Fonte: Moreira (2020).

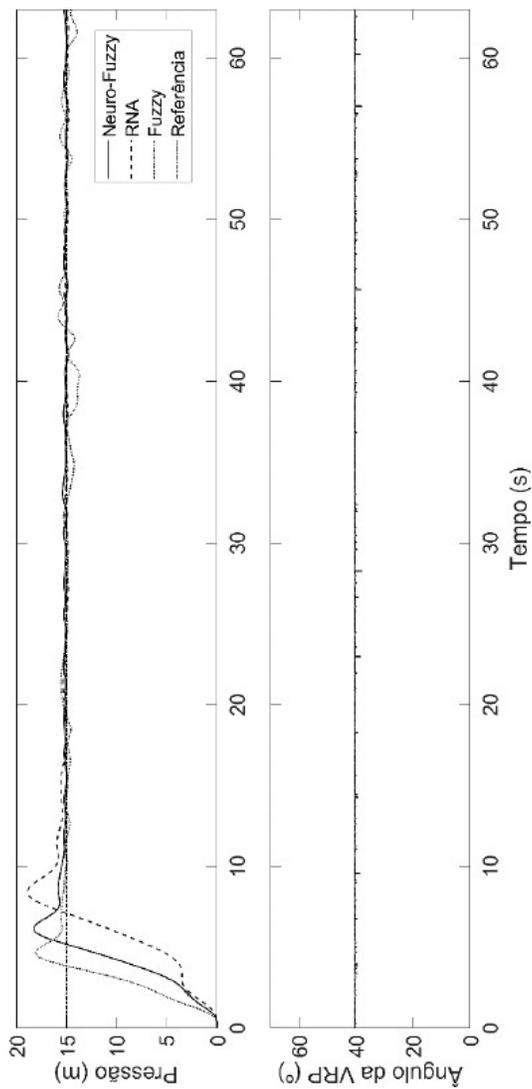


Figura 4.25: Resposta ao Degrau 15 mca.

Fonte: Moreira (2020).

Tabela 4.8: Análise do desempenho dos controladores.

Controlador	Tempo de subida [s]	Máxima ultrapassagem [%]	Tempo de acomodação [s]	Erro de regime permanente [%]
NF	6,6	11,5	12,2	0,9
Neural	12,9	0	18,2	1,2
Fuzzy	4,4	9,3	-	5,7

Fonte: Moreira (2020).

### 4.3.3.6 VARIAÇÃO DO VALOR DE REFERÊNCIA DO SISTEMA

Com o objetivo de demonstrar a efetividade do controlador em diferentes valores de referência, a Figura

4.26 apresenta o resultado da operação dos controladores com a mudança progressiva dos valores de pressão do sistema com VC em demanda média (40°). É possível observar que devido à mudança repetitiva do valor de referência, nenhum controlador atingiu um baixo erro de regime permanente, quando comparados ao degrau da Figura 4.24. Avaliando graficamente o tempo de subida e a estabilidade, os controladores NF e Neural apresentam resultados semelhantes, entre si, e superiores ao controlador *Fuzzy*.

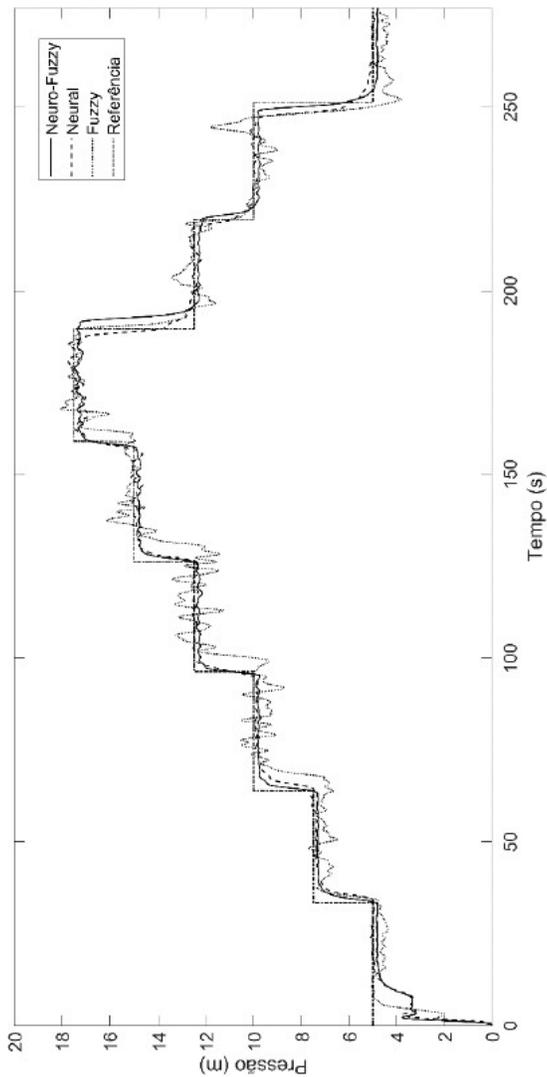


Figura 4.26: Variação do valor de referência com VC em 40°.  
 Fonte: Moreira (2020).

### 4.3.3.7 VARIAÇÃO CONTÍNUA DA VC

Um sistema de controle é considerado robusto quando ele é capaz de manter a estabilidade do sistema quando sujeito a distúrbios na planta. Sistemas de abastecimento possuem, na prática, demanda variável; assim, faz-se necessário a análise dos controladores diante de situações que mudem as características dinâmicas do sistema. A VC consegue deslocar a curva da tubulação verticalmente e induzir o controlador a encontrar um novo ponto de equilíbrio, através do controle da velocidade de rotação do CMB. Na Figura 4.27, ilustra-se a resposta do sistema com um valor de referência de 10 m, controlado quando a demanda do sistema é alterada através do ângulo da VC. É possível verificar que o controlador NF é o único que mantém boa estabilidade (erro < 8%), adaptando-se às mudanças do sistema com baixo erro, mesmo sob condições críticas de variação dinâmica.

Realizando um outro ensaio com 15 m como valor de referência, como ilustrado na Figura 4.28, ambos os controladores apresentam ultrapassagens não nulas; entretanto, o NF apresenta o melhor desempenho em relação ao erro de regime permanente, ao tempo de acomodação e à variação de demanda.

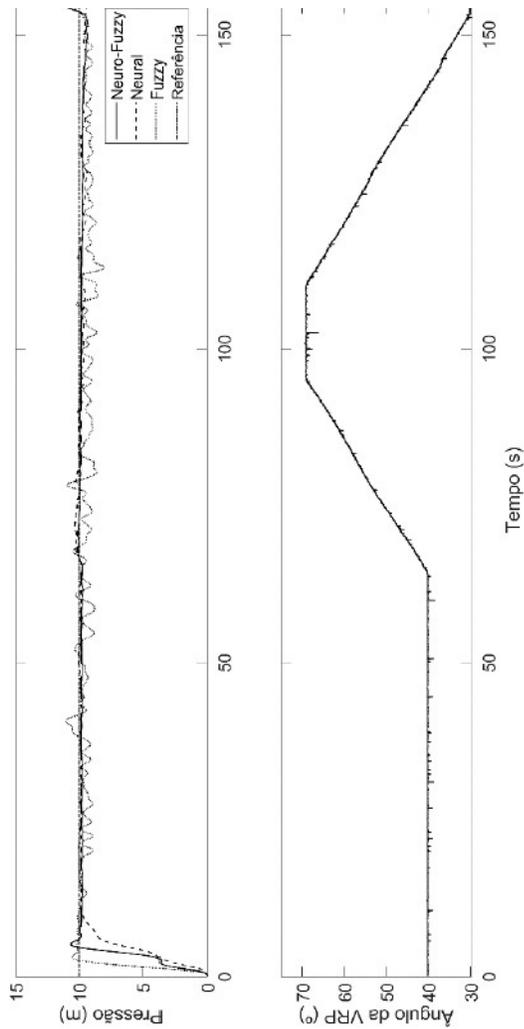


Figura 4.27: Degrau em 10 m com variação contínua da VC.  
 Fonte: Moreira (2020).

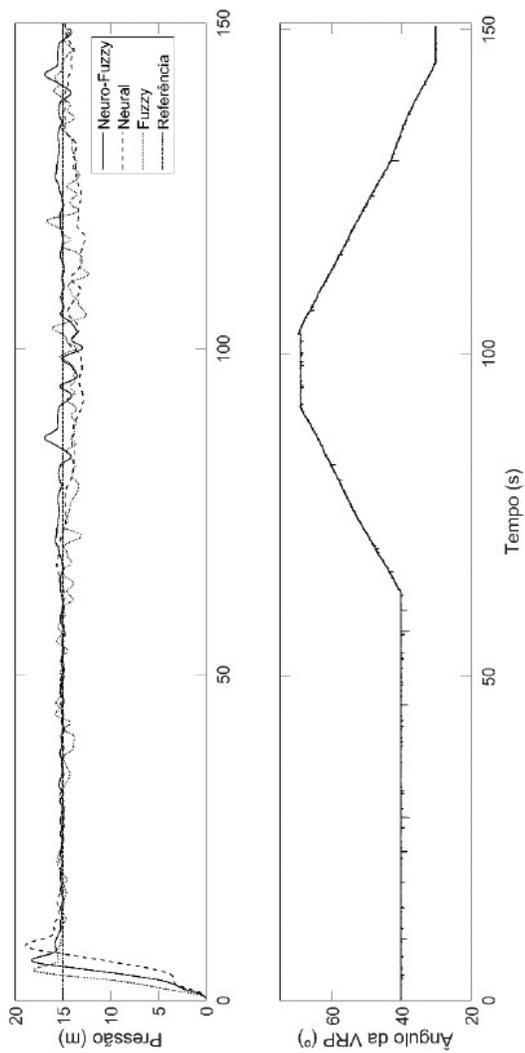


Figura 4.28: Degrau em 15 m com variação contínua da VC.

Fonte: Moreira (2020).

### 4.3.3.8 VARIAÇÃO PAUSADA DA VC

Apesar das mudanças bruscas na variação serem possíveis, o mais comum é que a variação ocorra de forma suave ao longo do dia. Analisando o desempenho do controlador ao variar pausadamente a demanda - uma condição mais branda que a observada nas Figuras 4.27 e 4.28 - é possível observar que o controlador NF mantém a pressão de serviço com baixo percentual de erro (erro < 3.3%), contra 9,8% do controlador Neural e 2,1% do Fuzzy, como ilustrado na Figura 4.29.

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 Figura 4.29 também ilustra a potência ativa do CMB, sendo estável e apresentando ausência de pico para o caso do controlador NF - aspecto importante para a proteção dos equipamentos eletromecânicos e eletrônicos. Entretanto, a presença de um elevado pico (até 179% maior que o controlador NF) na potência, para o controlador Fuzzy, mostra certa instabilidade nas características transitórias do sistema.

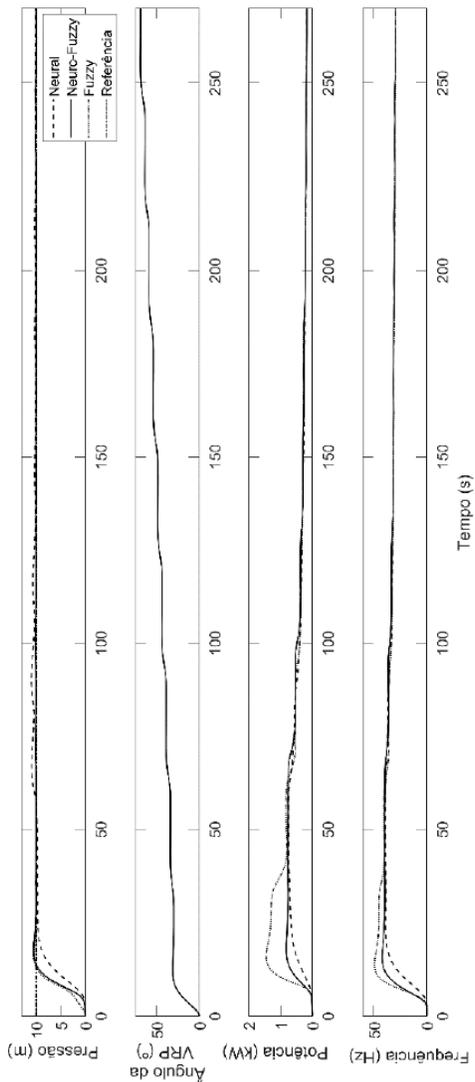


Figura 4.29: Degrau 10 m com var. pausada da VC.  
 Fonte: Moreira(2020)

Para avaliar a eficiência energética do sistema, controlado e não controlado, uma opção consiste em simular o perfil de consumo proposto por Gomes *et al.* (2012), o qual indica o consumo de água médio horário. A variação de consumo provoca flutuações significativas na pressão da rede. Assim, o controlador deve manter a pressão de serviço em valores de referência estabelecidos, objetivando reduzir o gasto energético do sistema. O consumo normalizado de água para o caso analisado foi de 0.765 l/s ( $k=1$ ).

Desta forma, para avaliar a eficiência energética do sistema foram ensaiados quatro cenários de operação, sendo que nos dois últimos o CMB está em sua velocidade nominal, como mostrados em seguida:

- Controle da pressão a jusante através da manipulação da velocidade do CMB por controlador *Fuzzy*;
- Controle da pressão a jusante através da manipulação da velocidade do CMB por controlador Neuro-Fuzzy;
- Controle da pressão a jusante por abertura/fechamento de válvula manual;
- Sistema não controlado.

Na Figura 4.30, ilustra-se o rendimento do CMB para cada período para cada uma das quatro situações de operação. Para este cálculo, a Equação (4.11) foi usada. Observa-se que durante os horários de baixa demanda o rendimento do sistema controlado é superior frente aos outros modos de operação. Entretanto, este rendimento é inferior nos horários de máxima demanda. O aumento do rendimento durante a mínima demanda citado anteriormente, deve-se ao fato do controlador manter a pressão em 10 m. Em contrapartida, nos outros dois casos o CMB opera sempre em velocidade nominal, independente da demanda, aumentando as perdas por vazamento ao longo da rede de distribuição, principalmente nos horários de mínima demanda.

Para o controlador *Fuzzy*, houve um acréscimo médio no rendimento de 9,16%. Para o controlador NF o acréscimo foi de 9,59%, resultado da menor ação de controle, refletindo na maior estabilidade e eficiência energética. Por outro lado, quando o sistema opera com o CMB em velocidade nominal e a demanda é controlada por registro manual, há uma queda da pressão no usuário final, devido ao excesso de perda de carga causada pelo registro, conseqüentemente impactando negativamente no rendimento global do sistema.

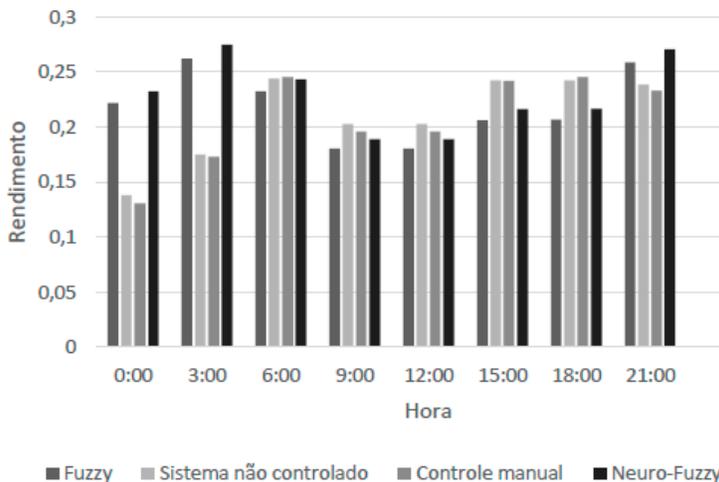


Figura 4.30: Rendimento do CMB.

Fonte: Moreira (2020).

Na Figura 4.31, encontra-se ilustrado o resultado da avaliação do consumo específico de energia (CE), na qual se evidencia que a atuação do controlador *Fuzzy* e NF produzem um CE menor ou igual quando comparado com as outras duas metodologias experimentadas. No período avaliado das 9h00 às 14h59, observa-se a igualdade do CE nos quatro métodos adotados; isso porque, em todos os casos, o sistema opera com velocidade nominal, devido à alta demanda. Além disso, é possível constatar uma redução máxima de 383% às 00h00, ao comparar o sistema operando com o controlador de pressão *Fuzzy* ao sistema não controlado. Quando comparado o controlador NF, ao sistema não controlado, o resultado é ainda melhor de até 392% para o período de 00h00 até 02h59, mostrando que o controlador NF pode reduzir em, aproximadamente, 4 vezes o consumo energético do sistema.

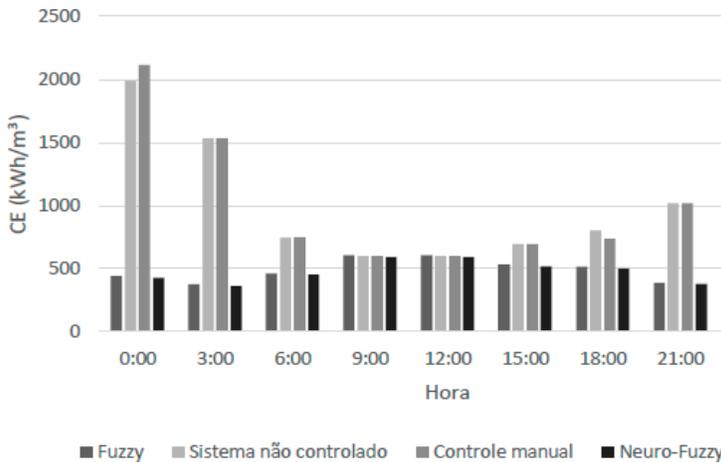


Figura 4.31: Coeficiente de consumo específico de energia (CE).

Fonte: Moreira (2020).

Investigando, também, o comportamento da pressão na saída do sistema ao longo das 24h para cada um dos quatro casos de operação propostos neste artigo, cujos resultados são apresentados na Figura 4.32. Para o controlador NF a pressão média foi de 10,3 m, já para o *Fuzzy* a pressão média foi de 10.7 m, erro de 3% e 7%, respectivamente. Constatou-se, também, que o sistema sem o controlador produz as maiores pressões durante os períodos de menores demandas. Isto pode ocasionar o rompimento de dutos, aumento dos vazamentos e redução da eficiência operacional.

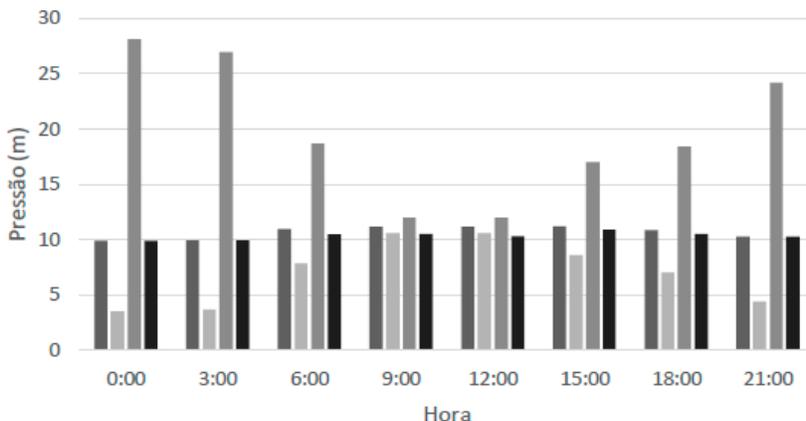


Figura 4.32: Pressões médias do sistema com demanda variável.

Fonte: Moreira (2020).

Neste capítulo, implementou-se a técnica Neuro-Fuzzy para identificar e controlar um sistema de abastecimento de água com demanda variável. A técnica foi aplicada com o objetivo de elevar a eficiência energética, através da estabilização das pressões da rede em valores de referência pré-estabelecidos.

Em alternativa aos modelos paramétricos, que apresentam deficiências em modelar sistemas multivariáveis e não-lineares, este trabalho propôs a utilização da técnica NF para a identificação do sistema de abastecimento de água com demanda variável. Para analisar estas técnicas foram realizadas análises comparativas. A primeira tratou da identificação do sistema com demanda fixa ( $VC=30^\circ$ ). Nesta análise, os modelos paramétricos mostraram boa capacidade de previsão; entretanto, com resultados inferiores para simulação (baixo ajuste e alto RMSE), quando comparado ao modelo Neuro-Fuzzy. A segunda análise consistiu na identificação do sistema com demanda variável, o que acrescentou não-

linearidades ao sistema. Nesse caso, somente os modelos Neural e NF apresentaram resultados satisfatórios. Apesar de ser possível melhorar a performance dos modelos paramétricos aumentando as suas respectivas ordens, uma desvantagem é observada; o aumento do custo computacional. É possível concluir que as técnicas inteligentes apresentam superioridade para a identificação de sistemas não-lineares e multivariáveis de bombeamento, frente aos modelos paramétricos, apontado através dos dados de validação e dos indicadores de performance. A análise dos modelos inteligentes mostrou que o Neuro-Fuzzy apresenta similaridades na predição (FPE) em relação às redes neurais, podendo-se utilizar qualquer uma para esta aplicação.

A técnica NF foi utilizada para caracterizar o rendimento global do sistema de bombeamento, suprimindo as deficiências dos modelos polinomiais; estes apresentam a vantagem da fácil obtenção; entretanto, a desvantagem de construir uma quantidade elevada de equações para determinar o comportamento global do sistema, o que é inviável. A análise do modelo permitiu observar que as regiões de máximo rendimento ocorrem quando o sistema opera com vazões médias. Assim, é possível idealizar um projeto com um maior número de CMBs operando em arranjos série/paralelo para suprir a pressurização da água. Entretanto, esta estratégia exige um maior investimento inicial na aquisição dos equipamentos eletromecânicos, sendo necessária uma análise financeira. Este procedimento pode ser estendido a outros sistemas hidráulicos/pneumáticos com demanda variável.

A técnica Neuro-Fuzzy foi aplicada no controle do sistema de bombeamento para regularizar as pressões e elevar a eficiência energética do sistema. O controlador NF e Neural foram

desenvolvidos utilizando dados de treinamento obtidos de um controlador *Fuzzy*. A comparação entre os três controladores mostrou que o controlador NF apresentou desempenho superior, aos demais, em todos os cinco testes para avaliação da resposta em regime transiente, permanente e em relação aos distúrbios inseridos pela VC. Como forma de avaliar o desempenho do controlador NF, controlando o sistema submetido à demanda variável, foi proposta a implementação da curva de consumo horário de água. Os resultados da análise hidroenergética mostraram que houve uma redução significativa do consumo energético com a implementação de automação nos sistemas de abastecimento. O controlador NF proporcionou um aumento de 4,7% do rendimento do CMB, quando comparado ao controlador *Fuzzy*; e de 9.59% comparado ao controle manual ou quando o sistema não é controlado. Houve também uma redução significativa do CE, sendo o controlador NF superior ao *Fuzzy*. Essas melhorias são consequência de uma menor ação de controle e maior performance em manter as pressões nos valores de referência.

### 4.3.3.9 CONSIDERAÇÕES FINAIS

Os controladores obtidos por modelagem computacional, como o NF e o Neural, baseiam-se no comportamento dos dados obtidos com o controlador primário, captando as tendências que esse apresenta. Desta forma, mesmo que os dados sejam imprecisos, ruidosos ou não reflitam o controle estável do sistema, os derivados desses terão a capacidade de controlar o sistema com maior robustez e desempenho.

Uma das grandes vantagens dos controladores baseados em modelagem computacional é que controladores mais eficientes podem ser desenvolvidos a partir de controladores não tão eficientes. Outra vantagem reside na menor ação de controle realizada pelos controladores NF e Neural, a qual resulta na maior estabilidade do sistema e no menor desgaste dos equipamentos eletromecânicos e elétricos.

Em suma, que a aplicação da técnica Neuro-Fuzzy fornece bons resultados na identificação e controle de sistemas de bombeamento com demanda variável, fornecendo resultados superiores aos modelos *Fuzzy* e Neural.

