



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

**SISTEMA INTELIGENTE PARA O CONTROLE DE PRESSÃO
DE REDES DE DISTRIBUIÇÃO DE ÁGUA ABASTECIDAS
POR BOMBAS ASSOCIADAS EM PARALELO**

Emmanuel Guerra de Barros Filho

EMÂNUEL GUERRA DE BARROS FILHO

**SISTEMA INTELIGENTE PARA O CONTROLE DE PRESSÃO
DE REDES DE DISTRIBUIÇÃO DE ÁGUA ABASTECIDAS
POR BOMBAS ASSOCIADAS EM PARALELO**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal da Paraíba, em cumprimento às exigências para obtenção do grau de Doutor em Engenharia Mecânica. Área de concentração: Dinâmica e Controle de Sistemas Mecânicos.

Orientador: Prof. Dr. Heber Pimentel
Gomes

Coorientador: Prof. Dr. Saulo de Tarso
Marques Bezerra

B277s Barros Filho, Emânuel Guerra de.
Sistema inteligente para o controle de pressão de redes de distribuição de água abastecidas por bombas associadas em paralelo / Emânuel Guerra de Barros Filho.- João Pessoa, 2016.
130f. : il.
Orientador: Heber Pimentel Gomes
Coorientador: Saulo de Tarso Marques Bezerra
Tese (Doutorado) - UFPB/CT
1. Engenharia mecânica. 2. Sistemas de bombeamento.
3. Redes neurais artificiais. 4. Eficiência energética e hidráulica.

UFPB/BC

CDU: 621(043)

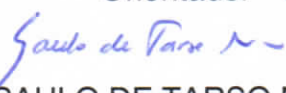
SISTEMA INTELIGENTE PARA O CONTROLE DE PRESSÃO DE REDES DE DISTRIBUIÇÃO DE ÁGUA ABASTECIDAS POR BOMBAS ASSOCIADAS EM PARALELO

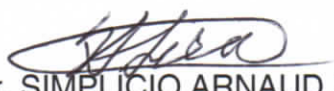
por

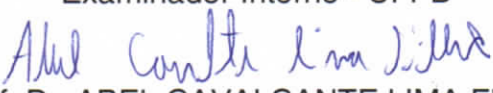
EMÂNUEL GUERRA DE BARROS FILHO

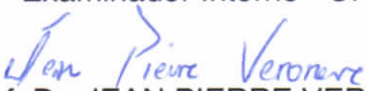
Tese aprovada em 05 de dezembro de 2016


Prof. Dr. HEBER GOMES PIMENTEL
Orientador - UFPB


Prof. Dr. SAULO DE TARSO MARQUES BEZERRA
Coorientador - UFPE


Prof. Dr. SIMPLÍCIO ARNAUD DA SILVA
Examinador Interno - UFPB


Prof. Dr. ABEL CAVALCANTE LIMA FILHO
Examinador Interno - UFPB


Prof. Dr. JEAN PIERRE VERONESE
Examinador Externo - UFPB


Prof. Dr. ARIEL AIRES DO NASCIMENTO
Examinador Externo - IFPB

*Dedico este trabalho aos meus pais,
Emanuel Guerra de Barros (in memoriam) e
Terezinha Castor Nóbrega Guerra,
por todo o esforço que fizeram por minha educação e
por meu crescimento pessoal e profissional.*

AGRADECIMENTOS

Primeiramente, a Deus, por ter-me iluminado e dado tranquilidade para seguir em frente com os meus objetivos e para não desanimar com as dificuldades na realização deste trabalho, e por Sua presença constante em minha vida.

À minha família, pelo grande esforço e pela dedicação em todas as etapas de minha vida, e por entender as minhas faltas e momentos de afastamento e reclusão.

Ao meu orientador, professor doutor Heber Pimentel Gomes, pela atenção, pela amizade, pela oportunidade de poder realizar este trabalho e pela orientação sempre que solicitada.

Ao meu coorientador, professor doutor Saulo de Tarso Marques Bezerra (UFPE), pela sua disponibilidade irrestrita sempre que procurado e pelas valiosas sugestões.

Aos professores doutores Abel Cavalcante Lima Filho (UFPB), Jean Pierre Veronese (UFPB) e Simplicio Arnaud da Silva (UFPB), por terem contribuído, como membros da banca de qualificação, com o enriquecimento deste trabalho.

Aos colegas professores do IFPB, pelo incentivo e pela motivação.

Aos parceiros de pesquisa Laís Régis Salvino e José Kleber Costa de Oliveira, pela contribuição e pelo incentivo no decorrer do Curso.

Ao Dr. Moisés Menezes Salvino, pela contribuição no decorrer do desenvolvimento e da montagem experimental deste projeto.

A todos os professores, em especial ao professor doutor Paulo Henrique de Miranda Montenegro, e aos colegas do Programa de Pós-Graduação em Engenharia Mecânica da UFPB, por estarem sempre dispostos a ajudar-me no desenvolvimento do trabalho.

Aos amigos e colegas do Curso, pelo auxílio e pelo incentivo.

Ao professor doutor Wilson Guerreiro Pinheiro, pela meticulosa revisão final desta tese.

A todas as pessoas que contribuíram para a realização deste trabalho, o meu Muito Obrigado!

