



Universidade Federal da Paraíba
Centro de Tecnologia
Programa de Pós-Graduação em Engenharia Mecânica
Mestrado-Doutorado

**DESENVOLVIMENTO DE UM *SOFT SENSOR* PARA ESTIMAÇÃO
DA VAZÃO EM SISTEMAS DE ABASTECIMENTO DE ÁGUA
UTILIZANDO REDES NEURAIS ARTIFICIAIS**

por

Robson Pacífico Guimarães Lima

Tese de Doutorado apresentada à Universidade Federal da Paraíba para
obtenção do grau de Doutor.

ROBSON PACÍFICO GUIMARÃES LIMA

**DESENVOLVIMENTO DE UM *SOFT SENSOR* PARA ESTIMAÇÃO
DA VAZÃO EM SISTEMAS DE ABASTECIMENTO DE ÁGUA
UTILIZANDO REDES NEURAIIS ARTIFICIAIS**

Tese apresentada ao curso de Pós-Graduação
em Engenharia Mecânica da Universidade
Federal da Paraíba, em cumprimento às
exigências para obtenção do Grau de
Doutor.

Orientador: Prof. Dr. Heber Pimentel Gomes
Coorientador: Prof. Dr. Juan Moises Mauricio Villanueva

Catálogo na publicação
Seção de Catalogação e Classificação

L732d Lima, Robson Pacífico Guimarães.

Desenvolvimento de um soft sensor para estimação da vazão em sistemas de abastecimento de água utilizando redes neurais artificiais / Robson Pacífico Guimarães Lima. - João Pessoa, 2022.

146 f. : il.

Orientação: Heber Pimentel Gomes.

Coorientação: Juan Moises Mauricio Villanueva.

Tese (Doutorado) - UFPB/CT.

1. Sistemas de abastecimento de água. 2. Medição indireta. 3. Soft sensor. 4. Redes neurais artificiais. I. Gomes, Heber Pimentel. II. Villanueva, Juan Moises Mauricio. III. Título.

UFPB/BC

CDU 628.1(043)

DESENVOLVIMENTO DE UM SOFT SENSOR PARA ESTIMAÇÃO DA VAZÃO EM SISTEMAS DE ABASTECIMENTO DE ÁGUA UTILIZANDO REDES NEURAIS ARTIFICIAIS

por




ROBSON PACÍFICO GUIMARAES LIMA

Tese aprovada em 12 de julho de 2022



Prof. Dr. HEBER PIMENTEL GOMES
Orientador - UFPB



Prof. Dr. FRANCISCO ANTONIO BELO
Examinador Interno - UFPB



Prof. Dr. MARCELO CAVALCANTI RODRIGUES
Examinador Interno – UFPB



Prof. Dr. KOJE DANIEL VASCONCELOS MISHINA
Examinador Externo – UFPB



Prof. Dr. JUAN MOISES MAURICIO VILLANUEVA
Examinador Externo – UFPB



Prof. Dr. SAULO DE TARSO MARQUES BEZERRA
Examinador Externo – UFPE

DEDICATÓRIA

Dedico este trabalho a meus pais que sempre acreditaram em mim.

Dedico também a todas as pessoas que colaboraram em algum momento na construção desta tese.

AGRADECIMENTOS

A minha mãe e a meu pai por tudo o que fizeram para que eu tivesse uma formação cidadã e consciente sempre na verdade.

Aos colegas do doutorado que me ajudaram de forma direta ou indireta quanto pagávamos as disciplinas obrigatórias do curso.

Aos meus amigos, em especial Thommas Kevin e Anne Louise, pelos auxílios fundamentais para que este trabalho de doutorado chegasse a se concretizar.

Ao professor Dr. Joafrâncio de Araújo pelos conselhos fundamentais na construção do texto deste trabalho.

Ao professor coorientador Dr. Juan Moisés Villanueva pela sua contribuição valiosa ao longo do desenvolvimento desta pesquisa e pela disposição, sem medir esforços, no que fosse necessário para o desenvolvimento do trabalho.

Ao professor orientador Dr. Heber Pimentel Gomes pelos conhecimentos transmitidos.

A todos os docentes do Programa de Pós-Graduação do Curso de Engenharia Mecânica da UFPB.

Ao Instituto Federal de Pernambuco (*campus* Ipojuca) por todo o apoio e incentivo para que meu curso de doutorado se tornasse realidade.

A todos e todas que auxiliaram, de alguma forma, na construção desta tese.

DESENVOLVIMENTO DE UM *SOFT SENSOR* PARA ESTIMAÇÃO DA VAZÃO EM SISTEMAS DE ABASTECIMENTO DE ÁGUA UTILIZANDO REDES NEURAIS ARTIFICIAIS

RESUMO

Um eficiente sistema de abastecimento de água é fundamental para a garantia de acesso a um recurso tão essencial à vida, seja nos mais diversos segmentos de consumo: residencial, comercial e industrial. Um sistema de abastecimento de água típico é composto por diversos elementos físicos (sensores, transdutores, válvulas, bombas etc.) e alguns desses elementos que compõem esse cenário possuem custos elevados e/ou instalação complexa. Desse modo, a técnica de medição indireta de uma determinada grandeza a partir de uma outra já conhecida pode ser utilizada como uma alternativa a fim de redução de custos com equipamentos que iriam promover aquela mensuração desejada. Esta técnica dispensaria a utilização de um determinado sensor direto na planta quando este dispositivo possui valor elevado de aquisição ou sua instalação for complexa do ponto de vista operacional. Desse modo, este trabalho possui como objetivo a implementação de um instrumento virtual (denominado de *soft sensor*) utilizando redes neurais artificiais capaz de estimar a vazão em uma planta que emula um sistema de abastecimento de água. A planta utilizada para a validação do *soft sensor* está instalada no Laboratório de Eficiência Energética e Hidráulica em Saneamento da Universidade Federal da Paraíba (LENHS/UFPB). Simulações computacionais e vários testes de laboratório foram realizados promovendo a comparação entre os valores mensurados por meio do *soft sensor* versus valores mensurados através de um sensor eletromagnético real de vazão e o maior valor referente ao erro máximo obtido foi de 4,7 l/s em um dos vários testes realizados com Erro Absoluto Médio Percentual de até 0,0023% em outro teste. Ademais, foram obtidos outros parâmetros robustos e os resultados obtidos corroboraram com a eficiência da técnica apresentada.

Palavras-Chaves: medição indireta, *soft sensor*, sistemas de abastecimento de água, redes neurais artificiais.

DEVELOPMENT OF A SOFT SENSOR FOR FLOW ESTIMATION IN WATER SUPPLY SYSTEMS USING ARTIFICIAL NEURAL NETWORKS

ABSTRACT

An efficient water supply system is essential to guarantee access to such an essential resource for life, whether in the most diverse consumer segments: residential, commercial and industrial. A typical water supply system is composed of several physical elements (sensors, transducers, valves, pumps, etc.) and some of these elements that make up this scenario have high costs and/or complex installation. In this way, the technique of indirect measurement of a certain quantity from another already known can be used as an alternative in order to reduce costs with equipment that would promote that desired measurement. This technique would dispense with the use of a specific sensor directly in the plant when this device has a high acquisition value or its installation is complex from an operational point of view. Thus, this work aims to implement a virtual instrument (called a soft sensor) using artificial neural networks capable of estimating the flow in a plant that emulates a water supply system. The plant used for the validation of the soft sensor is installed in the Laboratory of Energy and Hydraulic Efficiency in Sanitation of the Federal University of Paraíba (LENHS/UFPB). Computer simulations and several laboratory tests were performed promoting the comparison between the values measured through the soft sensor versus values measured through a real electromagnetic flow sensor and the highest value referring to the maximum error obtained was 4,7 l/s in one of several tests performed with Mean Percentage Absolute Error of up to 0.0023% in another test. Furthermore, other robust parameters were obtained and the results obtained corroborated the efficiency of the technique presented. Keywords: indirect measurement, soft sensor, water supply systems, artificial neural networks.

LISTA DE FIGURAS

Figura 1.1 – Ilustração de um Sistema típico de Abastecimento de Água (Salvino, 2012).....	2
Figura 1.2 – Esquema hidráulico de um sistema de bombeamento com motobomba afogada (Flores, 2021).....	4
Figura 3.1 – Esquema ilustrativo de um neurônio biológico (Ballini, 2000).....	17
Figura 3.2 – Esquema ilustrativo de um neurônio artificial (Ballini, 2000).....	17
Figura 3.3 – Estrutura de um controlador adaptativo básico (Tambara, 2018).....	20
Figura 3.4 – Controlador adaptativo direto (Tambara, 2018)	21
Figura 3.5 – Controlador adaptativo indireto (Tambara, 2018).....	21
Figura 3.6 – Controlador adaptativo por modelo de referência (Tambara, 2018).....	23
Figura 3.7 – Diagrama geral de um sistema de medição retroalimentado (adaptado de Morawski, 1994).....	30
Figura 4.1 – Elementos da bancada experimental (Flores, 2021).....	36
Figura 4.2 – Conjunto motor-bomba.....	37
Figura 4.3 – Inversor de frequência do sistema experimental.....	38
Figura 4.4 – Transdutor de pressão TP-ST18/ACROS.....	39
Figura 4.5 – Medidor de vazão eletromagnético (vista frontal e lateral)	40
Figura 4.6 – Válvula proporcional ARB24, Belimo.....	42
Figura 4.7 – <i>Interface</i> de aquisição, família NI-USB 62XX, <i>National Instruments Corporation</i>	43
Figura 4.8 – Painel frontal (sinótico) do supervisor utilizado.....	45
Figura 4.9 – Tela responsável por apresentar as curvas de estimação <i>versus</i>	45

vazão real no sistema

Figura 4.10 – Topologia da bancada experimental e do bloco estimador de vazão (adaptado de Flores, 2021).....	46
Figura 4.11 – Sistema retroalimentado para medição indireta da vazão.....	47
Figura 4.12 – Diagrama da RNA <i>Multi-layer Feedforward Backpropagation</i>	50
Figura 4.13 – Diagrama da RNA NARX.....	50
Figura 4.14 – Fluxograma para a concepção do <i>soft sensor</i>	51
Figura 4.15 – Estrutura da RNA <i>Multi-layer Feedforward Backpropagation</i> para estimação da vazão.....	55
Figura 4.16 – Estrutura da RNA NARX para estimação da vazão.....	56
Figura 5.1 – Pressão em PT3 com e sem pré-tratamento de dados para o ensaio A.....	59
Figura 5.2 – Ângulo de atuação da CV-1 com e sem pré-tratamento de dados para o ensaio A.....	61
Figura 5.3 – Vazão mensurada em FT-1 com e sem pré-tratamento de dados para o ensaio A.....	63
Figura 5.4 – Vazão medida e estimada durante a fase de teste da RNA <i>Multi-layer Feedforward Backpropagation</i> para o ensaio A.....	64
Figura 5.5 – Vazão medida e estimada durante a fase de teste da RNA NARX para a validação A.....	68
Figura 5.7 – Pressão mensurada em PT-3 com inserção de sinais espúrios do tipo ruídos.....	70
Figura 5.8 – Vazão medida e estimada durante a fase de teste da RNA NARX para ruídos.....	70
Figura 5.9 – Ângulo de CV-1 com inserção e identificação de ruídos.....	73
Figura 5.10 – Vazão estimada <i>versus</i> real para testes da validação C.....	74
Figura 5.11 – Frequência com inserção de sinais espúrios.....	76
Figura 5.12 – Vazão estimada <i>versus</i> real para testes da validação D.....	77
Figura 5.13 – Parâmetros de entrada com inserção de sinais espúrios.....	79
Figura 5.14 – Vazão estimada <i>versus</i> real para testes da validação E.....	80
Figura 5.15 – Respostas da planta controlada para diferentes valores desejados da pressão.....	83
Figura 5.16 – Vazão estimada <i>versus</i> real com a planta controlada para	83

diferentes valores desejados da pressão

Figura 5.17 – Respostas da planta controlada com variações abruptas de demanda de consumo.....	85
Figura 5.18 – Vazão estimada <i>versus</i> real com variações abruptas de demanda de consumo no sistema.....	86
Figura 5.19 – Sinal de PT-3 com inserção de <i>outliers</i> de acordo com cada degrau de <i>setpoint</i>	88
Figura 5.20 – Vazão estimada <i>versus</i> real mediante inserção de <i>outliers</i> em PT-3.....	88
Figura 5.21 – Sinal de CV-1 com inserção de <i>outliers</i>	91
Figura 5.22 – Vazão estimada <i>versus</i> real com inserção de <i>outliers</i> em CV-1 e segmentação de trechos de SP de pressão.....	92
Figura 5.23 – Sinal de CV-1 com inserção e identificação de <i>outliers</i>	95
Figura 5.24 – Vazão estimada <i>versus</i> real mediante inserção de <i>outliers</i> em CV-1e segmentação de trechos de SP de pressão.....	95
Figura 5.25 – Sinais de entrada frequência de rotação do CMB, ângulo da válvula CV-1 e pressão em PT-3 com ruídos.....	98
Figura 5.26 – Vazão estimada <i>versus</i> real para inserção ruídos nas três entradas do <i>soft sensor</i>	98
Figura A1 – Balança de peso morto utilizado para ajuste dos sensores de pressão (Flores, 2019).....	114
Figura A2 – Esquema de Detecção da corrente do Transdutor de Pressão (Flores, 2019).....	115
Figura A3 – Circuito condicionador de Sinal do Sensor de vazão (Fonte: Incontrol).....	116
Figura A4 – Diagrama de blocos do controlador IMRAC-PID (Flores, 2021).....	119

LISTA DE TABELAS

Tabela 3.1	– Valores de alguns medidores de vazão utilizados em SAA.....	31
Tabela 4.1	– Principais especificações técnicas do motor.....	37
Tabela 4.2	– Principais especificações técnicas da bomba.....	38
Tabela 4.3	– Principais especificações técnicas do inversor de frequência.....	38
Tabela 4.4	– Especificações técnicas do transdutor de pressão.....	40
Tabela 4.5	– Especificações técnicas do transdutor de vazão.....	41
Tabela 4.6	– Especificações técnicas da válvula de controle.....	42
Tabela 4.7	– Principais especificações técnicas das interfaces de aquisição de dados.....	43
Tabela 5.1	– Parâmetros utilizados para o ensaio A.....	59
Tabela 5.2	– Comparação entre o rastreamento do erro obtidos na estimação de vazão utilizando MLP e NARX para o ensaio A.....	61
Tabela 5.3	– Parâmetros utilizados para o teste relativo ao ensaio B.....	62
Tabela 5.4	– Comparação entre o rastreamento do erro obtidos na estimação de vazão utilizando RNA MLP e NARX para o ensaio B.....	64
Tabela 5.5	– Parâmetros utilizados para o teste relativo à validação A.....	66
Tabela 5.6	– Rastreamento do erro para o teste de validação A.....	68
Tabela 5.7	– Parâmetros para o teste da validação B.....	69
Tabela 5.8	– Rastreamento do erro para o teste de validação B.....	71
Tabela 5.9	– Parâmetros para o teste da categoria C.....	73
Tabela 5.10	– Rastreamento do erro para o teste de validação C.....	74
Tabela 5.11	– Parâmetros para o teste da categoria D.....	75

Tabela 5.12	– Rastreamento do erro para o teste de validação D.....	77
Tabela 5.13	– Parâmetros para o teste da categoria E.....	79
Tabela 5.14	– Rastreamento do erro para o teste de validação E.....	80
Tabela 5.15	– Parâmetros de entrada do <i>soft sensor</i> para diferentes valores de <i>setpoint</i> de pressão com ação do controlador.....	82
Tabela 5.16	– Métricas estatísticas do erro de rastreamento da vazão para diferentes valores desejados de pressão.....	84
Tabela 5.17	– Parâmetros de entrada do <i>soft sensor</i> com variações abruptas de demanda de consumo com ação do controlador.....	85
Tabela 5.18	– Métricas estatísticas do erro de rastreamento da vazão para demanda abrupta de consumo.....	86
Tabela 5.19	– Parâmetros de entrada do <i>soft sensor</i> incluindo sinais do tipo <i>outliers</i> em PT-3 com ação do controlador.....	87
Tabela 5.20	– Parâmetros de entrada do <i>soft sensor</i> incluindo sinais do tipo <i>outliers</i> em PT-3 com segmentação de degraus de pressão.....	89
Tabela 5.21	– Métricas estatísticas do erro de rastreamento da vazão mediante inserção de <i>outliers</i> em PT-3 para cada trecho da vazão estimada <i>versus</i> real apenas nos intervalos dos ruídos e em todos os pontos.....	91
Tabela 5.22	– Métricas estatísticas do erro de rastreamento da vazão mediante inserção de <i>outliers</i> em CV-1 para cada trecho da vazão estimada <i>versus</i> real apenas nos intervalos dos ruídos e em todos os pontos.....	92
Tabela 5.23	– Parâmetros de entrada do <i>soft sensor</i> incluindo sinais do tipo <i>outliers</i> na frequência de rotação do CMB.....	94
Tabela 5.24	– Métricas estatísticas do erro de rastreamento da vazão mediante inserção de <i>outliers</i> na frequência para cada trecho da vazão estimada <i>versus</i> real apenas nos intervalos dos ruídos e em todos os pontos.....	96
Tabela 5.25	– Parâmetros de entrada do <i>soft sensor</i> incluindo sinais espúrios em PT-3, CV-1 e frequência de rotação do CMB.....	97

Tabela 5.26	– Métricas estatísticas do erro de rastreamento da vazão mediante inserção de outliers em PT-3, CV-1 e frequência de rotação do CMB para cada trecho da vazão estimada versus real apenas nos intervalos dos ruídos e em todos os pontos.....	107
Tabela AI	– Testes para otimização dos parâmetros das RNAs.....	111

LISTA DE ABREVIATURA E SIGLAS

AC	<i>Alternating Current</i>
BST	<i>Booster</i>
CAGEPA	Companhia de Água e Esgotos da Paraíba
CMB	Conjunto Motor Bomba
CV	<i>Control Valve</i>
DAC	Dispositivo de Aquisição de Dados
DC	<i>Direct Current</i>
ETA	Estação de Tratamento de Água
FCM	<i>Fuzzy-C-medias</i>
FT	<i>Flow Transmitter</i>
IFPE	Instituto Federal de Pernambuco
IHM	Interface Humano Máquina
IP	Grau de proteção de motores elétricos
IMRAC-PID	<i>Model Reference Adaptive Control with PID</i>
LabVIEW	<i>Laboratory Virtual Instrument Engineering Workbench</i>
LENHS	Laboratório de Eficiência Energética e Hidráulica em Saneamento
LF	Lógica Fuzzy
LSTM	Long Short-Term Memory
MAPE	Mean Absolute Percentual Error
MATLAB	<i>MATrix LAboratory</i>
ME	Métrica estatística
MF	Função de Pertinência
MIMO	<i>Multiple Input Multiple Output</i>
MISO	<i>Multiple Input Single Output</i>
MLP BP	<i>Multilayer Perceptron Feedforward Backpropagation</i>

MRAC	<i>Adaptive Reference Model Controller</i>
MSE	<i>Mean Squared Error</i>
NARX	Neural-Autorregressivo com Entradas Exógenas
NI	<i>National Instruments</i>
PID	Proporcional-Integral-Derivativo
PPGEM	Programa de Pós-Graduação em Engenharia Mecânica
PT	<i>Pressure Transmitter</i>
RAM	<i>Random Access Memory</i>
RD	Ramal de Descarga
RNA	Rede Neural Artificial
SAA	Sistema de Abastecimento de Água
SAAEP	Serviço Autônomo de Água e Esgoto de Parauapebas
SABESP	Companhia de Saneamento Básico do Estado de São Paulo
SANEPAR	Companhia de Saneamento do Paraná
SP	<i>Setpoint</i>
UFPB	Universidade Federal da Paraíba
TM	Tabela de Mérito
VRP	Válvula Redutora de Pressão

LISTA DE SÍMBOLOS

A	Ampére
H	altura manométrica
H_g	altura geométrica
$\Sigma \Delta H_s$	somatório das perdas de cargas distribuídas e localizadas, na tubulação de sucção
$\Sigma \Delta H_r$	somatório das perdas de cargas distribuídas e localizadas, na tubulação de recalque
°C	Graus Celsius
cv	Cavalo-vapor
e	Erro
f(.)	Função de ativação da rede neural artificial
GB	gigabyte
GHz	gigahertz
h	hora
Hz	Hertz
I	Corrente
W_{ij}, W_{kj}	Pesos sinápticos
mA	miliampére
mca	Metro de coluna de água
mm	milímetro
ms	milisegundo
M_p	Valor de sobressinal
m ³	Metro cúbico
m ³ /h	Metro cúbico por hora
ns	nanosegundos
rpm	rotações por minuto
u	Potencial de ativação de uma rede neural artificial, Sinal de controle
V	Tensão
W_i	Matriz de pesos sinápticos entre a camada de entrada e a camada intermediária
W_s	Matriz de pesos sinápticos entre a camada de entrada e a camada de saída
y_r	Valor (resposta) real
μ	Taxa de aprendizagem de uma rede neural artificial
Σ	Combinador linear de uma rede neural artificial
β	Limiar de ativação (bias) de uma rede neural artificial

ε	Erro de rastreamento
α_1	Parâmetro de estimação 1
α_2	Parâmetro de estimação 2
α_3	Parâmetro de estimação 3
Υ	Coeficiente de aprendizado
J	Função custo
K_p	Ganho proporcional
K_i	Ganho integral
K_d	Ganho derivativo
$\Upsilon_{p,i,d}$	Ganhos de adaptação dos parâmetros do controlador
T	Período de amostragem
$H(.)$	Planta
a_p	Parâmetro da planta
b_p	Parâmetro da planta
y	Sinal de saída
Q	Vazão

SUMÁRIO

1 – INTRODUÇÃO.....	1
1.1 – OBJETIVOS.....	6
1.1.1 – OBJETIVO GERAL.....	6
1.1.2 – OBJETIVOS ESPECÍFICOS.....	6
1.2 – CONTRIBUIÇÕES DA PESQUISA.....	7
1.3 – PRODUTOS GERADOS.....	7
1.4 – ORGANIZAÇÃO DO TRABALHO.....	8
2 – REVISÃO BIBLIOGRÁFICA	9
3 – FUNDAMENTAÇÃO TEÓRICA.....	15
3.1 – INTRODUÇÃO.....	15
3.2 – SISTEMAS DE CONTROLE.....	15
3.2 – INTELIGÊNCIA ARTIFICIAL.....	16
3.2.1 – REDES NEURAIS ARTIFICIAIS.....	16
3.3 – CONTROLE ADAPTATIVO.....	19
3.3.1 – CONTROLE ADAPTATIVO DIRETO E INDIRETO.....	20
3.3.2 – CONTROLE ADAPTATIVO POR MODELO DE REFERÊNCIA.....	22
3.4 – ERRO ABSOLUTO E RELATIVO.....	23
3.5 – ERRO ABSOLUTO PERCENTUAL MÉDIO (MAPE).....	24