## REFERÊNCIAS

- BITTENCOURT, M. C. **Identificação de sistemas dinâmicos lineares – métodos paramétricos e não paramétricos**. Projeto de Graduação, Universidade de Brasília, Brasília, Brasil, 2007.
- LJUNG, L. **System Identification Toolbox User's Guide**. 2017. Disponível em: <http://www.mathworks.com>. Acesso em 18 de maio de 2020.
- LJUNG, L.; GLAD, T. **Modeling of dynamic systems**, 1ª ed., Editora Prentice Hall International, Reino Unido, 1994.
- MOREIRA, H.A.M. **Controle Neuro-Fuzzy para Eficiência Energética de Sistemas de Abastecimento de Água com Demanda Variável**. Dissertação de Mestrado, Departamento de Engenharia Mecânica, Universidade Federal da Paraíba, João Pessoa, Brasil, 2020.
- MOREIRA, H.A.M.; GOMES, H.P., VILLANUEVA, J.M.; GOMES, H.P.; VILLANUEVA, J.M.M.; BEZERRA, S.T.M. **Real-time neuro-fuzzy controller for pressure adjustment in water distribution systems**. *Water Supply & Water Technology Supply*, 21(4), 2021, pp. 116-132.
- PEDRYCZ, W.; GOMIDE, F. **Fuzzy systems engineering: toward human-centric computing**, Nova York, Editora Wiley IEEE Press, 2007.
- Rodrigues, G.G., 1996. **Identificação de Sistemas Dinâmicos Não Lineares Utilizando Modelos NARMAX Polinomiais - Aplicação a Sistemas Reais**. Dissertação de Mestrado do PPGEE, Universidade Federal de Minas Gerais, Belo Horizonte, Brasil, 1996.

# Capítulo 5: Controle de Pressão Fuzzy em Sistemas de Abastecimento de Água Baseado em Modelos de Sistemas com Redes Neurais Artificiais

*José Vinícius Santos de Araújo,  
Juan Moises Mauricio Villanueva  
e Heber Pimentel Gomes.*

## **5.1 CONTEXTO E PROBLEMAS DOS SISTEMAS DE ABASTECIMENTO DE ÁGUA**

Um dos grandes desafios para controlar a pressão hidrostática nas redes de abastecimento de água é a distância entre os sensores (relés de nível, medidores de vazão de água, sondas hidrostáticas, entre outros) e os atuadores de processo (conjuntos de bombas, conversores de frequência, e válvulas), pois esta dificulta a conexão física por meio de cabeamento.

Muitas vezes, uma estação elevatória de água dista mais de 3 km de uma das suas zonas de influência. Assim, o uso de

protocolos industriais do tipo Ethernet e tecnologias IoT de baixo custo são uma excelente alternativa para conectar os elementos do sistema de abastecimento de água, ampliando o monitoramento da rede e facilitando a realização do controle.

Neste capítulo, é apresentado um sistema de monitoramento e solução de controle de baixo custo para a rede de abastecimento de água usando ScadaLTS como sistema supervisório, ESP8266 e sensores de pressão hidrostática para coletar dados da rede hidráulica e lógica fuzzy desenvolvida em Python para controle, a fim de garantir pressão adequada para consumidores e a saúde das tubulações.

Para reduzir os riscos de aplicar a metodologia de controle proposta diretamente à rede hidráulica, também foi proposta a modelagem da rede hidráulica usando redes neurais (RNA) para que o ajuste do controlador fuzzy fosse realizado mais cedo neste modelo. O método apresentado é eficiente e simplificado, utilizando recursos de baixo custo para monitoramento (ESP8266) e lógica de controle eficiente em um ambiente de programação de fácil aprendizado (Python), de modo que as concessionárias de água podem replicá-lo sem dificuldade.

De forma sucinta, o método apresentado tem como vantagens: (1) controle mais eficiente da pressão da rede de abastecimento de água, (2) diminuição do número de tubos ocorrências de ruptura devido a pressão excessiva na rede e economia de energia ao usar inversores de frequência como atuadores em um sistema de malha fechada.

Um problema comum em redes de abastecimento de água diz respeito à regulação da pressão nas unidades consumidoras, por duas razões:

(1) algumas companhias de água ainda não modernizaram os seus sistemas de monitoramento, de modo que não se pode ter dados relativos à pressão atual nas unidades consumidoras e, por consequência, parâmetros adequados para avaliar a qualidade de fornecimento;

(2) quando os dados da pressão estão disponíveis, também há outro obstáculo, que é a distância entre o sistema de bombeamento de água e as unidades consumidoras pode ser razoavelmente alta (da ordem de quilômetros), o que dificulta que a medição da pressão nessas localidades por meio de sistemas a fio seja feita pelo controlador do sistema de bombeamento.

Dessa forma, muitas vezes o controle é alcançado pela ação de um operador que liga e desliga os conjuntos motobomba com o nível de compensação como uma referência, agindo para manter alto o nível de água do tanque e, conseqüentemente, ter estoque suficiente para suprir a população, sem, no entanto, provocar transbordamentos.

No entanto, outra restrição do sistema diz respeito ao nível dos reservatórios apoiados, pois os conjuntos motobomba não podem operar com eles em níveis baixos, devidos à entrada de ar durante a sucção da bomba, o que prejudica a sua vida útil. Assim, controlar a chegada de água a esse tipo de

tanque também é fundamental. Tais problemas também estão contemplados no exemplo deste capítulo, o qual chamaremos de sistema de bombeamento de água do tipo estrela. Essa estação de bombeamento atende a uma região da cidade com áreas de influência a distâncias maiores que 2,5 km. O período da noite é o mais problemático, pois a demanda de água cai drasticamente, o que causa o rápido aumento da pressão na rede e, conseqüentemente, provoca rupturas da tubulação.

## **5.2 CONTROLE DE PRESSÃO EM UM SISTEMA DE ABASTECIMENTO DO TIPO ESTRELA**

O sistema de abastecimento de água de tipo estrela considerado neste capítulo é composto por equipamentos para sensoriamento, atuação e controle da rede. Esses equipamentos são:

- (1) dois inversores de frequência (estação de bombeamento);
- (2) um tanque de compensação (estação de bombeamento);
- (3) dois conjuntos motobomba (estação de bombeamento);
- (4) duas válvulas (estação de bombeamento);
- (5) dois tanques apoiados (estação de bombeamento);
- (6) três transdutores de pressão (um na estação de bombeamento e dois nas unidades consumidoras);
- (7) um controlador lógico programável (CLP) Siemens.

Para enfatizar o processo de projeto, um esquemático do sistema está ilustrado na Figura 6.1, considerando os elementos hidráulicos presentes, tais como motores, reservatórios apoiados, válvulas e a caixa d'água, além de mostrar os percursos da água injetada pelos conjuntos motobomba. Nessa elevação de água, o tanque de água tem a função de elevar a pressão na rede. Atualmente, o tanque d'água serve como compensação para ajudar na injeção da rede em momentos de consumo elevado. Por fim, as válvulas apoiadas regulam a quantidade de água que chega ao elevatório.

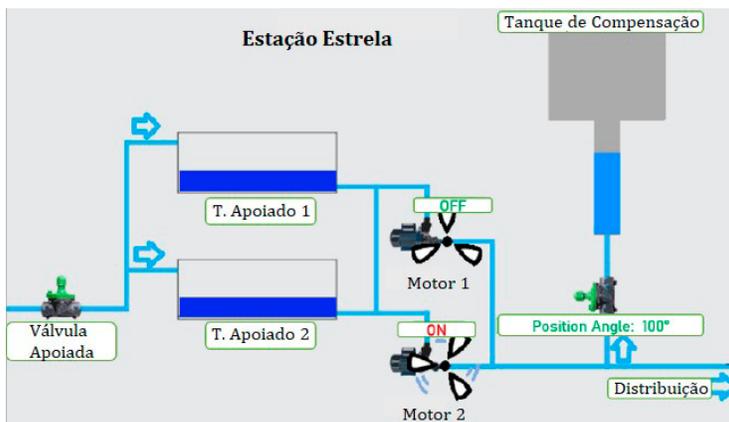


Figura 5.1: Esquemático da Estação Estrela.

Fonte: Adaptado de Araújo et al. (2022)

## 5.2.1 COMPONENTES DA SOLUÇÃO DE MONITORAMENTO E DO SISTEMA DE DISTRIBUIÇÃO

A rede de abastecimento de tipo estrela tem duas unidades de monitoramento, com a unidade 2 estando na ponta da zona de influência. Suas pressões são aferidas com um ESP8266 e um transdutor de pressão em cada ponto de medição localizado dentro de um estabelecimento com acesso à Internet fornecido pela companhia de abastecimento de água.

O transdutor de pressão usado neste exemplo está ilustrado na Figura 5.2 e é alimentado com 12 V de tensão, sendo capaz de prover sinais de corrente entre 4 e 20 mA, os quais são incompatíveis com o padrão analógico usado pela ESP8266, entre 0 e 3,3 V. Assim, um circuito de condicionamento composto por um resistor 165  $\Omega$  e um capacitor em paralelo para filtrar frequências acima de 60 Hz precisou ser usado para converter o sinal de corrente em um sinal de tensão entre 0,66 e 3,3 V.



Figura 5.2: Transdutor de Pressão.

Fonte: (Araújo et al., 2022)

Na Figura 5.3, ilustra-se o circuito de condicionamento usado para alterar o sinal de corrente para um de tensão.

A leitura dos dados realizados pela ESP8266 é fornecida para o sistema supervisorio por meio do protocolo HTTP Receiver a cada 12 segundos, totalizando 5 medições por minuto. Além disso, foi configurado para o banco de dados armazenar a média dos valores medidos a cada um minuto. Devido a característica lenta do sistema hidráulico em relação a outros processos industriais, essa taxa de amostragem se mostra satisfatória.

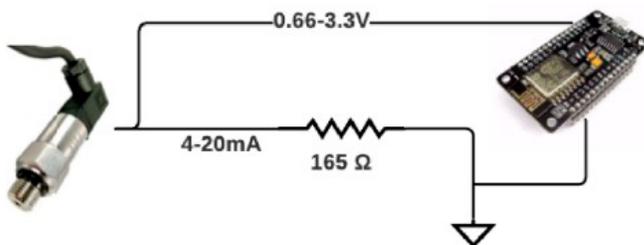


Figura 5.3: Circuito de condicionamento.

Fonte: (Araújo et al., 2022)

Ademais, para converter a leitura analógica de tensão em pressão usou-se o fato de que a resolução do conversor analógico-digital da ESP8266 é de 10 bits. Dessa forma, o nível de tensão de 3,3 V corresponde ao valor de número 1023 ( $2^{10} - 1$ ) do conversor. Considerando que os sensores hidrostáticos do sistema medem pressões de 0 a 50 mca, tem-se que a relação entre a pressão medida e o valor convertido para digital é conforme apresentado na Figura 5.4.

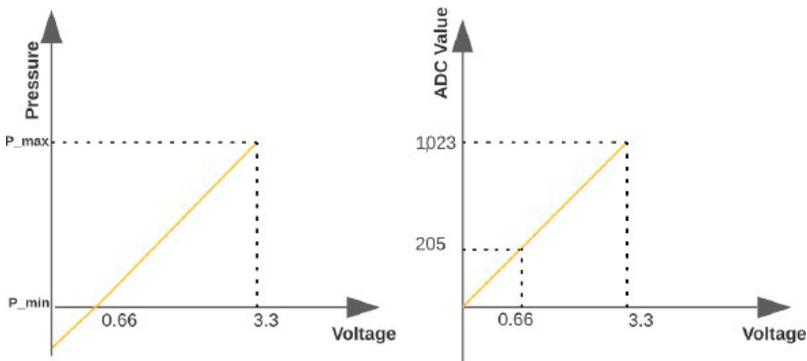


Figura 5.4: Relação entre a pressão medida e o valor convertido para a forma digital.

Fonte: (Araújo et al., 2022)

Sobre os elementos presentes, especificamente, na estação elevatória do sistema de estrela em questão tem-se:

– **Válvula Elétrica do Tipo Borboleta:** essa válvula está posicionada na entrada dos apoiados. São válvulas do tipo analógica que podem ser controladas via entrada de controle de 4 – 20mA, sendo 4 mA representando a válvula totalmente fechada e 20 mA para válvula totalmente

aberta. Ela foi conectada em uma das saídas analógicas do CLP da Siemens S7-1200, de maneira direta, sem circuitos de condicionamento. Na Figura 5.5 é possível observar a válvula presente no apoiado;



Figura 5.5: Válvula elétrica do tipo borboleta  
Fonte: (Araújo, 2021).

– **Dois conjuntos Motobomba:** os motores usados têm potência nominal de 45 kW. Já as bombas têm vazão de 363 m<sup>3</sup>/h. Apesar de os conjuntos motobomba estarem arranjados em paralelo, eles operam de maneira alternada: em um dia opera o conjunto 1 e no outro o conjunto 2. Na Figura 5.6, é possível observar os conjuntos motobomba em ação e como estão dispostos em campo;

– **Caixa D'água da Estação Elevatória:** possui altura manométrica máxima de 17,5 m. Seu abastecimento acontece por meio dos mesmos dois conjuntos motobomba que abastecem a população, de modo que a água injetada de uma tubulação principal é ramificada

em duas sendo uma para o enchimento da compensação e a outra para abastecimento da população. Dessa maneira, a caixa d'água pode ser observada na Figura 5.7.



Figura 5.6: Conjuntos motobomba em paralelo.

Fonte: (Araújo, 2021).

– **Reservatórios Apoiados:** a estação elevatória do sistema estrela possui dois reservatórios apoiados interligados. O nível máximo do apoiado é de aproximadamente 3 m. Eles estão mostrados na Figura 5.8.

– **Inversores de Frequência:** a regulação de velocidade de rotação dos conjuntos motobomba é realizada com inversores de frequência da fabricante Danfoss da linha CF202. O controle da velocidade de rotação pode ser feito por meio de uma entrada de referência ou enviando valores via comunicação serial no registrador de controle de velocidade.

Neste inversor, o controle de velocidade é feito considerando que o envio do valor 16384 implica que o motor rotaciona com a velocidade máxima configurada e 0 com velocidade mínima. Na Figura 5.9 é possível observar o inversor de frequência dentro do painel de controle.

– **Controlador:** para comunicação e controle dos elementos da elevatória, é utilizado o controlador da Siemens® da linha S7-1200 DC/DC/DC que possui 8 entradas digitais, 6 saídas digitais, uma entrada analógica 0 – 10V mais dois módulos de expansão: um Módulo RS232/485 para comunicações seriais, sendo utilizado para fazer Modbus RTU com os inversores de frequência e um módulo de expansão contendo 4 entradas analógicas e 2 saídas analógicas. A instalação do controlador no painel de comando pode ser observada na Figura 5.10.



Figura 5.7: Caixa d'água elevatória.

Fonte: (Araújo, 2021).



Figura 5.8: Reservatórios Apoiados.  
Fonte: (Araújo, 2021).



Figura 5.9: Inversores de frequência do sistema de distribuição.  
Fonte: (Araújo, 2021).



Figura 5.10: Controlador lógico programável do sistema de distribuição.  
Fonte: (Araújo, 2021).

Os materiais usados em cada etapa deste exemplo são:

**(1) Leitura e aquisição de sensores e atuadores:**

A. Sensores hidrostáticos localizados na distribuição via ESP8266;

B. Sensores hidrostáticos, válvulas e inversores de frequência localizados na estação elevatória de água via CLP S7-1200;

**(2) Controle local:**

A. Nível dos apoiados;

**(3) Controle remoto:**

A. Modelagem do sistema com RNA por meio de dados históricos em Python;

B. Desenvolvimento do controlador fuzzy em Python;

C. Validação do controle fuzzy sobre modelo em RNA;

D. Leitura de dados em tempo real do ScadaLTS via API REST e Python;

E. Envio de dados para o ScadaLTS após passagem pelo controlador fuzzy.

Na Figura 5.11, a metodologia da solução utilizada está representada na forma de um diagrama que relaciona os estágios do processo com os materiais e recursos empregados.

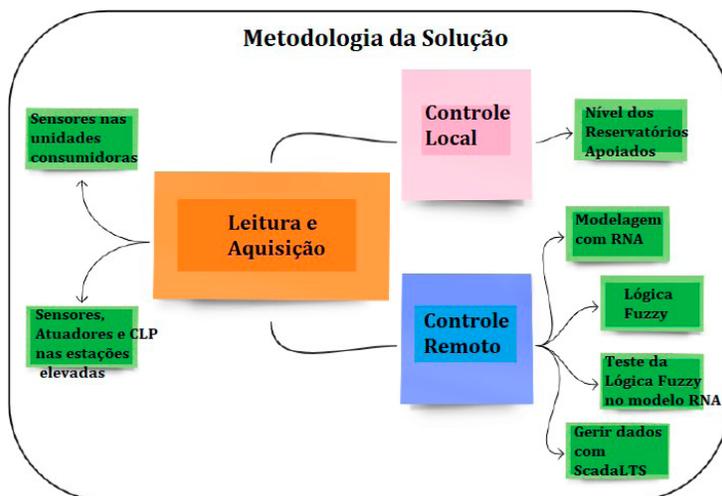


Figura 5.11: Esquemático da metodologia utilizada.

Fonte: Adaptado de Araújo et al. (2022).

### 5.2.1.1 USANDO O SCADALTS

Para que seja possível consolidar o controle remotamente via Python, é necessário utilizar três principais recursos do ScadaLTS: a possibilidade de coleta de dados de pressão em tempo real armazenados no banco de dados do sistema supervisório através de API REST; o envio de dados da velocidade de rotação dos motores e da pressão na rede através do protocolo Modbus TCP e HTTP Receiver, respectivamente e o conjunto eventos e tratadores de eventos que possibilita a aplicação do valor de uma variável em outra.

Descrevendo sobre o primeiro, o API REST do ScadaLTS permite integração segura entre um programa externo e os dados

armazenados no banco de dados associado ao supervisório. É possível fazer leituras e escritas de dados, acessar parâmetros do supervisório com simples palavras chaves e ainda garantindo a segurança devido ao requisito da API de autenticar o acesso por meio do uso de um usuário e senha válidos.

Em especial, dois métodos GET desta API são utilizados:

– /auth/{username}/{password}

Este método permite o acesso aos demais métodos da API ao se escrever nos campos *username* e *password* valores válidos, garantindo que apenas pessoas que estão cadastradas como usuários para o sistema supervisório.

– /point\_value/getValue/{xid}

Este método envia dados em formato json referentes ao datapoint desejado a partir do acesso direto ao banco de dados, por meio do xid, código atribuído pelo ScadaLTS que identifica a variável desejada.

Desse modo, em Python criou-se uma rotina para leitura de dados do ScadaLTS que faz requisições pela API a cada 1 minuto, por meio da biblioteca requests, ao mesmo tempo em que o sistema supervisório armazena os dados desejados no banco de dados. Essas requisições são realizadas para atualizar o controlador *fuzzy* sobre o estado atual do processo com o conhecimento das entradas (pressão na distribuição) e saídas (velocidade de rotação dos motores atuais).

Sobre o envio de dados para o ScadaLTS estabeleceu-se três fontes das quais os dados partem: do controlador localizado na estação elevatória de água; das ESP8266 localizadas na região de distribuição e de um computador da companhia de água a

qual está implementada a lógica nebulosa que envia a velocidade de referência para o sistema supervisório.

Para a comunicação com o controlador é utilizado o protocolo Modbus TCP, uma vez que se deseja que o controlador envie dados, mas também receba comandos a partir do sistema supervisório. O controlador, por sua vez, se comunica com os inversores de frequência por meio do protocolo Modbus RTU, atuando como um gateway entre o

ScadaLTS e os inversores. Um esquemático das etapas do processo de comunicação pode ser observado na Figura 5.12.

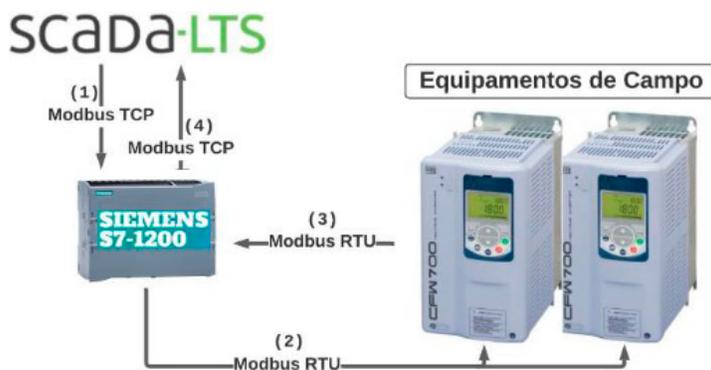


Figura 5.12: Esquemático da comunicação entre ScadaLTS e inversores de frequência.

Fonte: Adaptado de Araújo (2021).

Para a comunicação com as ESP8266 foi utilizado o protocolo HTTP Receiver, considerando que a única função das placas é ler a saída do sensor de pressão hidrostático e enviar o valor da medição para o ScadaLTS, não havendo necessidade de receber nenhum comando do supervisório. Para a comunicação do controlador nebuloso programado em Python foi utilizado,

também, o protocolo HTTP receiver. Apesar do programa em Python necessitar fazer leituras e envio de dados pelo ScadaLTS, as leituras já são realizadas através da API, que requisita do supervisor os dados de interesse (pressão e frequência de rotação dos motores) em tempo real. Por simplicidade e facilidade de implementação optou-se em realizar o envio das saídas do controlador nebuloso via HTTP, também pela biblioteca *requests*.

Por fim, para o ScadaLTS enviar comandos para os equipamentos de campo, é aplicado o recurso de tratadores de eventos, a qual a variável de velocidade de referência de rotação dos motores em HTTP é aplicada a variável de velocidade de referência de rotação dos motores em Modbus TCP, finalizando o caminho do sistema de controle.

### **5.2.1.2 MODELAGEM DO PROCESSO COM REDES NEURAIS ARTIFICIAIS**

A utilização das capacidades de redes neurais artificiais teve como finalidade a obtenção de um modelo virtual da rede hidráulica em estudo, possibilitando a realização de simulações do comportamento da rede sob a aplicação de diferentes sinais de atuação do controlador nebuloso. Deste modo, diminui-se os riscos de expor a rede hidráulica real a comportamentos indesejados, estimando situações reais e otimizando os parâmetros do controlador *fuzzy* para melhor desempenho quando aplicado a rede real.

Neste exemplo, para modelar o sistema de abastecimento do tipo estrela, fez-se uso do recurso de geração de relatórios do

ScadaLTS que permite que dados sejam organizados em planilhas CSV, de acordo com o período de tempo desejado. Esses dados contêm os valores históricos dos *datapoints* selecionados, os quais foram utilizados para compor o banco de dados de treinamento e validação da RNA.

Para este estudo de caso, foram coletados dados de 15 dias de operação da rede de abastecimento de água, tendo no total 21.600 amostras, com tempo de amostragem de 1 minuto entre cada amostra. Além disso, o minuto do dia em que cada amostra foi colhida é representado por uma variável denominada *TimeStamp*. Por exemplo, às 4h00, a *TimeStamp* será de  $240 \cdot (4-60)$ . Na Figura 5.13, ilustra-se a relação de retroalimentação (*feedback*) entre entradas e saídas baseada em redes neurais artificiais. Nela,  $k$  é o índice do período de amostragem, M1 e M2 são os conjuntos motobomba e unidade 2 é o ponto de medição de pressão.

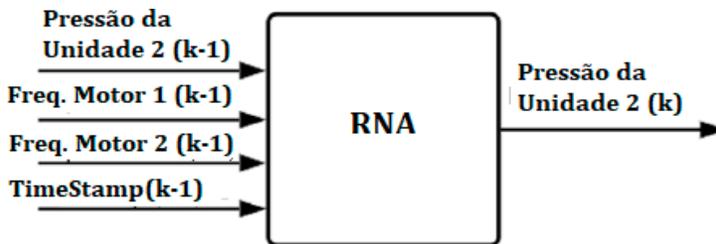


Figura 5.13: Relação entre entradas e saídas no modelo RNA.

Fonte: Adaptado de Araújo et al. (2022)

O controle de pressão da elevatória está baseado em um controlador de velocidade incremental que considera apenas o erro entre o *setpoint* e pressão atual da unidade consumidora de número 2.

A decisão de utilizar apenas uma unidade consumidora como variável de entradas foi realizada após conversas com especialistas, uma vez que a pressão medida na unidade consumidora de número 1 sofre com variações devido ao local de instalação do medidor hidrostático ser em uma torneira a qual casualmente é aberta provocando variações bruscas na medição de pressão. Na Figura 5.14 é possível observar o comportamento da pressão ao longo de um dia nas duas unidades consumidoras.