RESUMO

O objetivo desta pesquisa é desenvolver um sistema inteligente baseado em redes neurais artificiais para redes de distribuição de água que operam com bombas associadas em paralelo. O sistema tem por finalidade a automação do processo e a definição do estado de funcionamento dos motores elétricos (ligado, desligado ou com rotação parcial), visando simultaneamente ao controle de pressão e à redução do consumo de energia elétrica. O sistema inteligente desenvolvido é genérico, o que permite a aplicação da estrutura de controle em processos semelhantes, e foi aplicado em uma bancada experimental totalmente instrumentalizada que emula um sistema real de abastecimento de água. Os resultados mostraram que o desempenho da rede neural artificial é bastante satisfatório, e, assim, poderá ser implementada com sucesso em outros sistemas de distribuição de água similares, a fim de proporcionar redução do consumo de água e energia elétrica, diminuição dos custos de manutenção e aumento do grau de confiabilidade dos procedimentos operacionais.

Palavras-Chaves: Sistemas de bombeamento. Redes neurais artificiais. Eficiência energética e hidráulica.

ABSTRACT

The objective of this research is to develop an intelligent system based on artificial neural networks for water distribution systems that operate with pumps associated in parallel. The system aims at process automation and the definition of operating state for electric motors (on, off or with partial rotation), aiming at the same time the pressure control and reduction of electric power consumption. The developed intelligent system is a generic one, which allows the application of control structure in similar processes, and it was applied in a fully instrumented test rig that emulates a real system of water supply. The results showed that the performance of the artificial neural network is quite satisfactory, and thus can be successfully implemented in other similar water distribution systems in order to reduce consumption of water and electric energy, decrease costs of maintenance, and increase the degree of reliability of operational procedures.

Keywords: Pumping Systems. Artificial neural networks. Energy and hydraulic efficiency.

LISTA DE FIGURAS

Figura 2.1 – Esquema de um sistema de automação para controle em tempo real de sistemas de distribuição de água.....	36
Figura 2.2 – Altura manométrica para os métodos de controle de vazão: estrangulamento de válvula e controle de rotação com inversor de frequência N_1 e N_2 são velocidades de rotação da bomba, e $N_1 > N_2$. (BEZERRA et al., 2015, p. 72).....	41
Figura 2.3 – Potência para diferentes métodos de regulação de vazão de uma bomba centrífuga.....	41
Figura 2.4 – Região de operação recomendada para inversores de frequência — adaptação de Europump e Hydraulic Institute (2004).....	44
Figura 3.1 – Neurônio biológico.	57
Figura 3.2 – Neurônio de McCulloch e Pitts.....	59
Figura 3.3 – Funções de ativação parcialmente diferenciáveis: (a) função degrau, (b) função degrau bipolar e (c) função tipo rampa.	61
Figura 3.4 – Funções de ativação totalmente diferenciáveis: (a) função tangente hiperbólica, (b) função logística e (c) função gaussiana	61
Figura 3.5 – Exemplos de redes neurais artificiais.....	62
Figura 3.6 – Rede neural artificial de uma única camada.	63
Figura 3.7 – Rede neural artificial multicamada.	63
Figura 3.8 – Rede neural artificial <i>feedback</i> ou cíclica.	64
Figura 3.9 – Rede neural artificial <i>feedforward</i> ou acíclica.	65
Figura 3.10 – Topologia do perceptron de Rosenblatt.	69
Figura 3.11 – Rede PMC típica com duas camadas intermediárias (ocultas).....	70
Figura 4.1 – Sistema experimental de distribuição de água.	74
Figura 4.2 – Conjunto motor-bomba modelo CAM-W10.....	74
Figura 4.3 – Curvas características da bomba CAM-W10.....	75
Figura 4.4 – Curvas características das bombas do sistema experimental.	75

Figura 4.5 – Inversor de frequência CFW-11.....	76
Figura 4.6 – Válvula de controle ARB24-SR.....	77
Figura 4.7 – Transdutor de pressão Druck PTX 7217.....	77
Figura 4.8 – Medidor de vazão eletromagnético VMS Pro.....	78
Figura 4.9 – Variação do ângulo de fechamento da válvula <i>versus</i> a pressão para o conjunto PUMP-1 em operação com frequência de 30 Hz.	79
Figura 4.10 – Variação do ângulo de fechamento da válvula <i>versus</i> a pressão para o conjunto PUMP-1 em operação com frequência de 60 Hz.....	79
Figura 4.11 – Variação do ângulo de fechamento da válvula <i>versus</i> a pressão para os conjuntos PUMP-1 e PUMP-2 associados em paralelo, com frequência de 30 Hz.	80
Figura 4.12 – Variação do ângulo de fechamento da válvula <i>versus</i> a pressão para os conjuntos PUMP-1 e PUMP-2 associados em paralelo, com frequência de 60 Hz.	80
Figura 4.13 – Interface de aquisição de dados NI USB-6229.	81
Figura 4.14 – Supervisório da Bancada Experimental.	82
Figura 4.15 – Diagrama de Blocos do Sistema de Controle.....	83
Figura 4.16 – Arquitetura da rede neural artificial PMC.....	86
Figura 5.1 – Comportamento da variável de controle (pressão) – Experimento Tipo 1.	91
Figura 5.2 – Comportamento da frequência de acionamento dos motores – Experimento Tipo 1.....	92
Figura 5.3 – Comportamento do Erro no Regime Permanente – Experimento Tipo 1.....	93
Figura 5.4 – Resposta do controlador RNA a distúrbios – Experimento Tipo 1.....	93
Figura 5.5 – Comportamento da frequência de alimentação de tensão após distúrbios – Experimento Tipo 1.	93
Figura 5.6 – Comportamento da variável de controle (pressão) – Experimento Tipo 2	94
Figura 5.7 – Comportamento do Erro no Regime Permanente – Experimento Tipo 2.	95
Figura 5.8 – Comportamento da Frequência de Alimentação de Tensão – Experimento Tipo 2.....	96
Figura 5.9 – Resposta do controlador RNA ao distúrbio – Experimento Tipo 2.....	96