3.6 – ERRO QUADRÁTICO MÉDIO.....	24
3.7 – DESVIO PADRÃO.....	25
3.8 – SINAIS ESPÚRIOS.....	26
3.8.1 – <i>OUTILIERS</i>	26
3.8.2 – RUÍDOS GAUSSIANOS.....	28
3.4 – MEDIÇÃO INDIRETA DE GRANDEZAS FÍSICAS.....	29
3.5 – <i>SOFT SENSOR</i>	32
4 – MATERIAIS E MÉTODOS	35
4.1 – INTRODUÇÃO.....	35
4.2 – BANCADA EXPERIMENTAL.....	35
4.3 – METODOLOGIA APLICADA.....	45
4.3.1 – BLOCO DE RECONSTRUÇÃO DIRETA DA MEDIDA DE PRESSÃO.....	47
4.3.2 – BLOCO CORRESPONDENTE AO CONTROLADOR ADAPTATIVO.....	48
4.3.3 – BLOCO ASSOCIADO AO <i>SOFT SENSOR</i> (RECONSTRUÇÃO INDIRETA DA VAZÃO)	49
4.3.4 – IMPLEMENTAÇÃO DO <i>SOFT SENSOR</i> UTILIZANDO REDES NEURAIS ARTIFICIAIS.....	51
5 – PROCEDIMENTOS EXPERIMENTAIS E ANÁLISES DOS RESULTADOS	56
5.1 – INTRODUÇÃO.....	56
5.2 – ENSAIO A.....	58
5.2 – ENSAIO B.....	62
5.3 – VALIDAÇÃO DO <i>SOFT SENSOR</i>	64
5.3.1 – VALIDAÇÕES DO <i>SOFT SENSOR</i> SEM AÇÃO DO CONTROLADOR.....	65
5.3.1.1 – VALIDAÇÃO A.....	65
5.3.1.2 – VALIDAÇÃO B.....	68
5.3.1.3 – VALIDAÇÃO C.....	72
5.3.1.4 – VALIDAÇÃO D.....	75
5.3.1.5 – VALIDAÇÃO E.....	78

5.4.1 – VERIFICAÇÃO DA EFICIÊNCIA DO <i>SOFT SENSOR</i> COM A ATUAÇÃO DO CONTROLADOR NO SISTEMA.....	81
5.4.1.1 – ATUAÇÃO DO <i>SOFT SENSOR</i> PARA DIFERENTES VALORES DE <i>SETPOINT</i> DE PRESSÃO.....	81
5.4.1.2 – ATUAÇÃO DO <i>SOFT SENSOR</i> PARA VARIAÇÕES BRUSCAS DE DEMANDA DE CONSUMO.....	84
5.4.1.3 – ATUAÇÃO DO <i>SOFT SENSOR</i> PARA SINAIS ESPÚRIOS EM PT-3.....	86
5.4.1.4 – ATUAÇÃO DO <i>SOFT SENSOR</i> PARA SINAIS ESPÚRIOS EM CV-1.....	90
5.4.1.5 – ATUAÇÃO DO <i>SOFT SENSOR</i> PARA SINAIS ESPÚRIOS NA FREQUÊNCIA DE ROTAÇÃO DO CMB.....	93
5.4.1.6 – ATUAÇÃO DO <i>SOFT SENSOR</i> PARA SINAIS ESPÚRIOS EM SEUS SINAIS DE ENTRADA: PT-3, CV-1 e FREQUÊNCIA DE ROTAÇÃO DO CMB.....	96
6 – CONCLUSÕES E RECOMENDAÇÕES DE TRABALHOS FUTUROS	100
REFERÊNCIAS BIBLIOGRÁFICAS	102
AI – ANEXO I - TABELA DE MÉRITO PARA ESCOLHA DOS PARÂMETROS DAS RNAs.....	111
AII – ANEXO II – AJUSTES DOS TRANSDUTORES DE PRESSÃO E VAZÃO.....	114
II.A – AJUSTE DOS TRANSDUTORES DE PRESSÃO.....	114
II.B – AJUSTE DOS TRANSDUTORES DE VAZÃO.....	116
AIII – ANEXO III - CONTROLE ADAPTATIVO INDIRETO POR MODELO DE REFERÊNCIA.....	119

CAPÍTULO I

INTRODUÇÃO E OBJETIVOS

1.1 INTRODUÇÃO

A água é um recurso natural de fundamental importância para a sobrevivência humana e dos demais seres vivos e um bem tão relevante como esse deve ser preservado em relação ao seu uso consciente. A problemática do desperdício de água, não apenas relacionada ao desperdício doméstico (utilização excessiva de água para lavagem de calçadas, asseios demorados com registros abertos etc.) mas principalmente do desperdício do ponto de vista em sistemas de abastecimento (vazamentos em tubulações por exemplo) torna o problema muito mais elevado. A viabilização de meios que mitiguem o desperdício de água através de uma eficiente distribuição a um determinado local é de extrema importância, havendo a necessidade de um sistema eficiente de distribuição do recurso capaz de atender as demandas urbanas e rurais. Dessa forma, define-se por sistema de abastecimento de água o conjunto de obras, equipamentos e serviços destinados ao abastecimento de água potável a uma comunidade para fins de consumo doméstico, serviços públicos, consumo industrial e outras utilidades (Salvino, 2018). Essa água fornecida pelo sistema deverá ser, em quantidade suficiente e da melhor qualidade, do ponto de vista físico, químico e bacteriológico.

Em um contexto mais atual, de acordo com o Marco Legal do Saneamento Básico regido pelo Projeto de Lei nº 4.162/2019, dentre as metas estabelecidas, uma delas destaca-se que 99% da população brasileira deverá ter acesso à água potável em

suas residências até dezembro de 2033. Isso traz uma maior atenção ao aprimoramento/otimização de todos os elementos pertencentes aos sistemas de abastecimento de água existentes, incluindo constantes atualizações nas técnicas de mensuração da vazão e outras grandezas nestas redes.

De maneira geral, um Sistema de Abastecimento de Água (SAA) representa todo o processo de fornecimento de água tratada compreendendo desde sua obtenção até sua utilização por parte da população. O sistema definido anteriormente pode ser ilustrado por meio da Figura 1.1.




Figura 1.1 - Ilustração de um Sistema típico de Abastecimento de Água (Salvino, 2012).

Os principais elementos que constitui um SAA são descritos a seguir:

- **Captação:** consiste no conjunto de equipamentos (bombas por exemplo) e instalações (tubulações por exemplo) utilizados para a extração de água de uma determinada fonte (manancial);
- **Estação Elevatória e Adução da Água bruta:** responsáveis pelo recalque (condução) de água da captação até a(s) estação(ões) de Tratamento de água (ETA) ou até o(s) reservatório(s) de água;
- **Estação de Tratamento de Água:** local em que realiza a purificação da água captada de alguma fonte para torná-la própria para o consumo;

- **Reservação:** é a etapa destinada ao armazenamento da água bombeada da fonte ou da ETA, de forma a manter as pressões na rede de distribuição sempre constantes e a atender as variações de consumo durante os horários de maior demanda de consumo. As variações acontecem de acordo com os hábitos da comunidade, o clima e até mesmo a qualidade da água. As unidades físicas destinadas para fins de armazenamento da água são denominadas de **reservatórios**.

A água armazenada no reservatório de distribuição após as etapas de captação, elevação/adução e ETA pode ser pressurizada na tubulação por meio de duas maneiras: gravidade e/ou através de um conjunto motor-bomba (CMB). Por gravidade, a água é transportada até o consumidor sem a necessidade da utilização de energia elétrica. Por outro lado, no segundo caso, necessita-se de um sistema de impulsão artificial, isto é, por uma motobomba hidráulica acoplada a um motor elétrico (CMB) e/ou por meio de um *booster* (BST) (Salvino, 2018).

Geralmente, as bombas utilizadas são do tipo centrífuga. Estas aceleram o fluido através da força centrífuga fornecida pela rotação do rotor convertendo a energia cinética internamente em energia de pressão na saída do rotor mediante a carcaça da bomba. O rotor é o elemento da bomba que possui a responsabilidade de transferir para o fluido o movimento de rotação, e dessa forma, promovendo a conversão da energia mecânica em energia cinética (Tsutiya, 2006). Quando a bomba é instalada de modo intercalado na tubulação a mesma é denominada de *booster*, e possui como função aumentar a energia de pressão, contribuindo para o escoamento do fluido (Salvino, 2018).

A energia que ambos os métodos de impulsão (CMB ou BST) deve fornecer ao fluido deve ser suficiente para vencer a **altura geométrica de sucção**, isto é, a altura em metros entre o nível dinâmico da captação e o bocal de sucção da bomba; a **altura geométrica de recalque**, ou seja, a distância entre o bocal de sucção da bomba de água até a saída da tubulação de descarga; as **perdas de cargas** que correspondem às perdas de energia que um fluido, em uma tubulação sob pressão, sofre em razão de vários fatores como atrito ou turbulência devido às mudanças de direção do traçado da rede e, por fim, as **cargas cinéticas**, que correspondem a soma de alguns fatores contidos na seção transversal do canal durante o escoamento da água. O carregamento superado pelo CMB é denominado de **altura manométrica** (em metros).

O esquema hidráulico típico representativo de um sistema com CMB pode ser visualizado por meio da Figura 1.2 e a altura manométrica pode ser representada por meio da Equação 1.1.




Figura 1.2 - Esquema hidráulico de um sistema de bombeamento com motobomba afogada (Flores, 2021).

$$H = H_g + \sum \Delta H_s + \sum \Delta H_r + \frac{v_r^2}{2g} \quad (1.1)$$

em que:

H = altura manométrica (m);

H_g = altura geométrica (m);

$\sum \Delta H_s$ = somatório das perdas de cargas distribuídas e localizadas, na tubulação de sucção (m);

$\sum \Delta H_r$ = somatório das perdas de cargas distribuídas e localizadas, na tubulação de recalque (m);

$\frac{v_r^2}{2g}$ = carga cinética no recalque (m).

Uma alternativa para o controle da pressão nos SAAs consiste na aplicação de mecanismos para controlar a velocidade de rotação dos motores elétricos e consequentemente a energia hidráulica fornecida pelas bombas. Para esta finalidade geralmente são adotados inversores de frequência (Brogan *et al.*, 2016) (Sousa *et al.*, 2017). Esses dispositivos convertem uma dada tensão em uma outra com amplitude e

frequência desejada (controlada). Ao ser utilizado para acionar um conjunto motobomba, o inversor de frequência é capaz de promover o gerenciamento dos parâmetros elétricos e hidráulicos de uma estação de bombeamento, pois ao regular a velocidade de rotação regula-se também a altura manométrica (atuando na pressão), vazão e potência elétrica associados (Flores, 2021) (Salvino 2018). A energia despendida para promover o aumento da vazão e da pressão hidráulica depende da velocidade de rotação do conjunto motobomba.

Entre as diversas técnicas para esse controle em específico, destacam-se pela quantidade de trabalhos, as técnicas que utilizam Controle Fuzzy, PID, Redes Neurais Artificiais, Controle Adaptativo e Controlador por Modelo Preditivo. A escolha de qual controlador deva ser utilizado em um SAA depende de suas limitações e vantagens uma em relação a outra na aplicação.

Dentre os controles citados, o controle adaptativo é o que apresenta a maior capacidade de generalização, pois seu mecanismo de adaptação pode alterar os ganhos do controlador a partir das mudanças que ocorrem no sistema ao longo do tempo, sem necessariamente haver uma coleta de dados prévia para a modelagem (Flores, 2021) (Silva, 2014). Esse fator é importante para aplicações em SAA. Assim, esse tipo de controle foi utilizado para manter a pressão estabilizada no SAA da bancada experimental e essa pressão foi utilizada em um subconjunto de testes na bancada experimental para validação do instrumento virtual de vazão, escopo central deste trabalho.

Contextualizando para o escopo central desta tese, a técnica de estimação da vazão a partir de variáveis conhecidas (pressão, frequência de rotação de um conjunto motor-bomba etc.) comumente mensuradas em um SAA através de elementos reais pode dispensar a aquisição de instrumento(s) físico(s) de vazão, permitindo redução de custos bem como da eliminação da instalação física desse tipo de sensor.

Assim, a validação do *soft sensor* implementado nesta pesquisa foi realizada em um sistema de abastecimento de água localizado no Laboratório de Eficiência Energética e Hidráulica em Saneamento (LENHS) da Universidade Federal da Paraíba. As análises realizadas mediante comparações com resultados obtidos via medição indireta e medição por meio de um instrumento real de vazão presente no sistema comprovaram a eficiência da técnica de estimação.

1.2 OBJETIVOS

1.2.1 OBJETIVO GERAL

Desenvolver um instrumento virtual, denominado de *soft sensor*, capaz de estimar a vazão em um sistema de abastecimento de água, a fim de reduzir os custos de aquisição de medidores reais de vazão bem como da complexidade de instalação desses instrumentos em determinados locais da planta.

1.2.2 OBJETIVOS ESPECÍFICOS

- Comparar duas estruturas baseadas em Redes Neurais Artificiais: a RNA Multicamada *Backpropagation* e a RNA Não Linear Autorregressiva com Entradas Exógenas para exercer o papel de um *soft sensor* que irá estimar a vazão em um sistema de abastecimento de água;
- Validar, por meio de testes em laboratório, o *soft sensor* desenvolvido sem ação de controle na planta, considerando simulação de demanda brusca de consumo e inserção de sinais espúrios do tipo *outliers* e ruídos na(s) entrada(s) do instrumento virtual;
- Validar, por meio de testes em laboratório, o *soft sensor* desenvolvido com a ação de controle na planta, considerando mudanças no valor de *setpoint* de pressão, demandas bruscas de consumo de água e inserção de sinais espúrios do tipo *outliers* e ruídos na(s) entrada(s) do instrumento virtual;
- Avaliar a exatidão do *soft sensor* com respeito à mensuração indireta da vazão utilizando como método de análise estatística o Erro Médio Quadrático para todos os testes a serem realizados.

1.3 CONTRIBUIÇÕES DA PESQUISA

Ao final deste trabalho, espera-se propor uma ideia metodológica para estimação da vazão em sistemas de abastecimento de água contribuindo para a solução de algumas lacunas existentes em trabalhos anteriores, no que concerne à ausência de testes mais robustos para validação de instrumentos virtuais (sejam medidores de vazão, temperatura etc.) mediante condições de entradas severas tais como *outliers* e ruídos tanto intermitentes quanto contínuos. Também é esperada uma contribuição para a redução do dispêndio com instrumentos reais de vazão e consequente eliminação da problemática operacional de instalação física desses instrumentos. Ademais, a pesquisa permite a colaboração para a virtualização de sensores físicos, permitindo uma contribuição para a construção de Gêmeos Digitais (*digital twins*), tecnologia emergente da Indústria 4.0.

1.3.1 PRODUTOS GERADOS

Nesta seção são apresentados os produtos gerados durante o curso de doutorado.

- **[Publicado]** LIMA, R.P.G., VILLANUEVA, J.M.M., GOMES, H.P., FLORES, T.K.S., 2022, “Development of a Soft Sensor for Flow Estimation in Water Supply Systems Using Artificial Neural Networks”. *Sensors* 2022, 22(8), 3084; <https://doi.org/10.3390/s22083084>.
- **[Submetido]** LIMA, R.P.G., VILLANUEVA, J.M.M., GOMES, H.P., FLORES, T.K.S 2022, “Avaliação da Robustez de um Controlador Adaptativo para Entradas Caóticas em Sistemas de Abastecimento de Água”. In: Congresso Brasileiro de Automática, CBA. Fortaleza, Brasil.
- **[Aceito]** OLIVEIRA, A.L.M.B., GOMES, H.P., VILLANUEVA, J.M.M., LIMA, R.P.G., FLORES, T.K.S 2022, “Estimação de Rugosidade em Sistemas de Abastecimento de Água Utilizando o Algoritmo Refletiva da Região de Confiança e Gêmeo Digital”. In: Congresso Nacional de Engenharia Mecânica, CONEM, Teresina, Brasil.

- [Submetido] OLIVEIRA, A.L.M.B., GOMES, H.P., VILLANUEVA, J.M.M., LIMA, R.P.G., FLORES, T.K.S 2022, “Estimação de Rugosidade em Sistemas de Abastecimento de Água Utilizando Gêmeo Digital”. In: Congresso Brasileiro de Automática, CBA. Fortaleza, Brasil.

1.4 ORGANIZAÇÃO DO TRABALHO

O trabalho está segmentado em 6 capítulos e eles serão descritos de maneira concisa a seguir:

Este capítulo 1 aborda a parte introdutória do trabalho bem como o objetivo geral, os objetivos específicos, as contribuições da pesquisa e os produtos gerados ao longo do curso de doutorado;

No capítulo 2 será apresentada a revisão bibliográfica do estado da arte de algumas técnicas de controle utilizadas em sistemas de abastecimento de água e de alguns estudos relativos à estimação de grandezas comumente utilizada em sistemas de abastecimento de água, bem como as lacunas de alguns trabalhos já realizados na área de estimação de grandezas comumente utilizadas em sistemas de abastecimento de água;

No capítulo 3 será apresentada a fundamentação teórica acerca de sistemas de controle em geral, inteligência artificial (com foco em redes neurais artificiais), estudo do controlador adaptativo (utilizado neste trabalho), conceitos importantes sobre algumas métricas estatísticas utilizada, estudo dos sinais espúrios aplicados bem como o conceito de medição indireta de grandezas físicas. Essas abordagens são fundamentais para o entendimento do trabalho desenvolvido.

No capítulo 4 será descrita a bancada experimental utilizada para a realização dos testes bem como das etapas envolvidas para a concepção do *soft sensor*.

No capítulo 5 será descrito todos os experimentos realizados para a validação do *soft sensor* assim como as análises dos resultados obtidos.

No capítulo 6 serão apresentadas as conclusões e recomendações de trabalhos futuros.

CAPÍTULO II

REVISÃO BIBLIOGRÁFICA

2.1INTRODUÇÃO

Sistemas de controle e automação passaram a ter um papel mais decisivo desde a Revolução Industrial no final do século XVIII, quando houve a necessidade de tornar a operação dos processos industriais mais simples e econômica, além de versátil e confiável. A sua aplicabilidade concerne desde os robôs industriais, linhas de montagem de automóveis, manufaturas de circuitos eletrônicos, refinarias de petróleo, siderúrgicas, usinas de geração de energia, petroquímicas, estações de tratamento e sistemas de abastecimento de água e demais aplicações.

Sistemas de Abastecimento de Água (SAA) e diversos outros sistemas (óleo e gás, esgotos etc.) necessitam de um sistema de controle e automação com capacidade de supervisionar e monitorar as diversas variáveis do processo, tais como vazão, pressão, temperatura etc. (Quevedo *et al.*, 2014). Automatizar um SAA é uma forma de promover a eficiência energética e hidráulica deste sistema (Salvino, 2018).

Para o processo de automação de um SAA faz-se necessária a aquisição de equipamentos (sensores, bombas, controladores, tubulações etc.), montagem (instalações de tubulações e acessórios) e, ainda, instalações elétricas (proteção de dispositivos, cabeamento etc.) demandando custos materiais e mão-de-obra especializada. Muitas vezes, a aquisição de determinados instrumentos de medição de grandezas fundamentais a um SAA pode elevar ainda mais os custos já citados. Promover técnicas que auxiliem na redução da aquisição de instrumentos de custos

elevados sem comprometer a eficiência referente à mensuração correta das grandezas em um sistema automatizado é de grande relevância.

Diferentes tecnologias podem ser utilizadas em medição de grandezas de interesse em SAA. A vazão, por exemplo, é a terceira grandeza mais mensurada nos processos industriais (após pressão e nível) e as aplicações são vastas, desde aplicações como a medição de vazão de água em estações de tratamento e residências até medição de gases industriais e combustíveis (Adnormas, 2022). Uma das maneiras em se mensurar a vazão em SAA é por intermédio de tecnologias que utilizam princípios eletromagnéticos. Com relação às tecnologias que empregam esses princípios, os equipamentos associados possuem maiores custos de aquisição e instalação, dependendo do diâmetro da instalação e, conseqüentemente, do volume a ser mensurado (Zhao, *et al.*, 2021) (Cabral, *et al.*, 2019) (Mazur *et al.*, 2018). Em relação aos instrumentos que utilizam a tecnologia de sinais ultrassônicos não invasivos há, também, a problemática do custo elevado de aquisição desses instrumentos.

2.2 REVISÃO BIBLIOGRÁFICA

Contextualizando para o trabalho descrito nesse documento, diversas publicações apresentaram aplicações de técnicas de controle em conjunto com inversores de frequência visando o controle das pressões em redes de abastecimento de água. Alguns desses trabalhos foram úteis na construção da base teórica auxiliar para a tese. Também foi possível a análise de alguns trabalhos que aplicaram técnicas de estimação indireta para mensurar grandezas físicas em sistemas de abastecimento de água que serviram de base principal para o estudo do trabalho. Nesse contexto, alguns desses estudos são descritos a seguir:

Valentin e Denoeux (2001) utilizaram RNAs para promover o controle de coagulação em estações de tratamento de água potável. Foi utilizado um sensor virtual constituído por um sistema híbrido incluindo um mapa da região para validação dos dados e reconstrução de dados ausentes. O modelo utilizado foi o perceptron de múltiplas camadas (MPL) que serviu para modelar o processo de coagulação. O sistema foi capaz de considerar várias fontes de incerteza, como dados de entrada atípicos, erros de medição e conteúdo de informação limitado do conjunto de treinamento.

Kadlec *et al.* (2009) discutiram as possíveis aplicabilidades dos *soft sensors* na indústria utilizando as características dos dados de processo que são críticas para o desenvolvimento dos instrumentos virtuais baseados em dados. Essas características são comuns a um grande número de campos da indústria de processo, como a indústria química, indústria de bioprocessos, indústria siderúrgica, etc. O foco do trabalho, de natureza teórica, foi evidenciado nos *soft sensors* baseados em dados por causa de sua popularidade e potencial crescentes.