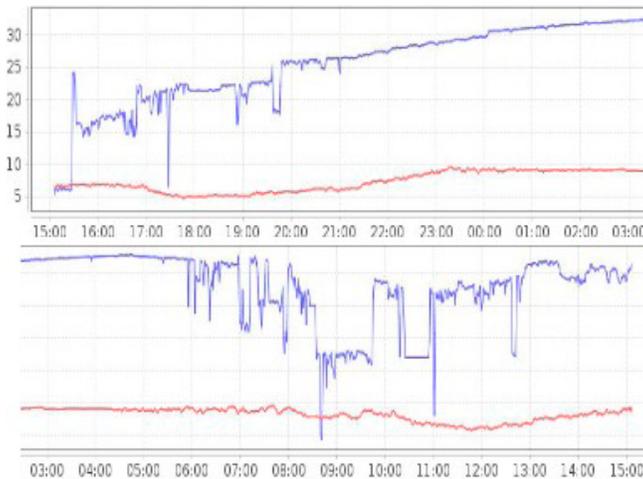


Figura 5.14: Pressão medida nas unidades consumidoras. Azul: Unidade consumidora nº1; Vermelho: Unidade consumidora nº2.

Fonte: Adaptado de Araújo (2021).

Como é possível observar na Figura 5.14, a pressão medida na unidade consumidora nº1 (em azul) frequentemente cai de forma brusca, com valores superiores a 5 mca em muitas vezes, restando uma referência instável demais para ser utilizada. Por esse motivo, foi descartado seu uso. Por outro lado, a pressão medida na unidade 2 (em vermelho) é mais apropriada para ser o sinal de controle de referência, por ser a unidade que sofre com menos pressão na rede e por ter uma medição de maior qualidade e com mais estabilidade.

O controle vigente que produziu os dados coletados pelo relatório, apesar de ser extremamente simples, provoca variações. A frequência de rotação do conjunto motobomba que está operando é incrementada de acordo com a diferença entre

a pressão de referência e a pressão medida, com incrementos discretizados. Na Tabela 5.1, está ilustrado o funcionamento do controle vigente.

Tabela 5.1: Lógica de Controle Vigente.

Erro (Setpoint - Pressão Atual)	$\Delta f$ (Hz)
Erro > 2	0.9
2 > Erro > 1	0.6
1 > Erro > 0.3	0.3
Erro < -2	-0.9
-2 < Erro < -1	-0.6
-1 < Erro < -0.3	-0.3

Fonte: Adaptado de Araújo et al. (2022)

### 5.2.1.3 CONTROLE FUZZY BASEADO EM PYTHON

Para entender melhor como atua o controlador *fuzzy* sobre a planta em estudo, na Figura 5.15 está apresentado um diagrama de blocos do sistema de controle. O controlador é composto por dois equipamentos, sendo um computador com a lógica *fuzzy* implementada em Python que envia para o CLP – e este interage com os atuadores – o sinal de atuação de maneira direta através do ScadaLTS. Inicialmente, o controlador faz uma requisição HTTP da pressão atual ao sistema supervisório, para usar como entrada da lógica *fuzzy* a diferença entre o setpoint e a pressão atual, bem como a variação do erro. O resultado da inferência *fuzzy* é transferido ao CLP, o qual aplica a velocidade de referência aos inversores de frequência que atuam diretamente sobre a planta hidráulica.

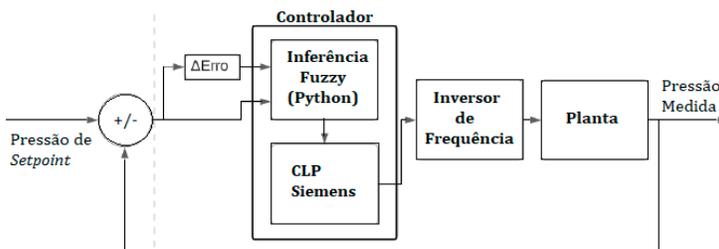


Figura 5.15: Diagrama do controlador fuzzy.

Fonte: Adaptado de Araújo *et al.* (2022).

A opção pela utilização de um controlador *fuzzy* a outros controladores tradicionais, como os controladores do tipo PID (Proporcional-Integral-Derivativo), se dá principalmente pelo desempenho mais baixo dos controladores tradicionais diante de processos industriais de difícil modelagem matemática e não-linearidades, como é o caso de um processo de hidráulico.

Por outro lado, os controladores nebulosos possuem algumas vantagens práticas, sendo confiáveis, robustos e resistentes a perturbações externas pela característica do processamento independente de cada regra. Além disso, o ajuste das regras *fuzzy* é mais simples podendo ser testados individualmente para cada situação específica, sendo eficazes tanto para sistemas lineares quanto para não-lineares.

Nesse sentido, o desenvolvimento da lógica *fuzzy* e suas regras é parte fundamental do desempenho de um controlador *fuzzy*. É muito importante o conhecimento da planta juntamente com o conhecimento dos especialistas para determinar, por exemplo, se o incremento de velocidade de rotação do conjunto motobomba é pequeno ou grande o suficiente para alterar a pressão medida para um valor mais próximo do desejado.

Segundo Moura (2017), o número de termos das funções de pertinência recomendado é entre dois e sete. Em tese, quanto maior o número de conjuntos maior é a precisão do controle nebuloso. Entretanto, para valores superiores a sete, não há melhorias significativas.

Tanto Moura (2017) quanto Flores (2019), em seus respectivos trabalhos para controle de pressão pela regulação de velocidade de um inversor de frequência, optaram por utilizar 2 variáveis de entrada para o controlador nebuloso, sendo elas o erro e a diferença entre erro atual e o anterior, saída como sendo o incremento de frequência a ser realizado, com 7 conjuntos para cada variável e lógica nebulosa do tipo mamdani. Eles serão usados como referência.

Foram construídos os conjuntos e as regras da lógica nebulosa. A diferença entre as regras deste exemplo e aquelas definidas pelas referências se deve às diferenças entre os estudos de caso: o processo da estação elevatória de água do sistema estrela possui um tempo de resposta mais lento; as atualizações de velocidade, devido às limitações, são realizadas a cada um minuto (um tempo muito maior em relação às referências citadas); há certos momentos do dia em que a demanda da rede é superior à capacidade do conjunto motobomba fornecer água para o sistema.

Considerando essas premissas, as variáveis linguísticas de entrada podem assumir 7 possíveis valores: "PG" (Positivamente Grande), "PM" (Positivamente Médio), "PP" (Positivamente Pequeno), "Z" (Zero), "NP" (Negativamente Pequeno), "NM" (Negativamente Médio) e "NG" (Negativamente Grande). Já a

variável linguística de saída pode assumir os seguintes valores: "IG" (Incremento Grande), "IM" (Incremento Médio), "IP" (Incremento Pequeno), "Z" (Zero), "DP" (Decremento Pequeno), "DM" (Decremento Médio) e "DG" (Decremento Grande).

Nas Figuras 5.16, 5.17 e 5.18, encontram-se ilustrados os conjuntos *fuzzy* de cada variável linguística: (1) erro, (2) diferença entre o erro atual e o anterior e (3) incremento de frequência, utilizando como função de pertinência, nos três casos, a triangular.

A interação entre esses conjuntos depende das regras nebulosas desenvolvidas. A ideia principal para a criação das regras é que o incremento/decremento da frequência seja realizado de acordo com erro e a diferença entre o erro atual e o anterior, de maneira que os incrementos sejam grandes quando a diferença entre o *setpoint* e a pressão medida seja alta ao passo que o incremento também seja suavizado à medida que o delta do erro seja considerado alto, uma vez que o delta do erro alta indica se a correção da pressão estiver mudando rápido demais.

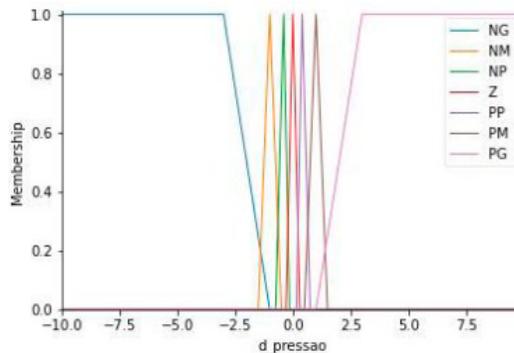


Figura 5.16: Conjunto fuzzy da variável Erro.

Fonte: (Araújo, 2021).

Na Tabela 5.2 estão apresentadas as regras *fuzzy* desenvolvidas pensando no comportamento desejado. Foram utilizadas apenas lógicas *and* para a interação entre os conjuntos. Por exemplo, caso o erro seja NG e a diferença do erro seja NG, a variação da frequência deverá ser DP.

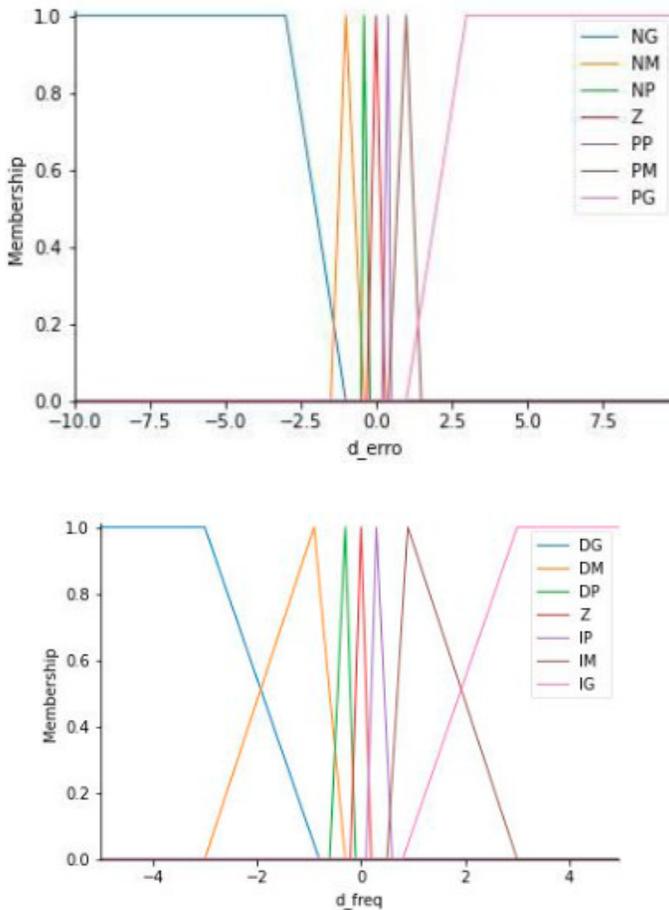


Figura 5.17: Conjunto fuzzy da variável Diferença de Erro.

Fonte: (Araújo, 2021).

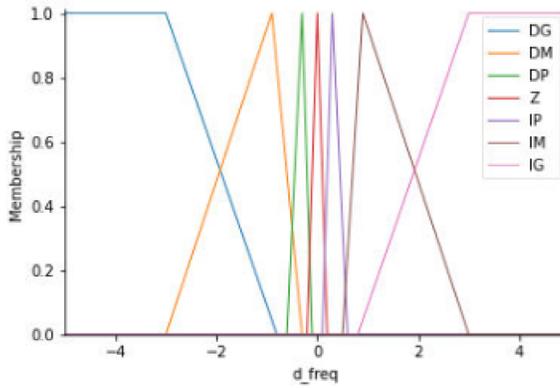


Figura 5.18: Conjunto fuzzy da variável incremento de frequência.

Fonte: (Araújo, 2021).

Tabela 5.2: Regras *Fuzzy* do controlador.

		Diferença de Erro						
		NG	NM	NP	Z	PP	PM	PG
Erro.	NG	DP	DP	DP	DM	DM	DG	DG
	NM	Z	DP	DM	DM	DM	DM	DM
	NP	Z	Z	DP	DP	DP	DP	DM
	Z	IP	Z	Z	Z	Z	Z	DP
	PP	IM	IM	IP	Z	IP	Z	Z
	PM	IM	IM	IM	IM	IM	IM	IP
	PG	IG	IG	IG	IM	IM	IM	IM

Fonte: Adaptado de Araújo *et al.* (2022)

Uma boa indicação de que a interação entre as regras e os conjuntos *fuzzy* está adequada é observando a superfície de relação entre as entradas e saída (ilustrada na Figura 5.19), de modo a verificar a suavidade das mudanças nos valores de saída para diferentes valores de entrada.

Todo o desenvolvimento da lógica *fuzzy* neste projeto, foi realizado utilizando a biblioteca *skfuzzy*, a qual tem suporte a diversas configurações, desde diversos tipos de funções de pertinência, como sigmóide, triangular e trapezoidal, até os métodos de defuzzyficação como o

centro de gravidade (o que foi utilizado para o estudo de caso) e a média dos valores máximos.

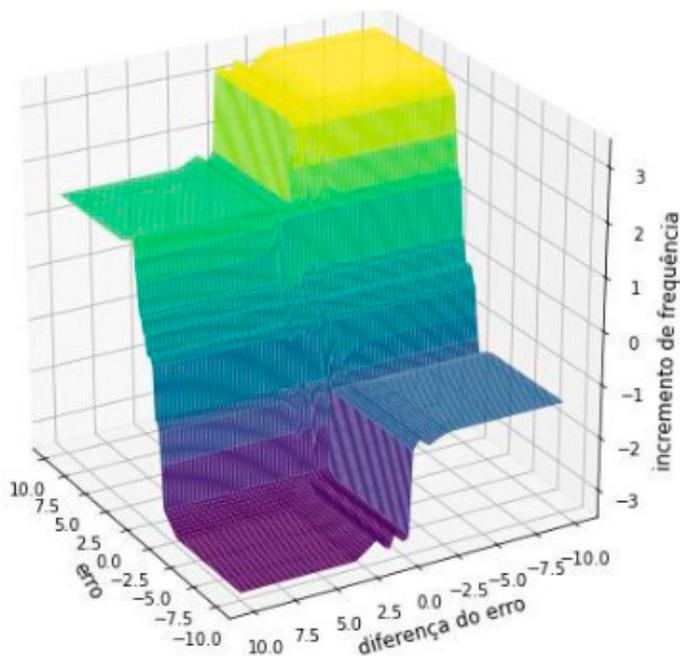


Figura 5.19: Superfície que relaciona variáveis fuzzy de entrada e de saída.  
Fonte: (Araújo, 2021).

Para resumir toda a metodologia empregada, está ilustrado na Figura 5.20 um diagrama de blocos mostrando toda a cadeia de controle, desde as medições dos sensores hidrostáticos em campo até o envio do sinal de atuação gerado pela lógica *fuzzy* para os atuadores. O controlador nebuloso está implementado em um computador. No entanto, a situação ideal é que esta lógica esteja embarcada em um *hardware* mais barato com este propósito, junto a unidade de bombeamento de água e com acesso à mesma rede de Internet, a fim de diminuir a necessidade de três redes de internet diferentes.

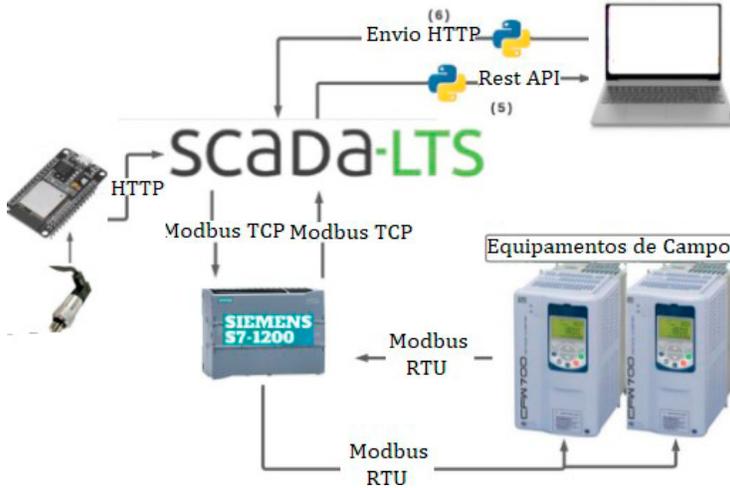


Figura 5.20: Diagrama representando a metodologia empregada.

Fonte: Adaptado de Araújo (2021).

Também seria possível direcionar os dados de medições enviados pela ESP 8226 para o CLP, de modo a permitir o desenvolvimento de uma lógica de controle interna ao CLP. Pode-se também escolher outra placa de desenvolvimento que seja capaz de fazer comunicação Lora, um dos meios físicos de comunicação à distância gratuitos, para evitar a necessidade de usar a Internet.

## 5.2.2 FUNCIONAMENTO DA SOLUÇÃO IOT SOBRE A REDE ESTRELA

### 5.2.2.1 FUNCIONAMENTO DO MODELO RNA

Por meio da modelagem via RNA com os dados coletados, foi possível ajustar e avaliar os parâmetros do controlador nebuloso no controle da pressão da unidade consumidora nº2, de maneira a aprimorar os incrementos/decrementos da frequência de rotação do inversor de frequência para operarem apropriadamente.

Para avaliar o desempenho da lógica nebulosa, utilizou-se as mesmas restrições da planta real: frequência máxima de rotação igual a 62,5 Hz, frequência mínima de rotação igual a 43 Hz e pressão de *setpoint* de 9 mca, 1 mca a menos que o mínimo pré-estabelecido pela norma ABNT NBR 12218. A definição de tal valor foi feita por sugestão de especialistas que acreditam ser a melhor escolha para a preservação da integridade da rede.

Portanto, para todos os modelos utilizados, analisamos aqui o desempenho do controlador nebuloso sob condições de dados diferentes, com entradas e saídas diferentes, variando o número de neurônios por camada, as funções de ativação utilizadas (*selu e relu*) e o otimizador (*Adam e Nadam*).

Nesse contexto, para fazer a modelagem do sistema, 5 variáveis estavam disponíveis: a pressão na unidade consumidora nº1, a pressão na unidade consumidora nº2, a frequência de rotação dos dois motores e o nível da compensação. Todas as variáveis foram amostradas a uma taxa de uma amostra por minuto. Em cada modelagem, como será mostrado mais adiante, é possível inserir novas variáveis para melhor representar o sistema.

A seguir, serão apresentadas análises do comportamento de modelos RNA de diferentes configurações.

## **EXEMPLO 1: MODELAGEM MALSUCEDIDA**

A princípio, vamos analisar o funcionamento de um modelo hipotético cujo esquema de entradas e saídas está ilustrado na Figura 5.21. Na modelagem dessa rede neural artificial, estabeleceu-se as seguintes configurações:

- duas camadas ocultas com 30 e 20 neurônios cada;
- cinco entradas: nível da compensação, frequência de rotação do motor 1, frequência de rotação do motor 2, pressão da unidade consumidora nº2 e o horário do dia;
- duas saídas: pressão da unidade consumidora nº2 e nível da compensação;
- Função de ativação: relu;
- Otimizador: Nadam;
- Número de épocas: 5000.

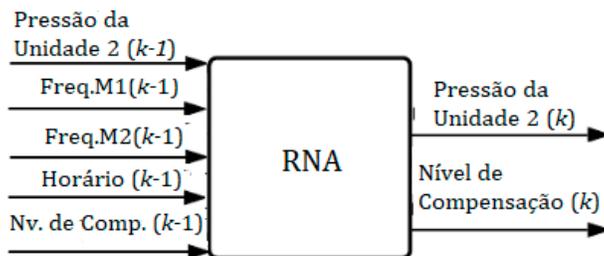


Figura 5.21: Esquema de entradas e saídas da RNA do Exemplo 1.

Fonte: Adaptado de Araújo (2021).

O horário do dia foi uma variável introduzida que foi utilizada em todos os exemplos apresentados neste capítulo, com o objetivo de ser a variável que sugira para a RNA a informação da demanda horária de água, uma vez que a dinâmica de consumo é maior em determinados horários (nos chamados horários de pico) e menores em outros horários (como de madrugada quando a maioria dos consumidores estão dormindo).

Dessa forma, considerou-se que essa informação poderia ser fundamental para a RNA entender que a frequência máxima de rotação, em horários de pico, não é suficiente para elevar ou manter a pressão na rede, enquanto em horários de baixo consumo a frequência máxima de rotação provoca um rápido aumento na pressão da rede.

Portanto, apenas para ilustrar, com uma taxa de amostragem de 1 minuto tem-se 1.440 amostras de dados por dia, totalizando 1.440 minutos (60 minutos  $\times$  24 horas). Então, dado um conjunto de dados coletados às 8h25, tem-se que seu respectivo valor de horário do dia é igual a 505 minutos (8  $\times$  60 + 25). Esse cálculo foi realizado para todas as amostras.

Com toda a configuração neural e de entradas e saídas realizadas, gerou-se o modelo da estação elevatória de água do sistema estrela, o qual entregou como resultado um erro quadrático médio de 0,0473 e um erro percentual médio de 2,7951%, considerado valores positivos uma vez que não foi realizado um trabalho de limpeza de dados faltantes e *outliers*.

Desse modo, após a modelagem da rede e a implementação da lógica fuzzy foi realizada a primeira simulação dos efeitos do controlador nebuloso sob a estação elevatória modelada. Inicialmente, observando para o gráfico da Figura 5.22(a), pode-se concluir que o controle nebuloso obteve sucesso em comparação com o controle vigente, uma vez que ele foi capaz de manter a pressão na rede seguindo a referência de 9 mca. No entanto, observando a Figura 5.22(b), fica evidente a incongruência da simulação: o modelo não percebe, apenas com os dados fornecidos, que em determinados horários a demanda na rede é maior exigindo maior injeção de água. Segundo o modelo RNA, seria possível para a rede manter-se equalizada em qualquer faixa de horário, o que é uma impossibilidade, dado que após as 6 horas da manhã a demanda começa a crescer de modo que mesmo que o conjunto motobomba opere em máxima rotação nesse horário e o modelo não seja capaz manter a pressão na rede, voltando para o valor de referência apenas após as 22h.

Essa informação sugere que acrescentar como entrada à RNA o perfil de consumo diário poderia melhorar o desempenho da rede.

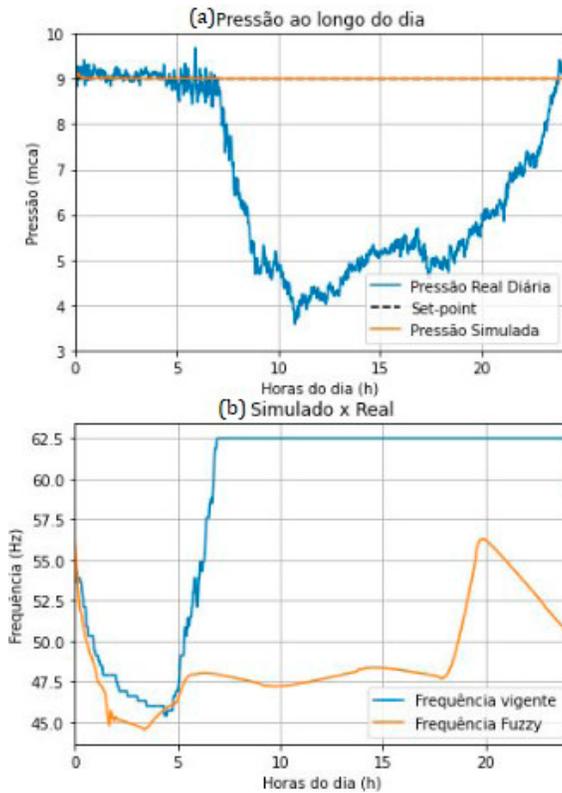


Figura 5.22: Resultado da simulação da RNA mal sucedida: a) Simulação de pressão e b) Simulação de frequência.

Fonte: Adaptado de Araújo (2021).

## EXEMPLO 2: MODELAGEM MALSUCEDIDA

Uma segunda possibilidade de modelagem tem o seu esquema ilustrado na Figura 5.23.

Considerando a inclusão de uma nova variável na

modelagem, estabeleceu-se a seguinte configuração para o modelo:

- 2 camadas ocultas com 30 e 20 neurônios cada;
- 5 entradas: frequência de rotação do motor 1, frequência de rotação do motor 2, pressão da unidade consumidora nº2, horário do dia e padrão de demanda genérico;
- 1 saída: pressão da unidade consumidora nº2;
- Função de ativação: selu;
- Otimizador: Nadam;
- Número de épocas: 5000.

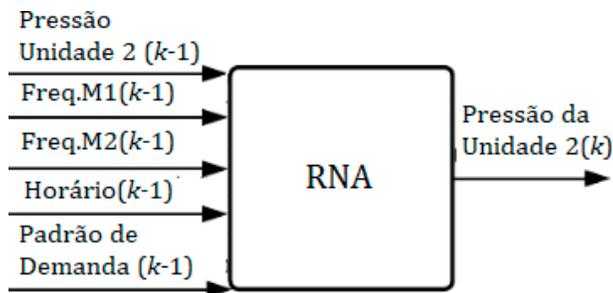


Figura 5.23: Esquema de entradas e saídas da RNA do Exemplo 2.