Figura 5.10 – Comportamento da frequência de alimentação após distúrbios – Experimento Tipo 2	97
Figura 5.11 – Curva de fechamento da válvula proporcional – Experimento Tipo 3	97
Figura 5.12 – Curvas de vazão total – Experimento Tipo 3	98
Figura 5.13 – Comportamento da pressão – Experimento Tipo 3.....	98
Figura 5.14 – Consumo energético dos conjuntos motor-bomba – Experimento Tipo 3.....	99
Figura 5.15 – Curva do comportamento do CE – Experimento Tipo 3.	99
Figura 5.16 – Curva de fechamento da válvula proporcional – Experimento Tipo 4.	100
Figura 5.17 – Curva de vazão total – Experimento Tipo 4	100
Figura 5.18 – Comportamento da variável de controle (pressão) – Experimento Tipo 4	101
Figura 5.19 – Comportamento das variáveis de saída - Frequências de Alimentação de Tensão – Experimento Tipo 4.	101
Figura 5.20 – Consumo energético do conjunto motor-bomba – Experimento Tipo 4.....	102
Figura 5.21 – Comportamento do CE – Experimento Tipo 4.	102
Figura A.1 – Programa principal desenvolvido em LabVIEW	125
Figura A.2 – Primeira parte do programa principal em LabVIEW	126
Figura A.3 – Segunda parte do programa principal em LabVIEW	127
Figura A.4 – Terceira parte do programa principal em LabVIEW	128
Figura A.5 – Quarta parte do programa principal em LabVIEW.....	129
Figura A.6 – Algoritmo da RNA desenvolvida em LabVIEW	130

LISTA DE TABELAS

Tabela 4.1 – Principais características dos motores.	74
Tabela 4.2 – Características dos transdutores de pressão Druck PTX 7217.	78
Tabela 4.3 – Principais propriedades do transdutor de vazão eletromagnético VMS 038.....	78
Tabela 5.1 – Critérios de avaliação do sistema de controle.....	91
Tabela 5.2 – Indicadores dos Experimentos Tipo 3 e Tipo 4.	103

LISTA DE ABREVIATURAS E SIGLAS

ACM	Abreviação do inglês <i>Association for Computing Machinery</i> [= Associação para Maquinaria da Computação]
ADALINE	Abreviação do inglês <i>Adaptive Linear Element</i> [= Elemento linear adaptativo]
ADRC	Abreviação do inglês <i>Active Disturbance Rejection Control</i> [= Controle com rejeição ativa de perturbações.]
AG	Algoritmo Genético
AIChE	Abreviação do inglês <i>American Institute of Chemical Engineers</i> [= Instituto Americano de Engenheiros Químicos]
AISB	Abreviação do inglês <i>Society for the Study of Artificial Intelligence and the Simulation of Behaviour</i> [= Sociedade para o Estudo de Inteligência Artificial e Simulação de Comportamento]
ANFIS	Abreviação do inglês <i>Adaptive Network-Based Fuzzy Inference System</i> [= Sistema de Inferência Neurofuzzy Adaptativo]
ANN	Abreviação do inglês <i>Artificial Neural Network</i> [= Rede neural artificial]
APPEEC	Abreviação do inglês <i>Asia-Pacific Power and Energy Engineering Conference</i> [= Conferência de Engenharia de Potência e Energia da Ásia-Pacífico]
ASCE	Abreviação do inglês <i>American Society of Civil Engineers</i> [= Sociedade Americana de Engenheiros Civis]
AWWA	Abreviação do inglês <i>American Water Works Association</i> [= Associação Americana de Distribuição de Água]
BHP	Abreviação do inglês <i>Brake Horsepower</i> [= Potência de freio (medida de potência avaliada por dinamômetro)]
BPTT	Abreviação do inglês <i>Backpropagation Through Time</i> [= Retropropagação através do tempo]
CCV	Custo do ciclo de vida
CE	Consumo específico de energia elétrica
CLP	Controlador Lógico Programável
CMB-01, CMB-02	Conjuntos motor-bomba
CO	Estado do Colorado (EUA).