Bezerra (2009) implementou um sistema fuzzy, que foi desenvolvido no ambiente Labview, para o controle piezométrico de sistemas de distribuição de água por meio do uso simultâneo de válvulas de controle e conversores de frequência acoplados a conjuntos motor-bomba, visando à economia de água e energia elétrica. O inversor de frequência manteve a altura manométrica do sistema de bombeamento em um valor ótimo (mínimo possível), enquanto as válvulas de controle possuíram a função de eliminar o excesso de pressão em diversos pontos do sistema. O sistema de controle foi formado por dois controladores fuzzy acoplados. O autor concluiu que o desempenho do sistema fuzzy se mostrou satisfatório, havendo a possibilidade de ser implementado em outros sistemas de distribuição de água similares, a fim de proporcionar redução do consumo de água e energia elétrica, diminuição nos custos de manutenção e aumento do grau de confiabilidade do sistema.

Isaac *et al.*, (2013) implementaram um algoritmo de Controle Adaptativo por Modelo de Referência (MRAC) para um sistema de tanques cônicos de água. Este controlador é comparado com um controlador Proporcional e Integral (PI) sintonizado pelo método de Ziegler Nichols. O MRAC apresentou melhor desempenho, pois o controlador PI apresentou Erro Integral Quadrado 4,62 vezes maior do que o valor adquirido no ensaio do controlador MRAC.

Kallesøe, Jensen e Wisniewski (2015) estudaram o gerenciamento da pressão nas redes de distribuição água sem reservatórios elevados, onde a pressão é controlada por uma única estação de bombeamento. Para isto, foi utilizado um Controle Adaptativo por Modelo de Referência. O controlador manteve, apesar das variações da demanda de água, a pressão constante ao longo de 50 dias, sendo robusto a perturbações e mudança no perfil de consumo da região estudada.

Xu *et al.*, (2015) propuseram um modelo NARX (Nonlinear Auto-Regressive with Exogenous Inputs) de RNA para previsão e controle em tempo real em uma aplicação de um SAA. O modelo desenvolvido estimou a demanda de consumo variável

no tempo de forma equivalente, explorando os dados operacionais de pressão e vazão como entradas em tempo real e históricos e estabeleceu uma relação funcional entre as principais variáveis da rede a partir da pressão. Além disso, foi proposto um esquema de treinamento para a RNA com uma combinação de treinamento de dados *offline* e treinamento de dados *online*. Os resultados demonstraram que o modelo foi considerado aplicável no que concerne ao rastreamento e previsão de falhas na rede. Embora os objetivos da pesquisa foram alcançados segundo os autores, eles não implementaram a técnica com outras variáveis associadas a um SAA típico, tais como frequência de rotação dos motores que impulsionam a água, válvulas redutoras de pressão, válvulas solenoides etc., e não promoveram um estudo comparativo entre algumas RNAs para verificar a eficiência dentre elas para o propósito do estudo. Também não está descrito no trabalho se o sistema foi validado com perturbações nas entradas ou sinais espúrios que poderiam comprometer a eficiência do sistema perante essas condições indesejáveis.

Rodriguez *et al.*, (2016) propuseram uma metodologia para detectar dados falsos e substituir dados ausentes ou falsos (reconstrução de dados segundo os autores) em medições de dados de vazão em um SAA localizado na cidade de Barcelona, Espanha. Utilizando RNA MLP BP (Multicamada *Backpropagation*) e Algoritmos Genéticos, os autores modelaram séries temporais geradas a partir de medições de transdutores de vazão localizados na planta e utilizaram intervalos de confiança (valores dentro de uma faixa pré-estabelecida como aceitáveis) para validar as informações. Os autores, no entanto, não realizaram estudos comparativos entre outras RNAs para verificar qual delas seria mais eficiente na aplicabilidade da pesquisa. Ademais, não está descrito na publicação se o sistema implementado foi experimentado com perturbações nas entradas, *outliers* ou sinais espúrios que poderiam comprometer a eficiência desse sistema.

Gwaivangmin e Jiya (2017) realizaram estudos acerca da previsibilidade de futuras demandas de água em uma rede de distribuição (localizada na cidade de Laminga na Nigéria) utilizando RNA. Eles utilizaram o software NeuNETPro 2.3 e desenvolveram um modelo baseado em registros históricos de demanda de água utilizando 15 nós de demanda de pressão. Os resultados obtidos serviram para o modelo realizar o controle e a supervisão dos parâmetros hidráulicos dos nós de demanda e reduziu o custo de produção da água. Estimadores de pressão foram utilizados como alternativas aos complexos modelos matemáticos e não linearidades encontradas na

planta. No entanto, os autores não utilizaram outros parâmetros de estimação a fim de verificar se o produto desenvolvido pudesse atingir maior otimização e o trabalho não faz menção a testes com sinais espúrios em determinadas entradas.

Salvino (2018) desenvolveu um sistema de controle inteligente, utilizando a técnica de Redes Neurais Artificiais, para operar uma rede pressurizada de distribuição de água com duas regiões de consumo com topografias distintas. Com a implementação do sistema de controle foi observada a redução do custo de energia do bombeamento para diversos cenários operacionais realizados.

Uma aplicação de instrumentação virtual foi realizada por (González, Jiménez e De Frutos, 2020) em que eles conseguiram classificar a categoria de veículos (passeio, caminhão etc.) que trafegam em uma rodovia. O critério para essa classificação foi baseado em um sistema com um transdutor piezoelétrico capaz de realizar funções automáticas e quase instantâneas de acordo para a categoria de veículo que circulava na estrada. A aplicação, embora não esteja relacionada à SAA, auxiliou acerca dos conceitos e reforço de técnicas de estimação em áreas distintas.

Flores *et al.*, (2020) propuseram um sistema com realimentação utilizando RNA e controlador utilizando Lógica Fuzzy para estimação indireta da vazão em uma rede de abastecimento de água. Os autores utilizaram um sistema MISO (*multiple inputs single output*) para estimar o valor de vazão a partir da frequência de rotação de um conjunto motor-bomba e da pressão existente na planta. Os resultados foram satisfatórios alcançando o objetivo proposto nos testes ao qual a técnica foi experimentada. No entanto, os autores não submeteram o produto final a testes que continham entradas com *outliers* ou ruídos que poderiam comprometer a eficiência da técnica perante essas adversidades e não inseriram outras entradas para análise do sistema. O sistema ficou limitado a apenas duas entradas.

Fontes (2020) propôs uma técnica para estimação indireta da temperatura baseada em algoritmo híbrido usando *Fuzzy c-médias* (FCM) e modelo exógeno autorregressivo não linear (NARX) com RNA para construir um sensor virtual capaz de prever a temperatura de ferro gusa - liga de ferro, resultado da redução do minério de ferro ao absorver carbono, em um alto-forno - e o teor de silício no material para um intervalo de amostragem regular em um auto-forno industrial. O FCM é uma técnica de modelagem de dados que se baseia em gerar grupos de subconjuntos nos quais os elementos pertencentes a um mesmo subconjunto apresentam maior semelhança entre si que os elementos pertencentes a qualquer outro subconjunto. O modelo neural objetivou gerar um modelo de predição dos indicadores. Os resultados obtidos demonstraram a técnica proposta apresentou um alto desempenho, tendo

um coeficiente de determinação para a predição para a temperatura e teor de silício no gusa de 99,7% e 99,6%, respectivamente. A aplicação, embora não esteja relacionada à SAA, auxiliou aos conceitos e reforço de técnicas de estimação em áreas distintas.

Liu *et al.*, (2021) desenvolveram um controlador adaptativo para utilização simultânea do gerenciamento da altitude e de vibrações para uma espaçonave em um espaço tridimensional, sujeito a perturbações de entradas e falhas desconhecidas. A dinâmica do sistema foi modelada como um espaço dimensional infinito, utilizando equações diferenciais parciais. A estratégia de controle adaptativa foi implementada para suprimir as vibrações do painel flexível da espaçonave durante a estabilização de altitude. Diversas simulações foram realizadas e os resultados obtidos comprovaram a eficiência da proposta de controle adaptativo implementada.

Nair *et al.*, (2022) implementaram um *soft sensor* para a estimação da quantidade total de fósforo (TP) e demanda química de oxigênio (DQO) nos córregos e afluentes de uma ETE (estação de tratamento de efluentes) em um pequeno município norueguês. Foi desenvolvido um modelo matemático identificando correlações estatísticas para alimentação dos dados do sensor virtual. Os dados obtidos com as medições virtuais foram comparados com medições físicas das variáveis demonstrando resultados esperados com relação à estimação das grandezas mensuradas.

Neste trabalho, é proposta a concepção de um instrumento virtual, denominado de *soft sensor*, capaz de mensurar (de maneira indireta) a vazão a partir de vários parâmetros de entrada comumente utilizadas em sistemas de abastecimento de água. A bancada experimental utilizada emula um sistema típico de distribuição de água. Assim, objetivou-se com a implementação do *soft sensor*, avaliar o desempenho do instrumento virtual mediante diversos cenários de atuação do sistema, tais como sem ação de controle na planta, com ação de controle na planta bem como a inserção de perturbações do tipo *outliers* e ruídos no sistema. Os *outliers* e ruídos podem ocorrer em instrumentos reais comumente encontrados em sistemas de abastecimento de água e podem comprometer a mensuração correta de grandezas físicas. Assim, almejou-se, como uma das contribuições deste trabalho, o preenchimento de algumas lacunas encontradas em vários trabalhos pertinentes ao tema.

CAPÍTULO III

FUNDAMENTAÇÃO TEÓRICA

3.1 INTRODUÇÃO

Este capítulo aborda os temas que norteiam a base teórica desta pesquisa. Assim, foi realizado um estudo acerca dos sistemas típicos de controle com foco em controle adaptativo; conceitos essenciais de inteligência artificial com foco em Redes Neurais Artificiais; definições acerca de algumas métricas estatísticas utilizadas na pesquisa e a teoria acerca de mensuração indireta de grandezas físicas com foco em sistemas de abastecimento de água.

3.2 SISTEMAS DE CONTROLE

Um sistema de controle é o conjunto de equipamentos e dispositivos que gerenciam (controlam) o comportamento automático de máquinas, componentes elétricos ou outros sistemas físicos dinâmicos. Por meio do monitoramento das variáveis de entrada, o controlador emite um sinal para controlar as variáveis de saída, visando mantê-las dentro de valores pré-estabelecidos pelo projetista. Em termos de eficiência do controlador, o mesmo pode ser avaliado segundo o seu desempenho em regime transitório, permanente ou em relação aos distúrbios, por meio das respostas

apresentadas pelo sistema controlado. A análise em regime transitório e em regime permanente são comumente utilizadas para verificar e comparar o desempenho de sistema de controle e controladores (Moreira, 2020).

Os sistemas em malha fechada podem operar de diversas formas mediante o algoritmo de programação proposto no que se refere ao controlador utilizado. Algumas das técnicas de controle comumente utilizadas são: *on-off* (liga-desliga), proporcional, integral, derivativo, ou ainda combinações dos três anteriores, conhecido como PID, controle adaptativo ou ainda, por meio de técnicas de inteligência artificial como a Lógica *Fuzzy*, as Redes Neurais Artificiais (RNA) ou até mesmo pela combinação destes (Neuro-Fuzzy). Neste trabalho, um controlador do tipo adaptativo foi utilizado para promover o controle da planta e atuar como auxiliar na reconstrução dos valores de vazão na bancada experimental.

3.3 INTELIGÊNCIA ARTIFICIAL

Uma área que tem apresentado um grande avanço nos últimos anos é o da inteligência artificial com suas vertentes nas Redes Neurais Artificiais, nos Sistemas Nebulosos (lógica *Fuzzy*) e nas suas hibridizações (Ballini, 2000). Essas vertentes têm motivado inúmeros trabalhos e uma larga gama de aplicações vêm sendo propostas na literatura. Um dos principais objetivos das pesquisas em inteligência artificial é o de criar sistemas computacionais que emulem características especiais inerentes aos seres humanos, como aprendizado, intuição, raciocínio lógico aproximado, capacidade de generalização, entre outras (Moreira, 2020).

3.3.1 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, axônio e dendrito, respectivamente. 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. As Figuras 3.1 e 3.2 ilustram

uma configuração típica de um neurônio biológico e de um neurônio artificial, respectivamente.




Figura 3.1 - Esquema ilustrativo de um neurônio biológico (Ballini, 2000).




Figura 3.2 - Esquema ilustrativo de um neurônio artificial (Ballini, 2000).

Base do sistema nervoso biológico, o neurônio é a célula característica do sistema nervoso com a capacidade de estabelecer conexões entre si ao receber estímulos do ambiente externo ou do próprio organismo. Essas estruturas são responsáveis por transmitir os impulsos nervosos ao cérebro. O ser humano, por exemplo, possui cerca de 86 bilhões de neurônios e sua estrutura é tipicamente a mesma: a existência de um corpo celular, que acomoda o núcleo e as organelas celulares; o axônio, uma prolongação única, revestida de mielina (camada lipídica que atua na condução dos impulsos nervosos) e responsável por conduzir os impulsos; e os dendritos, que são ramificações

tanto do corpo celular quanto do axônio e realizam a comunicação entre os neurônios, por meio das sinapses. Essa estrutura pode ser visualizada novamente pela Figura 3.1.

Uma RNA é composta por uma rede variada de neurônios organizados em camadas, interligados entre si por entrada(s) e saída(s), a qual 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 (Moreira, 2020). Essa estrutura pode ser visualizada novamente pela Figura 3.2.

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) x_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_k do neurônio. Tipicamente a excursão da ativação dos neurônios é confinada ao intervalo $(0, 1)$ ou $(-1, 1)$ (Ballini, 2000).

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.

Por fim, 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 (Ballini, 2000).

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 (Moreira, 2020). 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 o 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.

3.4 CONTROLE ADAPTATIVO

Na linguagem atual, o termo “adaptativo” significa uma modificação do comportamento de algum ente (pessoa, local, situação etc.) de acordo com as novas circunstâncias ou situações ao qual este ente está sendo exposto. No contexto de engenharia, controle adaptativo pode ser definido como uma técnica de controle que possui a capacidade de mudar seu comportamento de acordo com as modificações dos parâmetros, da dinâmica de um processo ou por distúrbios que afetam o sistema (Tambara, 2018). Um controlador adaptativo deve ter a capacidade de atualizar sua lei de controle por meio da mudança dos seus ganhos (ou parâmetros) em tempo real.

A Figura 3.3 ilustra um controlador do tipo adaptativo básico onde um mecanismo de ajuste de ganhos atualiza o controlador a partir da medição dos sinais de entrada u e saída y e de um sinal de referência r .




Figura 3.3 - Estrutura de um controlador adaptativo básico (Tambara, 2018).

Em aplicações que envolvam SAA parâmetros externos tais como, temperatura, desgaste dos equipamentos e perturbações podem alterar a dinâmica operacional do sistema. Assim, a utilização de controladores com ganhos estáticos, nestes cenários, acaba não sendo convenientes pois estes são sintonizados considerando que o sistema é invariante no tempo e/ou apenas para uma faixa específica de operação (Flores, 2021). Para realizar o controle destas categorias de sistema, os controladores com ganhos adaptáveis se sobressaem aos de ganhos estáticos, uma vez que possuem a capacidade de modificar os seus parâmetros mediante as alterações sofridas pelo sistema (Åström e Wittenmark, 2013).

3.4.1 CONTROLE ADAPTATIVO DIRETO E INDIRETO

Os controladores adaptativos podem ser divididos em dois grandes grupos: os diretos e os indiretos (Tambara, 2018). No método direto, os ganhos do controlador são estimados diretamente a partir de um modelo de referência pré-estabelecido, ou seja, não é necessário realizar a identificação dos parâmetros da planta (Flores *et al.* 2021). Considerando um sinal de referência r e uma saída y , no método direto, os ganhos do controlador (vetor θ) são estimados diretamente, normalmente, a partir de um modelo de referência pré-estabelecido, ou seja, não há a necessidade da estimação direta dos

parâmetros da planta. A Figura 3.4 ilustra a representação de um controlador adaptativo direto.




Figura 3.4 - Controlador adaptativo direto (Tambara, 2018).

No método indireto, o modelo da planta é determinado em função do vetor desconhecido de parâmetro da planta, exigindo um estimador em tempo real, utilizando a entrada e a saída dos sinais da planta. Portanto, o modelo gerado é tratado como verdadeiro e seus parâmetros são utilizados para o cálculo das variáveis do controlador. A Figura 3.5 ilustra a representação de um controlador adaptativo indireto.




Figura 3.5 - Controlador adaptativo indireto (Tambara, 2018).

Nesse método, inicialmente a lei de estimação paramétrica é utilizada para estimar os parâmetros da parte modelada da planta (vetor θ_p) e com base nesta estimação explícita os ganhos do controlador são calculados e então a ação de controle u é atualizada.

3.4.2 CONTROLE ADAPTATIVO POR MODELO DE REFERÊNCIA

Para o método direto de controle adaptativo, a maioria dos trabalhos utiliza o *Adaptive Reference Model Controller* (MRAC) (Silva, 2014). Neste controlador, o sinal de saída da planta é comparado com um sinal de referência de saída do modelo, gerando um erro de rastreamento (ε). Os parâmetros do controlador são ajustados utilizando uma função com base neste erro, fazendo o sinal de saída da planta convergir com o do modelo de referência. A condição de convergência é alcançada quando ε é igual a zero (Flores, 2021) (Teixeira, 2016). Geralmente, para essa função custo, o MSE (*mean squared error*) ou EMQ (erro médio quadrático) é o padrão adotado (Flores, 2021) (Silva, 2014).

Assim, um sistema de controle por modelo de referência é aquele em que o comportamento dinâmico do sistema em malha fechada é, idealmente, idêntico ao modelo de referência escolhido $W_m(s)$ pelo projetista, conforme ilustrado na Figura 3.6, de modo que o sinal y siga o sinal y_m . Ou seja, as especificações de desempenho do controlador são definidas por uma função de transferência pré-definida (no caso, W_m), considerando um certo sinal de entrada r . A partir das variáveis de entrada u e saída y da planta $G(s)$, calcula-se um vetor de parâmetros θ de tal modo que o erro de rastreamento e_1 seja minimizado. Assim, deseja-se que a resposta y da planta siga a resposta y_m do modelo de referência $W_m(s)$ (Tambara, 2018).

A Figura 3.6 ilustra a representação de um controlador adaptativo por modelo de referência.




Figura 3.6 - Controlador adaptativo por modelo de referência (Tambara, 2018).

A estimação dos parâmetros pode ser implementada das seguintes formas: *offline* ou *online*. Na estimação *offline*, os dados de entrada e saída são colhidos do sistema e armazenadas para aplicação e avaliação a posteriori dos algoritmos de estimação. No caso *online*, a estimação dos parâmetros é realizada em tempo real. Este processamento é rápido de forma a influenciar no resultado e que esse resultado esteja disponível à medida que os dados vão sendo obtidos do sistema (Silva, 2014). O controlador utilizado nesta pesquisa empregou a estimação de parâmetros do tipo *online*, contribuindo com uma redução do esforço computacional do controlador em estimar seus parâmetros.

3.5 ERRO ABSOLUTO E RELATIVO

Seja x um número real e $\bar{x}$, sua aproximação. O **erro absoluto** da aproximação $\bar{x}$ é definido pela Equação 3.1.

$$|x - \bar{x}| \quad (3.1)$$

O **erro relativo** da aproximação $\bar{x}$ é definido pela Equação 3.2.

$$\frac{|x - \bar{x}|}{|x|} \quad (3.2)$$

com $x \neq 0$.

3.6 ERRO ABSOLUTO PERCENTUAL MÉDIO (MAPE)

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 pela Equação 3.3.

$$MAPE (\%) = \frac{1}{n} \sum \frac{|x_r - x_p|}{|x_r|} \cdot 100 \quad (3.3)$$

em que n corresponde a uma determinada quantidade de dados.

3.7 ERRO QUADRÁTICO MÉDIO

O critério utilizado para verificação do erro de rastreamento relativo aos resultados obtidos nessa pesquisa foi o MSE (*mean squared error*) ou EMQ (erro médio quadrático). O objetivo da ferramenta estatística nesta pesquisa foi para fins de

verificação do desempenho do *soft sensor*. O Erro Médio Quadrático é uma medida do desvio dos valores calculados em relação aos valores originais (Willmott, 1981). Ele é estimado tomando-se 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 V_e e o parâmetro referencial V_v de uma amostra de dados n . Assim, o EMQ pode ser definido pela Equação 3.4.

$$EMQ = \frac{\sum_{i=1}^n (V_e - V_v)^2}{n} \quad (3.4)$$

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

O desenvolvimento matemático do controlador utilizado neste trabalho e que adota o padrão MSE para verificação do erro de rastreamento encontra-se no Anexo III deste documento.

3.8 DESVIO PADRÃO

Um dos ramos da Estatística bastante estudado é a medida de Dispersão de Dados. O objetivo das medidas de dispersão é mensurar quão próximos uns dos outros estão os valores de um grupo de dados adotando, para isto, uma medida de posição (Willmott, 1981). Assim, para o entendimento do desvio padrão, um dos parâmetros estatísticos utilizados nessa pesquisa, faz-se necessário o entendimento da **variância**.

Variância corresponde à média aritmética dos quadrados dos desvios de cada valor em relação à média. Ela proporciona uma mensuração da dispersão dos dados em torno da média.

Se $\mu = E(X)$ é o valor esperado (ou esperança ou média) da variável aleatória X , então a variância é definida pela Equação 3.5.

$$\text{var}(X) = E((X - \mu)^2) \quad (3.5)$$

Isto corresponde ao valor esperado do quadrado do desvio de X da sua própria média. Em uma outra forma de assimilação, o conceito de variância pode ser expresso como "a média do quadrado da distância de cada ponto até a média" ou então "a média do quadrado dos desvios". A variância da variável aleatória X é geralmente designada por $\text{var}(X)$ ou σ^2 .

Assim, o desvio padrão corresponde à raiz quadrada positiva da variância, apresentando a mesma unidade dos dados e da média, permitindo avaliar melhor a dispersão e pode ser definida pela Equação 3.6.

$$\sigma = \sqrt{\text{var}(X)} \quad (3.6)$$

3.7 SINAIS ESPÚRIOS

Nessa seção, passa-se a descrever a natureza dos sinais espúrios (do tipo *outliers* e ruídos gaussianos) utilizados para realização de um subconjunto de testes para a validação do *soft sensor*. A existência de ruídos e interferências por parte dos sensores pode interferir nas mensurações corretas de vazão bem como promover interferências na ação de controle e, nos piores casos, levar o sistema à instabilidade (Åström e Wittenmark, 2013). Assim, durante todos os experimentos realizados, o *soft sensor* foi capaz de atuar de maneira robusta perante esses sinais indesejáveis.