Fonte: Adaptado de Araújo (2021).

Neste exemplo, para inserir os dados do padrão de demanda genérico ao grupo de dados de entrada foram coletadas amostras a partir de um gráfico apresentado no trabalho de Guidi (2017) que aferiu uma série temporal de vazão em um ponto específico de demanda específico no município de Franca, em São Paulo. Na Figura 5.24, é apresentado o gráfico gerado a partir dessa referência, apresentando a curva adimensional de consumo.

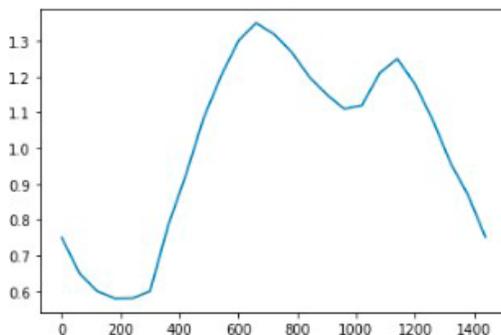


Figura 5.24: Curva adimensional de consumo genérico.

Fonte: (Araújo, 2021).

A partir desse novo dado que se repete diariamente, modelou-se o sistema. Dessa forma, a nova RNA apresentou um melhor desempenho em relação a modelagem malsucedida do Exemplo 1, fornecendo um erro médio quadrático igual de 0,0197 e um erro percentual médio de 1,3856%.

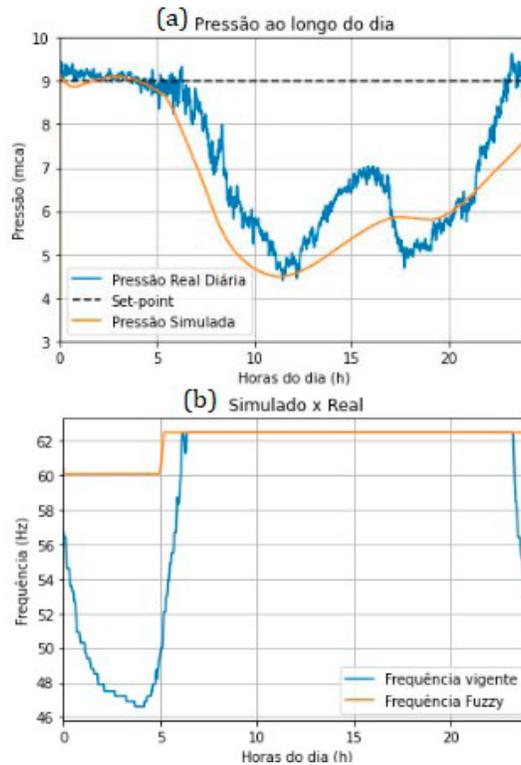


Figura 5.25: Comparação entre a simulação da segunda RNA e os dados reais: a) Pressão; b) Frequência.

Fonte: Adaptado de Araújo (2021).

Com isso, observou-se uma melhoria da pressão simulada em relação à pressão real diária apresentando algum grau de correção entre elas, mas novamente existe uma certa incongruência entre a frequência de rotação real

e a frequência de rotação simulada, sendo perceptível durante o horário de menor demanda entre a meia-noite e as 6h da manhã, onde o valor de frequência simulado provocaria um

aumento na pressão, o que não ocorre, conforme está ilustrado na Figura 5.25.

Novamente, a modelagem mostrou-se falha. Alternativamente, considerando que a demanda entre a meia-noite e as 6h possui menores variações em relação às demais faixas de horários, seguiu-se para mais uma proposta de modelagem, agora limitando os dados de entrada do modelo para a faixa de horário citada de menor demanda, excluindo da modelagem como entrada o perfil de consumo diário genérico, prezando a qualidade da modelagem nessa faixa de horário.

### **EXEMPLO 3: MODELAGEM BEM SUCEDIDA**

Uma modelagem bem sucedida é aquela baseada na relação de entradas e saídas da RNA mostrada anteriormente, no esquema da Figura 5.13.

Para este processo de treinamento da RNA, após vários testes com diferentes parâmetros, foram utilizadas as seguintes configurações:

- duas camadas ocultas com 30 e 20 neurônios cada;
- quatro entradas: frequência de rotação do motor 1, frequência de rotação do motor 2, pressão da unidade consumidora nº2 e o horário do dia;
- uma saída: pressão da unidade consumidora nº2;
- Função de ativação: relu;
- Otimizador: Nadam;
- Número de épocas: 5000.

A validação desse tipo de modelo (RNA) pode ser realizada utilizando os dados separados previamente em duas categorias: os dados de treinamento utilizados para criar o modelo e os dados de validação para avaliar o desempenho do modelo.

Na Tabela 5.3, está mostrado o desempenho obtido pelo modelo do Exemplo 3 considerando como parâmetros o erro quadrático médio (MSE - *Mean Squared Error*) e o erro percentual médio (*Mean Absolute Percentage Error*).

Tabela 5.3: Performance do modelo no Exemplo 3.

Performance	Erro Quadrático Médio (MSE)	Erro Percentual Médio (MAPE)
Treinamento	0.0150	0.8393
Validação	0.0203	0.9485

Fonte: Adaptado de Araújo *et al.* (2022)

Na Figura 5.26, está ilustrado o gráfico comparando os valores de saída reais da pressão na unidade consumidora 1 e os valores de saída previstos pela RNA.

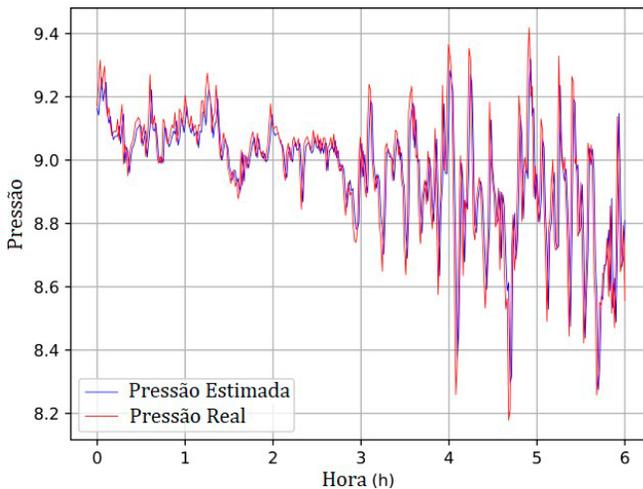


Figura 5.26: Comparação entre a pressão estimada pela RNA do Exemplo 3 e a pressão real na unidade consumidora 1.

Fonte: Adaptado de Araújo et al. (2022)

Para avaliar o desempenho da simulação, foi realizada uma comparação entre o comportamento real da rede, utilizando o controle vigente e o comportamento da rede controlada pelo controlador *fuzzy* durante a simulação. Dessa maneira, para inicializar as simulações foram utilizadas como entradas os valores reais no minuto zero coletados do sistema SCADA, de modo que os demais minutos até as 06h00 são dados pela RNA e a lógica nebulosa.

Na Figura 5.27, pode ser observado o comportamento diário da pressão na unidade consumidora nº2, prevista pela RNA utilizando como entrada a frequência de rotação do inversor de frequência dada pelo controlador *fuzzy*. O controle funciona satisfatoriamente, acompanhando bem a referência e com

pequeno sobrevalor de aproximadamente 1%. Os valores do eixo horizontal indicam o minuto atual que está sendo marcado.

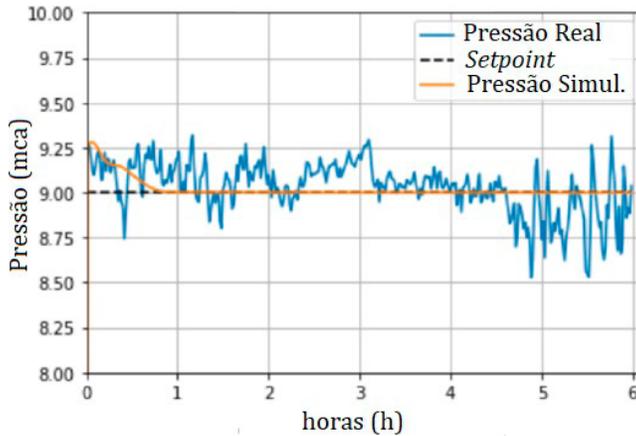


Figura 5.27: Pressão controlada prevista pela RNA.

Fonte: Adaptado de Araújo et al. (2022).

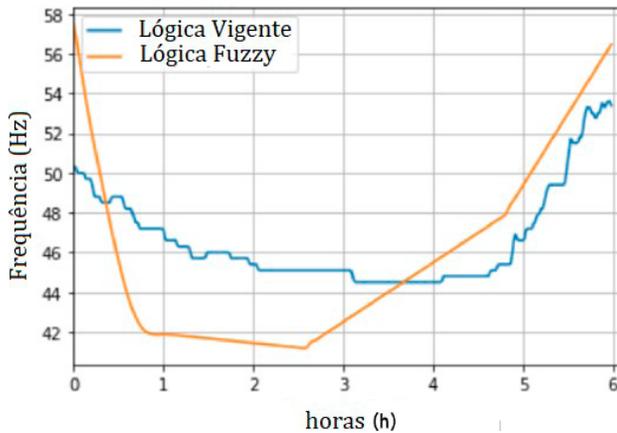


Figura 5.28: Comparação entre as frequências de rotação pela lógica vigente e pela lógica fuzzy.

Fonte: Adaptado de Araújo et al. (2022)

Para analisar o desempenho da simulação, uma comparação entre o comportamento convencional da rede e o da rede controlado por lógica *fuzzy*. Assim, para a inicialização, a simulação usou como entrada os valores atuais no minuto zero coletados pelo sistema ScadaLTS, de modo que os outros minutos até as 6h00 da manhã foram estimados pela RNA e a lógica *fuzzy*. Na Figura 5.28, é mostrada uma comparação entre as pressões atual e simulada da rede está apresentada. O controle *fuzzy* proporciona mais estabilidade que o controle vigente, mostrando poucas mudanças e variações na pressão.

### 5.2.2.2 RESULTADOS DA OPERAÇÃO NA REDE ESTRELA

Nesse ponto, o leitor deve estar se perguntando o que acontece quando o sistema de controle mostrado neste capítulo é introduzido em um sistema hidráulico real de distribuição de água. Responderemos a essa pergunta mostrando os procedimentos de testes e os resultados obtidos sobre o sistema de abastecimento de água da cidade de João Pessoa.

Na fase de testes, ambas as lógicas de controle foram monitoradas e registradas por um determinado período de tempo, mas apenas a lógica convencional vigente enviava os valores de referência de velocidade para os inversores de frequência, com a lógica nebulosa apenas sombreando. O objetivo principal desse teste é verificar a coerência entre ambas as lógicas, com o objetivo de aplicar a lógica nebulosa. Havendo resultados positivos pode-se aplicar a lógica nebulosa com mais segurança sobre a rede de distribuição.

A fase final dos testes é quando se aplica a lógica nebulosa aos inversores, observando o comportamento da rede e da velocidade de rotação dos conjuntos motobomba quando submetidos à lógica nebulosa. Em seguida, realiza-se uma comparação entre as duas lógicas de controle considerando como parâmetros de desempenho a estabilidade na pressão na rede, a diferença energética entre os controles e a variação de frequência dos conjuntos motobomba.

#### **– Teste de Sombreamento:**

Após enviar os valores processados pelo controlador nebuloso desenvolvido em Python para o sistema supervisor, foi possível fazer uma comparação entre os sinais de atuação do controle vigente escrito em uma variável meta do ScadaLTS e do controlador nebuloso. Conforme pode ser visto na Figura 5.29, considerando uma inspeção visual dos sinais de atuação observa-se que o controlador nebuloso acompanha o controlador vigente, mas atuando teoricamente, de maneira mais econômica uma vez que a velocidade de referência enviada é inferior ao controle vigente. Cabe ressaltar mais uma vez que o sistema com um único motor em operação não consegue fornecer água suficiente em todos os momentos do dia, devido ao consumo dos horários de pico ser superior a capacidade de fornecimento do conjunto motobomba. No gráfico da Figura 5.29 a zona não controlável começa quando a velocidade de referência satura.

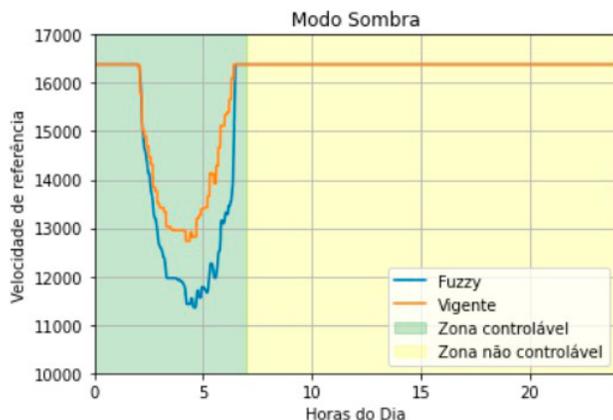


Figura 5.29: Teste de sombreamento para o controle fuzzy.

Fonte: Araújo (2021).

O sinal de atuação enviado pelo controlador vigente, escrito em uma variável meta do ScadaLTS, resultou na pressão da rede apresentada na Figura 5.30. Para esta forma de controle, pode-se observar alguns parâmetros de desempenho: um sobrevalor de cerca de 6,33%, considerando que o valor de referência desejado é de 9mca; durante a faixa de pressão controlável (entre as 02h00 e as 06h00 da manhã), observa-se um pequeno erro em regime permanente ao passo em que se observa também uma pequena oscilação em torno do valor de *setpoint*.

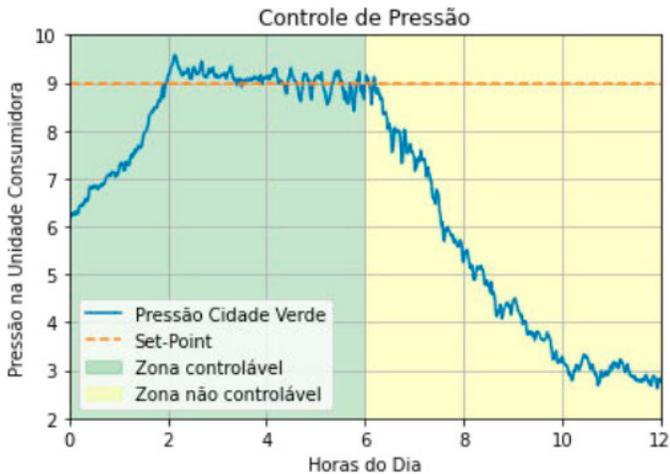


Figura 5.30: Pressão na rede produzida pelo controle vigente.

Fonte: (Araújo, 2021).

Em horários após as 6 horas da manhã, a demanda dos consumidores é superior à capacidade do motor de suprir essa demanda o que justifica a queda da pressão na rede. Portanto, na implantação do sistema com controle nebuloso em redes com comportamento semelhante àquela usada como exemplo aqui, os estudos deverão ser direcionados para os horários possíveis de controlar a pressão na rede.

### – Testes na Rede Real:

Superado o teste de sombreamento, a fase seguinte é a de testes do controle nebuloso sobre a rede hidráulica. Para analisar o desempenho da solução baseada em fuzzy, este controlador foi aplicado sobre a rede para comandar as ações de controle dos inversores de frequência por 2 dias e observar quais foram os benefícios baseados para os consumidores e para a empresa de distribuição de água.

Na Figura 5.31 pode-se observar a relação entre os sinais de atuação do controlador nebuloso e o controlador vigente, mas agora, com o controlador nebuloso comandando as ações de controle. Assim como aconteceu no teste de sombreamento, o controlador nebuloso apresentou a tendência de ser mais econômico que o controlador desenvolvido com uma variável meta do ScadaLTS, enviando uma velocidade de referência inferior.

O sinal de atuação do controlador nebuloso resultou no comportamento da rede que pode ser observada na Figura 5.32. É possível notar que o controlador nebuloso novamente atuou de maneira mais estável, com erro em regime permanente menor do que o controle vigente. No entanto, o sobrevalor resultante do controlador foi de aproximadamente 6,78%, um aumento pequeno em relação ao controlador vigente.

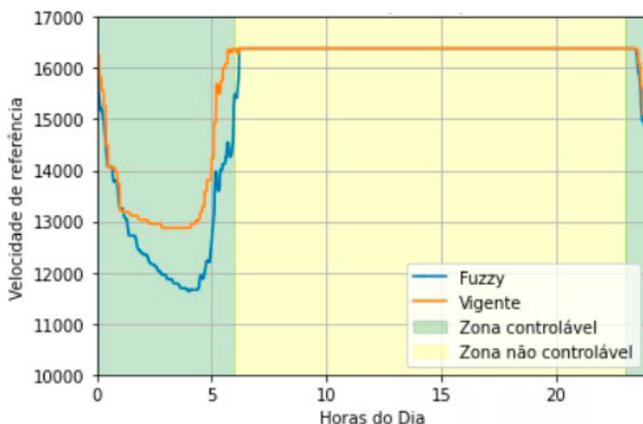


Figura 5.31: Controle fuzzy em operação.

Fonte: (Araújo, 2021).

Pensando na questão econômica, foram obtidas também as potências de atuação dos motores quando controlados pelo controlador nebuloso e estimado da potência de atuação dos motores (através do sinal de atuação) se estivessem sobre a lógica de controle vigente, para analisar a diferença energética diária entre ambas formas de controle.

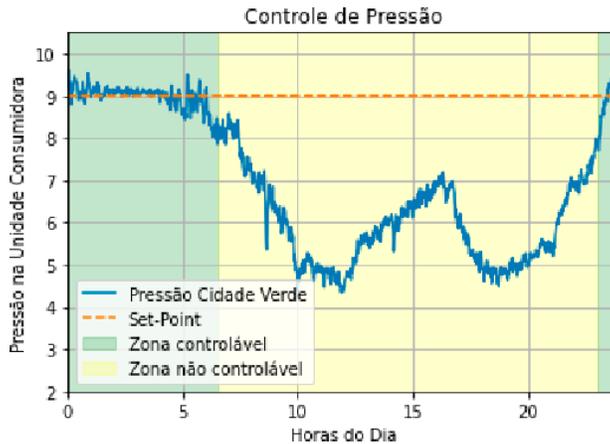


Figura 5.32: Controle de pressão via fuzzy.

Fonte: (Araújo, 2021).

Para o sinal de controle que parte do controlador vigente tem uma energia gasta estimada de 954,40 kWh em um dia, enquanto uma energia calculada do controle fuzzy de aproximadamente 926,79 kWh em um dia, representando uma economia de um pouco mais de 27,6 kWh diário.

Esse conjunto de desempenhos torna o dia 1 de aplicação da lógica de controle nebulosa muito satisfatório, propiciando benefícios a nível de controle e a nível financeiro para a concessionária.

Na Figura 5.33, tem-se a comparação entre os sinais de atuação de controle durante o segundo dia de operação do controlador nebuloso. Desta vez, houve um comportamento não desejado que provocou um grau de instabilidade no controle de pressão da rede. É possível observar entre as 04h00 e as 05h00 da manhã variações bruscas nos sinais de atuação, tanto do controle vigente quanto do controle *fuzzy*.



Figura 5.33: Controle fuzzy em ação no segundo dia de testes.

Fonte: (Araújo, 2021).

A certeza sobre origem desta variação brusca é desconhecida, no entanto, supõe-se que foi devido a seguinte fator: em alguns poucos momentos a interação entre o Python e a API com o ScadaLTS falha, resultando atrasos nos tempos de requisição entre supervisor e controlador nebuloso. Este atraso pode ter feito o controlador nebuloso perceber uma variação de pressão muito alta, gerando sinais de atuações bruscos, refletindo na pressão aplicada a rede. No entanto, esse defeito pode ser

sanado aprimorando os parâmetros dos conjuntos e regras fuzzy dando mais robustez para esse tipo de situação.

Nos testes de campo, essa variação brusca provocou seus impactos na rede, prejudicando momentaneamente a estabilidade do controle de pressão, conforme pode ser visto na Figura 5.34.

O sobrevalor registrado após as 20h00 foi de 7,5%. A instabilidade registrada para o controle de pressão entre as 04:00 e as 05:00h pode ser facilmente correlacionada com as variações bruscas do sinal de atuação do controlador nebuloso, considerando que as variações bruscas de atuação foram refletidas de uma maneira praticamente instantânea da pressão na rede.

Desse modo, percebe-se que, apesar das vantagens oferecidas, ainda há um gargalo importante que pode ser aprimorado em relação aos parâmetros do controlador nebuloso. A diminuição da taxa de amostragem de um minuto e um ajuste fino dos parâmetros fuzzy podem vir a melhorar a qualidade do controle.

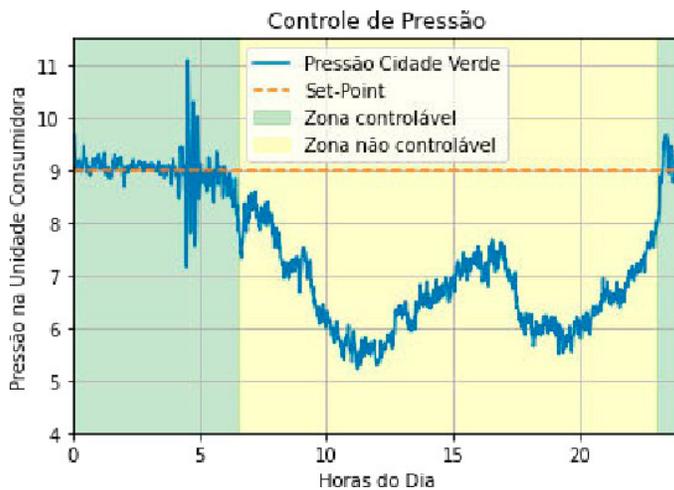


Figura 5.34: Controle de pressão via fuzzy no 2º dia de testes.

Fonte: (Araújo, 2021).

## REFERÊNCIAS

ABNT – Associação Brasileira de Normas Técnicas. **NBR 12218. Projeto de rede de distribuição de água para abastecimento público.** 1994.

ARAÚJO, J.V.S.; VILLANUEVA, J.M.M; CORDULA, M.M.; CARDOSO, A.A.; GOMES, H.P. **Fuzzy Control of Pressure in a Water Supply Network Based on Neural Network System Modeling and IoT Measurements.** *Sensors*, 22, 9130, 2022.

ARAÚJO, J.V.S. **Monitoramento e Controle de Pressão de Redes de Abastecimento de Água Utilizando IoT e Controle Fuzzy.** Trabalho de Conclusão de Curso (TCC), Departamento de Engenharia Elétrica, Universidade Federal da Paraíba (UFPB), 2021.

FLORES, T.K.S. **Sistema Fuzzy para Controle de Pressão Aplicado a Sistemas de Bombeamento Série-Paralelo visando a Eficiência Energética.** Trabalho de Conclusão de Curso (TCC), Departamento de Engenharia Elétrica, Universidade Federal da Paraíba (UFPB), 2018.

GUIDI, J.M.M. **Análise da Variação do Consumo de Água Utilizando Dados Obtidos por Sistemas Supervisionados Remotos - Estudo e Caso: Município Franca-SP.** FENASAN, 2017.

MOURA, G. A.; BEZERRA, S. T. M.; GOMES, H. P.; SILVA, S. A. **Sistema de Controle Fuzzy Neural para Operação Ótima de Redes de Distribuição de Água.** XV Seminário Iberoamericano de Redes de Agua y Drenaje, SEREA2017, 2017.

MOURA, G. A.; GOMES, H. P.; SILVA, S. A.; BEZERRA, S. T. M.; OLIVEIRA, J. K. C. **Rede Neural Adaptativa Aplicada ao Controle de Pressão em Sistemas de Distribuição de Água.** FENASAN, 2017.

# Capítulo 6: Desenvolvimento de um Sensor Virtual para a Estimação de Fluxo em Sistemas de Abastecimento de Água

*Robson Pacífico Guimarães Lima,  
Juan Moises Mauricio Villanueva,  
Heber Pimentel Gomes  
e Thommas Kevin Sales Flores.*

## 6.1 MEDIÇÃO INDIRETA DE GRANDEZAS FÍSICAS

Diversas tecnologias podem ser utilizadas para mensurar as principais grandezas físicas em sistemas de abastecimento de água. A vazão, grandeza que será explorada neste capítulo, pode ser mensurada por meio de tecnologias que utilizam sinais eletromagnéticos e ultrassônicos, por exemplo.