CV	Abreviação do inglês <i>Control Valve</i> [= Válvula de controle]
DAQ	Abreviação do inglês <i>Data Acquisition</i> [= Aquisição de Dados]
D.C.	Abreviação do inglês <i>District of Columbia</i> [=Distrito de Colúmbia]
DN	Diâmetro Nominal
EESMS	Abreviação do inglês <i>Environmental, Energy, and Structural Monitoring Systems</i> [= Sistemas de monitoramento ambiental, de energia e estrutural]
ed.	edição
Ed.	Editor(es)
e.g.	Abreviação da expressão latina <i>exempli gratia</i> [= por exemplo]
et al.	Abreviação da locução latina <i>et alii</i> [= e outros]
EUA	Estados Unidos da América
FIR	Abreviação do inglês <i>Finite Impulse Response</i> [= Resposta ao
FOC	Abreviação do inglês <i>Field Oriented Control</i> [= Controle de campo orientado]
FT	Abreviação do inglês <i>Flux Transducer</i> [= Transdutor de vazão]
GALESIA	Abreviação do inglês <i>Genetic Algorithms in Engineering Systems: Innovations and Applications</i> [= Algoritmos Genéticos em Engenharia de Sistemas: Inovações e Aplicações]
GIDAP	Abreviação do inglês <i>Graphical Interactive Demand Analysis and Prediction</i> [= Análise e Predição Gráfica de Demanda Interativa]
ICICIC	Abreviação do inglês <i>International Conference on Innovative Computing, Information and Control</i> [= Conferência Internacional em Computação Inovativa, Informação e Controle]
ICSCS	Abreviação do inglês <i>International Conference on Soft Computing Systems</i> [= Conferência Internacional em Sistemas de Computação Flexível]
IDC	<i>International Data Corporation</i>
IDFS	Abreviação do inglês <i>Interleaved Depth-First Search</i> [= Busca em profundidade intercalada primeiro]
IDG	<i>International Data Group</i>
IEE	Abreviação do inglês <i>Institution of Electrical Engineers</i> [= Instituição de Engenheiros Eletricistas]
IEEE	Abreviação do inglês <i>Institute of Electrical and Electronics Engineers</i> [= Instituto de Engenheiros Eletricistas e Eletrônicos]

IET	Abreviação do inglês <i>Institution of Engineering and Technology</i> [= Instituição de Engenharia e Tecnologia]
IGBT	Abreviação do inglês <i>Insulated Gate Bipolar Transistor</i> [= Transistor bipolar de porta isolada]
IJECCE	Abreviação do inglês <i>International Journal of Electronics Communication and Computer Engineering</i> [= Revista Internacional de Engenharia de Comunicação Eletrônica e da Computação]
IJETEE	Abreviação do inglês <i>International Journal of Emerging Trends in Electrical and Electronics</i> [= Revista Internacional de Tendências Emergentes em Elétrica e Eletrônica]
IJIREEICE	Abreviação do inglês <i>International Journal of Innovative Research in Electrical, Electronics, Instrumentation and Control Engineering</i> [= Revista Internacional de Pesquisa Inovativa em Engenharia Elétrica, Eletrônica, de Instrumentação e de Controle]
IMECS	Abreviação do inglês <i>International MultiConference of Engineers and Computer Scientists</i> [= Multiconferência Internacional de Engenheiros e Cientistas da Computação]
INNS	Abreviação do inglês <i>International Neural Network Society</i> [= Sociedade Internacional de Redes Neurais]
IP	Índice de Proteção [de motores]
IRE	Abreviação do inglês <i>Institute of Radio Engineers</i> [= Instituto de Engenheiros de Rádio]
ISBN	Abreviação do inglês <i>International Standard Book Number</i> [= Número Padrão Internacional de Livro]
ISPN	Abreviação do inglês <i>Information Processing in Sensor Networks</i> [= Processamento da informação em redes de sensores]
ISSN	Abreviação do inglês <i>International Standard Serial Number</i> [= Número Internacional Normalizado para Publicações Seriadas]
LabVIEW®	Abreviação do inglês <i>Laboratory Virtual Instrument Engineering Workbench</i>
LMN	Abreviação do inglês <i>Local Model Network</i> [= Rede de modelo local]
loc. cit.	Abreviação da locução latina <i>loco citatum</i> [= no lugar citado]
MA	Estado de <i>Massachusetts</i> (EUA)

MIT	Abreviação do inglês <i>Massachusetts Institute of Technology</i> [=Instituto de Tecnologia de Massachusetts]; motor de indução trifásico
MLP	Abreviação do inglês <i>Multiple Layer Perceptron</i> [v. PMC]
MME	Ministério de Minas e Energia
n.	número(s); nascido em.
NI	Abreviação do inglês <i>National Instruments</i>
NPSH	Abreviação do inglês <i>Net Positive Suction Head</i> [= Carga líquida positiva de sucção]
NY	Sigla do inglês <i>New York</i> [= Estado de Nova Iorque]
OH	Sigla do inglês <i>Ohio</i> [= Estado de Ohio]
PA	Estado do Pará
PB	Estado da Paraíba
PD	Proporcional-Derivativo [Diz-se de controlador.]
PI	Proporcional-Integral [Diz-se de controlador.]
PID	Proporcional-Integral-Derivativo [Diz-se de controlador.]
PMC	Perceptron Multicamadas
pp.	Abreviação do inglês <i>pages</i> [= páginas]
PPGEM	Programa de Pós-Graduação em Engenharia Mecânica
PT	Abreviação do inglês <i>Pressure Transducer</i> [= Transdutor de pressão]
PVC	Abreviação do inglês <i>Polyvinyl Chloride</i> [= Policloreto de vinila]
PWM	Abreviação do inglês <i>Pulse-Width Modulation</i> [= Modulação por largura de pulso]
RAM	Abreviação do inglês <i>Random Access Memory</i> [= Memória de acesso aleatório]
RBF	Abreviação do inglês <i>Radial Basis Function</i> [= Função de base radial]
RCC	Abreviação do inglês <i>Recurrent Cascade Correlation</i> [= Correlação em cascata recorrente]