3.7.1 OUTLIERS

Em análise de dados, *outliers* são valores que se diferenciam drasticamente de todos os outros esperados para aquela amostra de dados considerada. Em outras palavras, um *outlier* é um valor que diverge da normalidade e que possui grande possibilidade de impactar anomalias nos resultados obtidos por meio de algoritmos e sistemas de análise (Han *et al.*, 2011). Um *outlier* também pode ser conceituado por

uma observação que se diferencia drasticamente das demais observações e que levanta suspeitas de que aquela observação foi gerada por um mecanismo distinto (Hawkins, 1980).

No campo das redes de sensores, pode-se definir os *outliers* como as medições que desviam significativamente do padrão normal dos dados sensoriados (Valadares, 2012). As causas associadas a esse tipo de sinal indesejável em sensores relacionados à SAA podem ser locais sujeitos a vibrações onde esses equipamentos estejam instalados, erros de medição por parte de alguns instrumentos descalibrados, erros na amostragem de dados coletados dentre outros (Santoyo, 2017).

O princípio utilizado para a inserção dos *outliers* em determinados sinais de entradas utilizados para o teste de robustez do *soft sensor* nesta pesquisa foi baseada nos erros individuais (e_i) de cada estimativa, conforme pode ser observado pela Equação 3.7. Cada $P_i (i = 1, 2, \dots, n)$ atribuído há correspondência a valores inseridos intencionalmente e para cada $O_i (i = 1, 2, \dots, n)$ são correspondentes a valores reais (mensurados por meio de um sensor ou equipamento sob análise).

$$e_i = P_i - O_i \quad (3.7)$$

Com o erro individual de cada estimativa, é calculado o desempenho do modelo utilizando o Erro Médio Absoluto (EMA), conforme pode ser observado pela Equação (3.8). Segundo (Willmott *et al.*, 2009), essa é a melhor forma de avaliação para modelos com variáveis ambientais, devido principalmente a presença de *outliers* e dados com desvio de normalidade.

$$EMA = \frac{\sum_{i=1}^{i=n} |e|}{n} \quad (3.8)$$

No capítulo V são descritos os procedimentos experimentais relativos à inserção dos *outliers* (quando aplicável) na(s) variável(is) de entrada(s) do estimador de vazão pertencentes a um subconjunto de testes de validação do instrumento supracitado. Foi utilizado o software Matlab (versão 2020b) para a criação do algoritmo correspondente

aos *outliers*. A ferramenta computacional Matlab foi instalada em um computador do tipo *notebook* que possui um processador Intel Core i7 de 2,40 GHz com 8 Gb de memória RAM, juntamente com a Interface Humano-Máquina (desenvolvida por meio do ambiente de programação LabVIEW, versão 2017) que gerencia a bancada experimental.

3.7.2 RUÍDOS GAUSSIANOS

Ruído é qualquer sinal externo indesejável impregnado a um sinal existente (Godsill *et al.*, 2002). Considerando que os sinais possam ser “contaminados” por sinais indesejáveis, qualquer tipo de processamento realizado em um sinal que tende a introduzir alguns distúrbios indesejáveis podem ser identificados como ruído (Lathi, 1979).

No contexto de instrumentação industrial, os ruídos, assim como os *outliers*, são sinais indesejáveis que podem comprometer uma correta mensuração de grandezas físicas. Nesta pesquisa, os ruídos foram inseridos (da mesma forma que os *ouliers*) na(s) entrada(s) do *soft sensor* para avaliação da sua robustez frente a esses sinais indesejáveis.

Os ruídos gaussianos utilizados nesta pesquisa são caracterizados por possuírem uma **função densidade de probabilidade** (FDP) é igual à da distribuição normal. Uma função densidade de probabilidade $f(x)$ corresponde a uma função que representa a distribuição de probabilidade de ocorrência de uma variável aleatória seja contínua em x . Variável aleatória contínua é toda aquela em que os possíveis resultados abrangem todo um intervalo de números reais (Cortes *et al.*, 2017). Em termos estatísticos, a distribuição normal é uma distribuição de probabilidade absolutamente contínua e parametrizada pela sua esperança matemática (μ) e desvio padrão (σ). A densidade de probabilidade da distribuição normal pode ser denotada pela Equação 3.9.

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} \quad (3.9)$$

A distribuição normal com média nula e desvio padrão unitário é denominada de distribuição normal centrada e reduzida ou de distribuição normal padrão. Quando uma variável aleatória $\mathbf{X}$ segue uma distribuição normal, ela é denominada de gaussiana ou de normal. Comumente é utilizada a notação com a variância σ^2 quando $\mathbf{X} \approx \mathbf{N}(\mu, \sigma^2)$. A curva de densidade é denominada de curva de Gauss ou de curva em formato de sino.

No capítulo V são descritos os procedimentos experimentais relativos à inserção dos ruídos gaussianos (quando aplicável) na(s) variável(is) de entrada(s) do estimador de vazão para um subconjunto de testes de validação do *soft sensor*. Foi utilizado o software Matlab (versão 2020b) para a criação dos algoritmos correspondentes aos ruídos gaussianos.

3.8 MEDIÇÃO INDIRETA DE GRANDEZAS FÍSICAS

Diversas tecnologias podem ser utilizadas para mensurar as principais grandezas físicas em um SAA. A vazão, grandeza de maior interesse neste trabalho, pode ser mensurada por meio de tecnologias que utilizam sinais eletromagnéticos e ultrassônicos, dentre outros. Com relação às tecnologias 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 (Cabral, *et al.*, 2019) (Mazur *et al.*, 2018).

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 (Flores *et al.*, 2021). 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.

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.

A Figura 3.7 ilustra um diagrama, adaptado do modelo proposto por (Morawski, 1994) 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 .




Figura 3.7 - Diagrama geral de um sistema de medição retroalimentado (adaptado de Morawski, 1994).

Utilizando sensores a fim de 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 a 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 3.10 descreve o fator de conversão para obtenção do sinal x_s .

$$x_s = R_D(y) = f^{-1}(y) \quad (3.10)$$

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 3.11 representa essa estimativa.

$$x_p = R_i(x_s, u) \quad (3.11)$$

O sinal de atuação modifica a dinâmica da planta $P(.)$ 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 do como o controlador foi projetado.

A Tabela 3.1 contém alguns exemplos para valores cotados em moeda nacional corrente de alguns dos instrumentos de vazão utilizados por diversas companhias estaduais de abastecimento de água.

Tabela 3.1 - Valores de alguns medidores de vazão utilizados em SAA.

Modelo/Marca	Valor unitário (R\$)	Empresa contratante e aplicabilidade do(s) instrumento(s)	Número do contrato (ou pregão)
Medidor de vazão magnético MAG 600 (DWYLER)	14.310,74	Sabesp - SP 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	Sanepar - PR 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	Saaep - PA Conexão entre duas ETAs na cidade de Parauapebas - PA	012018-CP/SAAEP de 20/11/2018

A utilização da técnica de estimação indireta da vazão pode auxiliar na redução dos custos de aquisição dos instrumentos físicos de vazão, pois a técnica desenvolvida

nesse trabalho permite o desenvolvimento dos denominados *soft sensors* (ou sensores virtuais) com uma resposta dinâmica rápida ao sistema de abastecimento de água relacionado à variável vazão. O estudo possibilita a capacidade de redução de custos relativos à aquisição de instrumentos de vazão bem como de custos operacionais relativos à instalação desses instrumentos.

Por fim, a técnica de medição indireta da vazão pode ser bastante útil para a implementação de Gêmeos Digitais (*Digital Twin*) da Indústria 4.0 a partir da implementação de sensores virtuais. Os gêmeos digitais permitem que os sistemas automatizados físicos sejam “espelhados” no mundo virtual possibilitando uma tomada de decisão rápida acerca da previsibilidade de manutenção da planta.

Para efeitos de validação da tecnologia apresentada nesse trabalho, a técnica foi validada experimentalmente em uma planta que emula um sistema de abastecimento de água. O sistema está localizada no Laboratório de Eficiência Energética e Hidráulica em Saneamento (LENHS/UFPB).

3.9 SOFT SENSOR

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 (Kadlec *et al.*, 2009). Estes sensores virtuais geralmente auxiliam quanto à indisponibilidade de sensores de *hardware* (reais) em diversos segmentos industriais, permitindo assim menor ocorrência de falhas e melhor desempenho de controle (Liu e Xie, 2020). A instrumentação virtual surge como uma alternativa viável para monitoramento em tempo real de parâmetros que necessitam de um princípio de medição confiável (Nair *et al.*, 2022). O propósito de um *soft sensor* 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, a base para o desenvolvimento do *soft sensor* neste trabalho de tese são as RNAs (Redes Neurais Artificiais). A opção pela técnica desenvolvida foi baseada em algumas propriedades

das RNAs em que elas foram decisivas para adoção desta técnica. A seguir são descritas algumas delas:

- **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 (Moreira, 2020) (Belhaj *et al.*, 2021);
- **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 (Vilela e Mateus, 2016) (Ambrósio, 2002);
- **Classificação de padrões:** essas redes agrupam e organizam dados criando agrupamentos com características semelhantes (Vilela e Mateus, 2016) (Belhaj *et al.*, 2021);
- **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 (Vilela e Mateus, 2016) (Ballini, 2000).

A rede NARX, que é a base para o *soft sensor* desenvolvido, 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.

Assim, no contexto da RNA do tipo NARX, a memória incorporada por essa rede fornece caminhos mais curtos para propagar idealmente as informações e retropropagar o sinal de erro, reduzindo as dependências de longo prazo do modelo

(Fontes, 2020), (Xu, *et al.*, 2015). O valor atual da entrada do modelo é indicado por x_n e o valor correspondente da saída do modelo é indicado por y_{n+1} ; isto é, a saída está à frente da entrada em uma unidade de tempo. Portanto, a entrada da rede corresponde a valores presentes e passados da entrada, ou seja, $x_n, x_{n-1}, \dots, x_{n-q+1}$ que representam entradas exógenas (externas) originárias de fora da rede. Assim como valores atrasados da saída, ou seja, $y_n, y_{n-1}, \dots, y_{n-q+1}$, nos quais a saída do modelo y_{n+1} é a regredida.

A Equação 3.12 descreve os modelos NARX e a Figura 3.9 ilustra uma estrutura típica de uma RNA do tipo NARX em que F é uma função não linear e q o número de atrasos.

$$y_{n+1} = F(y_n, \dots, y_{n-q+1}, x_n, \dots, x_{n-q+1}) \quad (3.12)$$




Figura 3.9 - Estrutura de uma rede NARX (Vilela e Mateus, 2016).

CAPÍTULO IV

MATERIAIS E MÉTODOS

4.1 INTRODUÇÃO

Neste capítulo serão apresentados os materiais e a metodologia empregada para o desenvolvimento e teste do *soft sensor*. Para isto foi utilizada uma bancada experimental totalmente instrumentalizada e automatizada a qual possui um sistema de monitoramento por meio de um supervisor desenvolvido em plataforma LabVIEW onde é processada as ações de controle e estimação em tempo real da vazão.

4.2 BANCADA EXPERIMENTAL

Os experimentos foram realizados em uma bancada experimental instalada nas dependências do Laboratório de Eficiência Energética e Hidráulica em Saneamento da Universidade Federal da Paraíba - LENHS/UFPB.

O LENHS é resultado do desenvolvimento de ações integrantes do Programa Nacional de Eficiência Energética no Saneamento Ambiental – PROCEL SANEAR – das Centrais Elétricas Brasileiras S.A – ELETROBRÁS. A estrutura laboratorial permite o desenvolvimento de serviços especializados, atividades de ensino, pesquisa e extensão, relacionadas ao uso eficiente de energia e água no saneamento. Seu objetivo maior é a geração de economia por intermédio do combate aos desperdícios e

incrementos na eficiência energética e hidráulica de sistemas e equipamentos referentes à SAA, reduzindo custos e aumentando a competitividade setorial.

A bancada experimental utilizada neste trabalho de tese emula um típico sistema de abastecimento de água. A Figura 4.1 ilustra os principais elementos que constituem a planta experimental supracitada.




Figura 4.1 – Elementos da bancada experimental (Flores, 2021).

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 4.1. Com a utilização do inversor de frequência, foi possível alterar a velocidade de rotação do conjunto CMB.

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 à nenhuma das entradas do estimador virtual de vazão. Por fim, a água ficou contida em um reservatório com 310 L.

Os elementos que constituem a bancada experimental são descritos a seguir:

O **conjunto motor-bomba** (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 4.2 ilustra a estrutura correspondente ao CMB e as Tabelas 4.1 e 4.2 reúnem as principais especificações técnicas do CMB supracitado.



Figura 4.2 - Conjunto motor-bomba (Flores, 2021).

Tabela 4.1 - Principais especificações técnicas do motor.

Modelo / Fabricante	WEG
Potência (CV)	3
Tensão (V AC)	380
Frequência (Hz)	60
Corrente (A)	4,86
Rotação nominal (rpm)	3450
Fator de potência	0,84
Índice de proteção	55

Tabela 4.2 - Principais especificações técnicas da bomba.

Modelo/Fabricante	BC-21R/Schneider motobombas
Altura manométrica (mca)	23
Vazão máxima (m ³ /h)	41,5
Diâmetro do rotor (mm)	121
Pressão máxima sem vazão (mca)	25
Rotação nominal (rpm)	3450

As informações contidas nas Tabelas 4.1 e 4.2 foram extraídas do Manual Geral de Instalação, Operação e Manutenção de Motores Elétricos para Atmosferas Explosivas, WEG Group - Motors Business Unit e do Manual de Instruções das Bombas e Motobombas, Franklin Electric Indústria de Motobombas S.A, respectivamente.

O **inversor de frequência** utilizado foi responsável por regular a velocidade de rotação do motor elétrico do CMB mantendo seu torque constante. A Figura 4.3 ilustra o equipamento e a Tabela 4.3 contém as principais especificações técnicas, extraídas do Manual do Inversor de Frequência, WEG Equipamentos Elétricos S.A.



Figura 4.3 - Inversor de frequência do sistema experimental

Tabela 4.3 - Principais especificações técnicas do inversor de frequência.

Modelo/Fabricante	CFW-08/WEG - Equipamentos Elétricos
Tensão de alimentação (V AC)	380-480
Corrente nominal (A)	3 a 7,8
Faixa de frequência (Hz)	50 - 60

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.

O **transdutor de pressão** utilizado foi da marca TP-ST18/ACROS. O instrumento 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. A Figura 4.4 ilustra o instrumento e a Tabela 4.4 reúne suas principais especificações técnicas.



Figura 4.4 - Transdutor de pressão TP-ST18/ACROS (Flores, 2021).

Tabela 4.4 - Especificações técnicas do transdutor de pressão.

Modelo/Fabricante	TP-ST18/ACROS
Sinal de saída	4-20 mA
Tensão de alimentação	24 V DC
Faixa de operação	0-40 mca
Tempo de resposta	< 1 ms
Precisão	0,25% (Fundo de escala)

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 de validação da técnica de medição indireta apresentado nesse trabalho, 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 4.5 e as suas principais especificações técnicas podem ser visualizadas na Tabela 4.5.



Figura 4.5 - Medidor de vazão eletromagnético - vista frontal e lateral (Flores, 2021).

Tabela 4.5 - Especificações técnicas do transdutor de vazão.

Modelo/Fabricante	VMS 038/Icontrol S/A
Série	VV16897
Tipo	Eletromagnéticos de fluxo
Sinal de Saída	4-20 mA
Faixa de Velocidade	0,3 a 10 m/s
Diâmetro interno	38 mm
Precisão	0,5% de leitura e 0,25% F.E

O transdutor de pressão bem como o de vazão utilizados na pesquisa foram devidamente ajustados (conforme as especificações de cada manual correspondente) a fim de identificar se os dispositivos de medição estavam aptos a realizar medições adequadas e que os valores apresentados por eles não iriam interferir na qualidade final dessas medições. Os procedimentos experimentais relativos aos ajustes para medição correta dos instrumentos supracitados encontram-se no ANEXO I.

As **válvulas de controle** (CVs) ou **válvulas redutoras de pressão** (VRPs) presentes na planta são da marca ARB-24/ Belimo, cuja função foi 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 x abertura completa-se em 90 segundos).

Para os experimentos relativos a este trabalho, 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. A Figura 4.6 ilustra uma das válvulas supracitadas e a Tabela 4.6 contém as suas principais especificações técnicas.



Figura 4.6 - Válvula de controle ARB2/Belimo (Camboin, 2012).

Tabela 4.6 - Especificações técnicas da válvula de controle.

Modelo/Fabricante	ARB - 24 / Belimo
Tensão de alimentação (Vdc)	24
Sinal de controle (V)	2 a 10
Ângulo de abertura (°)	0
Ângulo de fechamento (°)	90
Pressão máxima de operação (mca)	140,62

O **Sistema de Aquisição de Dados (DAQ)** utilizado foi responsável pela comunicação entre os componentes eletrônicos da bancada experimental e o computador onde estão instalados o controlador e o sistema supervisor. O DAQ recebia sinais da CV-1 e do inversor de frequência e realizada a comunicação bidirecional com o sistema de supervisão instalado no computador. Além disso, o DAQ também recebia sinais do estimador de vazão. Nesta bancada experimental existem duas interfaces de aquisição de dados instaladas: a interface NI USB 6229 que foi 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 enviava os sinais de excitação e recebia os sinais de resposta da válvula CV-3.

A Figura 4.7 ilustra a interface de dados em questão e a Tabela 4.7 reúne as principais especificações técnicas correspondentes.



Figura 4.7 - Interface de aquisição, família NI-USB 62XX, *National Instruments Corporation* (Flores, 2021).

Tabela 4.7 - Principais especificações técnicas das interfaces de aquisição de dados.

Modelo / Fabricante	NI USB - 6229	NI USB - 6221
Alimentação (V_{AC})	220	220
Canais de saída analógica	4	4
Canais de entrada analógica	32	32
Canais de entrada digital	32	32
Taxa de amostragem (ns)	50	50
Faixa de tensão de entrada (V)	± 10	± 10
Faixa de tensão de saída (V)	0 - 5	0 - 5
Corrente de saída (mA)	± 20	± 20
Transferência dos dados	Cabo USB	Cabo USB

O **Supervisório** 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 exibe 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, foram determinantes para a sua escolha nessa pesquisa.

As informações necessárias (pressão e vazão na rede, velocidade de rotação do CMB etc.) foram 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 supervisório. Essa 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*. As Figuras 4.8 e 4.9 ilustram, respectivamente, a tela sinótica (principal) do supervisório bem como da tela secundária referente a visualização da vazão real *versus* estimada. Para a pesquisa descrita nesse documento, foi utilizada apenas uma parte do supervisório.




Figura 4.8 - Painel frontal (sinótico) do supervisor utilizado (Salvino, 2018).




Figura 4.9 - Tela responsável por apresentar as curvas de estimação *versus* vazão real no sistema.

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

4.3 METODOLOGIA APLICADA

A Figura 4.10 ilustra uma representação esquemática da topologia do processo utilizada na pesquisa. Ademais, é possível observar quais sinais específicos provenientes de alguns elementos do sistema (PT-3, CV-1 e CMB) foram utilizados pelo *soft sensor* para mensurar a vazão de maneira indireta. Também é possível observar uma representação (por setas) do sentido do fluxo de água circulando no sistema.




Figura 4.10 - Topologia da bancada experimental e do bloco estimador de vazão (adaptado de Flores, 2021).

A Figura 4.11 ilustra, de maneira generalizada, a configuração proposta de um sistema de medição com realimentação (*feedback*) para estimação indireta da vazão da bancada experimental localizada no LENHS/UFPB onde os parâmetros de entrada e saída do sistema foram classificados por meio de blocos tracejados.




Figura 4.11 - Sistema retroalimentado para medição indireta da vazão.

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 será 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 (P). O sinal de frequência obtido na saída do controlador será convertido em um sinal analógico, mediante um conversor digital-analógico (D/A) que servirá de entrada para atuação do inversor de frequência e, consequentemente, para variação da velocidade do CMB.

A seguir são explicitados maiores detalhes acerca do bloco que compõe a reconstrução direta do sinal de pressão (P), do bloco associado ao controlador e do bloco associado à reconstrução indireta.

4.3.1 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. Finalmente, 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 pode ser visualizada pela Equação 4.1.

$$P(k) = R_D(V(k)) = 5,27V(k) - 10,54 \quad (4.1)$$

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

A título de exemplificação, quando $V(k)$ for igual a 2V (valor mínimo de referência da tensão), $P(k)$ assume valor igual a zero e quando $V(k)$ for igual a 10V (valor máximo de referência de tensão), $P(k)$ assume valor igual a 42,16 mca. Esses valores correspondem ao range do instrumento considerando sua margem de tolerância.

4.3.2 BLOCO CORRESPONDENTE AO CONTROLADOR ADAPTATIVO

Nos sistemas de abastecimento de água, o controle da pressão é fundamental para o seu correto funcionamento, uma vez que o excesso de pressão pode causar prejuízos físicos e financeiros, devido ao rompimento das tubulações (Camboim, 2012). Deste modo, 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 *soft sensor*.

4.3.3 BLOCO ASSOCIADO AO *SOFT SENSOR* (RECONSTRUÇÃO INDIRETA DA VAZÃO)

De acordo com o diagrama proposto na Figura 4.11, 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 utilizar as relações entre o variáveis de entrada e saída mediante as Equações 4.2, 4.3 e 4.4, 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 (Flores *et al.*, 2020).

$$\frac{\partial P}{\partial t} = \frac{a^2}{Ag} \frac{\partial Q}{\partial x} \quad (4.2)$$

$$\frac{\partial Q}{\partial t} = -gA \frac{\partial P}{\partial x} - \frac{\beta Q^2}{2DA} \quad (4.3)$$

$$\beta = \frac{\rho \beta_f a x}{2D} \quad (4.4)$$

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 b é o fator de atrito do fluido com as paredes do tubo, ρ é a densidade do fluido e β_f é o fator de fricção (Flores *et al.*, 2020). Assim, a estimativa da vazão pode ser obtida solucionando o sistema das Equações 4.2 a 4.4. 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.