Com relação às tecnologias de medição que empregam princípios eletromagnéticos, os equipamentos associados possuem maiores custos de aquisição e instalação, dependendo do diâmetro da instalação e, conseqüentemente, do volume a ser mensurado.

Outras técnicas também podem ser utilizadas para mensuração da vazão, como as equações que caracterizam a operação de uma bomba (curva de pressão-vazão). No entanto, a utilização deste método de estimativa requer

constantes calibrações no sistema, uma vez que se baseiam nas características construtivas da bomba que se desgasta durante o funcionamento, variando suas características ao longo do tempo. Assim, faz-se necessária a utilização de técnicas de medição que mitiguem a problemática do custo de aquisição (muitas vezes bastante elevados) de instrumentos de medição de vazão bem como da complexidade de instalação desses dispositivos e as técnicas de mensuração indireta podem ser bastante úteis nesse sentido.

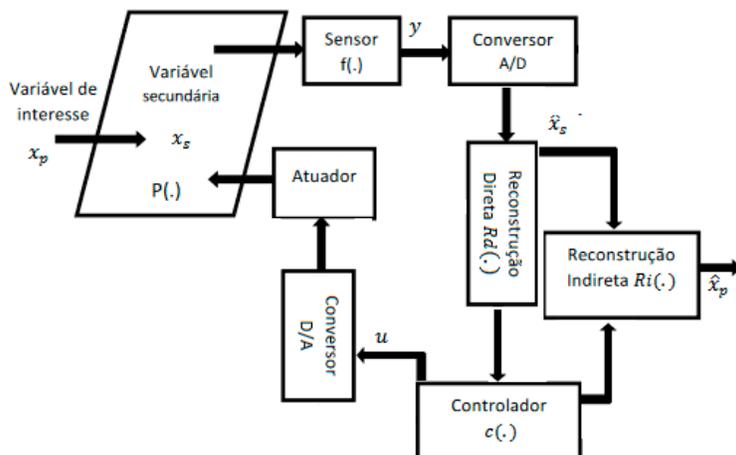


Figura 6.1: Diagrama geral de um sistema de medição retroalimentado.

Fonte: Adaptado de Lima (2022).

De maneira geral, as medições indiretas estimam a variável (ou quantidade ou grandeza) principal de um sinal elétrico obtido por meio da medição direta de uma variável secundária que está relacionada com a variável principal.

Na Figura 6.1, ilustra-se um diagrama de um sistema de medição com realimentação no qual o meio de medição  $P(\cdot)$  está relacionado dinamicamente com a variável principal  $x_p$ , com a variável secundária  $x_s$  e com o sinal de controle  $u$ .

Utilizando sensores para a aquisição de variáveis de entrada, a variável secundária  $x_s$  é adquirida e convertida em um sinal elétrico  $y$  utilizado a função do sensor  $f(\cdot)$ . Então, este sinal é convertido em um sinal digital através de um conversor A/D fornecendo um sinal  $\tilde{y}$ , que é utilizado para estimar a quantidade secundária  $\hat{x}_s$ , usando a função de reconstrução  $R_d(\cdot)$ . Essa última relação corresponde à função Inversa do sensor implementado

em um sistema discreto. O sinal  $\hat{x}_p$  corresponde à reconstrução do sinal advindo da entrada mas de maneira indireta a partir do controlador  $c(\cdot)$  e da reconstrução direta  $R_D(\cdot)$ . A Equação (6.1) descreve o fator de conversão para obtenção do sinal  $x_s$ .

$$x_s = R_D(y) = f^{-1}(y) \quad (6.1)$$

O controlador é o elemento responsável por controlar a variável secundária  $x_s$  em um determinado valor de referência (*setpoint*). Para isso, o controlador utiliza os valores medidos da variável secundária juntamente com o valor de setpoint gerando um sinal discreto ( $u$ ). Este sinal é convertido em um sinal analógico (por meio de um conversor D/A) e em seguida, por meio de um atuador, a resposta é aplicada à planta  $P(\cdot)$ . Dessa forma, após esses procedimentos, a variável principal é estimada no bloco de reconstrução indireta  $R_i(\cdot)$ , utilizando os valores do sinal de controle. A Equação 6.2 representa essa estimação.

$$x_p = R_i(x_s, u) \quad (6.2)$$

O sinal de atuação modifica a dinâmica da planta  $P(\cdot)$  de maneira que a resposta do sinal secundário  $x_s$  acompanha o valor de *setpoint* e, portanto, irá modificar a dinâmica na estimativa da variável principal  $x_p$ . A velocidade de convergência dessa estimativa dependerá de como o controlador foi projetado.

A Tabela 6.1 contém alguns exemplos para valores cotados em moeda nacional corrente (no ano de 2022) de alguns dos instrumentos de vazão utilizados por diversas companhias estaduais de abastecimento de água.

Tabela 6.1: Cotação de equipamentos usados em SAA no ano de 2022.

Modelo/Marca	Valor unitário (R\$)	Empresa contratante e aplicabilidade do(s) instrumento(s)	Número do contrato (ou preção)
Medidor de vazão magnético MAG 600 (DWYLER)	14.310,74	<b>Sabesp - SP</b> Utilização na ETA do município de Pardinho - SP, Médio Tietê.	01104/21 - 00 de 21/05/2021
Medidor de vazão eletromagnético 1,0 Mpa, DN 600 (ISOMAG)	24.600,00	<b>Sanepar - PR</b> Utilização em ponto fixo, em tubulações pressurizadas de um SAA em Curitiba - PR.	40595 de 29/06/2020
Medidor de vazão eletromagnético DN200 (WOLTMAN)	10.640,34	<b>Saaep - PA</b> Conexão entre duas ETAs na cidade de Parauapebas - PA	012018-CP/SAEEP de 20/11/2018

Fonte: Lima (2022).

A utilização da técnica de estimação indireta da vazão pode auxiliar na redução dos custos de aquisição e de instalação dos instrumentos físicos de vazão. Neste capítulo, os passos do desenvolvimento de soft sensors (ou sensores virtuais) de vazão com uma resposta dinâmica rápida ao sistema de abastecimento de água. O funcionamento do sensor virtual usado como exemplo também será explorado, com base em dados experimentais.

## 6.2 SENSORES VIRTUAIS

Nas últimas décadas, os soft sensors se estabeleceram como uma alternativa valiosa aos tradicionais meios para a aquisição de variáveis críticas de processo, monitoramento de sistemas e outras tarefas que são relacionados ao controle de processos industriais. Estes sensores virtuais geralmente são especialmente úteis diante da indisponibilidade de sensores de hardware (reais) em diversos segmentos industriais, permitindo assim menor ocorrência de falhas e melhor desempenho de controle. A instrumentação virtual surge como uma alternativa viável para monitoramento em tempo real de parâmetros que necessitam de um princípio de medição confiável.

O propósito de um sensor virtual consiste na estimação de uma variável que não é medida diretamente mas que esta variável esteja relacionada por um modelo

adequado a várias outras variáveis de processo que são mensuradas de maneira direta.

Assim, para o contexto de aplicabilidade em SAA, descreveremos aqui o desenvolvimento do sensor virtual baseado em redes neurais artificiais. Essa opção se deve às propriedades das RNAs, tais como:

- Dispensa de modelos matemáticos: as RNAs dispensam complexos que, por muitas vezes, acabam limitando a abrangência real da planta por ter de considerar diversas restrições/limitações. Essas restrições são comumente utilizadas por outras técnicas de estimação;
- Capacidade de generalização: mesmo com dados incompletos ou imprecisos, as redes neurais artificiais

podem preencher as lacunas sem sofrer degradação considerável da informação. Em outras palavras, em razão do grande número de conexões, a rede possui a capacidade de continuar funcionando mesmo se parte de sua estrutura interna for corrompida, tal como acontece no cérebro biológico;

- Classificação de padrões: essas redes agrupam e organizam dados criando grupamentos com características semelhantes;
- Aprendizagem com exemplos: a rede aprende a partir do relacionamento com o ambiente por meio de um algoritmo de treinamento capaz de absorver a interação entre as variáveis do modelo.

A rede NARX, que é a base para o *soft sensor* descrito neste capítulo, é uma categoria especial de RNA dinâmica recorrente (realimentada) que descreve o processo com base em variáveis de entrada/saída atrasadas. O conceito de rede do tipo recorrente ocorre quando os neurônios da camada de saída realimentam a rede como sinais de entrada.

Este tipo de característica torna a rede apta para ser utilizada em tratamento dinâmico de informações, ou seja, em processos que variam com o tempo, como por exemplo, a otimização e identificação de sistemas, controle de processos e previsão de séries temporais.

## 6.3 DESENVOLVIMENTO DO SENSOR VIRTUAL

Nesta seção, serão apresentados os materiais e a metodologia empregadas para o desenvolvimento e teste do sensor virtual de vazão. Para auxiliar no desenvolvimento, utilizou-se uma bancada experimental totalmente instrumentalizada e automatizada, a qual possui um sistema de monitoramento por meio de um supervisório desenvolvido na plataforma LabVIEW, onde é processada as ações de controle e estimação em tempo real da vazão.

### 6.3.1 BANCADA EXPERIMENTAL

A bancada experimental utilizada no desenvolvimento do sensor virtual emula um sistema de abastecimento de água. Na Figura 6.3, estão indicados os principais elementos que constituem a planta experimental. O sistema de bombeamento é composto por um conjunto motor-bomba (CMB) que é formado por uma bomba centrífuga acoplada a um motor elétrico. Essa estrutura é responsável por impulsionar a água de um reservatório para o sistema de distribuição. O sistema de impulsão é acionado por um inversor de frequência, localizado em uma sala de controle ao lado da bancada, não visualizada na Figura 6.3. Com a utilização do inversor de frequência, é possível alterar a velocidade de rotação do conjunto CMB.



Figura 6.3: Elementos da bancada experimental utilizada.

Fonte: (Flores, 2021).

As pressões no sistema são coletadas pelos transdutores de pressão PT-1, PT-2 e PT-3 (esta última utilizada neste trabalho e que faz parte de uma das entradas do estimador virtual de vazão). A vazão no sistema é mensurada pelo medidor de vazão FT-1. A válvula CV-1 (ou VRP CV-1), um dos elementos principais da bancada, atua como um elemento redutor de pressão na rede e corresponde a uma das entradas do estimador virtual de vazão. Para simular a demanda do sistema, foram utilizadas duas válvulas proporcionais auxiliares: a válvula CV-2 (ou VRP CV-2) e a válvula CV-3 (ou VRP CV-3). Essas válvulas auxiliares não correspondem a nenhuma das entradas do estimador virtual de vazão. Por fim, a água ficou armazenada em um reservatório com 310 litros.

Os elementos que constituem a bancada experimental são os seguintes:

(1) O CMB é composto por uma bomba centrífuga acoplada a um motor de indução trifásico. A função desse conjunto é transportar água do reservatório até o terminal de consumo. O acionamento desse conjunto é realizado por um inversor de frequência cuja finalidade é o ajuste da velocidade de rotação do CMB. A Figura 6.4 ilustra a estrutura correspondente ao CMB.

(2) O inversor de frequência utilizado foi responsável por regular a velocidade de rotação do motor elétrico do CMB mantendo seu torque constante. O inversor de frequência utilizado dispõe de uma interface humano-máquina (IHM), onde são configuradas todas as características necessárias ao seu funcionamento: tempo de aceleração e desaceleração, entradas e saídas digitais, entradas e saídas analógicas etc. Ademais, em relação à entrada analógica, ela foi utilizada para permitir o controle remoto da velocidade de rotação por meio de uma tensão de referência com valores de 0 a 10 V, cuja equivalência à velocidade de rotação mínima foi de 0 Hz e a máxima de 60 Hz.



Figura 6.4: Conjunto motor-bomba utilizado. Fonte: (Flores, 2021).

(3) O transdutor de pressão utilizado é do tipo piezoresistivo, isto é, um dispositivo eletromecânico que converte a deformação sofrida em uma variação de sua resistência elétrica. Ao aplicar uma diferença de potencial nos terminais deste sensor, é possível mensurar a altura manométrica ou pressão correspondente à variação da resistência. O instrumento possui como função principal converter a grandeza física pressão em um sinal elétrico analógico. Na bancada experimental existiam três transdutores de pressão instalados: PT-1, a montante do CMB; PT-2 a jusante do CMB e PT-3, nas proximidades do ramal de descarga. Esse instrumento está ilustrado na Figura 6.5.



Figura 6.5: Transdutor de pressão utilizado. Fonte: (Flores, 2021).

(4) O transdutor de vazão eletromagnético foi instalado com o objetivo de informar sobre o comportamento da demanda hidráulica do sistema em detrimento da vazão. Para efeito demonstração da técnica de medição indireta apresentada neste capítulo, foram comparados os resultados reais de medição física utilizando este transdutor de vazão com os resultados obtidos a partir do *soft sensor*.

O princípio de operação do transdutor de vazão está baseado na lei da indução eletromagnética de Faraday, a qual estabelece que quando um condutor se move em um campo magnético, na direção perpendicular, uma força eletromotriz é induzida perpendicularmente à direção do movimento do condutor e à direção do campo magnético. O valor da força

eletromotriz é proporcional à velocidade do condutor e à densidade do fluxo magnético. O instrumento supracitado pode ser visualizado pela Figura 6.6.



Figura 6.6: Transdutor de vazão utilizado. Fonte: (Flores, 2021).

(5) As válvulas de controle (CVs) ou válvulas redutoras de pressão (VRPs) presentes na planta têm a função de controlar o fluxo, variando a demanda de vazão do sistema. Por meio delas simulou-se a abertura e fechamento de determinados pontos do sistema para obter, conseqüentemente, uma maior ou menor demanda de água. O controle de cada válvula é feito por meio de um sinal de tensão de 2 a 10 Vcc, sendo 2 Vcc para a válvula totalmente fechada e 10 Vcc para a válvula totalmente aberta. Para valores intermediários a válvula assume posições intermediárias. Juntamente com a alimentação

e os sinais de comando é transmitido um sinal indicador do estado atual de abertura da válvula (também na forma de tensão de 2 a 10 Vcc), visto que a válvula se movimenta de forma lenta (o ciclo completo de fechamento a abertura completa-se em 90 segundos).

Para os experimentos em questão, foi utilizada como válvula principal a CV-1 (uma das entradas do soft sensor), localizada a jusante do conjunto motor-bomba funcionando como uma válvula redutora de pressão. O dispositivo atuava sobre o sistema aumentando a perda de carga com o decorrer da diminuição da área por onde o fluido passava por meio do grau de fechamento do dispositivo. As demais válvulas (CV-2 e CV-3) foram utilizadas de maneira auxiliar no trabalho. Elas emularam a variação da vazão demandada por meio da mudança do grau de seu fechamento. Na Figura 6.7, está ilustrada uma dessas válvulas.



Figura 6.7: Válvula de Controle.  
Fonte: (Camboim et al., 2014).

(6) O Sistema de Aquisição de Dados (DAQ) é o responsável pela comunicação entre os componentes eletrônicos da bancada experimental e o computador onde estão instalados o controlador e o sistema supervisorio. Neste experimento, o DAQ recebe sinais da CV-1 e do inversor de frequência e realiza a comunicação bidirecional com o sistema de supervisão instalado no computador. Além disso, o DAQ também recebe sinais do estimador de vazão.

Na bancada experimental existem duas interfaces de aquisição de dados instaladas: a interface NI USB 6229 que é responsável por enviar os sinais de excitação para os inversores e para as válvulas CV-1 e CV-2, além de receber os sinais dos transdutores de pressão e de vazão e a interface NI USB 6221 que envia os sinais de excitação e recebe os sinais de resposta da válvula CV-3.

O Supervisorio utilizado foi desenvolvido na plataforma LabVIEW (versão 2017, 17.0) e ele possuiu a função de monitoramento das informações da planta. O LabVIEW (*Laboratory Virtual Instrument Engineering Workbench*) é uma linguagem de programação gráfica originária da National Instruments. Os programas em LabVIEW são denominados de instrumentos virtuais ou, simplesmente, VIs. O desenvolvimento do programa no LabVIEW é baseado em uma linguagem de programação gráfica. O programa não é processado por um interpretador, mas sim compilado. Deste modo, o seu desempenho é

comparável à exibida pelas linguagens de programação de alto nível. A linguagem gráfica do LabVIEW é denominada de “Linguagem G”. No trabalho desenvolvido, o LabVIEW foi utilizado para compor o Sistema Supervisório que exhibe toda a interface de comunicação entre o operador do sistema e a planta bem como a inserção do estimador de vazão na plataforma. O fato de o LabVIEW ser totalmente compatível com o dispositivo de aquisição de dados (DAQ) e a facilidade para processar, armazenar e analisar os dados justificam a sua escolha.

As informações necessárias (pressão e vazão na rede, velocidade de rotação do CMB etc.) são coletadas por meio dos sensores e outros dispositivos, armazenados, manipulados e apresentados ao operador (usuário) via interface. O usuário, baseado nas operações do sistema, pode controlar a planta como um todo por intermédio do supervisor.

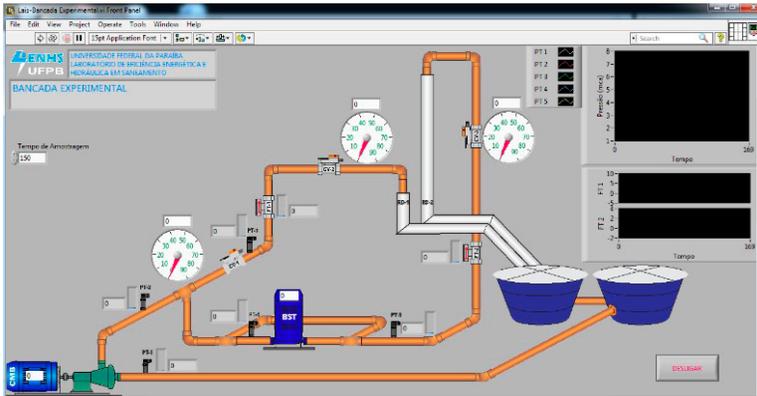


Figura 6.8: Painel frontal (sinótico) do supervisório utilizado.

Fonte: (Salvino, 2018).

A plataforma promove ao sistema as informações necessárias para o gerenciamento hidráulico e elétrico por parte do operador. O mesmo, diante dessas informações, pode, por exemplo, abrir ou fechar uma válvula ou acionar o CMB, dentre outras possibilidades. O supervisório também

foi capaz de receber os dados do estimador de vazão e exibir o resultado da comparação da medição de FT-1 com a vazão estimada pelo soft sensor.

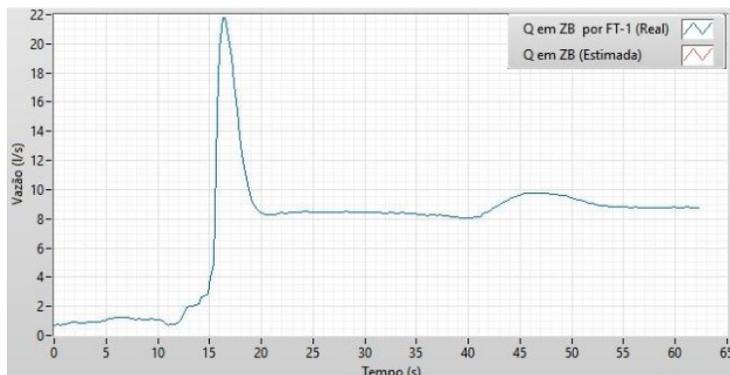


Figura 6.9: Tela em que se apresentam as curvas de estimação versus vazão real no sistema.

Fonte: Adaptado de Lima (2022).

Nas Figuras 6.8 e 6.9, ilustram-se, respectivamente, a tela sinótica (principal) do supervisor bem como da tela secundária referente a visualização da vazão real versus estimada. No experimento, foi utilizada apenas uma parte do supervisor.

As conexões e tubulações pertencentes à bancada experimental são constituídas por materiais de PVC ou policloreto de vinila (polyvinyl chloride).

## 6.3.2 METODOLOGIA DE DESENVOLVIMENTO

Na Figura 6.10, ilustra-se uma representação esquemática da topologia do processo utilizada no desenvolvimento da pesquisa. Ademais, é possível observar quais sinais específicos provenientes de alguns elementos do sistema (PT-3, CV-1 e CMB) foram utilizados pelo sensor virtual para mensurar a vazão de

maneira indireta. Também é possível observar uma representação (por setas) do sentido do fluxo de água circulando no sistema.

Na Figura 6.11 ilustra-se, de maneira generalizada, a configuração do sistema de medição com realimentação (*feedback*) para estimação indireta da vazão da bancada experimental, onde os parâmetros de entrada e saída do sistema foram classificados por meio de blocos tracejados.

Os sinais de pressão ( $P$ ) coletados em PT-3 são convertidos em um sinal digital mediante um conversor analógico-digital (A/D) pelo DAC, cujo resultado é um sinal que corresponde à entrada do controlador bem como do bloco de reconstrução indireta (*soft sensor*). A saída do controlador é um sinal de frequência ( $f$ ) atuante para a variação da rotação do CMB bem como para compor uma das entradas do soft sensor juntamente com o ângulo de CV-1 e a pressão. O sinal de frequência obtido na saída do controlador é convertido em um sinal analógico, mediante um conversor digital-analógico (D/A) que serve de entrada para atuação do inversor de frequência e, conseqüentemente, para variação da velocidade do CMB.

### **6.3.2.1 BLOCO DE RECONSTRUÇÃO DIRETA DA MEDIDA DE PRESSÃO**

O bloco de reconstrução direta relaciona a variável pressão em PT-3 com o sinal elétrico correspondente ao sensor de pressão. O sensor PT-3 é um sensor de pressão do tipo piezoelétrico, ou seja, um dispositivo eletromecânico que converte a deformação sofrida em uma variação de sua resistência elétrica. Assim, a

pressão medida (variando de 0 a 40 mca com precisão de 0,2%) irá corresponder a um sinal de corrente na faixa de 4-20 mA, de maneira linear. Este sinal de corrente obtido linearmente é então convertido em tensão, utilizando um sistema de condicionamento de sinal operando em uma faixa dinâmica de 2–10 V.

O sinal de tensão é registrado em um computador usando conversor A/D de 16 bits, para ser utilizado em uma etapa de reconstrução posterior. Dessa forma, a função de reconstrução direta  $R_D(V(k))$  da variável secundária implementa uma função linear inversa do sensor, transformando a tensão em pressão. A expressão correspondente a essa conversão é dada por

$$P(k) = R_D(V(k)) = 5,27V(k) - 10,54. \quad (6.3)$$

em que  $P(k)$  é a medição de pressão (em mca) no instante  $k$  e  $V(k)$  é a tensão medida no transdutor, que varia linearmente entre 2 a 10 V. A corrente equivalente à faixa linear de tensão é de 4 a 20 mA.

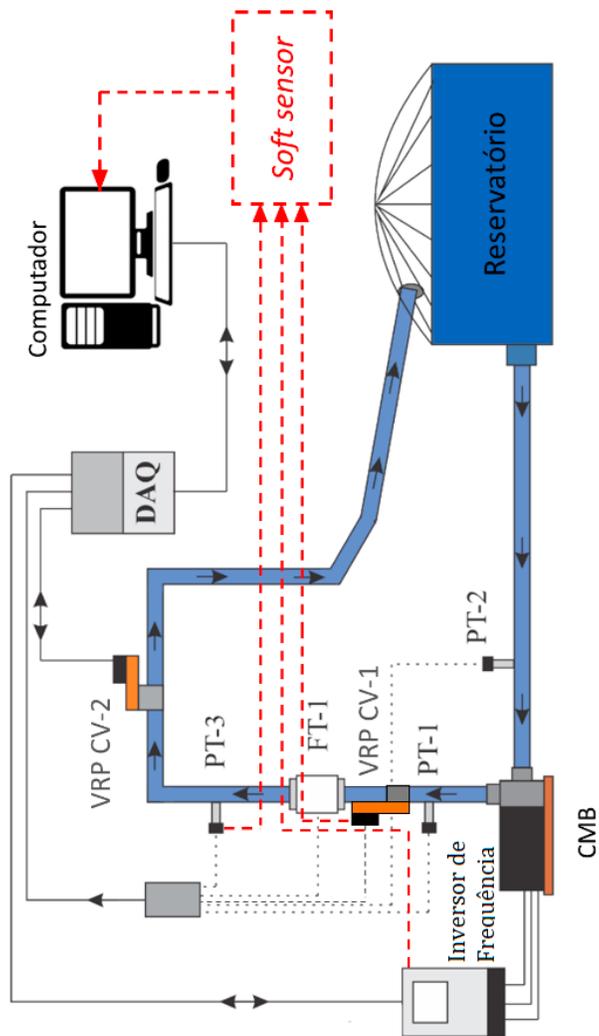


Figura 6.1: Topologia da bancada e do bloco estimador de vazão.  
 Fonte: Adaptado de Lima (2022).