RJ	Estado do Rio de Janeiro
RNA	Rede Neural Artificial
RS	Estado do Rio Grande do Sul
RTRL	Abreviação do inglês <i>Real-Time Recurrent Learning</i> [= Aprendizagem recorrente em tempo real]
SAA	Sistema de Abastecimento de Água
SABESP	Companhia de Saneamento Básico do Estado de São Paulo
SCADA	Abreviação do inglês <i>Supervisory Control and Data Acquisition System</i> [= Sistema de Controle e Aquisição de Dados]
s.l.	Abreviação da expressão latina <i>sine loco</i> [= sem local (de publicação)]
s.n.	Abreviação da expressão latina <i>sine nomine</i> [= sem nome (do editor)]
SP	Estado de São Paulo
SQL	Abreviação do inglês <i>Structured Query Language</i> [= Linguagem de Consulta Estruturada]
Trad.	Tradução
UFPB	Universidade Federal da Paraíba
UFPE	Universidade Federal de Pernambuco
UFRN	Universidade Federal do Rio Grande do Norte
UK	Abreviação do inglês <i>United Kingdom</i> [= Reino Unido]
UNESP	Universidade Estadual Paulista “Júlio de Mesquita Filho”
UNICAMP	Universidade Estadual de Campinas
USA	Abreviação do inglês <i>United States of America</i> [v. EUA]
USP	Universidade de São Paulo
UTR	Unidade de Transmissão Remota
v.	veja; volume
vol.	volume
WRPMD	Abreviação do inglês <i>Water Resources Planning and Management Conference</i> [= Conferência de Planejamento e Gerenciamento de Recursos Hídricos]

LISTA DE SÍMBOLOS

A	Ampère
<i>a</i>	Constante
<i>a_i(t)</i>	Atividade pós-sináptica
<i>a_j(t)</i>	Atividade pré-sináptica
<i>b</i>	Constante
cv	Cavalo-vapor
<i>e</i>	Valor do erro da rede neural artificial
<i>E</i>	Energia consumida no tempo <i>t</i>
<i>E(t)</i>	Função de custo da rede neural artificial
exp	Exponencial
<i>f</i>	Frequência de acionamento do motor
<i>f(.)</i>	Função de ativação da rede neural artificial
GB	Gigabyte
GHz	Gigahertz
GWh	Gigawatt-hora
h	hora
<i>H</i>	Altura manométrica
<i>H_i</i>	Altura manométrica total do <i>i</i> -ésimo elemento
Hz	Herz
<i>i</i>	<i>i</i> -ésimo elemento
<i>k</i>	Constante
kW	Quilowatt
kWh	Quilowatt-hora

m	metro
m³	metro cúbico
m³/h	metro cúbico por hora
mA	miliampère
mca	metro de coluna de água
ms	milissegundo
MS/s	Abreviação do inglês <i>Mega Samples per Second</i> [= mega-amostras por segundo]
<i>n</i>	Número de elementos; número total de entradas da rede neural artificial
N₁, N₂	Velocidades de rotação da bomba
<i>n_i</i>	Velocidade de rotação do <i>i</i> -ésimo elemento
nm	nanômetro
Nm	Newton-metro
<i>n_R</i>	Velocidade de rotação do eixo do motor
<i>p</i>	Número de polos do motor
<i>Pot_i</i>	Potência do <i>i</i> -ésimo elemento
<i>Q_i</i>	Vazão do <i>i</i> -ésimo elemento
rms	Abreviação do inglês <i>root-mean-square</i> [= valor médio quadrático ou valor eficaz]
rpm	rotações por minuto
<i>s</i>	Escorregamento do motor assíncrono; segundo
<i>t</i>	Tempo
TWh	Terawatt-hora
<i>u</i>	Potencial de ativação
<i>u_i</i>	Nível de atividade interna do neurônio
V	Volume bombeado no tempo <i>t</i> ; volt

Vca	Tensão alternada
Vcc	Tensão contínua
w_{ab}	Matriz de pesos entre a camada de entrada e a camada intermediária da rede neural PMC
w_{bc}	Matriz de pesos sinápticos que ligam os neurônios da camada intermediária aos neurônios da camada de saída da rede neural PMC
w_i	i -ésimo peso sináptico da rede neural artificial
x_b	Variável de entrada dos neurônios da camada intermediária da rede neural PMC
x_c	Entrada da camada de saída da rede neural PMC
x_i	i -ésimo sinal de entrada da rede neural artificial
y	Valor de saída produzido pelo neurônio da rede neural artificial
y_b	Valor de saída de cada neurônio da camada intermediária da rede neural PMC
y_c	Sinal de saída calculado pela RNA
y_d	Valor desejado do sinal de saída da RNA
y_i	i -ésima variável y ; saída do neurônio
α	Taxa de aprendizagem da rede neural artificial
β	Parâmetro da função de ativação da rede neural artificial
Θ	Limiar de ativação (<i>bias</i>) da rede neural artificial
Σ	Combinador linear de uma rede neural artificial; somatório
Φ	Diâmetro do rotor da bomba

SUMÁRIO

CAPÍTULO 1 INTRODUÇÃO E OBJETIVOS	22
1.1 Introdução.....	22
1.2 Objetivos.....	25
CAPÍTULO 2 REVISÃO DA LITERATURA	26
2.1 Operação de Sistemas de Distribuição de Água.....	26
2.2 Motores de Indução Trifásicos	37
2.3 Bombas em Operação com Velocidade de Rotação Variável.....	40
2.4 Redes Neurais Artificiais.....	47
CAPÍTULO 3 REDES NEURAIS ARTIFICIAIS	55
3.1 Introdução.....	55
3.2 Neurônio Biológico	56
3.3 Modelo de um Neurônio Artificial.....	59
3.4 Arquitetura de uma RNA	62
3.5 Aprendizagem	65
3.6 Rede Perceptron Multicamadas.....	69
CAPÍTULO 4 MATERIAIS E MÉTODOS	73
4.1 Sistema Experimental.....	73
4.2 Sistema de Controle.....	81
4.3 Modelagem da RNA.....	84
CAPÍTULO 5 RESULTADOS E DISCUSSÃO	90
5.1 Experimento Tipo 1.....	90
5.2 Experimento Tipo 2.....	94
5.3 Experimento Tipo 3.....	97
5.4 Experimento Tipo 4.....	99