Para efetuar a reconstrução indireta da vazão, foram implementados dois algoritmos computacionais baseados em dois tipos de RNAs (aqui os algoritmos serão denominados de redes): a primeira rede considerada é a que utiliza 03 (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 (rede) 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. As Figura 4.12 e 4.13 ilustram, respectivamente, as configurações das redes MLP e NARX atuantes no processo de estimação da vazão.




Figura 4.12 - Diagrama da RNA *Multi-layer Perceptron Feedforward Backpropagation*.




Figura 4.13 - Diagrama da RNA NARX.

Com a implementação da NARX, o bloco de reconstrução indireta RI pode ser implementado para a estimativa indireta da vazão pela Equação 4.5.

$$Q(k) = R_I(P(k), \alpha(k), Q(k-1), f(k)) \quad (4.5)$$

4.3.4 IMPLEMENTAÇÃO DO *SOFT SENSOR* UTILIZANDO REDES NEURAIS ARTIFICIAIS

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 um fluxograma representado pela Figura 4.14.




Figura 4.14 - Fluxograma para a concepção do *soft sensor*.

As etapas associadas à Figura 4.14 são descritas a seguir:

Etapas 1 - Coleta de dados

Esta etapa correspondeu 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.

Etapa 2 – Base de dados

Os dados coletados (etapa 1) foram dispostos em vetores do tipo coluna, separadas de acordo com cada variável de interesse ao estimador. O objetivo dessa 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.

Etapa 3 – RNA MLP e NARX (treinamento e teste)

Essa etapa corresponde ao treinamento e testes das RNAs analisando as suas topologias, quantidade de neurônios, funções de ativação, erro de estimação, dentre outros parâmetros. As redes em questão são a Multicamada *Perceptron Feedforward Backpropagation* e a NARX (*Nonlinear Autoregressive with Exogenous Inputs*) e o resultado dessas implementações é o *soft sensor*. A sessão 4.3 contém uma descrição detalhada dessa etapa.

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 dispendido para a realização do treinamento das redes. Assim, 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 testes realizados e que constam na TM (localizada no Anexo I deste trabalho) seguiram as recomendações propostas por (Silva e Oliveira, 2001) na tentativa de obtenção dos melhores parâmetros para as RNAs. Os resultados mais otimizados dentre esses testes realizados foi o adotado para ambas as redes.

A seguir passa-se a descrever algumas dessas recomendações.

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. Assim, optou-se, a partir dos resultados dos testes, a utilização de 01 (uma) camada oculta nas redes propostas.

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 é recomendado manter o número de neurônios ocultos baixo, mas não tão baixo quanto o estritamente necessário. Assim, optou-se, a partir dos resultados dos testes, a utilização de 08 (oito) neurônios na camada oculta para cada rede proposta após o melhor teste obtido contido na TM.

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. Assim, optou-se, a partir dos resultados dos testes, a utilização da taxa de 0,1 a partir dos testes realizados contidos na TM.

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 e ela foi adotada para o treinamento das RNAs propostas.

5. Critérios de Parada do 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 3000 ciclos de treinamento. Assim, foi utilizado um valor de 1000 para o número de ciclos, padrão do software Matlab.

Outro critério de parada de treinamento utilizado é o critério do erro. Isso consiste em encerrar o treinamento após o erro médio quadrático (MSE) 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. Para uma melhor otimização dos parâmetros de finalização dos treinamentos das RNA propostas, foi utilizada a combinação dos dois métodos citados (número de ciclos e critério de erro). Desta forma, o treinamento é encerrado quando qualquer um dos critérios acima é atendido.

De maneira sucinta, a partir da TM, as RNAs implementadas como estimador de vazão possuem três entradas (para a RNA MLP) e quatro entradas (para a NARX) e uma camada oculta com oito neurônios seguida por uma camada de saída com um neurônio para ambas as redes. Além disso, a função de ativação escolhida para a camada oculta foi a **Sigmóide Tangente Hiperbólica (STH)** enquanto para a camada de saída foi adotada a função **Linear**. Finalmente, o algoritmo de treinamento utilizado foi o **Levenberg-Marquardt (LM)**, para ambas as estruturas. Segundo (Haykin, 2001)

(Santos, 2018) a função de ativação do tipo Sigmóide Tangente Hiperbólica é a mais comumente utilizada nas camadas ocultas de uma RNA em diversas aplicações, diferindo das demais por apresentar valores de ativação em um intervalo de valores positivos e negativos. Além disso, a STH é uma função de ativação totalmente diferenciável, ou seja, ela é caracterizada por ter suas derivadas de primeira ordem existentes e conhecidas em todos os pontos de seu domínio de definição. Assim, foi adotada a função de ativação STH para a camada oculta das redes implementadas.

Segundo (Bottura, 2010) (Santos, 2018), o algoritmo de Levenberg-Marquardt é o mais utilizado para promover o treinamento de uma RNA por convergir a uma resposta mais rápida que os demais algoritmos. Assim, foi adotado o método de LM o treinamento das RNAs implementadas. Por fim, a função de ativação linear foi adotada por ser uma função básica, não alterando a resposta na saída do neurônio (Ballini, 2000) (Santos, 2018).

As Figuras 4.15 e 4.16 ilustram, respectivamente, as estruturas das RNAs MLP e NARX implementadas.




Figura 4.15 - Estrutura da RNA *Multi-layer Perceptron Feedforward Backpropagation* para estimação da vazão.




Figura 4.16 - Estrutura da RNA NARX para estimação da vazão.

em que:

W_i = peso sináptico das entradas da rede;

β = função de ativação;

W_s = peso de saída da rede

z^{-1} = realimentação da rede (para a NARX);

$k - 1$ = atraso para na entrada de vazão (para a NARX).

A teoria acerca dos elementos supracitados bem como seus valores otimizados e utilizados nas redes implementadas nesta tese encontra-se no Anexo I.

CAPÍTULO V

PROCEDIMENTOS EXPERIMENTAIS E ANÁLISES DOS RESULTADOS

5.1 INTRODUÇÃO

Este capítulo aborda os procedimentos experimentais, os resultados obtidos e as análises pertinentes a cada situação referente ao *soft sensor*. 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 neste trabalho foram:

- **Média do erro absoluto:** corresponde à média de todos os valores obtidos com o erro de rastreamento das curvas de vazão real *versus* estimada,

utilizando o valor absoluto (módulo) de cada dado obtido. Isso evita a soma, e posterior média de valores positivos (+) e negativos (-) tornando o resultado infiel à qualidade da técnica de rastreamento do erro;

- **MAPE:** utilização do erro absoluto percentual médio pelo fato dele expressar a precisão como uma porcentagem do erro, facilitando o entendimento. Por exemplo, se o MAPE é igual a 5, em média, a precisão está incorreta em 5% para mais ou para menos;
- **Erro máximo absoluto:** corresponde ao maior valor absoluto do erro de todo o conjunto de dados obtidos por meio do rastreamento do erro das curvas de vazão real *versus* estimada;
- **Desvio padrão do erro absoluto:** medida que expressa o grau de dispersão de um conjunto de dados absolutos obtidos com o erro de rastreamento das curvas de vazão real *versus* estimada. Um valor elevado do desvio padrão indica que os pontos dos dados estão espaçados distante da média e um pequeno desvio padrão indica que os pontos dos dados estão agrupados próximos à média

Maiores detalhes acerca da teoria de cada métrica utilizada pode ser obtida no Capítulo III desse documento.

5.2 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

na posição de 0°. As válvulas CV-2 e CV-3 são válvulas auxiliares 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.

A Tabela 5.1 contém os parâmetros utilizados para os testes relativos ao ensaio A.

Tabela 5.1 - Parâmetros utilizados para o 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

Em relação ao procedimento de coleta de dados foram obtidas cerca de 2160 amostras. A taxa de amostragem foi fixada em 10 amostras/s em que as 1500 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.

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 5.1 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 5.1 - Vazão medida e estimada durante a fase de teste da RNA *Multi-layer Feedforward Backpropagation* para o ensaio A.

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 5.1. 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 5.1, foram determinadas algumas métricas estatísticas referentes ao estimador baseado em MLP. Os dados obtidos estão dispostos na Tabela 5.2.

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. No entanto, os dados relativos à vazão, resultado do processamento das entradas PT-3, frequência e CV-1 foi retroalimentado (*feedback*) como uma entrada adicional $Q(k - 1)$ atrasada. Essa retroalimentação apresenta a dinâmica ao sistema para que o aprendizado da rede seja constantemente otimizado. A Figura 5.2 ilustra a saída referente à vazão estimada utilizando a rede implementada em NARX.




Figura 5.2 - Vazão medida e estimada durante a fase de teste da RNA NARX para o ensaio A.

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 5.2, foram determinadas algumas métricas estatísticas utilizando o critério MSE, referente à rede NARX. A Tabela 5.2 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.

Tabela 5.2 - Comparação entre o rastreamento do erro obtidos na estimação de vazão utilizando MLP e NARX para o ensaio A.

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

5.2 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°, a CV-3 na posição de 45° e a CV-2 sofreu variação crescente e decrescente de 15° em 15° até 75° como ângulo máximo de fechamento, iniciando em 0°. 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 5.3 contém os parâmetros utilizados para os testes relativos à categoria B.

Tabela 5.3 - Parâmetros utilizados para o teste relativo ao ensaio B.

Frequência de rotação do CMB) (Hz)	Pressão (mca)	Ângulo de CV-1 (°)	Ângulo de CV-2 (°)	Ângulo de CV-3 (°)
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

Em relação ao procedimento de coleta de dados foram obtidas cerca de 2232 amostras. A taxa de amostragem foi fixada em 10 amostras/s em que 1600 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.

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 5.3 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*.




Figura 5.3 - Vazão medida e estimada durante a fase de teste da RNA *Multi-layer Perceptron Feedforward Backpropagation* para o ensaio B.

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.

Para fins de quantificação do rastreamento do erro obtido mediante os resultados obtidos a partir dos dados que compuseram as curvas da Figura 5.3 relativas ao ensaio B, foram determinadas algumas métricas estatísticas referentes à rede MLP utilizando o critério MSE. Os resultados estão dispostos na Tabela 5.4.

Foi realizada também a análise da rede implementado em NARX para a fase de teste. A Figura 5.4 ilustra a saída referente à vazão estimada utilizando a RNA do tipo NARX.




Figura 5.4 - Vazão medida e estimada durante da RNA NARX para o ensaio B.

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 5.4, foram determinadas algumas métricas estatísticas referentes à NARX. A Tabela 5.4 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 5.4 - Comparação entre o rastreamento do erro obtidos na estimação 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

5.3 VALIDAÇÃO DO *SOFT SENSOR*

A partir dos resultados apresentados na seção anterior foi adotada apenas a RNA do tipo NARX para 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 isto, foi utilizado o supervisório implementado no Labview para parametrização e controle da planta e o *soft sensor* desenvolvido no Matlab, cujo código foi inserido dentro do supervisório. Os testes descritos a seguir legitimaram de fato o *soft sensor* implementado seja com ou sem a ação do controlador atuando no sistema.

5.3.1 VALIDAÇÕES DO *SOFT SENSOR* SEM AÇÃO DO CONTROLADOR

5.3.1.1 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.

A Tabela 5.5 contém os valores de entradas relativos a este teste.

Tabela 5.5 - 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

Os dados aleatórios dos valores da Tabela 5.5 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.

```
% 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
```

A Figura 5.6 ilustra 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 5.5.




Figura 5.6 - Pressão em PT-3 para o teste de validação A.

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 5.6. Observou-se que a curva do valor estimado foi 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.




Figura 5.6 - Vazão estimada *versus* real para testes da validação A.

Para fins de quantificação do rastreamento do erro mediante os dados que compuseram os gráficos ilustrados na Figura 5.6, 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 5.6.

Tabela 5.6 - Rastreamento do erro para o teste de validação A.

Métrica estatística	Valor
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

Através da análise dos dados referentes à Tabela 5.6, observou-se que a média, o MAPE (%) e o desvio padrão do erro de rastreamento possuíram valores bem inferiores a 1 o que infere 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.

5.3.1.2 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 pela Equação 5.1.

$$r(t) = C(t) + a(t) \quad (5.1)$$

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 $r(t)$.

A Tabela 5.7 contém os parâmetros de entrada para este teste em questão.

Tabela 5.7 - Parâmetros para o teste da validação B.

Frequência (Hz)	Tag	Pressão* (mca)	Range da componente aleatória do ruído** (mca)	Intervalo de tempo de inserção dos ruídos (s)	CV-1 (°)	CV-2 (°)	CV-3 (°)
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

A Figura 5.7 ilustra a curva correspondente à pressão em PT-3 bem como os ruídos inseridos à cada mudança de degrau.




Figura 5.7 - Pressão mensurada em PT-3 com inserção de sinais espúrios do tipo ruídos.

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 5.8. 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.




Figura 5.8 - Vazão estimada *versus* real para testes da validação B.

Para fins de análise dos dados referentes aos pontos que formam as curvas ilustradas na Figura 5.8, 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 as métricas estatísticas das curvas como um todo, isto é, considerando todos os pontos de ambos os gráficos ilustrados na Figura 5.8. Os resultados obtidos (valores aproximados) estão dispostos na Tabela 5.8. 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.

Tabela 5.8 - 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

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 quando associados à Sistemas de Abastecimento de Água podem ser provocados por ruído elétrico no sistema, vibrações na rede etc.

Foi observado que todos os valores correspondentes às métricas de desempenho tiveram valores muito inferiores a 1 (um), o que infere uma boa estimativa 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 possuiu 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.

5.3.2.3 VALIDAÇÃO C

O teste de validação C possui como objetivo verificar a atuação do *soft sensor* quando a entrada (CV-1) 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 em repouso (0 Hz) e em seguida sendo comutada para 30 Hz, 40 Hz, 50 Hz, 60 Hz, 50 Hz, 40 Hz e 30 Hz. O tempo adotado para cada alteração de frequência foi de um minuto;
- A pressão (referente ao sensor PT-3) foi mensurada com o sistema experimental atuando em malha aberta;
- 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;
- 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 um sinal que contém uma amplitude de referência* adicionada a um valor aleatório** dentro de um intervalo específico, correspondendo de maneira análoga à Equação 5.1 do experimento B desta seção.

Os dados estão contidos na Tabela 5.9.

Tabela 5.9 - Parâmetros para o teste da categoria C.

Frequência (Hz)	Tag	Pressão (mca)	Range da componente aleatória do ruído** (°)	Intervalo de tempo de inserção dos ruídos (s)	CV-1* (°)	CV-2 (°)	CV-3 (°)
30	I	6,21	-18 a 20	10 a 50	0	45	45
40	II	10,62	-20 a 20	15 a 30	0	45	45
50	III	16,24	-18 a 20	8 a 40	0	45	45
60	IV	23,44	-20 a 20	10 a 55	0	45	45
50	V	16,66	-16 a 19	20 a 40	0	45	45
40	VI	10,49	-18 a 20	15 a 45	0	45	45
30	VII	5,91	-19 a 19	5 a 55	0	45	45

A Figura 5.9 ilustra a curva correspondente ao ângulo de atuação de CV-1 bem como os ruídos inseridos em cada trecho destacado.




Figura 5.9 - Ângulo de CV-1 com inserção e identificação de ruídos.

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 5.10.




Figura 5.10 - Vazão estimada *versus* real para testes da validação C.

Para dimensionamento e análise dos dados referentes aos pontos que compuseram as curvas ilustradas na Figura 5.10, foram determinadas algumas métricas estatísticas relacionadas ao rastreamento do erro para cada identificação de degrau de vazão apenas para as condições de inserção dos ruídos em CV-1 bem como para todo o período do teste (curvas completas). Foram desconsiderados, para análise dos trechos I a VII, os valores correspondentes às transições de um degrau de vazão para outro imediatamente superior ou inferior. Os resultados obtidos (valores aproximados) estão dispostos na Tabela 5.10.

Tabela 5.10 -

Trecho correspondente	Erro médio absoluto (l/s)	MAPE (%)	Erro máximo absoluto (l/s)	Desvio padrão do erro (l/s)
I	0,0297	0,0038	0,1134	0,0230
II	0,0208	0,0026	0,0810	0,0161
III	0,0258	0,0028	0,0712	0,0174
IV	0,0285	0,0029	0,0999	0,0220
V	0,0253	0,0034	0,0981	0,0180
VI	0,0306	0,0057	0,5278	0,0573
VII	0,0251	0,0060	0,0880	0,0210
Curvas completas	0,0969	0,0127	1,9136	0,2089

A eficiência do *soft sensor* permitiu que a mensuração indireta da vazão fosse realizada de maneira eficiente mesmo com a possibilidade de sinais espúrios na CV-1. Ao comparar as métricas estatísticas de rastreamento do erro para cada segmento das curvas (I até VII), foi observado que todos os resultados possuíram valores bem inferiores 1, o que induziu um bom desempenho por parte do *soft sensor* mesmo com a inserção de *outliers* em uma de suas entradas. Em relação ao erro máximo obtido com a análise de todos os pontos das curvas (curvas completas) seu resultado foi consequência da consideração do período transitório, ou seja, do instante de saída da inércia do sistema até a estabilização da primeira frequência (30 Hz) bem como da presença de água e ar nas tubulações antes do acionamento do inversor. No entanto, foi constatado que o *soft sensor* foi capaz de estimar a vazão em todo o teste em questão.

5.3.2.4 VALIDAÇÃO D

O teste de validação D objetivou a verificação da atuação do *soft sensor* quando a frequência de rotação do CMB 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 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 pressão (referente ao sensor PT-3) foi mensurada com o sistema experimental atuando em malha aberta;
- 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;
- 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 um sinal que contém uma amplitude de referência* adicionada a um valor aleatório** dentro de um intervalo específico, correspondendo de maneira análoga à Equação 5.1 do experimento B desta seção.

A Tabela 5.11 contém os parâmetros de entrada para este teste em questão.

Tabela 5.11 - Parâmetros para o teste da categoria D.

Frequência* (Hz)	Tag	Pressão (mca)	Range da componente aleatória do ruído** (Hz)	Intervalo de tempo de inserção dos ruídos (s)	CV-1 (°)	CV-2 (°)	CV-3 (°)
30	I	5,9	10 a 50	10 a 50	0	45	45
40	II	10,5	20 a 60	15 a 30	0	45	45
50	III	16,9	30 a 70	8 a 40	0	45	45
60	IV	23,1	42 a 80	10 a 55	0	45	45
50	V	16,3	30 a 68	20 a 40	0	45	45
40	VI	10,6	20 a 58	15 a 45	0	45	45
30	VII	6,3	10 a 30	12 a 51	0	45	45

A Figura 5.12 ilustra o sinal obtido relativo à frequência de rotação do CMB com a inserção dos ruídos em seus respectivos trechos destacados.



5.12 - Frequência de rotação do CMB com inserção de sinais espúrios.

O resultado da comparação entre o valor real da vazão mensurada pelo sensor FT-1 e o *soft sensor* para as condições do teste é ilustrado na Figura 5.13.




Figura 5.13 - Vazão estimada *versus* real para testes da validação D.

Para fins de quantificação e análise dos dados referentes aos pontos que formam as curvas ilustradas na Figura 5.13, foram determinadas algumas métricas estatísticas relacionadas ao rastreamento do erro para cada identificação do degrau de vazão apenas nos instantes de tempo em que os ruídos foram inseridos assim como para as curvas como um todo. Foram desconsiderados, nos trechos I a VII, os valores correspondentes às bordas de subida ou descida de um degrau de vazão para outro imediatamente superior ou inferior. Os resultados obtidos (valores aproximados) estão dispostos na Tabela 5.12.

Tabela 5.12 - Rastreamento do erro para o teste de validação D.

Trecho correspondente	Erro médio absoluto (l/s)	MAPE (%)	Erro máximo absoluto (l/s)	Desvio padrão do erro (l/s)
I	0,0351	0,0050	0,1760	0,0261
II	0,0349	0,0015	0,0755	0,0327
III	0,0450	0,0024	0,0607	0,0159
IV	0,0351	0,0037	0,0978	0,0262
V	0,0239	0,0043	0,0872	0,0203
VI	0,0355	0,0046	0,5199	0,0499
VII	0,0231	0,0052	0,0890	0,0209
Curva completa	0,0998	0,0087	2,8093	0,2704

O *soft sensor* permitiu que a mensuração indireta da vazão fosse realizada de maneira eficiente mesmo com a possibilidade de sinais espúrios na entrada correspondente à frequência de rotação do CMB. Ao comparar as métricas estatísticas de rastreamento do erro para cada segmento das curvas (I até VII), todos os valores obtidos foram bem inferiores a 1, conferindo bom desempenho por parte do *soft sensor* mesmo com a inserção de *outliers* na frequência de rotação do CMB. Em relação ao erro máximo obtido ao considerar todos os pontos das curvas de vazão real *versus* estimada (curva completa), o valor aproximado de 3, como nos testes anteriores, foi consequência da consideração de todos os pontos por adoção do sistema partir do repouso até a primeira frequência inserida no CMB através do inversor bem como da presença de água e ar antes do acionamento do inversor de frequência. Entretanto, foi observado que o *soft sensor* foi capaz de estimar a vazão em todo o teste em questão verificado com a aproximação das curvas da Figura 5.13 e dos resultados das métricas analisadas.

5.3.2.5 VALIDAÇÃO E

Esse teste teve como objetivo verificar a atuação do *soft sensor* quando as três entradas (pressão em PT-3, válvula CV-1 e a frequência de rotação do CMB) foram submetidas a **sinais espúrios do tipo ruído intermitente com amplitudes diferentes entre si**. Assim, para este teste foram adotadas as seguintes premissas:

- Variação de frequência de rotação do CMB estando 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 pressão (referente ao sensor PT-3) foi mensurada com o sistema experimental atuando em malha aberta;
- 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;
- Foram inseridos segmentos de ruídos para cada entrada (pressão, ângulo e frequência de rotação), caracterizados por sinais de natureza gaussiana.

Cada segmento foi identificado por um *tag* (algarismo romano de I a VII) em que cada trecho foi caracterizado por um sinal que contém uma amplitude de referência* adicionada a um valor aleatório** dentro de um intervalo específico, correspondendo de maneira análoga à Equação 5.1 do experimento B desta seção.

A Tabela 5.13 contém os parâmetros de entrada para este teste em questão.

Tabela 5.13 - Parâmetros para o teste da categoria E.