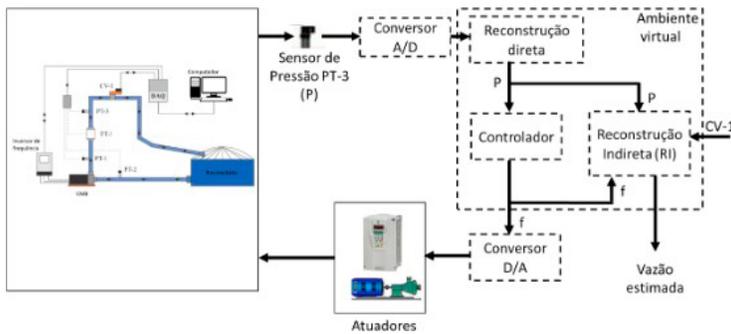


Figura 6.1: Sistema retroalimentado para medição indireta da vazão.  
Fonte: Adaptado de Lima (2022).

Para o controle da pressão no sistema, foi utilizado um controlador adaptativo do tipo Controle Proporcional, Integral e Derivativo Adaptativo Indireto por Modelo de Referência (PID-IMRAC), com o MSE (mean squared error) como critério de erro de rastreamento. O controlador foi desenvolvido por Flores (2021). Os testes com pressão controlada fizeram parte de um subconjunto de testes objetivando a validação do sensor virtual.

### 6.3.2.2 BLOCO ASSOCIADO AO *SOFT SENSOR* (RECONSTRUÇÃO INDIRETA DE VAZÃO)

De acordo com o diagrama ilustrado na Figura 6.11, o bloco responsável pela reconstrução indireta (RI) da vazão (o *soft sensor* propriamente dito) foi implementado considerando como entradas a variável secundária pressão, o sinal da abertura ou fechamento da válvula CV-1 e o sinal de frequência do CMB por meio da atuação do inversor de frequência.

Para a implementação do bloco RI também poderiam ser usadas as relações entre o variáveis de entrada e saída mediante as Equações 6.4, 6.5 e 6.6, que definem a dinâmica do comportamento da rede hidráulica, desde que algumas hipóteses sejam consideradas: fluxo unidimensional, elasticidade linear das paredes do tubo, e as mesmas correlações para o estado estacionário e perda de pressão transitória.

$$\partial P / \partial t = (a^2 / A \cdot g)(\partial Q / \partial x). \quad (6.4)$$

$$\partial Q / \partial t = - A \cdot g \cdot (\partial P / \partial x) - \beta \cdot Q^2 / (2 \cdot D \cdot A). \quad (6.5)$$

$$\beta = \rho \cdot \beta_f \cdot a \cdot x / (2 \cdot D). \quad (6.6)$$

em que  $a$  é a velocidade do fluxo, que depende da densidade de massa do fluido, do modo da elasticidade das paredes do tubo, da espessura da parede do tubo, dentre outros fatores;  $g$  é a gravidade;  $A$  é a área da seção transversal do tubo;  $Q$  é o fluxo;  $x$  é a distância da bomba até o ponto de medição desejado;  $D$  é o diâmetro da bomba;  $P$  é a pressão e  $\beta$  é o fator de atrito do fluido com as paredes do tubo,  $\rho$  é a densidade do fluido e  $\beta_f$  é o fator de fricção. Assim, a estimativa da vazão pode ser obtida solucionando o sistema das Equações (6.4) a (6.6). No entanto, esta é uma modelagem não linear e multivariável de

uma solução complexa e com aproximações que limitam sua aplicação generalizada. Assim, para aplicações em SAA essas equações não foram utilizadas.

Na metodologia em questão, a reconstrução indireta da vazão é implementada com dois algoritmos computacionais (ou redes) baseados em dois tipos de RNAs: a primeira rede considerada é a que utiliza três vetores como parâmetros de entrada: frequência de rotação do CMB,  $f(k)$ ; ângulo de abertura ou fechamento da válvula CV-1,  $\alpha(k)$  e a pressão real mensurada pelo sensor PT-3,  $P(k)$ . E como parâmetro de saída, tem-se a vazão estimada  $Q(k)$ . Essa primeira RNA utilizada é a denominada

Multi-layer Perceptron Feedforward Backpropagation (MLP) e a segunda RNA utilizada é denominada de Nonlinear Autoregressive Exogenous (NARX).

A RNA NARX também utiliza os mesmos vetores de entrada e de saída que a MLP BP, no entanto, o vetor  $Q$  (vazão) da saída é realimentado (feedback) à entrada do vetor passado estimado da vazão ( $Q-1$ ). Essa retroalimentação, característica típica de uma rede neural recorrente, possui como objetivo apresentar a dinâmica ao sistema para que o aprendizado da rede seja constantemente otimizado. Nas Figuras 6.12(a) e 6.12(b) ilustram-se, respectivamente, as configurações das redes MLP e NARX atuantes no processo de estimação da vazão.

Com a implementação da NARX, o bloco de reconstrução indireta RI pode ser configurado para a estimativa indireta da vazão pela Equação 6.7.

$$Q(k) = R_i \cdot (P(k), a(k), Q(k - 1), f(k)). \quad (6.7)$$

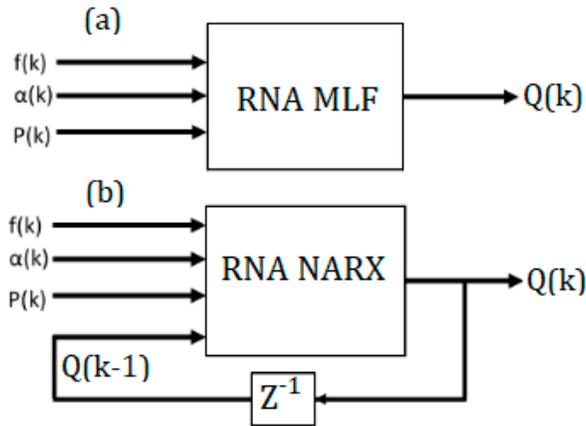


Figura 6.12: Redes (a) MLP e (b) NARX. Fonte: Adaptado de Lima(2022).

### 6.3.2.3 IMPEMENTAÇÃO DO SOFT SENSOR USANDO REDES NEURAI ARTÍFICIAIS

Para a implementação das redes candidatas a exercer o papel do soft sensor, foi utilizado o *software* Matlab (versão 2020b). A sequência de passos utilizados desde a análise das RNAs propostas até a obtenção do *soft sensor* pode ser visualizada por meio do fluxograma representado pela Figura 6.13.

As etapas associadas à Figura 6.13 são:

(1) Etapa 1 - Coleta de dados: corresponde à aquisição de dados oriundos dos instrumentos e equipamentos da planta

que servirão de entradas diretas ao estimador de vazão e demais entradas auxiliares. Os dados foram coletados através de um sistema SCADA (*Supervisory Control And Data Acquisition*) e armazenados em uma planilha eletrônica.

(2) Etapa 2 – Base de dados: os dados coletados na Etapa 1 foram dispostos em vetores do tipo coluna, separadas de acordo com cada variável de interesse ao estimador. O objetivo desta etapa é a construção do Banco de Dados que servirá para treinamento e testes das redes implementadas. Para cada variável coletada, aproximadamente 70% dos primeiros dados obtidos foram separados para a etapa de treinamento das RNAs (descrita na Etapa 4) e os demais foram utilizados para a etapa de testes das RNAs (também descrita na Etapa 4). O critério de divisão dos dados para serem utilizados nas fases de treinamento e teste das redes foi empírico.

(3) Etapa 3 – RNA MLP e NARX (treinamento e teste): corresponde ao treinamento e testes das RNAs em questão analisando as suas topologias, quantidade de neurônios, funções de ativação, erro de estimação, dentre outros parâmetros. O resultado dessas implementações é o soft sensor.

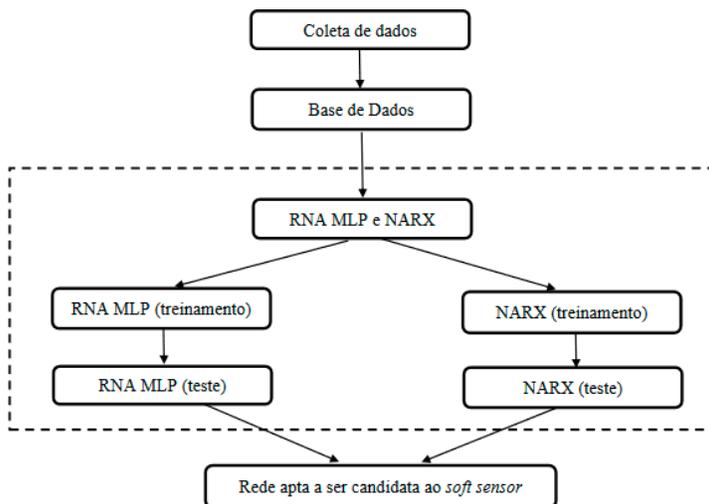


Figura 6.13: Fluxograma para a concepção do soft sensor.

Fonte: (Lima, 2022).

Assim, foi desenvolvido, utilizando o software Matlab, um código correspondente à RNA MLP e outro código correspondente à RNA NARX. Uma Tabela de Mérito (TM) foi criada contendo diversos testes realizados a fim de verificar a quantidade ótima de camadas ocultas bem como a quantidade ótima de neurônios pertencentes a cada uma dessas camadas para as duas redes analisadas. Também foi observado o tempo despendido para a realização do treinamento das redes. Existem alguns critérios que contribuem para a otimização dos parâmetros de uma RNA.

No entanto, não existe um método capaz de determinar fidedignamente todos os parâmetros ótimos. Os resultados mais otimizados foram o adotado para ambas as redes.

Os parâmetros de rede adotados, ao fim dos testes, foram uma (01) camada oculta composta por oito (08) neurônios

em ambas as redes, taxa de aprendizado de 0,1, dinâmica de treinamento por interação e um critério de parada misto, em 1000 ciclos de treinamento ou em um erro MSE inferior a 0,01.

## 6.4 EXPERIMENTOS E ANÁLISES

Uma vez desenvolvido o *soft sensor*, foram realizados experimentos e análises pertinentes a certos cenários, a fim de verificar o seu funcionamento. Para isto, foram implementados dois tipos de redes candidatas a exercer a função do *soft sensor*: uma rede utilizando a técnica de RNA Multicamada *Perceptron Backpropagation* e outra utilizando a técnica de RNA Não Linear Autorregressiva com Entradas Exógenas. A partir de então, foram realizados testes com ambas as estruturas com o objetivo de verificar qual delas seria a adotada para, de fato, atuar como estimador de vazão na bancada experimental. Deste modo, para os testes de desempenho e escolha da RNA mais adequada, foram realizados ensaios organizados em dois grupos: ensaio A e ensaio B.

Algumas métricas estatísticas foram utilizadas para análise dos dados obtidos em todos os experimentos realizados nesta pesquisa, objetivando quantificar o desempenho de estimação da vazão por parte do *soft sensor*. Uma métrica é uma medida quantificável utilizada para avaliar o status de um processo, ação ou estratégia específica. Dessa forma, as métricas utilizadas foram: MAPE, média do erro absoluto, erro máximo absoluto e desvio padrão do erro absoluto.

## 6.4.1 ENSAIO A

O ensaio A foi realizado com o objetivo de verificar qual das duas redes apresenta menor erro no que se refere à estimação da vazão quando o sistema emula a demanda intermediária de consumo na rede da bancada experimental. Para essa condição foram adotadas as seguintes premissas para a coleta de dados da planta:

- O CMB iniciou no estado de repouso (0 Hz) e em seguida sua frequência de rotação sofreu variação em degraus de 30 Hz, 40 Hz, 50 Hz, 60 Hz, 50 Hz, 40 Hz, e 30 Hz a cada 3 minutos;
- As válvulas CV-1 e CV-3 permaneceram com seus ângulos de abertura sempre na posição de 45° cada uma, enquanto a válvula CV-2 encontrava-se 59 na posição de 0°. As válvulas CV-2 e CV-3 são válvulas auxiliares responsáveis por regular o fluxo de água no sistema. Seus sinais coletados não foram considerados entradas do soft sensor;
- A pressão (referente ao sensor PT-3) foi mensurada com o sistema experimental atuando em malha aberta.

Na Tabela 6.2, estão dispostos os parâmetros utilizados para os testes relativos ao ensaio A.

Em relação ao procedimento de coleta de dados, foram obtidas cerca de 2.160 amostras. A taxa de amostragem foi fixada em 10 amostras/s em que as 1.500 primeiras amostras obtidas foram utilizadas para o treinamento das RNAs e as 660

restantes foram utilizadas para a etapa de teste. Em termos percentuais, aproximadamente 70% dos dados foram utilizados para treinamento e aproximadamente os 30% restantes para testes das redes. A partir de então, todo o ensaio foi realizado em ambiente computacional, utilizando o software Matlab.

Tabela 6.2: Parâmetros usados no Ensaio A.

Frequência de rotação do CMB (Hz)	Pressão (mca)	Ângulo de CV-1 (°)	Ângulo de CV-2 (°)	Ângulo de CV-3 (°)
30	7,93	45	0	45
40	12,13	45	0	45
50	17,23	45	0	45
60	24,21	45	0	45
50	17,62	45	0	45
40	12,09	45	0	45
30	7,86	45	0	45

Fonte: (Lima, 2022).

Inicialmente foi examinada a RNA MLP *Backpropagation* para a fase de teste da rede utilizando os dados de entrada: frequência de rotação do CMB, ângulo de CV-1 e pressão mensurada em PT-3. A saída estimada foi a vazão. A Figura 7.14 ilustra a vazão medida por meio de um sensor eletromagnético de vazão (FT-1) e a vazão estimada resultante da fase de teste para a RNA MLP *Backpropagation*.

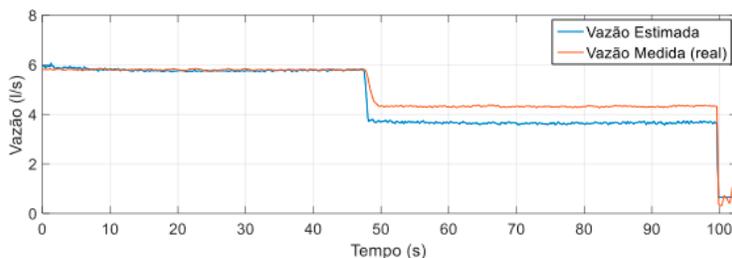


Figura 6.14: Vazão medida e estimada durante a fase de teste da RNA Multilayer Feedforward Backpropagation para o ensaio A.

Fonte: (Lima, 2022).

Foi observado um desvio de medição referente à vazão de até 0,9 L/s entre os valores estimados e medidos ao longo das curvas ilustradas na Figura 6.14. Essa discrepância ocorre devido ao desconhecimento da dinâmica do sistema pela RNA, ou seja, a falta de conhecimento do comportamento da vazão nas amostras anteriores. Para fins de quantificação do rastreamento do erro mediante os resultados obtidos a partir dos dados que compuseram as curvas da Figura 6.14, foram determinadas algumas métricas estatísticas referentes ao estimador baseado em MLP. Os dados obtidos estão dispostos na Tabela 6.3.

Para comparação entre o desempenho entre as redes, também foi realizada a simulação para a fase de teste da NARX, utilizando os mesmos dados de entrada da MLP. A Figura 6.15 ilustra a saída referente à vazão estimada utilizando a rede implementada em NARX.

Métrica estatística	RNA MLP	NARX	Razão $ME_{(MLP)}$ e $ME_{(NARX)}$
Média do erro absoluto	0,2104	0,0262	8,0305
MAPE (%)	0,1336	0,00045	296,8889
Erro máximo absoluto	1,5002	0,1308	11,4694
Desvio padrão do erro absoluto	0,8731	0,0055	158,7454

Tabela 6.3: Comparação entre o rastreamento dos erros obtidos na estimação de vazão utilizando MLP e NARX para o ensaio A.

Fonte: (Lima, 2022).

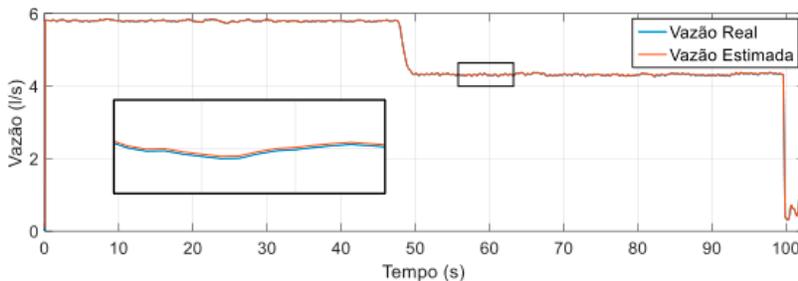


Figura 6.15: Vazão medida e estimada durante a fase de teste da RNA NARX para o ensaio A.

Fonte: (Lima, 2022).

A curva correspondente à vazão estimada (em vermelho) na fase de teste da RNA NARX foi comparada com o valor mensurado por meio do sensor físico FT-1 (em azul). Elas encontram-se quase sobrepostas e foi necessário fazer um recorte ampliado em um determinado trecho para poder visualizar as curvas distintas. A estimação bastante aproximada ao valor real está diretamente relacionada à introdução da dinâmica ao sistema à NARX pois ela possui conhecimento do comportamento da vazão nas amostras anteriores.

Para fins de quantificação do rastreamento do erro mediante os dados que compuseram os gráficos ilustrados na Figura 6.15, foram determinadas algumas métricas estatísticas utilizando o critério MSE, referente à rede NARX. A Tabela 6.3 contém a comparação (em valores aproximados) entre as métricas estatísticas obtidas para as duas redes, evidenciando a eficiência com respeito à confiabilidade da estimação da vazão utilizando a NARX na fase de simulação.

## 6.4.2 ENSAIO B

O ensaio B foi realizado com o objetivo de verificar qual das duas redes apresenta menor erro no que se refere à estimação da vazão quando o sistema emula demandas crescentes e decrescentes na rede de abastecimento de água. Para essa condição foram adotadas as seguintes premissas para a coleta de dados da planta:

- O CMB operou em sua velocidade nominal (60 Hz) durante todo esse ensaio em específico;
- A válvula CV-1 permaneceu na posição de  $0^\circ$ , a CV-3 na posição de  $45^\circ$  e a CV-2 sofreu variação crescente e decrescente de  $15^\circ$  em  $15^\circ$  até  $75^\circ$  como ângulo máximo de fechamento, iniciando em  $0^\circ$ . Cada alteração de degrau em relação à CV-2 teve duração de 2 minutos;
- A pressão (referente ao sensor PT-3) foi mensurada com o sistema experimental atuando em malha aberta.

A Tabela 6.4 contém os parâmetros utilizados para os testes relativos à categoria B.

Em relação ao procedimento de coleta de dados foram obtidas cerca de 2.232 amostras. A taxa de amostragem foi fixada em 10 amostras/s em que 1.600 dessas amostras obtidas foram utilizadas para o treinamento das RNAs e as 632 restantes foram utilizadas para a etapa de teste das RNAs, abrangendo aproximadamente 70% (para treinamento) e aproximadamente 30% (para teste) dos dados coletados, respectivamente.

Tabela 6.4: Parâmetros utilizados para o teste relativo ao ensaio B.

<b>Frequência de rotação do CMB) (Hz)</b>	<b>Pressão (mca)</b>	<b>Ângulo de CV-1 (°)</b>	<b>Ângulo de CV-2 (°)</b>	<b>Ângulo de CV-3 (°)</b>
60	6,01	0	0	45
60	7,15	0	15	45
60	10,54	0	30	45
60	17,64	0	45	45
60	21,37	0	60	45
60	23,41	0	75	45
60	22,44	0	60	45
60	20,64	0	45	45
60	14,50	0	30	45
60	8,34	0	15	45

Fonte: (Lima, 2022)

Da mesma forma que o ensaio anterior, de início foi examinada a RNA MLP *Backpropagation* para a fase de teste da rede utilizando os dados de entrada: frequência de rotação do CMB, ângulo de CV-1 e pressão mensurada em PT-3. A saída estimada foi a vazão. A Figura 6.16 ilustra a vazão medida por meio de um sensor eletromagnético de vazão (FT-1) e a vazão estimada como resultado da fase de teste para a RNA MLP *Backpropagation*.

A curva correspondente à vazão estimada (em azul) na fase de teste da RNA MLP foi comparada com o valor mensurado pelo sensor físico FT-1 (curva de cor vermelha) ainda na fase de simulação. Percebe-se um desvio de até 2 L/s entre os valores estimados e medidos. Isso ocorre devido ao desconhecimento da dinâmica do sistema pela RNA, ou seja, a falta de conhecimento do comportamento da vazão nas amostras anteriores.

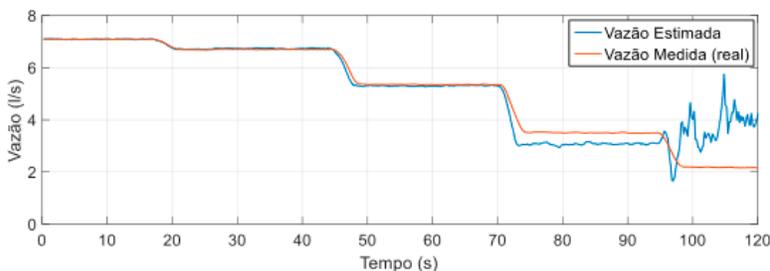


Figura 6.16: Vazão medida e estimada durante a fase de teste da RNA *Multi-layer Perceptron Feedforward Backpropagation* para o ensaio B.

Fonte: (Lima, 2022).

Para fins de quantificação do rastreamento do erro obtido mediante os resultados obtidos a partir dos dados que compuseram as curvas da Figura 6.16 relativas ao ensaio B, foram determinadas algumas métricas estatísticas referentes à rede

MLP utilizando o critério MSE. Os resultados estão dispostos na Tabela 6.5.

Foi realizada também a análise da rede implementada em NARX para a fase de testes. A Figura 6.17 ilustra a saída referente à vazão estimada utilizando a RNA do tipo NARX.

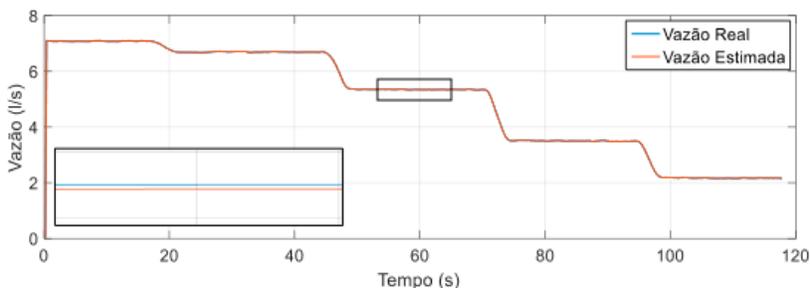


Figura 6.17: Vazões medida e estimada da RNA NARX no ensaio B.

Fonte: (Lima, 2022).

A curva correspondente à vazão estimada (em vermelho) na fase de teste da RNA NARX foi comparada com o valor mensurado pelo sensor físico FT-1 (em azul). Elas encontram-se praticamente sobrepostas e foi necessário fazer um recorte ampliado em um determinado trecho para poder visualizar as curvas distintas. Essas curvas bastante próximas estão diretamente relacionadas à introdução da dinâmica ao sistema à NARX pois ela possui conhecimento do comportamento da vazão nas amostras anteriores.

Para fins de quantificação do rastreamento do erro obtido mediante os resultados obtidos a partir da Figura 6.17, foram determinadas algumas métricas estatísticas referentes à NARX. A Tabela 6.5 contém a comparação (em valores aproximados) entre as métricas estatísticas obtidas para as redes estudadas,

evidenciando a eficiência quanto à confiabilidade da estimação da vazão utilizando a NARX na fase de simulação.

Tabela 6.5: Comparação entre os rastreamentos dos erros obtidos nas estimativas de vazão utilizando RNA MLP e NARX para o ensaio B.