CAPÍTULO 6 CONCLUSÕES	104
REFERÊNCIAS	106
APÊNDICE A – DESENVOLVIMENTOS EM LabVIEW®	124

CAPÍTULO 1

INTRODUÇÃO E OBJETIVOS

1.1 Introdução

Diante da saturação da matriz energética e da escassez hídrica nacional dos últimos tempos, é imprescindível adotar medidas que possam reduzir os desperdícios e aperfeiçoar os processos envolvidos na distribuição de água. Os últimos avanços tecnológicos associados às técnicas de controle modernas podem proporcionar o aumento da eficiência hidráulica e energética na maioria dos sistemas de abastecimento de água.

Nos últimos anos, as companhias de saneamento brasileiras e a comunidade científica vêm tentando acompanhar o desenvolvimento tecnológico dos demais setores industriais. A automação pode ser definida como qualquer aplicação de técnica computadorizada ou mecânica para diminuir ou suprimir a interferência humana em qualquer processo. Mecanismos automáticos podem ser empregados tanto no controle de processos simples quanto no controle de grandes sistemas. (BEZERRA, 2009, p. 54).

A automação é uma importante ferramenta para os sistemas de abastecimento de água (SAAs), pois permite o monitoramento em tempo real e o controle dos diversos setores do sistema, possibilitando, principalmente, a melhoria na qualidade do abastecimento e a redução dos custos operacionais.

A necessidade de otimização e a complexidade encontrada na operação de sistemas de abastecimento de água apontam para a adoção de técnicas computacionais avançadas e equipamentos eletrônicos sofisticados. No atual cenário do setor de saneamento, é imprescindível que o fornecimento de água potável seja efetuado com confiabilidade e qualidade, de tal modo a satisfazer os anseios dos consumidores e atender satisfatoriamente a legislação imposta.

Os sistemas de abastecimento de água são compostos, geralmente, por redes de distribuição de água, reservatórios e conjuntos motor-bomba. Por conseguinte, a energia elétrica é imprescindível para tornar a água potável e movê-la através dos SAAs. Cada litro de água que é transportado nas tubulações representa um determinado consumo de energia. Segundo Brasil (2009, p. 14), é necessário cerca de 0,6 kWh para produzir um metro cúbico de água potável.

As empresas de saneamento consomem de 2% a 10% do total da eletricidade utilizada em um país. (PELLI; HITZ, 2000, p. 55). No mundo, as companhias gastam com energia cerca de US\$ 14 bilhões por ano para bombear água. (SENSUS, 2012). James, Campbell e Godlove (2002) estimaram que os países latino-americanos gastam de 1 a 1,5 bilhão de dólares por ano apenas para bombear água. No Brasil, o setor de saneamento básico é um dos que mais consomem energia elétrica, e, em 2014, representou cerca de 3% do consumo total do País, de 475,4 TWh (BRASIL, 2015, p. 7), ou seja, o equivalente a cerca de 14 GWh, sendo que 90% dessa energia é consumida por conjuntos motor-bomba. (BRASIL, 2009). Na grande maioria das vezes, os custos com energia em sistemas de bombeamento, ao longo da vida útil dos projetos, ultrapassam os custos de investimento das instalações. (GOMES, 2005).

Em sistemas de abastecimento de água, os custos com bombeamento estão entre as principais despesas das companhias de água. (COSTA, L. et al., 2016; VIEIRA; RAMOS, 2008). Nos países em desenvolvimento, a energia elétrica é geralmente o custo mais elevado associado com o abastecimento de água. (BARRY, 2007).

A otimização da operação de sistemas de bombeamento resulta em impactos econômicos significativos, os quais, no caso de grandes sistemas, podem atingir uma poupança de milhões de reais por ano. Segundo James, Campbell e Godlove (2002), o consumo de energia na maioria dos sistemas de abastecimento de água em todo o mundo poderia ser reduzido, por meio da implementação de medidas direcionadas ao aumento de eficiência energética e hidráulica, em, pelo menos, 25%, o que equivale, por exemplo, à energia consumida na Tailândia.

Sistemas de bombeamento representam quase 20% da energia consumida por motores elétricos e de 25% a 50% da energia elétrica total necessária em algumas indústrias. (EUROPUMP; HYDRAULIC INSTITUTE, 2004). Mesmo com a evolução de práticas de conservação, a preocupação com o uso de energia estimula a busca por soluções tecnológicas “inteligentes”, que resultem em sistemas de bombeamento de água mais eficientes e sustentáveis. (LEWIS; HENDRIX, 2012). Diversos estudos na Europa e nos Estados Unidos indicam que o setor industrial tem um potencial de redução de 30% a 50% do consumo em sistemas de bombeamento. (HOVSTADIUS, 2007). A adoção de técnicas de controle e otimização de processos para a melhoria dos sistemas de bombeamento é crucial, o que impulsiona a comunidade científica para desenvolver pesquisas voltadas ao aumento da eficiência dos equipamentos e sistemas.