Tags	Setpoint do ângulo de CV-1 (°)	Range do ângulo de CV-1 (°)	Setpoint da pressão em PT-3 (°)	Range da pressão em PT-3 (mca)	Setpoint da frequência do CMB (Hz)	Range da frequência do CMB (Hz)
I	0	10 a -30	6	-35 a 35	30	10 a 50
II	0	10 a -30	10	-30 a 40	40	22 a 60
III	0	10 a -30	18	-25 a 50	50	30 a 70
IV	0	10 a -30	22	-18 a 30	60	45 a 80
V	0	10 a -30	18	-25 a 45	50	30 a 58
VI	0	10 a -30	10	-30 a 40	40	22 a 58
VII	0	10 a -30	6	-30 a 35	30	15 a 50

A Figura 5.14 ilustra o sinal obtido relativo às 3 entradas com a inserção dos ruídos em cada um dos trechos destacados.




Figura 5.14 - Parâmetros de entrada com inserção de sinais espúrios.

O resultado da comparação entre o valor real da vazão mensurada pelo sensor FT-1 e o *soft sensor* para a condição das três entradas com ruídos é ilustrado na Figura 5.15.




Figura 5.15 - Vazão estimada *versus* real para testes da validação E.

Conforme padronização dos testes, também foram determinadas algumas métricas estatísticas relacionadas ao rastreamento do erro para cada identificação do degrau de vazão com os dados obtidos que foram as curvas ilustradas na Figura 5.15, apenas nos instantes de tempo em que os ruídos foram inseridos e nas curvas completas. Assim como nos testes anteriores, a parte relativa à borda de subida e de descida de cada degrau de vazão foi desconsiderada. Os resultados obtidos estão dispostos na Tabela 5.14.

Tabela 5.14 - Rastreamento do erro para o teste de validação E.

Trecho correspondente	Erro médio absoluto (l/s)	MAPE (%)	Erro máximo absoluto (l/s)	Desvio padrão do erro (l/s)
I	0,0358	0,0066	0,0980	0,0229
II	0,0210	0,0026	0,0647	0,0155
III	0,0222	0,0024	0,0704	0,0160
IV	0,0278	0,0025	0,0758	0,0181
V	0,0211	0,0032	0,0822	0,0170
VI	0,0202	0,0039	0,0905	0,0163
VII	0,0273	0,0071	0,0996	0,0298
Curvas completas	0,0987	0,0193	2,8093	0,2704

Observou-se, a partir da comparação entre as métricas estatísticas de rastreamento do erro para cada segmento das curvas (I até VI), que todos os resultados obtidos possuíam valores bastante inferiores a 1, validando o desempenho do *soft sensor*. Apenas o erro máximo obteve um valor próximo a 2,8 quando foram considerados todos os pontos (curvas completas). A inserção simultânea de sinais espúrios nas entradas do estimador representou um dos piores cenários para a validação do instrumento virtual de vazão. Independente dessa situação, constatou-se, através das curvas analisadas e das métricas estatísticas que o *soft sensor* estimou a vazão em todo o período de realização do teste. Importante destacar também que o sistema não perdeu a estabilidade após o alcance da primeira frequência de referência (30Hz) e que os erros referentes à estimação possuíam valores bem próximos a zero, excetuando apenas o erro máximo já citado referente às curvas completas.

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

Para esta nova 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.

5.4.1.1 ATUAÇÃO DO *SOFT SENSOR* PARA DIFERENTES VALORES DE SETPOINT 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:

- $K_p = K_i = K_d = \alpha_1 = \alpha_2 = \alpha_3 = 0,01$, correspondente aos parâmetros otimizados do controlador adaptativo;

- As válvulas CV-2 e CV-3 permaneceram com seus ângulos de abertura sempre na posição de 45° cada uma enquanto a válvula CV-1 encontrava-se na posição de 0° e 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 60s cada SP a partir da estabilização do primeiro;
- A frequência de rotação do CMB acompanhava o *setpoint* de pressão.

Os parâmetros utilizados nesse teste em específico estão contidos na Tabela 5.15.

Tabela 5.15 - Parâmetros de entrada do *soft sensor* para diferentes valores de *setpoint* de pressão com ação do controlador.

<i>Setpoint</i> de pressão (mca)	Frequência (Hz)	Ângulo de CV-1 (°)	Ângulo de CV-2 (°)	Ângulo de CV-3 (°)
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

A Figura 5.16 ilustra a curva controlada de pressão com incrementos e decrementos fixos de SP. Foi verificado que a planta levou cerca de 130s 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.




Figura 5.16 - Respostas da planta controlada para diferentes valores desejados da pressão.

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 5.17. O *soft sensor* conseguiu estimar adequadamente a vazão. As oscilações nos primeiros instantes de tempo foram efeitos da presença de água nas tubulações bem como do regime transitório antes da estabilização do primeiro *setpoint*. 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 5.17 - Vazão estimada *versus* real com a planta controlada para diferentes valores desejados da pressão.

Para análise quantitativa, foram determinadas algumas métricas estatísticas relacionadas ao rastreamento do erro, comparando os dados que compuseram as curvas da Figura 5.17 para o caso da curva quando o sistema atingiu o **regime permanente**, adotado a partir do instante 100s. Os resultados obtidos estão contidos na Tabela 5.16.

Tabela 5.16 - 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

Observou-se que todas as métricas estatísticas obtidas possuíam valores muito inferiores a 1, comprovando que o *soft sensor* conseguiu estimar a vazão na condição de mudança de *setpoint* de pressão.

5.4.1.2 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° cada uma enquanto a válvula CV-1 encontrava-se na posição de 0° e a bomba encontrava-se, inicialmente, em repouso (0 Hz);
- Os *setpoints* de pressão foram considerados utilizando os dados da Tabela 5.17, duração aproximada de 50s cada, a partir da estabilização do primeiro
- A frequência de rotação do CMB acompanhava o *setpoint* de pressão.

Todos os parâmetros utilizados nesse teste em específico estão contidos na Tabela 5.17.

Tabela 5.17 - Parâmetros de entrada do *soft sensor* com variações abruptas de demanda de consumo com ação do controlador.

Setpoint de pressão (mca)	Frequência (Hz)	Ângulo de CV-1 (°)	Ângulo de CV-2 (°)	Ângulo de CV-3 (°)
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

A Figura 5.18 ilustra 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.




Figura 5.18 - Respostas da planta controlada com variações abruptas de demanda de consumo.

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 5.19.




Figura 5.19 - Vazão estimada *versus* real com variações abruptas de demanda de consumo no sistema.

Da mesma forma que no teste anterior, foram determinadas algumas métricas estatísticas referentes ao rastreamento do erro em **regime permanente**, considerado o início no instante 100s. Os resultados obtidos estão contidos na Tabela 5.18.

Tabela 5.18 - Métricas estatísticas do erro de rastreamento da vazão para demanda abrupta de consumo em regime permanente.

Métrica estatística	Valor em regime permanente
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

Foi observado que todas as métricas obtidas possuíram valores inferiores a 1 o que corrobora com o bom desempenho por parte do *soft sensor*. O estimador de vazão conseguiu mensurar com eficiência a vazão mesmo com oscilações de pressão na rede.

5.4.1.3 ATUAÇÃO DO *SOFT SENSOR* PARA SINAIS ESPÚRIOS EM PT-3

Esse teste teve como objetivo a 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:

- $K_p = K_i = K_d = \alpha_1 = \alpha_2 = \alpha_3 = 0,01$;
- As válvulas CV-2 e CV-3 permaneceram com seus ângulos de abertura sempre na posição de 45° 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 60s 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).

Os dados relativos aos testes em questão podem ser observados na Tabela 5.19.

Tabela 5.19 - Parâmetros de entrada do *soft sensor* incluindo sinais do tipo *outliers* em PT-3 com segmentação de degraus de pressão.

Setpoint de pressão (mca)	Tag	Tempo de inserção dos Outliers (s)	Range de cada conjunto de outliers associado a cada tag (mca)
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

A Figura 5.20 ilustra a curva de pressão em PT-3 com sinais do tipo *outliers*.




Figura 5.20 - Sinal de PT-3 com inserção de *outliers* de acordo com cada degrau de *setpoint*.

Foi verificado que a ação do controlador foi capaz de manter o sistema estável mesmo com a inserção dos *outliers*. Foi verificado que 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 foram esses parâmetros, maior foi o tempo despendido para que o sistema alcance 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 5.21 com as suas respectivas identificações por degrau de vazão.




Figura 5.21 - Vazão estimada *versus* real mediante inserção de *outliers* em PT-3.

Foi constatado que, da mesma maneira que nos testes anteriores, as oscilações presentes nos primeiros instantes de tempo foram consequência da presença de água nas tubulações antes do acionamento do controlador bem como ao momento transitório do sinal até a sua estabilização. 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 5.21, 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). Os resultados obtidos estão dispostos na Tabela 5.20.

Tabela 5.20: 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

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 possuíram valores inferiores a bem inferiores a 1, o que inferiu 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. No entanto, constatou-se que o *soft sensor* conseguiu estimar a vazão mesmo com as adversidades presentes no teste.

5.4.1.4 ATUAÇÃO DO SOFT SENSOR PARA SINAIS ESPÚRIOS EM CV-1

O objetivo desse foi verificar a atuação do *soft sensor* quando a válvula CV-1 se encontrava submetida a sinais espúrios do tipo *outliers*. As premissas adotadas referentes a este teste foram:

- $K_p = K_i = K_d = \alpha_1 = \alpha_2 = \alpha_3 = 0,01$;
- As válvulas CV-2 e CV-3 permaneceram com seus ângulos de abertura sempre na posição de 45° 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;
- 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 conjunto de *outliers* (dentro dos 60 segundos especificados) foi identificado por um *tag* (algarismo romano de I a VII).

Os parâmetros utilizados nesse teste em específico estão contidos na Tabela 5.21.

Tabela 5.21 - Parâmetros de entrada do *soft sensor* incluindo sinais do tipo *outliers* em CV-1.

Setpoint de pressão (mca)	Tag	Tempo de inserção dos Outliers (s)	Range de cada conjunto de outliers associado a cada tag (°)
10	I	10, 15, 20, 25, 30, 35, 40, 45, 50	-18 a 12
12	II	10, 15, 20, 25, 30, 35, 40, 45, 50	-19 a 19
14	III	10, 15, 20, 25, 30, 35, 40, 45, 50	-13 a 13
16	IV	10, 15, 20, 25, 30, 35, 40, 45, 50	-18 a 19
14	V	10, 15, 20, 25, 30, 35, 40, 45, 50	-15 a 17
12	VI	10, 15, 20, 25, 30, 35, 40, 45, 50	-18 a 13
10	VII	10, 15, 20, 25, 30, 35, 40, 45, 50	-15 a 18

A Figura 5.22 ilustra o resultado obtido a partir dos parâmetros de entrada do teste.




Figura 5.22 - Sinal de CV-1 com inserção e identificação de *outliers*.

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 5.23 com as suas respectivas identificações por degrau de vazão.




Figura 5.23 - Vazão estimada *versus* real com inserção de *outliers* em CV-1 e segmentação de trechos de SP de pressão.

Para fins de análise dos dados referentes aos pontos que compuseram as curvas ilustradas na Figura 5.23, foram determinadas 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 CV-1, assim como a consideração das curvas como um todo (curvas completas). Os resultados obtidos estão dispostos na Tabela 5.22.

Tabela 5.22 - Métricas estatísticas do erro de rastreamento da vazão mediante inserção de *outliers* em CV-1 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	0,0301	0,0033	0,0997	0,0222
II	0,0293	0,0022	0,0970	0,0220
III	0,0285	0,0023	0,1062	0,0215
IV	0,0244	0,0020	0,1057	0,0182
V	0,0287	0,0031	0,1154	0,0224
VI	0,0301	0,0032	0,1061	0,0251
VII	0,0317	0,0048	0,1216	0,0257
Curvas completas	0,0661	0,0107	4,4158	0,1529

Mesmo realizando a análise estatística da curva estimada e segmentada em diversos trechos de atuação dos *outliers*, os sinais indesejáveis em CV-1 não influenciaram no resultado esperado da mensuração da vazão pelo *soft sensor*. Apenas o erro máximo teve um valor superior a 4 ao ser consideradas as curvas completas. Da mesma forma que nos testes anteriores, isso ocorreu devido à consideração de todos os pontos que formam as curvas analisadas (regime transitório e permanente) e da presença prévia de água nas tubulações.

5.4.1.5 ATUAÇÃO DO *SOFT SENSOR* PARA SINAIS ESPÚRIOS NA FREQUÊNCIA DE ROTAÇÃO DO CMB

O objetivo desse teste foi verificar a atuação do *soft sensor* quando a frequência de rotação do CMB esteve submetida a sinais espúrios do tipo *outliers*. As premissas adotadas referentes a este teste foram:

- $K_p = K_i = K_d = \alpha_1 = \alpha_2 = \alpha_3 = 0,01$;
- As válvulas CV-2 e CV-3 permaneceram com seus ângulos de abertura sempre na posição de 45° cada uma enquanto a válvula CV-1 encontrava-se na posição de 0° e 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 60s para cada *setpoint* após a estabilização do primeiro e 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 conjunto de outliers (dentro dos 60 segundos especificados) foi identificado por um tag (algarismo romano de I a VII), conforme consta na Tabela 5.23.

Tabela 5.23 - Parâmetros de entrada do *soft sensor* incluindo sinais do tipo *outliers* na frequência de rotação do CMB.

Setpoint de pressão (mca)	Tag	Frequência (Hz)	Tempo de inserção dos <i>Outliers</i> (s)	Range de cada conjunto de <i>outliers</i> associado a cada tag (Hz)
10	I	39	10, 15, 20, 25, 30, 35, 40, 45, 50	22 a 56
12	II	42	10, 15, 20, 25, 30, 35, 40, 45, 50	24 a 62
14	III	45	10, 15, 20, 25, 30, 35, 40, 45, 50	28 a 63
16	IV	50	10, 15, 20, 25, 30, 35, 40, 45, 50	47 a 70
14	V	46	10, 15, 20, 25, 30, 35, 40, 45, 50	30 a 62
12	VI	42	10, 15, 20, 25, 30, 35, 40, 45, 50	24 a 57
10	VII	40	10, 15, 20, 25, 30, 35, 40, 45, 50	30 a 57

A Figura 5.24 ilustra a inserção de *outliers* no sinal de frequência de rotação do CMB. Nos instantes iniciais da elevação da frequência, foi possível observar uma curva um pouco espessa. Isso ocorreu devido ao período de partida do controlador mediante aos parâmetros considerados no momento da aprendizagem por parte dele. No regime permanente (atingido a partir de 150s) como o sistema já venceu a inércia do motor, a curva encontrou-se estabilizada (com exceção dos *outliers* inseridos intencionalmente), bem como da frequência de rotação do CMB ser a variável de controle no sistema e a pressão a variável a ser controlada.

O tempo de inserção dos sinais espúrios estava contido dentro da janela de 60 segundos de duração de cada degrau de *setpoint* com exceção do trecho I, cujo período foi maior pois foi considerado o tempo de acionamento do controlador, a saída da inércia do sistema e a estabilização total do primeiro SP de pressão.




Figura 5.24 - Sinal de frequência de rotação do CMB com inserção e identificação de *outliers* de acordo com cada degrau de *setpoint*.

O resultado da comparação entre o valor real da vazão mensurada pelo instrumento eletromagnético FT-1 e o estimado pelo do *soft sensor* é ilustrado na Figura 5.25.




Figura 5.25 - Vazão estimada *versus* real com inserção de *outliers* na frequência de rotação do CMB.

Foi verificado que as oscilações presentes nos primeiros instantes de tempo foram decorrentes da presença de água nas tubulações antes da atuação do controlador na planta bem como ao instante transitório do sinal até a sua estabilização após a atuação de controle. Entretanto, ainda com a presença de oscilações iniciais constatou-se a atuação do *soft sensor* acompanhando o valor real da vazão mediante a situação apresentada.

Para fins de análise dos dados referentes aos pontos que compuseram as curvas ilustradas na Figura 5.25, foram determinadas métricas estatísticas relacionadas ao

rastreamento do erro, apenas nos instantes de tempo em que os *outliers* foram inseridos e nas curvas como um todo. Os resultados obtidos (valores aproximados) estão dispostos na Tabela 5.24.

Tabela 5.24 - Métricas estatísticas do erro de rastreamento da vazão mediante inserção de *outliers* na frequência 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	0,0272	0,0019	0,0929	0,0209
II	0,0281	0,0020	0,1049	0,0232
III	0,0279	0,0022	0,1139	0,0213
IV	0,0260	0,0026	0,1367	0,0217
V	0,0246	0,0023	0,0686	0,0169
VI	0,0274	0,0025	0,1239	0,0220
VII	0,0357	0,0065	0,1174	0,0269
Curvas completas	0,1074	0,0101	3,4300	0,2601

Da mesma maneira que na análise estatística dos testes anteriores, ao comparar as métricas estatísticas de rastreamento do erro para cada segmento das curvas (I até VII), foi observado que todos os resultados possuem valores inferiores a 1, o que confere bom desempenho por parte do *soft sensor* mesmo com a inserção de *outliers* na frequência de rotação do CMB concomitante à variação do SP de pressão. A única métrica cujo valor foi superior a 1 foi o erro máximo, devido a consideração de todos os pontos das curvas (transitório e permanente) bem como a presença prévia de ar nas tubulações.

5.4.1.6 ATUAÇÃO DO *SOFT SENSOR* PARA SINAIS ESPÚRIOS EM SEUS SINAIS DE ENTRADA: PT-3, CV-1 e FREQUÊNCIA DE ROTAÇÃO DO CMB

Esse teste teve como objetivo a verificar a atuação do *soft sensor* quando as três entradas: pressão em PT-3, válvula CV-1 e a frequência de rotação do CMB estiveram submetidas a sinais espúrios do tipo ruído contínuo com amplitudes diferentes entre si. Esse cenário representa uma das piores situações que podem acontecer aos elementos de entrada do estimador. Para este teste foram adotadas 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° cada uma enquanto a válvula CV-1 encontrava-se na posição de 0° e a bomba encontrava-se inicialmente em repouso (0 Hz);
- O *setpoint* de pressão foi fixado em 10 mca durante todo o teste;
- A frequência de rotação do CMB acompanhava o *setpoint* de pressão desde o início até a sua estabilização;
- Os ruídos inseridos para este teste específico são compostos por sinais de natureza gaussiana, e cada um possui uma amplitude de referência* (valor constante) adicionada a um valor aleatório** dentro de uma faixa específica, conforme a Equação 5.1.

Os parâmetros utilizados nesse teste em específico estão contidos na Tabela 5.25.

Tabela 5.25 - Parâmetros de entrada do *soft sensor* incluindo sinais espúrios em PT-3, CV-1 e frequência de rotação do CMB.

Variável de entrada	<i>Setpoint</i> (referência)*	<i>Range da componente</i> aleatória**
Ângulo (°)	0	-30 a 10
Pressão (mca)	10	-30 a 40
Frequência (Hz)	39	20 a 58

A Figura 5.26 ilustra a as curvas com ruídos na frequência de rotação do CMB, na válvula CV-1 e no sensor de pressão PT-3. A partir do instante 200s foi iniciada a inserção de ruídos de natureza contínua e com amplitude diferentes para cada variável de entrada (pressão, ângulo e frequência de rotação). Os ruídos permaneceram até o instante aproximado de 300s.




Figura 5.26 - Sinais de entrada frequência de rotação do CMB, ângulo da válvula CV-1 e pressão em PT-3 com ruídos.

O resultado da comparação entre o valor real da vazão mensurada pelo instrumento eletromagnético FT-1 e o estimador de vazão é ilustrado na Figura 5.27.




Figura 5.27 - Vazão estimada *versus* real para inserção ruídos nas três entradas do *soft sensor*.

Para fins de análise dos dados referentes aos pontos que formam as curvas ilustradas na Figura 5.27, foram determinadas algumas métricas estatísticas relacionadas ao rastreamento do erro para as curvas como um todo (curvas completas) bem como para o trecho referente apenas ao instante de tempo de inserção dos ruídos. Os resultados obtidos (valores aproximados) estão dispostos na Tabela 5.26.

Tabela 5.26 - Métricas estatísticas do erro de rastreamento da vazão mediante inserção de *outliers* em PT-3, CV-1 e frequência de rotação do CMB 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)
Apenas ruídos	0,0376	0,0026	0,1367	0,0262
Curvas completas	0,1678	0,0225	2,3843	0,3098

Ao realizar a comparação das métricas estatísticas de rastreamento do erro no instante da inserção dos ruídos, foi observado que todos os resultados possuíram valores muito inferiores a 1, o que induz um desempenho esperado por parte do *soft sensor* mesmo com a inserção de ruídos em suas três entradas. Sinais espúrios concomitantes nas três entradas do estimador de vazão corresponde a um dos piores cenários para verificar a robustez do instrumento virtual. Entretanto, o *soft sensor* estimou a vazão em toda a excursão das curvas analisadas perante este teste de robustez crítica.

CAPÍTULO VI

CONCLUSÕES E RECOMENDAÇÕES DE TRABALHOS FUTUROS

O principal objetivo deste trabalho foi a implementação de um instrumento virtual, denominado *soft sensor*, capaz de mensurar a vazão em um sistema de abastecimento de água. Assim, para o escopo do trabalho, 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. Esta etapa da pesquisa correspondeu ao primeiro dos objetivos específicos almejados. Assim, foram realizados dois tipos de ensaios 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. A partir da análise dos resultados obtidos através das curvas de vazão estimada versus real e das métricas estatísticas analisadas, foi adotada RNA do tipo NARX a fim de exercer o papel do *soft sensor* perante os testes de validação.

Os testes de validação foram categorizados em testes sem a presença do controlador atuando no sistema (cinco testes) e com a presença do controlador (neste caso o controlador PID-IMRAC) atuando no sistema (mais seis testes). Os testes fizeram parte do segundo e do terceiro objetivos específicos esperados como resultados da pesquisa. Todos os testes de validação realizados corroboraram com a eficiência da técnica de estimação apresentada neste trabalho. O Erro Médio Quadrático foi o critério para rastreamento do erro utilizado, associando ao quarto objetivo específico almejado.

Foi verificado durante a análise dos resultados dos testes a partir das 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.

Algumas limitações foram observadas ao longo da pesquisa como a possibilidade de não alteração significativa da planta experimental para realização de testes relativos à influência da vazão mediante perdas ou furtos de água, por exemplo, devido à planta ser de uso compartilhado com outras pesquisas ocorrendo em paralelo. Outra limitação encontrada foi a quantidade relativamente pequena de pesquisas realizadas na área de estimação de grandezas específicas em SAA, através do qual esta tese e publicações associadas puderam contribuir neste sentido. Ademais, a pandemia de Covid-19 também influenciou negativamente no andamento da pesquisa.