Métrica estatística	RNA MLP	NARX	Razão $ME_{(MLP)}$ e $ME_{(NARX)}$
Média do erro absoluto	0,1202	0,00024	500,8333
MAPE (%)	0,0560	0,0006	933,3333
Erro máximo absoluto	1,8597	0,0011	1690,6363
Desvio padrão do erro absoluto	0,8656	0,00185	467,8919

Fonte: (Lima, 2022).

### 6.4.3 VALIDAÇÃO DO *SOFT SENSOR*

A partir das análises apresentadas na seção anterior, a RNA do tipo NARX foi a única adotada para os testes de validação e, assim, esta rede pôde estar apta a atuar como *soft sensor*. Para essa categoria de testes, o acompanhamento da vazão real (mensurada pelo sensor de vazão eletromagnético FT-1) versus vazão estimada foi realizado de maneira simultânea e durante a realização de cada experimento em tempo real. Para tanto, foi utilizado o supervisor implementado no Labview para parametrização e controle da planta e o *soft sensor* desenvolvido no Matlab, cujo código foi inserido dentro do supervisor. A seguir, descrevem-se os testes que validam o uso do *soft sensor* implementado, seja com ou sem a ação do controlador atuando no sistema.

## **6.4.3.1 VALIDAÇÃO DO SOFT SENSOR SEM AÇÃO DO CONTROLADOR**

### **6.4.3.1.1 VALIDAÇÃO A**

O teste de validação A foi realizado com o objetivo de verificar a inserção de demandas bruscas de consumo na rede de abastecimento de água sem a atuação do controlador a fim de verificar a atuação do soft sensor nessa situação. Para essa condição foram adotadas as seguintes premissas:

- A bomba encontrava-se inicialmente no estado de repouso (0 Hz), e a partir de então, a de frequência de rotação do CMB foi modificada de forma aleatória dentro de um intervalo de 30 a 60 Hz com duração de 2 minutos cada modificação;
- As três válvulas de controle sofreram variação do seu ângulo de abertura dentro de um intervalo aleatório entre 0° até 75° com duração de 2 minutos a cada modificação;
- A pressão (referente ao sensor PT-3) foi mensurada com o sistema experimental atuando em malha aberta.

Tabela 6.6: Parâmetros utilizados para o teste relativo à validação A.

Frequência de rotação do CMB (Hz)	Pressão (mca)	Ângulo de CV-1 (°)	Ângulo de CV-2 (°)	Ângulo de CV-3 (°)
50	4,9	41	35	72
41	1,4	61	18	77
60	6,3	9	6	52
39	3,6	73	68	30
45	4,3	20	15	52
46	14,5	21	76	48
58	18,5	3	84	14
35	7,2	50	51	64
30	5,4	11	35	31

Fonte: (Lima,2022).

A Tabela 6.6 contém os valores de entradas relativos a este teste. Os dados aleatórios dos valores da Tabela 6.6

foram determinados mediante a utilização da função rand do software Matlab (mesma versão utilizada para a programação das RNAs), conforme código abaixo, tomando como exemplo, neste caso, a frequência de rotação do CMB.

Na Figura 6.18, ilustra-se a curva correspondente à pressão em PT-3 a sua correspondência para cada alteração de frequência inserida nesse teste de validação. A variação da frequência foi definida de maneira aleatória dentro de um intervalo de 30 Hz a 60 para compor os valores dispostos na coluna 1 da Tabela 6.6.

O resultado da comparação entre o valor real da vazão mensurada pelo instrumento eletromagnético FT-1 e o estimador de vazão para as condições mencionadas nesse teste é ilustrado na Figura 6.19. A curva do valor estimado ficou muito próxima à curva de vazão (valores medidos pelo transdutor de fluxo

eletromagnético), conforme destacado. As oscilações presentes no início decorrem da presença prévia de água nas tubulações.

Para fins de quantificação do rastreamento do erro mediante os dados que compuseram os gráficos ilustrados na Figura 6.19, foram determinadas algumas métricas estatísticas relativas ao erro comparando as curvas de vazão real versus estimada. Os resultados obtidos (valores aproximados) estão expostos na Tabela 6.19.

```
% Exemplo para a obtenção dos valores aleatórios de frequência do CMB. O
procedimento para os ângulos das válvulas foram os mesmos, observando suas
limitações de intervalo.

a = 30; % limite inferior da frequência de rotação do CMB (30 Hz)

b = 60; % limite superior da frequência de rotação do CMB (60 Hz)

n = 9; % Quantidade de frequências aleatórias geradas dentro do intervalo
especificado.

f = a + (b-a).*rand(n,1) % função utilizada para gerar as frequências
aleatórias com n elementos dispostos em 1 coluna

fa = round(f,0) % Arredondando f para um número natural fa
```

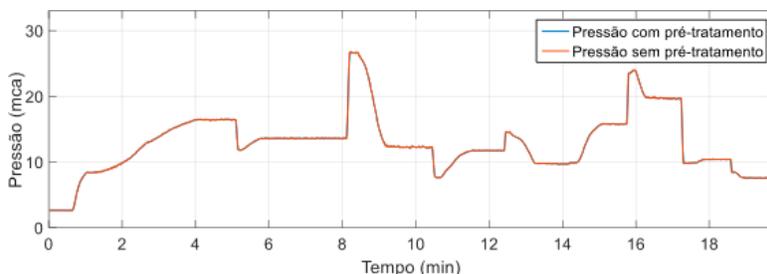


Figura 6.18: Pressão em PT-3 para o teste de validação A.

Fonte: (Lima, 2022).

Para fins de quantificação do rastreamento do erro mediante os dados que compuseram os gráficos ilustrados na Figura 6.19, foram determinadas algumas métricas estatísticas relativas ao erro comparando as curvas de vazão real versus estimada. Os resultados obtidos (valores aproximados) estão contidos na Tabela 6.7.

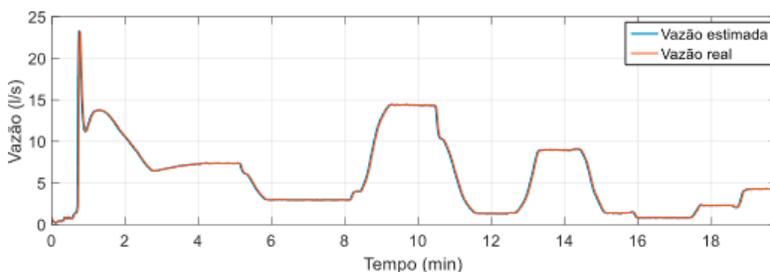


Figura 6.19: Vazão estimada versus real para testes de validação A.

Fonte: (Lima, 2022).

Tabela 6.7: Rastreamento do erro para o teste de validação A.

<b>Métrica estatística</b>	<b>Valor</b>
Média do erro absoluto (l/s)	0,1228
MAPE (%)	0,0017
Erro máximo absoluto (l/s)	3,5160
Desvio padrão do erro absoluto (l/s)	0,2270

Fonte: (Lima, 2022).

Através da análise dos dados referentes à Tabela 6.7, observa-se que a média, o MAPE (%) e o desvio padrão do erro de rastreamento possuem valores significativamente inferiores a 1, o que é indicativo de bom desempenho por parte do *soft sensor*. O erro máximo obtido foi relativamente baixo e ocorreu devido ao fato de da consideração da utilização de todos os pontos para a análise estatística do

rastreamento do erro, incluído o regime transitório (sistema partindo do repouso até a primeira frequência pré-estabelecida) e pela presença prévia de água e ar nas tubulações antes do acionamento do inversor. Entretanto, o *soft sensor* mensurou a vazão de maneira adequada para quaisquer condições apresentadas e, até mesmo, antes do acionamento do inversor de frequência.

### 6.4.3.1.2 VALIDAÇÃO B

O teste de validação B objetivou verificar a atuação do *soft sensor* quando a entrada correspondente à pressão (PT-3) esteve submetida a sinais espúrios do tipo ruídos intermitentes. As premissas adotadas referentes a este teste foram:

- Variação de frequência de rotação do CMB estando iniciando em repouso (0 Hz) e posteriormente sendo comutada para 30 Hz, 40 Hz, 50 Hz, 60 Hz, 50 Hz, 40 Hz e 30 Hz com duração de 1 minuto cada variação;
- A válvula CV-1 encontrava-se a 0° enquanto CV-2 e CV-3 encontravam-se a 45° durante todo o período de execução do teste;

- A pressão (referente ao sensor PT-3) foi mensurada com o sistema experimental atuando em malha aberta;
- Foram inseridos segmentos de ruídos, caracterizados por sinais de natureza gaussiana. Cada segmento foi identificado por um tag (algarismo romano de I a VII) e caracterizado por ser um sinal que contém uma amplitude de referência adicionada a um valor aleatório dentro de um intervalo específico, conforme representado por

$$r(t) = C(t) + a(t), \quad (7.8)$$

em que  $r(t)$  representa o sinal associado a cada segmento de ruído inserido,  $C(t)$  corresponde à amplitude fixa de  $r(t)$  e  $a(t)$  corresponde à componente aleatória de  $r(t)$ .

Na Figura 6.20 ilustra a curva correspondente à pressão em PT-3 bem como os ruídos inseridos a cada mudança de degrau.

O resultado da comparação entre o valor real da vazão mensurada pelo sensor FT-1 e o soft sensor para as condições mencionadas nesse teste é ilustrada na Figura 6.21. Observou-se, da mesma maneira que no teste anterior, as oscilações presentes nos primeiros instantes de tempo são consequências da presença de água e ar nas tubulações bem como da consideração do período transitório. No entanto, mesmo com oscilações iniciais, foi constatada a atuação do soft sensor acompanhando o valor real da vazão perante esta situação.

Tabela 6.8: Parâmetros para o teste da validação B.

<b>Frequência (Hz)</b>	<b>Tag</b>	<b>Pressão (mca)</b>	<b>Range da componente aleatória do ruído (mca)</b>	<b>Intervalo de tempo de inserção dos ruídos (s)</b>	<b>CV-1 (°)</b>	<b>CV-2 (°)</b>	<b>CV-3 (°)</b>
30	I	6,23	-15 a 25	10 a 50	0	45	45
40	II	10,69	-10 a 30	15 a 30	0	45	45
50	III	16,14	0 a 35	8 a 40	0	45	45
60	IV	23,07	5 a 45	10 a 55	0	45	45
50	V	16,26	-5 a 35	20 a 40	0	45	45
40	VI	10,58	-10 a 30	15 a 45	0	45	45
30	VII	5,93	-15 a 25	5 a 55	0	45	45

Fonte: (Lima, 2022).

Para fins de análise dos dados referentes aos pontos que formam as curvas ilustradas na Figura 7.21, foram determinadas algumas métricas estatísticas relacionadas ao rastreamento do erro para cada identificação (I até VIII) de degrau de vazão apenas nos instantes de tempo em que os ruídos foram inseridos. Também foram determinadas assimétricas estatísticas das curvas como um todo, isto é, considerando todos os pontos de ambos os gráficos ilustrados na Figura 6.21. Os resultados obtidos (valores aproximados) estão dispostos na Tabela 6.9. Foram desconsiderados, no para análise dos trechos I a VII, os valores

correspondentes às transições (borda de subida ou descida) de um degrau de vazão para outro imediatamente superior ou inferior.

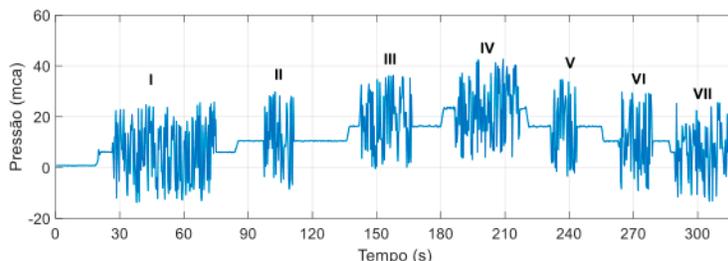


Figura 6.20: Pressão mensurada em PT-3 com inserção de sinais espúrios.

Fonte: (Lima, 2022).

A eficiência do soft sensor permitiu que a mensuração indireta da vazão fosse realizada de maneira eficiente mesmo com a possibilidade de sinais espúrios no sensor de pressão PT-3. Esses sinais indesejáveis em Sistemas de Abastecimento de Água podem ser provocados por ruídos elétricos no sistema, vibrações na rede etc.

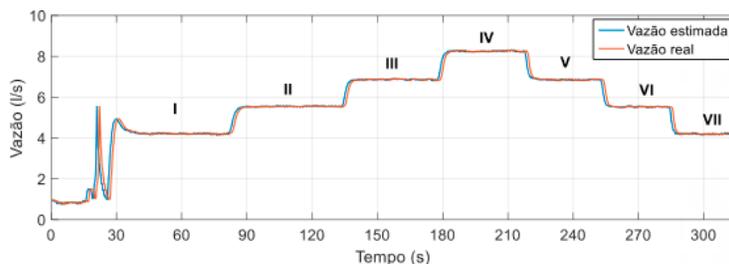


Figura 6.21: Vazão estimada versus real para testes de validação B.

Fonte: (Lima, 2022).

Tabela 6.9: Rastreamento do erro para o teste de validação B.

Trecho correspondente	Erro médio absoluto (l/s)	MAPE (%)	Erro máximo absoluto (l/s)	Desvio padrão do erro (l/s)
I	0,0252	0,0043	0,0964	0,0211
II	0,0221	0,0027	0,0700	0,0156
III	0,0233	0,0027	0,0947	0,0185
IV	0,0256	0,0031	0,0807	0,0189
V	0,0236	0,0034	0,0696	0,0170
VI	0,0404	0,0082	0,0836	0,0189
VII	0,0260	0,0066	0,0822	0,0204
Curvas completas	0,1059	0,0127	3,8682	0,2835

Fonte: (Lima, 2022).

Observou-se que todos os valores correspondentes às métricas de desempenho tiveram valores muito inferiores a 1 (um), o que infere uma boa estimacão de vazão ao considerar apenas os trechos destacados (I a VII). Apenas ao considerar todos os pontos analisados (curvas completas) foi observado que o erro

máximo obtido possui valor aproximado de 3,9 justamente devido à consideração do período transitório bem como a presença prévia de água e ar nas tubulações antes do acionamento do inversor de frequência. Entretanto, constatou-se que o *soft sensor* conseguiu estimar a vazão de maneira adequada mesmo com as adversidades presentes no teste e desde o início das curvas, antes mesmo do acionamento do CMB.

Análises semelhantes, considerando que outros componentes do sistema estejam sujeitos a ruídos intermitentes, podem ser realizadas. De fato, outras análises estão disponíveis em Lima (2022). Agora, considerar-se-á a atuação dos *soft sensors* diante da atuação de controladores.

#### **6.4.4.3.2 VERIFICAÇÃO DA EFICIÊNCIA DO SOFT SENSOR COM A ATUAÇÃO DO CONTROLADOR NO SISTEMA**

Nesta categoria de testes foi utilizado o controlador desenvolvido por Flores (2021), bem como seus parâmetros otimizados para o controle da pressão mensurada pelo sensor PT-3. O objetivo da ação de controle foi fazer com que a pressão permanecesse em determinado(s) valor(es) pré-estabelecido(s), obtido(s) em regime permanente. O objetivo em relação ao *soft sensor* foi com que ele mensurasse a vazão no sistema também com a ação do controlador atuando na planta.

### 6.4.3.2.1 ATUAÇÃO DO SOFT SENSOR PARA DIFERENTES SETPOINTS DE PRESSÃO

Este teste teve como objetivo verificar a atuação do soft sensor estimando a vazão quando o controlador se encontrava sujeito à mudança no valor desejado de pressão. Para esse teste foram consideradas as seguintes premissas:

- (1)  $K_p = K_i = K_d = \alpha_1 = \alpha_2 = \alpha_3 = 0,01$ , correspondentes aos parâmetros otimizados do controlador adaptativo;
- (2) As válvulas CV-2 e CV-3 permaneceram com seus ângulos de abertura sempre na posição de  $45^\circ$  cada uma enquanto a válvula CV-1 encontrava-se na posição de  $0^\circ$  e a bomba encontrava-se, inicialmente, em repouso (0 Hz);
- (3) Os valores desejados de pressão foram iguais a 10, 12, 14, 16, 14, 12 e 10 mca com duração aproximada de 60 s cada SP a partir da estabilização do primeiro;
- (3) A frequência de rotação do CMB acompanhava o setpoint de pressão.

Os parâmetros utilizados neste teste em específico estão expostos na Tabela 6.10. Na Figura 6.22 ilustra-se a curva controlada de pressão com incrementos e decrementos fixos de SP. Foi verificado que a planta levou cerca de 130 s para que o seu sinal atingisse o primeiro valor do setpoint adotado. Isso ocorreu devido a escolha dos parâmetros utilizados bem como a própria inércia do sistema. Quanto maiores os parâmetros supracitados maior seria o tempo necessário para atingir o valor de *setpoint*.

O controlador necessita de um tempo para aprendizagem dos parâmetros otimizados por ele promover o ajuste desses parâmetros em tempo real. Em contrapartida, melhor seria a atuação do sistema em termos de uma resposta mais suave. Porém, ao vencer a etapa do primeiro degrau, não existiu mais o efeito da inércia e, assim, a velocidade de convergência foi reduzida consideravelmente.

Tabela 6.10: Parâmetros de entrada do soft sensor para diferentes valores de setpoint de pressão com ação do controlador.

<b>Setpoint de pressão (mca)</b>	<b>Frequência (Hz)</b>	<b>Ângulo de CV-1 (°)</b>	<b>Ângulo de CV-2 (°)</b>	<b>Ângulo de CV-3 (°)</b>
10	39,00	0	45	45
12	42,96	0	45	45
14	46,64	0	45	45
16	50,09	0	45	45
14	46,77	0	45	45
12	43,04	0	45	45
10	39,16	0	45	45

Fonte: Lima (2022).

O resultado da comparação entre o valor real da vazão mensurada pelo instrumento eletromagnético FT-1 e o estimado pelo *soft sensor* é ilustrado na Figura 6.23. O *soft sensor* conseguiu estimar adequadamente a vazão. As oscilações nos primeiros instantes de tempo foram efeitos da presença de água e ar nas tubulações bem como do regime transitório antes da estabilização do primeiro *setpoint* e do período de aprendizagem por parte do controlador

buscando a otimização dos parâmetros. Quando o sinal ficou estabilizado, isto é, atingiu-se o regime permanente, foi constatada a eliminação desses transientes. No entanto, mesmo com oscilações bruscas iniciais já foi possível verificar a atuação do soft sensor acompanhando o valor real da vazão nesta situação.

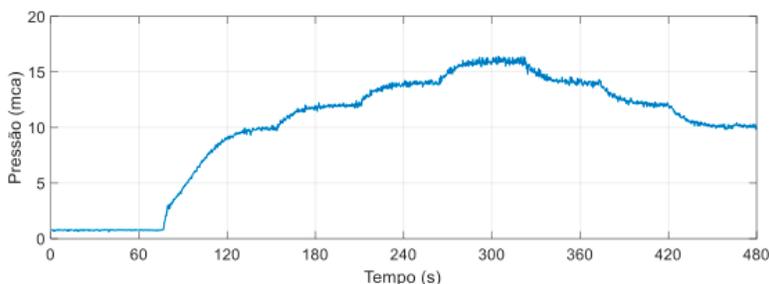


Figura 6.22: Respostas da planta controlada para diferentes valores desejados da pressão.

Fonte: (Lima, 2022).

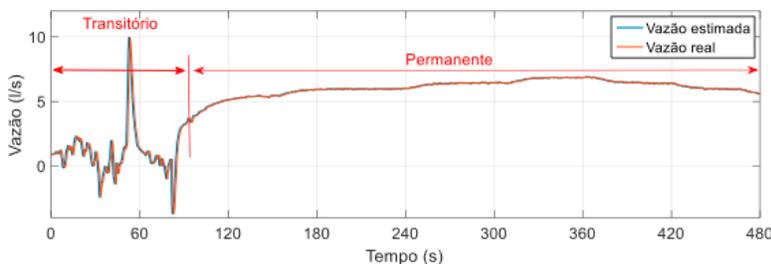


Figura 6.23: Vazão estimada versus real com a planta controlada para diferentes valores desejados da pressão.

Fonte: (Lima, 2022).

Para análise quantitativa, foram determinadas algumas métricas estatísticas relacionadas ao rastreamento do erro de regime permanente, isto é, o erro a partir do instante 100 s. Os resultados estão expostos na Tabela 6.11.

Tabela 6.11: Métricas estatísticas do erro de rastreamento da vazão para diferentes valores desejados de pressão em regime permanente.

Métrica estatística	Valor em regime permanente
Média do erro absoluto (l/s)	0,0339
MAPE (%)	0,0042
Erro máximo absoluto (l/s)	0,4286
Desvio padrão do erro absoluto (l/s)	0,0292

Fonte: (Lima, 2022)

Todas as métricas estatísticas usadas apresentaram valores muito inferiores a 1, comprovando que o *soft sensor* é capaz de estimar a vazão na condição de mudança de *setpoint* de pressão.

### 6.4.3.2.2 ATUAÇÃO DO SOFT SENSOR PARA VARIAÇÕES BRUSCAS DE DEMANDA DE CONSUMO

Este teste teve como objetivo verificar a atuação do *soft sensor* estimando a vazão na condição de variações bruscas de demanda de consumo do sistema. Para esse teste foram consideradas as seguintes premissas:

$$-K_p = K_i = K_d = \alpha_1 = \alpha_2 = \alpha_3 = 0,01;$$

- As válvulas CV-2 e CV-3 permaneceram com seus ângulos de abertura sempre na posição de  $45^\circ$  cada uma enquanto a válvula CV-1 encontrava-se na posição de  $0^\circ$  e a bomba encontrava-se, inicialmente, em repouso (0 Hz);
- Os *setpoints* de pressão foram considerados utilizando os dados da Tabela 6.12, duração aproximada de 50 s cada, a partir da estabilização do primeiro;
- A frequência de rotação do CMB acompanhava o *setpoint* de pressão.

Todos os parâmetros utilizados neste teste em específico estão contidos na Tabela 6.12.

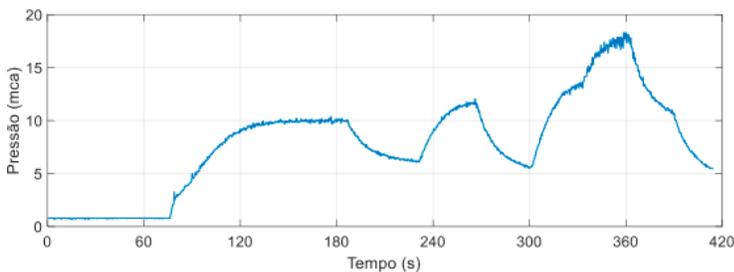


Figura 6.24: Respostas da planta controlada com variações abruptas de demanda de consumo. Fonte: (Lima, 2022).

Na Figura 6.24, ilustra-se a curva controlada de pressão com variação brusca de demanda. As variações bruscas de demanda de consumo, representadas por variações abruptas

de *setpoint* de pressão emulam aumento ou redução repentina de consumo na rede.

Tabela 6.12: Parâmetros de entrada do soft sensor com variações abruptas de demanda de consumo com ação do controlador.

<b><i>Setpoint de pressão (mca)</i></b>	<b>Frequência (Hz)</b>	<b>Ângulo de CV-1 (°)</b>	<b>Ângulo de CV-2 (°)</b>	<b>Ângulo de CV-3 (°)</b>
10	39,04	0	45	45
6	30,36	0	45	45
12	42,60	0	45	45
5	28,85	0	45	45
14	45,39	0	45	45
18	52,83	0	45	45
10	40,81	0	45	45
4	28,41	0	45	45

Fonte: (Lima, 2022).

O resultado da comparação entre o valor real da vazão mensurada pelo instrumento eletromagnético FT-1 e o estimado pelo *soft sensor* está ilustrado na Figura 6.25.

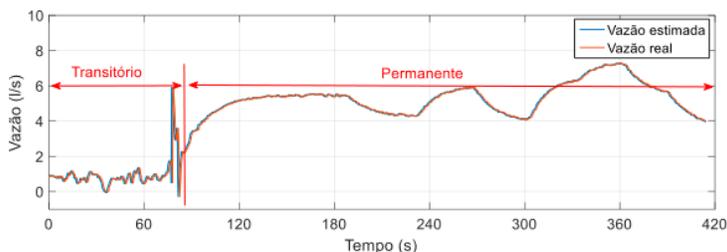


Figura 6.25: Respostas da planta controlada com variações abruptas de demanda de consumo. Fonte: (Lima, 2022).