A alternativa mais eficiente para reduzir o consumo de energia elétrica dos SAAs é através da diminuição das vazões e pressões dos sistemas. O controle da pressão é imprescindível para a redução do consumo de água e do volume de perdas reais (físicas) em sistemas urbanos de distribuição de água. (DAI; LI, P., 2016; GUPTA; NAIR; ORMSBEE, 2016; SIGNORETI, 2016; VITKOVSKY; SIMPSON; LAMBERT, 2000). Com frequência, o controle da pressão é apontado na literatura como a principal ação de gestão de perdas em sistemas de abastecimento de água.

Como afirmam Bezerra, S. Silva e Gomes (2010, p. 9), a “influência da pressão nas perdas é conhecida há muito tempo pelos pesquisadores e técnicos das companhias de saneamento.” Segundo Bezerra e Cheung (2013), no início da década de 1990:

[...] foram publicados no Reino Unido vários relatórios como resultado da *National Leakage Initiative*, destacando o *Report G - Managing Water Pressure*, que se tornou uma referência tradicional da relação entre pressão e volume de vazamento. De modo geral, uma diminuição de 10% na pressão em grandes sistemas implica uma redução aproximada de 12% no volume perdido por vazamentos.

O controle de vazão/pressão em SAAs é realizado por meio de válvulas de manobras (válvulas tipo globo, gaveta ou borboleta), *by-pass* ou variadores de velocidade de rotação de bombas. No Brasil, a maioria dos sistemas adota o controle de fluxo através de válvulas de manobras operadas de acordo com a demanda. Esse tipo de controle é alcançado por meio do acréscimo de perda de carga, que desloca o ponto de operação do sistema. Wood e Reddy (1994) definiram bem o controle de vazão/pressão através de válvulas, afirmando ser o mesmo que “conduzir um carro com o freio de mão acionado: o resultado é o desperdício desnecessário de energia”. Ademais, as válvulas diminuem a vida útil do equipamento, e a energia excedente gera vibrações nos conjuntos motor-bomba, provocando danos aos elementos do sistema. (PEMBERTON, 2005).

Nesse contexto, a variação da velocidade de rotação de bombas por meio de inversores de frequência é a melhor opção para o controle de bombeamento, pois reduz o consumo de água e energia elétrica. Atualmente, um grande campo de pesquisas está aberto para a busca do desenvolvimento de sistemas inteligentes direcionados para a aplicação de inversores de frequência em sistemas de bombeamento de SAAs que busquem o uso sustentável de água e energia, confiabilidade operacional, redução dos custos de produção e garantia da continuidade do abastecimento.

1.2 Objetivos

O objetivo geral desta pesquisa é o desenvolvimento de um sistema de controle inteligente, baseado em redes neurais artificiais (RNAs), para o controle de pressão de sistemas de distribuição de água abastecidos por bombas associadas em paralelo acionadas por inversores de frequência. O sistema desenvolvido é do tipo direto, uma vez que os pesos sinápticos da rede neural artificial foram ajustados diretamente com base nos parâmetros da planta.

São objetivos específicos da pesquisa:

- Implantação de um sistema de distribuição de água experimental com bombas associadas em paralelo acionadas por inversores de frequência;
- Desenvolvimento de um sistema supervisor, utilizando o programa LabVIEW[®], para monitoramento em tempo real e análise dos parâmetros hidráulicos e elétricos do sistema experimental;
- Desenvolvimento de um sistema inteligente, baseado em redes neurais artificiais, para o acionamento automático e simultâneo de bombas associadas em paralelo acionadas por inversores de frequência;
- Avaliação do consumo de energia elétrica do sistema experimental controlado pela rede neural artificial desenvolvida.

CAPÍTULO 2

REVISÃO DA LITERATURA

2.1 Operação de Sistemas de Distribuição de Água

A aplicação da automação em sistemas de abastecimento de água (SAAs) é uma prática que está sendo difundida no setor de saneamento. Entretanto, são raras as pesquisas científicas desenvolvidas na área de dinâmica e controle automático de processos. Na prática, os controladores atuais empregam técnicas de controle “convencionais”, tipo PID, desenvolvidas e acopladas pelos fabricantes de equipamentos.

Na indústria, o uso de controladores Proporcional-Integral-Derivativo (PID) tem desempenhado um papel importante no controle de vazão e nível. (CAMPISANO; MODICA, 2002). No entanto, são poucas as pesquisas que adotam esse tipo de controlador em redes de distribuição de água reais. O principal obstáculo para a adoção de controladores PID é a dinâmica desses sistemas, que não é linear e varia significativamente com o tempo. A seguir, são apresentadas pesquisas recentes na área de dinâmica.

Prasanna Kumar e Mohan Kumar (2009) desenvolveram um controlador baseado na técnica de inversão dinâmica não linear robusta para o controle de transientes em redes hidráulicas com múltiplos reservatórios. O controlador desenvolvido foi comparado com controladores PD e PID, apresentando melhores resultados. A aplicação de controladores convencionais resultou em transientes hidráulicos, e os valores-alvos não foram alcançados. O desempenho dos controladores foi verificado em três estudos de caso. O primeiro refere-se ao controle de velocidade de rotação de bombas de uma sequência de estações de bombeamento que fornecem água para reservatórios. O segundo problema corresponde à rede de distribuição da cidade de Faridabad, Índia, que possui um sistema de bombeamento que fornece água para diferentes reservatórios. O terceiro sistema avaliado foi o da cidade de Bangalore, Índia, que possui várias estações de bombeamento que distribuem água para diferentes reservatórios.