Como recomendações de trabalhos futuros, pode-se citar, dentre outras possibilidades:

- A aplicabilidade da metodologia para a concepção do *soft sensor* em um contexto de um sistema de abastecimento de água de maiores dimensões, observando características reais de variação da demanda de consumo populacional estruturando o *soft sensor* desenvolvido às condições físicas do sistema a ser utilizado;
- A integração do instrumento virtual de vazão com um sistema inteligente de aquisição de pressão com alimentação autônoma de energia (mediante sensores que utilizam técnicas de Colheita de Energia), em que os dados colhidos por estes sensores servissem como uma das entradas do *soft sensor*;
- A possibilidade de um estudo a médio e longo prazos envolvendo a eficiência da técnica de estimação apresentada nesta tese. Poderia ser levado em consideração o envelhecimento dos dispositivos utilizados comumente em SAA (tubulações, bombas e demais acessórios), baseados na vida útil desses dispositivos e a validação do *soft sensor* perante essas condições.

REFERÊNCIAS BIBLIOGRÁFICAS

A AVALIAÇÃO DA INCERTEZA DE MEDIÇÃO DA VAZÃO DOS FLUIDOS. 2022. *Revista Adnormas*, São Paulo, n.196.

AMBRÓSIO, P. E., 2002, *Redes Neurais Artificiais no Apoio ao Diagnóstico Diferencial de Lesões Intersticiais Pulmonares*. Dissertação de M.Sc., USP, Ribeirão Preto, SP, Brasil.

ALMEIDA, V. A., 2017, *Uma Metodologia para Tratamento de Dados de Curvas de Carga Baseada em Técnicas de Inteligência Artificial*. Dissertação de M.Sc., UFRJ, Rio de Janeiro, RJ, Brasil.

ÅSTRÖM, K. J.; WITTENMARK, B., 2013. “Adaptive control”, Courier Corporation.

BALLINI, R., 2000, *Análise e Previsões de Vasões Utilizando Modelos de Series Temporais, Redes Neurais e Redes Neurais Nebulosas*. Tese de D.Sc., - UNESP, Campinas, SP, Brasil.

BABUNSKI, D., Z, E., TUNESKI, A., 2018, “Optimization methods for water supply SCADA system”, In: *7th Mediterranean Conference on Embedded Computing*. pp.1-4, (MECO).

BELHAJ, A. F., ELRAIES, K. A., ALNARABJI, M. S., KAREEM, F. A. A., SHUHLI, J. A., MAHMOOD, S. M., BELHAJ, H., 2021. “Experimental investigation, binary modelling and artificial neural network prediction of surfactant adsorption for enhanced oil recovery application”. *Chemical Engineering Journal*, v. 406, 127081.

BEZERRA, S. T. M.; CHEUNG, P. B., 2013, “Perdas de água: tecnologias de controle”, João Pessoa: Editora Universitária da UFPB, 2013. 220p.

BEZERRA, S. T. M., 2009. “Sistema fuzzy para controle piezométrico de sistemas de distribuição de água visando à economia de água e energia”. Tese. Universidade Federal da Paraíba, João Pessoa.

BOTTURA, F.B., 2010. “Um método alternativo e inteligente para o monitoramento remoto das variações de tensão de curta duração em um sistema de distribuição de energia elétrica”. Tese. Universidade de São Paulo, São Paulo.

BRASIL. Lei n. 14026, de 30 de jul. de 2020. Atualiza o marco legal do saneamento básico e altera a Lei nº 9.984, de 17 de julho de 2000, Brasília - DF, jul. 2020.

BROGAN, A., GOPALAKRISHNAN, V., STURTEVANT, K., VALIGOSKY, Z., KISSOCK, K., 2016. “Improving Variable-Speed Pumping Control to Maximize Savings”. *ASHRAE Transactions*, v. 122(2).

CABRAL, M.; LOUREIRO, D.; ALMEIDA, M.D.C.; COVAS, D., 2019, “Estimation of costs for monitoring urban water and wastewater networks”. *J. Water Supply Res. Technology*. pp. 87-97, v.68, Aug.

CAGEPA - Companhia de Água e Esgotos da Paraíba. Ata de Registro de Preços n.007/2020. Disponível em <http://www.cagepa.pb.gov.br/atas-de-registro-de-preco/>. Acesso em 05 de jun. 2021.

CAMBOIM, W. L. L.; SILVA, S. A.; GOMES, H. P., 2014, “Aplicação de técnicas Fuzzy no controle de pressão em sistemas de abastecimento de água”, p. 67-77, *Engenharia Sanitária e Ambiental*, v. 19.

CAMBOIM, M.M.; VILLANUEVA, J.M.M.; DE SOUZA, C.P., 2020, “Fuzzy Controller Applied to a Remote Energy Harvesting Emulation Platform”. *Sensors*.

CARVALHO, P. S. O., 2012. *Controle para Bombeamento Distribuído com Vistas à Minimização dos Custos Energéticos Aplicado a Sistemas de Abastecimento de Água*. Tese de D.Sc., UFPB, João Pessoa, PB, Brasil.

CATUNDA, S.Y.C.; DEEP, G.S.; VAN HAANDEL, A.C.; FREIRE, R.C.S., 1999, “Feedback Control Method for Estimating the Oxygen Uptake Rate in Activated Sludge Systems”.In: *J. IEEE Trans. Instrum. Meas.* pp. 864-869.

CORTES, R. X.; MARTINS, T. G.; PRATES, M. O.; SILVA, B. F. A. 2017. “Inference on dynamic models for non-Gaussian random fields using INLA”. *Brazilian Journal of Probability and Statistics*, v. 31, p. 1-23.

FLORES, T. K, VILLANUEVA, J.M.M, GOMES, H.P, CATUNDA, S.Y.C., 2021, “Adaptive Pressure Control System Based on the Maximum Correntropy Criterion”. *Sensors*, v. 21, n. 1, p. 5156.

FLORES, T. K, VILLANUEVA, J.M.M, GOMES, H.P, CATUNDA, S.Y.C., 2020, “Indirect Feedback Measurement of Flow in a Water Pumping Network Employing Artificial Intelligence”. *Sensors*, v. 21, n. 1, p. 75

FLORES, T. K., 2021, *Controle Adaptativo Utilizando o Critério da Máxima Correntropia Aplicado a um Sistema de Bombeamento de Água*. Dissertação de M.Sc., UFPB, João Pessoa, PB, Brasil.

FONTES, D. O.L, 2020. *Desenvolvimento de Soft Sensor para Predição do Estado Térmico do Ferro Gusa em Alto-Forno usando Fuzzy c-Médias e Modelo Exógeno Auto-Regressivo não Linear*. Dissertação de M.Sc., UFCG, Campina Grande, PB, Brasil.

GODSILL, Simon; RAYNER, Peter; CAPPÉ, Olivier. “Digital audio restoration. 2002. Applications of digital signal processing to audio and acoustics”. Springer, Boston, p. 133-194.

GOMES, H. P., 2009, *Sistemas de Bombeamento*. João Pessoa, Editora Universitária UFPB.

GONZÁLEZ, B.; JIMÉNEZ, F.J.; DE FRUTOS, J., 2020, “A Virtual Instrument for Road Vehicle Classification Based on Piezoelectric Transducers”. *Sensors*, 20, 4597.

GWAIVANGMIN, B.I.; JIYA, J.D., 2017,” Water Demand Prediction Using Artificial Neural Network for Supervisory Control”. *Niger. J. Technol.* pp.148-154, 36.

GWOZDZIEJ-MAZUR, J.; SWIĘTOCHOWSKI, K., 2018, “Analysis of The Water Meter Management of The Urban-Rural Water Supply System”. In: *E3S Web Conf.* pp. 44- 51.

HAN, J.; PEI, J.; KAMBER, M. “Data mining: concepts and techniques”. [S.l.]: Elsevier, 2011.

HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. 2. ed. New Jersey: Prentice Hall, 2001. 908p.

HAWKINS, D. M. “Identification of outliers”. [S.l.]: Springer, v. 11, 1980.

JOSEPH, A.; ISAAC, J. S. et al. 2013, “Real time implementation of model reference adaptive controller for a conical tank. *International Journal on theoretical and applied research in Mechanical Engineering*”, v. 2, n. 1, p. 57–62.

KADLEC, P., GABRYS, B., STRANDT, S. 2009. “Data-driven soft sensors in the process industry. *Computers & chemical engineering*”, v. 33(4). p. 795-814.

KALLESØE, C. S.; JENSEN, T. N.; WISNIEWSKI, R., 2015. “Adaptive reference control for pressure management in water networks”. In: *IEEE. 2015 European Control Conference (ECC)*. [S.l.], p. 3268–3273.

LATHI. B.P., “*Sistemas de Comunicação*”. Guanabara Dois, 1979.

LEIRENS, S. et al., 2010, “Coordination in urban water supply networks using distributed model predictive control”. In: IEEE. Proceedings of the 2010 American Control Conference. [S.l.], p. 3957–3962.

LIMA, R.P.G., 2013. “*Uma Aplicação Baseada em Sistemas Imunológicos Artificiais para Detecção de Falhas em uma Plataforma de Abastecimento de Água*”. Dissertação de M.Sc., UFPB, João Pessoa, PB, Brasil.

LIU, D. et al. 2019. “Distributed zone mpc of pressure management for water distribution network systems”. IET Control Theory & Applications, IET, v. 13, n. 11, p. 1704–1717.

LIU, D. et al., 2019, “Zone model predictive control for pressure management of water distribution network”. Asian Journal of Control, Wiley Online Library.

LIU, Y., XIE, M. 2020.”Rebooting data-driven soft-sensors in process industries: A review of kernel methods. Journal of Process Control”, v. 89, p. 58-73.

LIU, Z., HAN, Z., ZHAO, Z., HE, W. 2021. “Modeling and adaptive control for a spatial flexible spacecraft with unknown actuator failures”. Science China Information Sciences, v. 64(5), p. 1-16.

LOPES, R.D. 2002. “Previsão de Autopeças: Estudo de Caso em uma Concessionária de Veículos”. Dissertação de M.Sc., UFSC, Florianópolis, SC, Brasil.

MAGALHÃES, Marcos Nascimento; DE LIMA, Antônio Carlos Pedroso. “Noções de probabilidade e estatística”. Editora da Universidade de São Paulo, 2002.

MALUTTA, C. 2004. *Método de Apoio à Tomada de Decisão sobre Adequação de Aterros Sanitários utilizando a Lógica Fuzzy*. Tese de D.Sc., UFSC, Florianópolis, SC, Brasil.

MARTINEZ, W., MARTINEZ, A., 2002. *Computational Statistics Handbook with Matlab*, 1 ed., Chapman and Hall/CRC.

MENDONÇA, K. H., 2016. *Sistema de Controle Fuzzy na Operação Otimizada de Redes Setorizadas com Bombeamento Direto*. Dissertação de M.Sc., UFPB, João Pessoa, PB, Brasil.

MORAWSKI, R. Z., 1994. “Unified approach to measurand reconstruction. iee transactions on instrumentation and measurements”, Vol. 43, n. 2, pp 226-231.

MOREIRA, H.A.M., 2020. *Controle Neuro-Fuzzy para Eficiência Energética de Sistemas de Abastecimento de Água com Demanda Variável*. Dissertação de M.Sc., UFPB, João Pessoa, PB, Brasil.

NAIR, A., HYKKERUD, A., RATNAWEERA, H. 2022. “Estimating Phosphorus and COD Concentrations Using a Hybrid Soft Sensor: A Case Study in a Norwegian Municipal Wastewater Treatment Plant”. *Water*, v. 14, n. 3, p. 332.

NETO, L.S.R., 1999. *Artificial Neural Networks, Fuzzy Logic and Neuro-Fuzzy System In The Role Of Short Term Load Forecast*. Dissertação M.Sc., PUC-RIO, Rio de Janeiro, RJ, Brasil.

NETTO, A., FERNANDEZ, J.M., ARAÚJO, M. F., 1998, “Manual de Hidráulica”. 8.ed. São Paulo, Edgard Blücher.

PEDRYCZ, W., GOMIDE, F., 2007. “Fuzzy systems engineering: toward human-centric computing”, In: *IEEE Press*, New York: Wiley.

QUADROS, A. S.; PINTO, A. M. D. A. 2013. “Controle pid com sintonia automática e adaptativa de válvulas redutoras de pressão em sistemas de abastecimento de água”. *Proceeding Series of the Brazilian Society of Computational and Applied Mathematics*, v. 1, n. 1.

QUADROS, A.; MURILO, A., 2014. “Automatic and adaptive tuning of pid controllers for pressure reducing valves in water supply systems”. *ABCM Symposium Series in*

Mechatronics, v. 6, p. 182–191.

QUEVEDO, J.; CHEN, H.; CUGUERÓ, M.À.; TINO, P.; PUIG, V.; GARCÍA, D.; YAO, X., 2014, “Combining learning in model space fault diagnosis with data validation/reconstruction: Application to the Barcelona water network”. *Eng. Appl. Artif. Intell.* v.30, pp.18-29.

RODRIGUEZ, H.; PUIG, V.; FLORES, J.J.; LOPEZ, R., 2016, “Flow Meter Data Validation and Reconstruction Using Neural Networks: Application to the Barcelona Water Network”. In: *Eur. Control Conf. (ECC)*, v.1, pp. 1746-1751.

ROMAN, R.C.; PRECUP, R.E.; PETRIU, E.M., 2020, “Hybrid Data-Driven Fuzzy Active Disturbance Rejection Control for Tower Crane Systems”. *Eur. J. Control*

SAAEP. Serviço Autônomo de Água e Esgoto em Parauapeba - PA, Concorrência Pública N° 01/2018saaep. Disponível em http://www.saaep.com.br/wp-content/uploads/2018/11/Edital-Concorrência-Pública-n%C2%BA-01_2018SAAEP.pdf. Acesso em 05 de jun. 2021.

SABESP - Companhia de Saneamento Básico do Estado de São Paulo. Sistema de Licitações, 2020. Disponível em <https://licitacoes.sanepar.com.br/SLI16100.aspx?NumPro=111920>. Acesso em 05 de jun. 2021.

SALVINO, L. R., 2018. *Eficiência Energética em Sistemas Pressurizados de Distribuição de Água com o uso de Redes Neurais Artificiais*. Tese D.Sc., UFPB, João Pessoa, PB, Brasil.

SALVINO, M. M., 2012. *Modelagem Computacional Visando a Reabilitação de Redes Hidráulicas*. Tese de D.Sc., UFPB, João Pessoa, PB, Brasil.

SANEPAR - Companhia de Saneamento do Paraná. Sistema de Licitações, 2021. Disponível em <http://sabesp-info18.sabesp.com.br/licita/Publica.nsf/de7bd4310298d1e183257250005c8911/4c4e6f60a582c3b2032586ea00227123?OpenDocument>. Acesso em 05 de jun. 2021.

SANTOS, R. B., 2018. “Aplicação de redes neurais artificiais na predição dos parâmetros de cor e turbidez no processo de coagulação.” Trabalho de conclusão de curso, UEPB, Campina Grande, PB, Brasil.

SANTOYO, S., 2017. “A brief overview of outlier detection techniques”. Towards data science.

SILVA, E., OLIVEIRA, A, “Dicas para a configuração de redes neurais”. Rio de Janeiro, 2001.

SILVA, M. J. G, 2014. “Controle Adaptativo aplicado a um Sistema de bombeamento de água visando a redução das perdas de energia elétrica e água.” Tese de D.Sc., UFPB, João Pessoa, PB, Brasil.

SIMÕES, M. G., SHAW, I. S., 2007, “Controle e Modelagem Fuzzy”, ed. 1, São Paulo-SP, Editora Edgard Blücher Ltda.

SOUSA, R. D., 2017. “Uso de Válvulas Redutoras de Pressão na Otimização de Rede Setorizada de Distribuição de Água.” Dissertação de M.Sc., UFPB, João Pessoa, PB, Brasil.

TAMBARA. R. V, 2018, “Controle Adaptativo: Teoria e Aplicação”, ed. 1, Santa Maria - RS, Editora Santa Maria.

TEIXEIRA, L. R. d. L. 2016. “Controlador em modo dual adaptativo robusto indireto (idmarc)”. Brasil.

TSUTIYA, M. T., 2006. Abastecimento de água. 4. ed. São Paulo: Departamento de Engenharia Hidráulica e Sanitária da Escola Politécnica da Universidade de São Paulo, 2006. 643p.

VALADARES, Fabrício G.; AQUINO, A. L. L.; RABELO, R. A. 2012. “Detecção de outliers multivariados em redes de sensores sem fio”. XLIV Simpósio Brasileiro de Pesquisa Operacional.

VALENTIN, N.; DENOEU, T., 2001, “A Neural Network-Based Software Sensor for Coagulation Control in a Water Treatment Plant”. *Intell. Data Anal.* v.5, pp. 23-39.

VILELA, L. B.; MATEUS, T. H. A. 2016. “Aplicação de rede neural narx para a previsão do preço da soja”, XXXVI Encontro Nacional de Engenharia de Produção. João Pessoa, Brasil.

VLADIMIR, C.; HEILIÖ, M.; KREJIC, N.; NEDELJKOV, M., 2008, “Mathematical Model for Efficient Water Flow Management. Nonlinear Analysis: Real World Applications”. *J. Abbr.* v.10, pp. 142-149.

WANG, G.; KIAMEHR, K.; SONG, L. T., 2016, “Development of A Virtual Pump Water Flow Meter with a Flow Rate Function of Motor Power and Pump Head”. *Energy Build.* v.117, pp. 63-70.

WILLMOTT, C. J., 1981, “On the validation of models”, *Phys. Geogr.* v.2, pp. 184-194.

WILLMOTT, C. J.; MATSUURA, K.; ROBESON, S. M., 2009. “Ambiguities inherent in sums-of-squares-based error statistics”. *Atmospheric Environment*, Elsevier Ltd, v. 43, n. 3, p. 749–752.

XU, Z.; YANG, J.; CAI, H.; KONG, Y.; HE, B., 2015, “Water distribution network modeling based on NARX”. *IFAC-PapersOnLine*, v 48, pp.72-77.

ZHAO, T.; SUN, Y.; LIU, Z.; LI, K. 2021. “An engineering-oriented variable water flow air-conditioning system terminal flow rate estimation method based on component flow resistance characteristics”. *Energy Science & Engineering*. Vol.9 (6), pp.843-854

ANEXO I – TABELA DE MÉRITO PARA ESCOLHA DOS PARÂMETROS DAS RNAs

A Tabela AI contém os resultados de alguns testes, realizados de maneira empírica, buscando a otimização das RNAs tanto para a fase de treinamento quanto para a fase de testes, baseadas nas recomendações segundo (Silva e Oliveira, 2001).

Tabela AI - Testes para otimização dos parâmetros das RNAs

MSE	Gradiente	Epoch	Algoritmo de treinamento	Nº de camadas ocultas	Nº de neurônios na camada oculta	Função de ativação
5,589.10 ⁻¹²	6,12.10 ⁻⁵	1000	LM	1	5	tansig
7,313.10 ⁻¹¹	9,61.10 ⁻⁶	1000	LM	1	6	tansig
1,383.10 ⁻¹¹	3,68.10 ⁻⁶	1000	LM	1	7	tansig
1,639.10⁻¹⁰	1,32.10⁻⁹	1000	LM	1	8	tansig
3,214.10 ⁻¹⁰	3,30.10 ⁻⁶	1000	LM	1	9	tansig
3,434.10 ⁻¹⁰	2,02.10 ⁻⁷	1000	LM	1	10	tansig
3,511.10 ⁻⁹	3,47.10 ⁻⁵	1000	LM	1	11	tansig
1,313.10 ⁻¹⁰	3,11.10 ⁻⁶	1000	LM	1	12	tansig
6,112.10 ⁻¹⁰	2,68.10 ⁻⁶	1000	LM	1	25	tansig

Os principais parâmetros encabeçados na Tabela AI são descritos a seguir:

MSE ou EMQ

Corresponde ao erro quadrático médio ou erro quadrático médio (ou *mean squared error* em inglês). É um parâmetro estatístico capaz de avaliar os resultados de uma rede neural. Normalmente é utilizado como indicador de desempenho da rede. O EMQ pode ser representado pela Equação A.I.

$$MSE = \frac{1}{N} \sum_{j=1}^M \sum_{k=1}^N (y_{jk} - yd_{jk})^2 \quad (A.I)$$

onde M é o número de saídas da rede, N é o número de amostras de treinamento ou validação, y_j é a saída da rede, y_{dj} é o valor de saída desejado e o MSE é o erro médio entre a saída da rede y_j e os valores desejados y_{dj} .

Durante o treinamento, o MSE normalmente inicia com valores elevados e então decresce conforme o número de interações (*epoch*) aumenta. Ao final, o MSE se mantém praticamente constante e a rede neural converge (Santos, 2018). Maiores detalhes sobre o MSE (ou EMQ) podem ser obtidas no Capítulo III.

Gradiente

Algoritmo que busca minimizar o MSE de modo a se obter um conjunto de pesos otimizado, que encerrará o processo de treinamento, tornando a rede apta a produzir padrões de saída aceitáveis (Santos, 2018).

Iterações (*epochs*)

Ciclo completo em que a rede Neural “visualizou” todos os seus dados.

Algoritmo de treinamento

O algoritmo de treinamento ou as “regras de aprendizado” determinam como os pesos sinápticos de uma RNA serão modificados. Este processo envolve o ajuste dos valores dos pesos e desvios da rede para otimizar o desempenho da rede, conforme definido pela função de desempenho da rede. O algoritmo utilizado nesta etapa é o de Levenberg–Marquardt (LM). Esse algoritmo consiste em um método de otimização publicado primeiramente por Kenneth Levenberg e aperfeiçoado por Donald Marquardt.

Esse método consiste na determinação das derivadas de segunda ordem do erro quadrático em relação aos pesos visando a aceleração do treinamento (Bottura, 2010) (Santos, 2018).

Número de camadas ocultas

São camadas que não fazem parte nem da camada de entrada ou nem da camada de saída. São as camadas intermediárias da rede.

Número de neurônios ocultos

São os neurônios que não fazem parte nem da camada de entrada ou nem da camada de saída.

Função(ões) de ativação

Funções que decidem se um determinado neurônio deve ser ativado ou não.