Tabela 6.13: Métricas estatísticas do erro de rastreamento da vazão para demanda abrupta de consumo em regime permanente.

<b>Métrica estatística</b>	<b>Valor em regime permanente</b>
Média do erro absoluto (l/s)	0,0539
MAPE (%)	0,0013
Erro máximo absoluto (l/s)	0,2659
Desvio padrão do erro absoluto (l/s)	0,0399

Fonte: (Lima, 2022).

Da mesma forma que no teste anterior, foram determinadas algumas métricas estatísticas referentes ao rastreamento do erro em regime permanente, considerado o seu início no instante 100 s. Os resultados obtidos estão expostos na Tabela 6.13.

Todas as métricas obtidas apresentaram valores inferiores a 1, o que é um indicativo de um bom desempenho por parte do *soft sensor*. O estimador de vazão conseguiu mensurar com eficiência a vazão mesmo com oscilações de pressão na rede.

### 6.4.3.2.3 ATUAÇÃO DO *SOFT SENSOR* PARA SINAIS ESPÚRIOS EM PT-3

Esse teste teve como objetivo verificar a atuação do *soft sensor* quando o sensor de pressão PT-3 se encontrava submetido a sinais espúrios do tipo *outliers* e, concomitantemente, sofrendo variação de *setpoint* de maneira crescente e decrescente. As premissas adotadas referentes a este teste foram:

- $Kp = Ki = Kd = \alpha1 = \alpha2 = \alpha3 = 0,01$ ;
- As válvulas CV-2 e CV-3 permaneceram com seus ângulos de abertura sempre na posição de 45° durante toda a execução do teste, enquanto a válvula CV-1 encontrava-se sempre na posição de 0°. A bomba encontrava-se inicialmente em repouso (0 Hz);
- Os valores desejados de pressão foram iguais a 10, 12, 14, 16, 14, 12 e 10 mca com duração aproximada de 60 s para cada setpoint após a estabilização do primeiro;
- A frequência de rotação do CMB acompanhava o setpoint de pressão;
- Foram inseridos *outliers* dentro de um intervalo de tempo pré-estabelecido de 60 segundos. Cada *outlier* inserido teve uma duração aproximada de 1 segundo e cada subconjunto de *outliers* (dentro dos 60 segundos

especificados) foi identificado por um tag (algarismo romano de I a VII).

Tabela 6.14: Parâmetros de entrada do *soft sensor* incluindo sinais do tipo *outliers* em PT-3 com segmentação de degraus de pressão.

<i>Setpoint de pressão (mca)</i>	<i>Tag</i>	<i>Tempo de inserção dos Outliers (s)</i>	<i>Range de cada conjunto de outliers associado a cada tag (mca)</i>
10	I	10, 15, 20, 25, 30, 35, 40, 45, 50	5 a 30
12	II	10, 15, 20, 25, 30, 35, 40, 45, 50	-7 a 27
14	III	10, 15, 20, 25, 30, 35, 40, 45, 50	-1 a 33
16	IV	10, 15, 20, 25, 30, 35, 40, 45, 50	-2 a 32
14	V	10, 15, 20, 25, 30, 35, 40, 45, 50	-2 a 35
12	VI	10, 15, 20, 25, 30, 35, 40, 45, 50	-6 a 31
10	VII	10, 15, 20, 25, 30, 35, 40, 45, 50	-5 a 29

Fonte: (Lima, 2022).

Os dados relativos aos testes em questão podem ser consultados na Tabela 6.14.

Na Figura 6.26, ilustra-se a curva de pressão em PT-3 com sinais do tipo *outliers*.

Verificou-se que a ação do controlador foi capaz de manter o sistema estável mesmo com a inserção dos *outliers*. A planta levou cerca de 70 segundos para que a frequência da bomba atingisse o valor mínimo de frequência a fim de vencer a inércia do sistema e que depois a partir de então, levou mais cerca de 60 segundos para que o seu sinal atingisse o primeiro valor do setpoint adotado (10 mca). Isso esteve associado aos parâmetros adotados. Quanto maiores esses parâmetros, maior o tempo despendido para que o sistema alcançasse o valor de SP.

No entanto, o sistema teve uma resposta transitória suave, sem sobressinal e com erro em regime permanente próximo a zero. E essas condições já foram suficientes para atender as necessidades do teste em questão.

O resultado da comparação entre o valor real da vazão mensurada pelo instrumento eletromagnético FT-1 e o estimado pelo *soft sensor* é ilustrado na Figura 6.27 com as suas respectivas identificações por degrau de vazão.

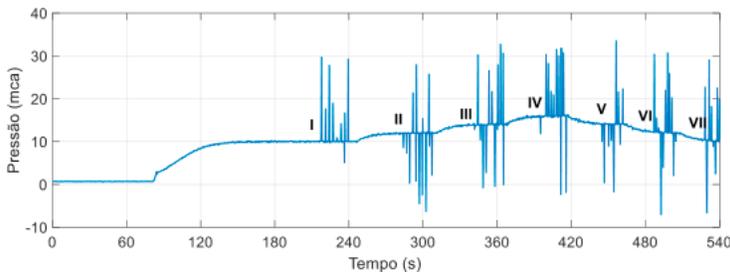


Figura 6.26: Sinal de PT-3 com inserção de *outliers* de acordo com cada degrau de *setpoint*.

Fonte: (Lima, 2022).

Constatou-se que, assim como nos testes anteriores, as oscilações presentes nos primeiros instantes de tempo foram consequência da presença de água e ar nas tubulações antes do acionamento do controlador bem como ao momento transitório do sinal até a sua estabilização (mesma consideração dos experimentos anteriores). No entanto, mesmo com oscilações iniciais constatou-se a atuação do *soft sensor* acompanhando o valor real da vazão antes mesmo do acionamento do sistema.

Para fins de quantificação e análise dos dados referentes aos pontos que compuseram as curvas ilustradas na Figura 6.27,

foram determinadas algumas métricas estatísticas relacionadas ao rastreamento do erro para cada identificação de degrau de *setpoint* de vazão apenas nos instantes de tempo em que os ruídos foram inseridos, em regime permanente (I a VII), dentro dos 60s para cada variação de SP de pressão. Para este teste, foram consideradas as transições de um valor de vazão para outro pelo fato de agora o sistema ser controlado e as transições ocorreram de maneira suave. Também foram determinados os valores correspondentes às métricas estatísticas das curvas como um todo (curvas completas).

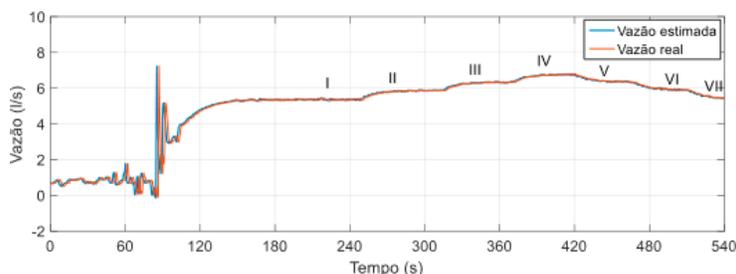


Figura 6.27: Vazão estimada versus real mediante inserção de outliers em PT-3.

Fonte: (Lima, 2022).

Os resultados dos testes estão dispostos na Tabela 6.15.

Ao comparar as métricas estatísticas de rastreamento do erro para cada segmento das curvas (tags de I até VII), foi observado que todos os resultados possuíam valores inferiores a 1, indicando bom desempenho por parte do *soft sensor*, mesmo com a inserção de outliers em PT-3 e a variação crescente e decrescente de pressão em cada trecho. Assim, estes sinais não influenciaram no resultado esperado da mensuração da vazão

pelo instrumento virtual. Em relação ao erro máximo absoluto ter valor aproximado de 4,7 l/s, ele foi obtido com a análise de todos os pontos das curvas (antes da ação de controle e durante os regimes transitório e permanente com a ação de controle atuando na planta), das oscilações iniciais antes da atuação do controle, da presença prévia de água e ar nas tubulações e da pressão ser a variável que mais influenciou na estimação da vazão comparada às demais. No entanto, constatou-se que o *soft sensor* conseguiu estimar a vazão mesmo com as adversidades presentes no teste.

Testes considerando os efeitos de sinais espúrios sobre outros elementos do sistema também foram apresentados por Lima (2022) nesta bateria de testes. No entanto, o procedimento de análise é semelhante ao realizado nesta seção, de modo que os omitiremos no presente texto.

Tabela 6.15: Métricas estatísticas do erro de rastreamento da vazão mediante inserção de outliers em PT-3 para cada trecho da vazão estimada versus real apenas nos intervalos dos ruídos e em todos os pontos.

Trecho correspondente	Erro médio absoluto (l/s)	MAPE (%)	Erro máximo absoluto (l/s)	Desvio padrão do erro absoluto (l/s)
I	0,0339	0,0028	0,1245	0,0264
II	0,0329	0,0026	0,1384	0,0277
III	0,0303	0,0027	0,1246	0,0259
IV	0,0317	0,0026	0,0934	0,0230
V	0,0324	0,0034	0,1394	0,0242
VI	0,0391	0,0045	0,1355	0,0280
VII	0,0351	0,0042	0,1192	0,0269
Curvas completas	0,1071	0,0135	4,7436	0,3081

Fonte: (Lima, 2022).

## 6.4.4 CONSIDERAÇÕES FINAIS

Em resumo, verificou-se a partir da análise dos resultados dos testes com diferentes métricas estatísticas que os sinais espúrios (*outliers ou ruídos*) influenciaram nos valores dos MAPEs e dos erros máximos absolutos quando foram considerados todos os pontos (excursão completa dos sinais) que compuseram as curvas vazão estimada *versus* real, com valores discretamente aumentados. No entanto, essa elevação de valores foi pouco significativa quando comparada à ausência dos sinais indesejáveis nos testes. Valores de MAPE (%) de até 0,0023% e erro máximo absoluto de até 4,7 l/s obtidos apenas em casos de excursão completa do sinal reforçaram um eficiente desempenho do *soft sensor* implementado.

## REFERÊNCIAS

CAMBOIM, W. L. L.; SILVA, S. A.; GOMES, H. P. **Aplicação de técnicas Fuzzy no controle de pressão em sistemas de abastecimento de água.**

Engenharia Sanitária e Ambiental, Vol. 19, 2014, pp.67-77.

FLORES, T. K. **Controle Adaptativo Utilizando o Critério da Máxima Correntropia Aplicado a um Sistema de Bombeamento de Água.**

Dissertação de Mestrado, Departamento de Engenharia Elétrica, UFPB, João Pessoa, Brasil, 2021.

LIMA, R.P.G. **Desenvolvimento de um Soft Sensor para Estimação da Vazão em Sistemas de Abastecimento de Água Usando Redes Neurais Artificiais.** Tese de doutorado, Departamento de Engenharia Mecânica, UFPB, João Pessoa, Brasil, 2022.

LIMA, R.P.G.; VILLANUEVA, J.M.M.; GOMES, H.P. FLORES, T.K.S.

**Development of a Soft Sensor for Flow Estimation in Water Supply Systems Using Artificial Neural Networks.** Sensors, vol.22, Ano: 2022.

SALVINO, L. R. **Eficiência Energética em Sistemas Pressurizados de Distribuição de Água com o uso de Redes Neurais Artificiais.** Tese de

Doutorado, Departamento de Engenharia Mecânica, UFPB, João Pessoa, Brasil, 2018.

## **SOBRE OS(AS) AUTORES(AS)**

**Juan Mauricio Moises Villanueva** – Possui graduação em Engenharia Eletrônica - Universidad Nacional de Ingeniería (Lima/Perú) (2002), Mestrado em Engenharia de Eletricidade pela Universidade Federal do Maranhão (2005) e Doutorado pela Pontifícia Universidade Católica do Rio de Janeiro (2009). Pós-Doutorado na Universidade Federal de Campina Grande (2012). Atualmente é Professor Associado II no Departamento de Engenharia Elétrica e Professor Permanente do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal da Paraíba (UFPB). Participa ativamente na gestão e execução de projetos EMBRAPAII CEAR/UFPB. Com áreas de interesse nos seguintes temas: Sistemas de Medição Inteligente, Inteligência Artificial, Automação e Controle. Atualmente é pesquisador DT-2 CNPq de Produtividade em Desenvolvimento Tecnológico e Extensão Inovadora.

**Heber Gomes Pimentel** – Possui graduação em Engenharia Civil, Campina Grande, pela Universidade Federal da Paraíba (1977), mestrado em Engenharia Civil pela Universidade Federal de Campina Grande (1980) e doutorado em Ingeniería Civil - Universidad Politécnica de Madrid (1992). Atualmente é professor Titular da Universidade Federal da Paraíba, sem vínculo empregatício nas seguintes entidades: Associação Brasileira de

Engenharia Sanitária e Ambiental; Associação Brasileira de Recursos Hídricos; Centrais Elétricas Brasileiras S/A (ELETROBRÁS); Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES); Financiadora de Estudos e Projetos (FINEP) e Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq). Tem experiência nas áreas de Engenharia Civil, Mecânica e Sanitária, com ênfase em Técnicas de Abastecimento da Água, atuando principalmente nos seguintes temas: otimização, redes, eficiência hidráulica, eficiência energética, dimensionamento econômico, irrigação e abastecimento de água. É coordenador do Laboratório de Eficiência Energética e Hidráulica em Saneamento (LENHS) da UFPB.

**Saulo de Tarso Marques Bezerra** – Professor Associado do curso de Engenharia Civil do Campus Agreste da Universidade Federal de Pernambuco (UFPE). Possui graduação em Engenharia Civil (2003), mestrado em Engenharia Civil e Ambiental (2005), e doutorado em Engenharia Mecânica, ênfase em Automação (2009). Atualmente (2023) é vice-coordenador do Programa de Pós-Graduação em Engenharia Civil e Ambiental (PPGECAM), coordenador do Laboratório Multiusuário de Água e Energia (LMAE), e vice-coordenador do Laboratório Multiusuário de Tecnologias para o Semiárido (LAMTESA) e do Laboratório de Geoprocessamento (GEOLAB), pertencentes ao PPGECAM. Bolsista de Produtividade em Pesquisa do CNPq.

**Rafael Moura Duarte** – Obteve o título de bacharel em engenharia elétrica pela Universidade Federal da Paraíba (UFPB) em 2014, com ênfase em eletrônica. Ao longo da sua graduação foi bolsista de iniciação científica (PIBIC) por duas vezes. Ainda em 2014, iniciou um mestrado acadêmico na mesma instituição, obtendo o título de mestre em 2016. Ao longo da sua vida acadêmica, participou de atividades de pesquisa e realizou publicações técnicas. Em 2016, se tornou doutorando no PPGEE/UFCG, tendo obtido o título em maio de 2021. Recentemente, ocupou a posição de professor substituto de ensino básico e técnico (EBTT) no Instituto Federal do Mato Grosso (IFMT) por seis meses. No ano de 2023, ingressou novamente na UFPB através de um projeto de pós-doutorado financiado pela Fapesq e cujo objeto de estudos são aplicações de inteligência artificial em sistemas de abastecimento de água.

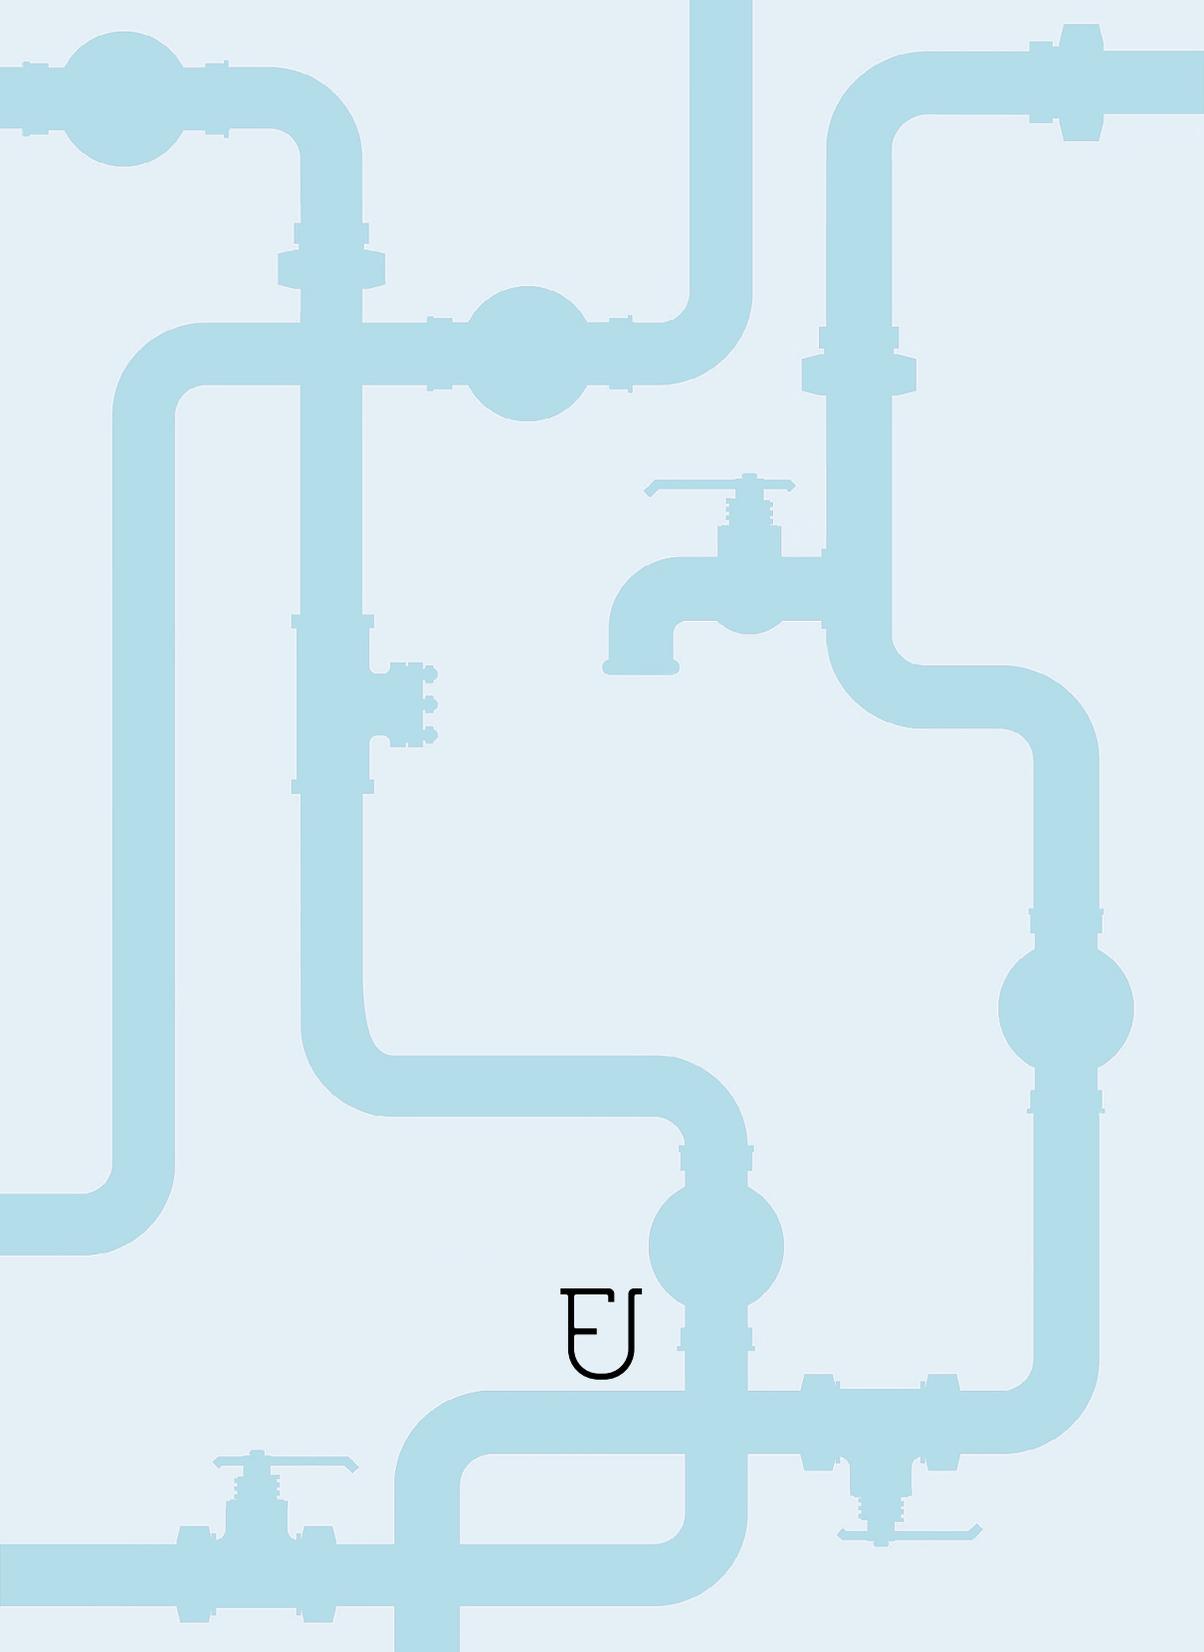
**José Vinícius Santos de Araújo** – Graduado em Engenharia Elétrica pela Universidade Federal da Paraíba, ex-monitor da disciplina de “Teoria de Controle”, ex-participante do projeto de extensão “Inspeção das Instalações Elétricas do Centro de Tecnologia” e ex-participante de projeto P&D em parceria com a CHESF denominado projeto OSERAAD. Estágio realizado na CAGEPA pela empresa SANCOOL solucionando problemas de automação e controle utilizando controladores lógicos programáveis, programação em c/c++ e Python e sistema supervisor ScadaBR. Atualmente é engenheiro da unidade EMBRAPIL - CEAR. Experiências com automação industrial, inversores de frequência, inteligência artificial, algoritmos de otimização, redes industriais e sistemas supervisórios.

**Hugo Augusto Marinho Moreira** – Graduado em Engenharia Mecânica pelo IFPE (2018). Durante a graduação atuou na programação de sistemas embarcados no projeto A Casa Inteligente e como Líder do Hórus AeroDesign/SAE-IFPE. Foi bolsista PIBIC atuando na simulação numérica e análise de dispositivos de expansão (adiabáticos e não-adiabáticos) para sistemas de refrigeração por absorção e compressão. Trabalhou na indústria aeronáutica, no setor de projetos realizou a certificação de uma aeronave da classe LSA. Atualmente é Doutorando no LENHS/UFPB onde estuda Inteligência Artificial aplicada à eficiência energética de sistemas de abastecimento de água.

**Thomas Kevin Sales Flores** – Doutorando em Engenharia Elétrica e da Computação, com ênfase em Processamento Inteligente da Informação, pela Universidade Federal do Rio Grande do Norte (UFRN). Mestre em Engenharia Elétrica, com foco em Sistemas Eletrônicos e Automação, pela Universidade Federal da Paraíba (UFPB). Se graduou em Engenharia Elétrica pela mesma instituição em 2018, com ênfase em Controle e Automação. Durante a graduação, atuou como monitor no componente curricular de Eletrônica, onde conduz pesquisas voltadas para a aplicação de algoritmos de inteligência artificial em sistemas de bombeamento de água e indústria 4.0. Após a graduação, tornou-se trainee de engenharia elétrica e hoje exerce a função de analista de tecnologias operacionais na indústria de papel e celulose.

**Robson Pacífico Guimarães Lima** – Doutor em Engenharia Mecânica na área de Dinâmica e Controle de Sistemas pela Universidade Federal da Paraíba - UFPB (2022), mestre em Engenharia Elétrica na área de Sistemas de Energia pela Universidade Federal da Paraíba - UFPB (2013), além de possuir especialização em Gestão de Projetos (área de Engenharia de Produção) pela Universidade Federal de Pernambuco - UFPE (2009), graduação em Engenharia Elétrica pela Universidade Federal de Campina Grande - UFCG (2006) e técnico em Eletrônica pelo Instituto Federal de Educação, Ciência e Tecnologia da Paraíba - IFPB (1999). O pesquisador é professor efetivo do Instituto Federal de Pernambuco (desde 2010), onde atua nas áreas de ensino, pesquisa e extensão. Atuou na área industrial como Engenheiro Projetista de Automação (2007 a 2010) com projetos em PCHs (Pequenas Centrais Hidrelétricas), automação em usinas de produção de açúcar e etanol e comissionamento industrial em campo.





EU