A função de ativação, ou transferência, mais comum é a função sigmoide (comando *tansig* no Matlab) ou logística por possui boas propriedades matemáticas como continuidade e diferenciabilidade, que são fundamentais ao treinar uma rede neural com gradiente descendente (Halkin, 2001) (Fontes, 2020).

ANEXO II - AJUSTE DOS TRANSDUTORES DE PRESSÃO E VAZÃO

O ajuste de instrumentos é um procedimento que possibilita identificar se os dispositivos de medição utilizados numa planta instrumentada estão aptos a realizar medições adequadas e que os valores apresentados por eles não irão interferir na qualidade final dessas medições. Dessa forma, todos os instrumentos utilizados cujas variáveis (pressão e vazão) são necessárias às etapas posteriores do projeto, foram devidamente calibrados seguindo rigorosamente as recomendações do fabricante de cada instrumento.

IIA. AJUSTES DOS TRANSDUTORES DE PRESSÃO

Um Transdutor de Pressão (PT), às vezes denominado de transmissor de pressão, é um instrumento industrial que converte a pressão, identificada por uma base capaz de sofrer deformação, em um sinal elétrico analógico. Os transdutores utilizados no cenário do SDA possuem, como princípio de funcionamento, a causa/efeito deformação/sinal elétrico. Para a os ajustes dos transdutores de pressão (PT) existentes na bancada experimental (cenário) utilizou-se de uma **balança de peso morto**. Uma balança de peso morto é um padrão de ajuste que utiliza o princípio de um equilíbrio de pressão para calibrar instrumentos de medição de pressão. O esquema desse dispositivo pode ser visualizado pela Figura A1.



Figura A1 - Balança de peso morto utilizado para ajuste dos sensores de pressão (Flores, 2019).

O procedimento para o correto ajuste de cada transdutor de pressão é descrito da seguinte maneira:

- A balança de peso morto é preenchida internamente com óleo, enquanto a manivela é deixada na sua posição de máximo curso a fim de evitar pressurização do sistema e, por conseguinte, vazamento de óleo;
- Após a instalação do transdutor de pressão, aplica-se pressão ao sistema por meio do deslocamento (giro em sentido horário de maneira devagar) da manivela;
- A partir de então, a pressão é aplicada tanto ao transdutor quanto ao peso-morto, que consiste no peso de referência colocado no êmbolo do sistema, sendo que esse último são conhecidas sua massa e área. Então, quando o peso de referência “flutua”, isto é, se desloca até uma determinada altura indicada pela balança, é neste momento que a medida do instrumento deve ser igual ao peso de referência. Os índices 1, 2 e 3 na Figura A1, representam, respectivamente, o correto posicionamento do transdutor de pressão a ser calibrado, o peso de referência sobre o pistão de deslocamento e os demais pesos de referência, sendo estes equivalentes a 10 (dez) mca cada um.

Para o correto ajuste de cada transdutor de pressão foi montado um esquema de configuração representado pela Figura A2.




Figura A2 - Esquema de Detecção da corrente do Transdutor de Pressão
(Flores, 2019).

O esquema foi utilizado para determinar os valores da corrente correspondente a cada medida de peso utilizados como referência do ajuste do sensor. No procedimento citado anteriormente, o transdutor é do tipo piezoresistivo, isto é, o valor da resistência é variável mediante a deformação causada pela pressão a qual está submetido.

II.B AJUSTE DOS TRANSDUTORES DE VAZÃO

Um transdutor de vazão é um instrumento utilizado para medir a taxa de vazão, linear ou não linear, da massa ou do volume de um líquido ou um gás. Os transdutores de vazão utilizados no cenário (planta do SAA) são do tipo eletromagnéticos não invasivos, ou seja, o sistema de medição não está em contato com o fluido medido.

O método de ajuste dos transdutores de vazão utilizados consiste no manuseio de três potenciômetros presente no circuito de condicionamento do sensor (placa de conexão elétrica). Um desses potenciômetros realiza o **ajuste de zero** do instrumento (item 10 da Figura A3) e os outros dois referem-se ao ajuste da **faixa de operação** do instrumento, isto é, de 4 a 20 mA respectivamente (itens 8 e 9 da Figura A3). de faixa de operação. A Figura A3 ilustra, de maneira geral as conexões elétricas existentes na placa eletrônica do medidor de vazão em questão e as descrições a seguir explicitam as descrições de cada item enumerado e os ajustes realizados no instrumento em questão.




Figura A3 - Circuito condicionador de Sinal do Sensor de vazão (Fonte: Incontrol).

Os itens enumerados mostrados na Figura A3 correspondem a:

1. Ponto de aterramento (GND);
2. Saída 4-20 mA;
3. Saída pulso isolada (NPN);
4. Alimentação 24 Vcc e 250 mA;
5. Fusível 0,5 A;
6. Ajuste da frequência da saída pulso (P6 - Hz);
7. Jumper para calibração (JP1);
8. Ajuste do 4 mA (P5 - 4 mA);
9. Ajuste do 20 mA (P4 - 20 mA);
10. PT4 - Ponto de teste do ajuste de zero;
11. Zero (P2 - Ajuste de zero);
12. PT5 - Terra (aterramento);
13. LD1 - LED (indicador informando que a placa está devidamente alimentada).

Para o teste correspondente ao **ajuste de zero**, foram adotadas, seguindo o manual do fabricante (Incontrol, 2009) os seguintes procedimentos:

- O instrumento foi preenchido com fluido (no caso do teste foi utilizada água por ser o fluido a ser medido no cenário);
- O instrumento foi alimentado com 24 V (item 4, pinos 1 e 2, da Figura A3);
- Após 30 (trinta) minutos foi ajustado o potenciômetro que corresponde ao ponto de teste do ajuste de zero (item 10 da Figura A3) de modo a obter 0,0 mVcc entre o ponto de medição correspondente ao item 10 (medição) e ao item 12 (PT5-Terra). Para essa medição, foi utilizado um multímetro digital.
- Atentou-se, para esse teste, o aterramento (utilizando a blindagem do mesmo cabo quem contém os fios de alimentação e de dados) correto do instrumento a fim de evitar oscilações indesejadas de leitura tanto no ato do ajuste bem como na posterior utilização do instrumento quando ele estiver efetuando, de fato, as medições de vazão.

Também foi realizado o **ajuste e teste de saída** correspondente a **4-20mA** do instrumento seguindo o manual do fabricante (Incontrol, 2009) mediante os procedimentos descritos a seguir:

- Inicialmente alimentou-se o equipamento com 24Vcc;
- Foi retirado o *jumper* JP1 (correspondente ao item 7 da Figura A3), isto é, ele não estava conectado a nenhuma posição para funcionamento normal da placa;
- Mediu-se, com um amperímetro na escala de 20 mA, a corrente na saída 4-20 mA (conforme visualizado pelo item 2 da Figura A3) nos terminais respectivos entre o multímetro e o medidor. Para isso, foi observada a indicação do amperímetro e ajuste (regulação da resistência) do potenciômetro “P5 - 4 mA” (conforme visualizado pelo item 8 da Figura A3) até que o valor da corrente seja 4,00 mA
- O *jumper* JP1 foi comutado para a posição CL (conforme manual do fabricante), observada a indicação do amperímetro e ajuste (regulação da resistência) do potenciômetro “P4 - 20 mA” (conforme visualizado pelo item 9 da Figura A3) até que o valor da corrente seja 20,00 mA;
- Após a realização desses procedimentos, o *jumper* JP1 foi comutado para a posição PV (conforme manual do fabricante para funcionamento normal do dispositivo) e o instrumento estava pronto para utilização.

ANEXO III - CONTROLE ADAPTATIVO INDIRETO POR MODELO DE REFERÊNCIA

A Figura A3 ilustra o diagrama em blocos do controlador IMRAC-PID desenvolvido por (Flores, 2021).




Figura A3 - Diagrama de blocos do controlador IMRAC-PID (Flores, 2021).

Para o desenvolvimento matemático deste controlador, (Flores, 2021) considerou uma planta de primeira ordem (Equação (A.1)), um modelo de referência de segunda ordem (Equação (A.2)) e um controlador Proporcional, Integral e Derivativo (Equação (A.3)), cujos parâmetros a serem adaptados são K_p, K_i e K_d .

$$H_p(s) = \frac{Y_p(s)}{U(s)} = \frac{b_p}{s + a_p} \quad (\text{A.1})$$

$$H_m(s) = \frac{Y_m(s)}{R(s)} = \frac{b_m}{s^2 + sa_{m1} + a_{m2}} \quad (\text{A.2})$$

$$H_c(s) = K_p + \frac{K_i}{s} + sK_d \quad (\text{A.3})$$

em que $R(s)$ é o sinal de referência, $Y_p(s)$ é a saída da planta, $Y_m(s)$ é a saída do modelo de referência, $U(s)$ é o sinal de atuação do controlador e $H_p(s)$, $H_m(s)$ e $H_c(s)$ são as funções de transferência da planta, do modelo e do controlador, respectivamente. Portanto, pode-se definir a seguinte lei de controle:

$$U(s) = H_c(s)(R(s) - Y_p(s)) \quad (\text{A.4})$$

Para que o sistema em malha fechada se comporte tal como o modelo de referência, é necessário que $Y_p(s) = Y_m(s)$. Para isto, é necessário descrever a saída da planta em função do sinal de referência, substituindo a Equação A.1 em Equação A.4, obtém-se:

$$Y_p(s) = H_p(s)H_c(s)(R(s) - Y_p(s)) \quad (\text{A.5})$$

ou ainda

$$\frac{Y_p(s)}{R(s)} = \frac{H_p(s)H_c(s)}{1 + H_p(s)H_c(s)} \quad (\text{A.6})$$

Em seguida, substituindo a Equação A.1 e a Equação A.3 em Equação A.6, resulta:

$$Y_p(s) = \frac{s^2 K_d b_p + s K_p b_p + K_i b_p}{s^2 + s a_p} (R(s) - Y_p(s)) \quad (\text{A.7})$$

ou ainda

$$\frac{Y_p(s)}{R(s)} = \frac{s^2 K_d b_p + s K_p b_p + K_i b_p}{s^2(1 + K_d b_p) + s(a_p + K_p b_p) + K_i b_p} \quad (\text{A.8})$$

Para que possamos derivar parcialmente no domínio do tempo a variável $Y_p(s)$ deve-se considerar que o operador s equivale ao operador diferencial no domínio do tempo, denotamos $s \equiv \frac{d(.)}{dt}$. Assim, a Equação A.6 é reescrita como:

$$y_p(t) = \frac{\left(\frac{d(.)}{dt}\right)^2 (K_d b_p) + \left(\frac{d(.)}{dt}\right) (K_p b_p) + K_i b_p}{\left(\frac{d(.)}{dt}\right)^2 (1 + K_d b_p) + \left(\frac{d(.)}{dt}\right) (a_p + K_p b_p) + K_i b_p} r(t) \quad (\text{A.9})$$

Dessa forma, para aproximar o sinal em malha fechada da saída da planta y_p ao sinal de saída do modelo de referência y_m é necessário minimizar o erro de rastreamento $\varepsilon = y_p - y_m$. Para isto, considere a seguinte função custo:

$$J = \frac{1}{N} \sum_{i=1}^N \frac{1}{2} \varepsilon_i^2 \quad (\text{A.10})$$

$$J = \frac{1}{N} \sum_{i=1}^N \frac{1}{2} (y_{p_i} - y_{m_i})^2 \quad (\text{A.11})$$

Substituindo as Equações (A.9) e (A.2) na forma contínua, na Equação (A.11).

Logo, para minimizar o valor de J , é razoável modificar os parâmetros K_p, K_i e K_d em direção ao gradiente descendente, tal como:

$$\frac{dK_p}{dt} = -\gamma_p \frac{\partial J}{\partial K_p} = -\gamma_p \left(\frac{\partial J}{\partial e} \right) \left(\frac{\partial e}{\partial y_p} \right) \left(\frac{\partial y_p}{\partial K_p} \right) \quad (\text{A.12})$$

$$\frac{dK_i}{dt} = -\gamma_i \frac{\partial J}{\partial K_i} = -\gamma_i \left(\frac{\partial J}{\partial e} \right) \left(\frac{\partial e}{\partial y_p} \right) \left(\frac{\partial y_p}{\partial K_i} \right) \quad (\text{A.13})$$

$$\frac{dK_d}{dt} = -\gamma_d \frac{\partial J}{\partial K_d} = -\gamma_d \left(\frac{\partial J}{\partial e} \right) \left(\frac{\partial e}{\partial y_p} \right) \left(\frac{\partial y_p}{\partial K_d} \right) \quad (\text{A.14})$$

em que $\frac{\partial J}{\partial \varepsilon} = \varepsilon$, $\frac{\partial e}{\partial y_p} = 1$, $D = d(\cdot)/dt$, γ_p, γ_i e γ_d são os ganhos de adaptação do controlador, os quais regulam a velocidade de aprendizagem.

$$\frac{\partial y_p}{\partial K_p} = \left(\frac{\left(\frac{b_p}{1+K_b b_p} \right) D}{D^2 + D \left(\frac{a_p + K_p b_p}{1+K_d b_p} \right) + \left(\frac{K_i b_p}{1+K_d b_p} \right)} \right) (r(t) - y_p(t)) \quad (\text{A.15})$$

$$\frac{\partial y_p}{\partial K_i} = \left(\frac{\left(\frac{b_p}{1+K_b b_p} \right)}{D^2 + D \left(\frac{a_p + K_p b_p}{1+K_d b_p} \right) + \left(\frac{K_i b_p}{1+K_d b_p} \right)} \right) (r(t) - y_p(t)) \quad (\text{A.16})$$

$$\frac{\partial y_p}{\partial K_d} = \left(\frac{\left(\frac{b_p}{1+K_b b_p} \right) D^2}{D^2 + D \left(\frac{a_p + K_p b_p}{1+K_d b_p} \right) + \left(\frac{K_i b_p}{1+K_d b_p} \right)} \right) (r(t) - y_p(t)) \quad (\text{A.17})$$

Então, $d \frac{K_p}{dt}$, $d \frac{K_i}{dt}$ e $d \frac{K_d}{dt}$ podem assumir as seguintes expressões:

$$\frac{dK_p}{dt} = -\gamma_p \varepsilon \frac{\partial y_p}{\partial K_p} = -\gamma_p \frac{1}{N} \sum_{t=N_1}^{N_2} \varepsilon(t) \left(\frac{\left(\frac{b_p}{1+K_b b_p} \right) D}{D^2 + D \left(\frac{a_p + K_p b_p}{1+K_d b_p} \right) + \left(\frac{K_i b_p}{1+K_d b_p} \right)} \right) (r(t) - y_p(t)) \quad (\text{A.18})$$

$$\frac{dK_i}{dt} = -\gamma_i \varepsilon \frac{\partial y_p}{\partial K_i} = -\gamma_i \frac{1}{N} \sum_{t=N_1}^{N_2} \varepsilon(t) \left(\frac{\left(\frac{b_p}{1+K_b b_p} \right)}{D^2 + D \left(\frac{a_p + K_p b_p}{1+K_d b_p} \right) + \left(\frac{K_i b_p}{1+K_d b_p} \right)} \right) (r(t) - y_p(t)) \quad (\text{A.19})$$

$$\frac{dK_d}{dt} = -\gamma_d \varepsilon \frac{\partial y_p}{\partial K_d} = -\gamma_d \frac{1}{N} \sum_{t=N_1}^{N_2} \varepsilon(t) \left(\frac{\left(\frac{b_p}{1+K_b b_p} \right) D^2}{D^2 + D \left(\frac{a_p + K_p b_p}{1+K_d b_p} \right) + \left(\frac{K_i b_p}{1+K_d b_p} \right)} \right) (r(t) - y_p(t)) \quad (\text{A.20})$$

em que $N_2 - N_1 = N$; N é definido como a janela de observação, isto é, a quantidade de valores utilizados para atualizar o parâmetro a ser adaptado. O erro de estimação ε é definido como sendo a diferença entre o sinal da planta estimada y_e e a saída da planta controlada y_p e este erro deve ser minimizado, no mecanismo de estimação paramétrica, de tal modo que a planta estimada se comporte igual à planta controlada. Para isto, será utilizado o método do gradiente descendente para minimizar a Equação (A.21). O modelo adotado da planta estimada é o Autoregressivo com Entrada Exógenas (ARX) de primeira ordem, definido pela Equação (A.22). Esta ordem foi escolhida devido às características de primeira ordem da resposta de um sistema de bombeamento.

$$J = \frac{1}{N} \sum_{i=1}^N \frac{1}{2} (y_p - y_e)^2 \quad (\text{A.21})$$

$$y_e(t) = a_1 u(t) + a_2 u(t-1) + a_3 y_e(t-1) \quad (\text{A.22})$$

em que α_1 , α_2 e α_3 são os **parâmetros estimados** da planta, u_c é o sinal de excitação e y_e é a saída estimada. Substituindo as Equações (A.9) e (A.22) na forma contínua, na Equação (A.21) e aplicando o método do gradiente descendente para cada um dos valores estimados da planta, têm-se:

$$\frac{da_1}{dt} = -\gamma_{a_1} \frac{\partial J}{\partial a_1} \quad (\text{A.23})$$

$$\frac{da_2}{dt} = -\gamma_{a_2} \frac{\partial J}{\partial a_2} \quad (\text{A.24})$$

$$\frac{da_3}{dt} = -\gamma_{a_3} \frac{\partial J}{\partial a_3} \quad (\text{A.25})$$

Substituindo a Equação (A.22) nas Equações (A.23), (A.24) e (A.25), e sabendo que, por não depender dos parâmetros a serem estimados, a derivada parcial de y_p é igual a zero, são obtidos os seguintes resultados:

$$\frac{da_1}{dt} = -\gamma_{a_1} \frac{1}{N} \sum_{t=N_1}^{N_2} \varepsilon_e(t) u(t) \quad (\text{A.26})$$

$$\frac{da_2}{dt} = -\gamma_{a_2} \frac{1}{N} \sum_{t=N_1}^{N_2} \varepsilon_e(t) u(t-1) \quad (\text{A.27})$$

$$\frac{da_3}{dt} = -\gamma_{a_3} \frac{1}{N} \sum_{t=N_1}^{N_2} \varepsilon_e(t) y_e(t-1) \quad (\text{A.28})$$

As Equações (A.26), (A.27) e (A.28) podem ainda assumir a forma discreta:

$$\frac{a_1[k] - a_1[k-1]}{T} = -\gamma_{a_1} \frac{1}{N} \sum_{k=N_1}^{N_2} \varepsilon_e[k] u[k] \quad (\text{A.29})$$

$$\frac{a_2[k] - a_2[k-1]}{T} = -\gamma_{a_2} \frac{1}{N} \sum_{k=N_1}^{N_2} \varepsilon_e[k] u[k-1] \quad (\text{A.30})$$

$$\frac{a_3[k] - a_3[k-1]}{T} = -\gamma_{a_3} \frac{1}{N} \sum_{k=N_1}^{N_2} \varepsilon_e[k] y_e[k-1] \quad (\text{A.31})$$

em que T é o período de amostragem.

Aplicando o método discretização de Tustin na função de transferência da planta (observe a Equação (A.1)), é obtido a função de transferência discreta da planta, com período de amostragem T, conforme exposto na Equação (A.32).

$$y_p[k] = \left(\frac{a_p T}{2 + T b_p} \right) u[k] + \left(\frac{a_p T}{2 + T b_p} \right) u[k-1] + \left(\frac{2 + b_p T}{2 + T b_p} \right) y_p[k-1] \quad (\text{A.32})$$

Deste modo, para que o erro de estimação ε seja zero, $y_p[k]$ deve ser igual a $y_e[k]$ ou seja, a Equação (6.24) deve ser igual à Equação (6.20), obtendo:

$$a_1 = \frac{a_p T}{2 + T b_p} \quad (\text{A.33})$$

$$a_2 = \frac{a_p T}{2 + T b_p} \quad (\text{A.34})$$

$$a_3 = \frac{2 + b_p T}{2 + T b_p} \quad (\text{A.35})$$

em que a_1 , a_2 e a_3 são os **parâmetros de estimação** do modelo.

Resolvendo o sistema de Equações (A.33) e (A.35) para colocar em função de a_p e b , são obtidas as expressões (A.36) e (A.37). Observe que os parâmetros da planta (a_p e b) receberam um sinal de circunflexo por se tratar de estimativas e não os valores verdadeiros, pois estamos considerando que os parâmetros da planta são desconhecidos.

$$\hat{a}_p = \frac{2a_1 + a_1 b_p T}{T} \quad (\text{A.36})$$

$$\hat{b}_p = \frac{2a_3 + 2}{T - a_3 T} \quad (\text{A.37})$$

Assim sendo, como $\hat{a}_p \rightarrow a_p$ e $\hat{b}_p \rightarrow b_p$, a formulação matemática apresentada nas Equações (A.18), (A.19) e (A.20) utilizadas no mecanismo de adaptação para atualização dos parâmetros do controlador são reescritas como:

$$\frac{dK_p}{dt} = -\gamma_p \frac{1}{N} \sum_{t=N_1}^{N_2} \varepsilon(t) \left(\frac{\left(\frac{\hat{b}_p}{1+K_b \hat{b}_p} \right) D}{D^2 + D \left(\frac{\hat{a}_p + K_p \hat{b}_p}{1+K_d \hat{b}_p} \right) + \left(\frac{K_i \hat{b}_p}{1+K_d \hat{b}_p} \right)} \right) (r(t) - y_p(t)) \quad (\text{A.38})$$

$$\frac{dK_i}{dt} = -\gamma_i \frac{1}{N} \sum_{t=N_1}^{N_2} \varepsilon(t) \left(\frac{\left(\frac{\hat{b}_p}{1+K_b \hat{b}_p} \right)}{D^2 + D \left(\frac{\hat{a}_p + K_p \hat{b}_p}{1+K_d \hat{b}_p} \right) + \left(\frac{K_i \hat{b}_p}{1+K_d \hat{b}_p} \right)} \right) (r(t) - y_p(t)) \quad (\text{A.39})$$

$$\frac{dK_d}{dt} = -\gamma_d \frac{1}{N} \sum_{t=N_1}^{N_2} \varepsilon(t) \left(\frac{\left(\frac{\hat{b}_p}{1+K_b \hat{b}_p} \right) D^2}{D^2 + D \left(\frac{\hat{a}_p + K_p \hat{b}_p}{1+K_d \hat{b}_p} \right) + \left(\frac{K_i \hat{b}_p}{1+K_d \hat{b}_p} \right)} \right) (r(t) - y_p(t)) \quad (\text{A.40})$$