Mohammed e Abdulrahman (2009) apresentaram um controlador preditivo, técnica que tem uma aplicação generalizada na indústria de processos, para a operação de SAAs por meio da variação da velocidade de rotação das bombas. Os resultados mostraram que a técnica teve melhor desempenho que o controlador PID projetado pelos pesquisadores. Além disso, a estrutura do controlador desenvolvido pode-se ajustar a alterações na planta.

Madoński, Nowicki e Herman (2014) analisaram a utilização de uma estrutura de controle com rejeição ativa de perturbações (abreviadamente ADRC, do inglês *Active Disturbance Rejection Control*) para o controle de pressão em redes hidráulicas. A adaptabilidade e a robustez do controlador proposto melhoraram significativamente o desempenho de um controlador baseado no PID convencional com realimentação. O trabalho investigou a abordagem proposta em um sistema experimental, e que, comparada com um controlador PID convencional, apresentou melhores resultados.

A operação otimizada de SAAs busca o controle de pressão da rede e o fornecimento eficiente e equitativo de água aos consumidores. Se há disponibilidade suficiente de água, o objetivo do controle é atender às demandas dos consumidores, evitando o desperdício. Por outro lado, se a água disponível é insuficiente ou inadequada para atender às exigências dos consumidores com as pressões requeridas, a distribuição equitativa dos recursos disponíveis é de primordial importância. (SANKAR et al., 2015).

Usha Manohar e Mohan Kumar (2014) apresentaram a aplicação de uma técnica de controle não linear para o SAA de Bangalore, Índia, que se caracteriza pelo abastecimento por zonas. Devido à intermitência, a distribuição de água equitativa para setores com características diferentes (vazão, topografia, etc.) torna a operação complexa. A água é bombeada para a rede hidráulica a partir de uma distância de aproximadamente 100 km, com uma variação de altitude que chega a 400 metros. Visando a superar as dificuldades operacionais da planta, os pesquisadores desenvolveram um controlador de inversão dinâmica não linear com características da técnica PID para acionar as válvulas redutoras de pressão instaladas nas entradas dos setores, de modo que a demanda imposta nas diferentes zonas da cidade fossem atendidas.

Sankar et al. (2015) propuseram um controlador preditivo não linear que, segundo os autores, busca o controle de pressão da rede e o fornecimento eficiente e equitativo de água aos consumidores. A abordagem apresentada considera a disponibilidade de água dos reservatórios nos pontos de origem e de consumo. O desempenho do controlador foi verificado por meio de simulação numérica de vários cenários de disponibilidade de água. No cenário em que há água suficiente, a estratégia foi capaz de satisfazer as exigências dos consumidores e minimizar a quantidade de água fornecida. No cenário com déficit, o algoritmo explorou os reservatórios domiciliares dos consumidores para reduzir a falta de abastecimento por cerca de 20%.

Eduardo Nogueira Cunha (2015) apresentou um modelo matemático do sistema de abastecimento de água da Universidade Federal do Rio Grande do Norte. Três controladores foram simulados pelo pesquisador, e tiveram seus desempenhos comparados: um controlador servossistema linear multivariável, um controlador preditivo linear e um controlador preditivo não linear. O controlador servossistema linear multivariável respondeu à dinâmica somente no ponto de operação. O controlador preditivo linear proporcionou um bom comportamento com baixo sobressinal, mas com erro constante em regime permanente e dependência do ponto de operação. O controlador não linear mostrou melhor desempenho que os demais controladores desenvolvidos, respondendo satisfatoriamente à dinâmica imposta pelo modelo, com baixo sobressinal e sem erro em regime permanente.

As pesquisas recentes para o controle de sistemas de bombeamento que operam com inversores de frequência são apresentadas na Seção 2.3.

A revisão da literatura apontou que a grande maioria das pesquisas científicas desenvolvidas para o setor de saneamento, no tema abordado por esta tese, é direcionada para a definição de rotinas operacionais de sistemas de distribuição de água por meio de modelos matemáticos e *sistemas de supervisão e aquisição de dados* (abreviadamente SCADA, do inglês *Supervisory Control And Data Acquisition*). Na prática, são raros os trabalhos científicos que abordam especificamente técnicas de controle de processos em sistemas de abastecimento de água.

A automatização de sistemas de abastecimento de água atinge níveis diferenciados em função das suas características, de sua importância e do risco admissível a falhas. Os sistemas mais complexos tendem a evoluir de uma operação baseada em supervisão e monitoramento (sistemas SCADA) para uma operação totalmente automatizada, de modo a liberar os operadores para tarefas de supervisão. (ZAHED FILHO, 1990).

Os sistemas SCADA são empregados em SAAs para o controle e monitoramento, em tempo real, de variáveis hidráulicas e elétricas e de atuadores (tais como bombas, válvulas, reservatórios, etc.), possibilitando uma melhoria no desempenho operacional, mensuração das atividades e redução dos custos. De acordo com Gellings (2009), o potencial de poupança de energia com a adoção dos sistemas SCADA é de 10% a 20% do consumo total dos sistemas de distribuição de água.

Fallside e Perry (1975) e Coulbeck, Orr e Brdys (1988) estão entre os primeiros pesquisadores a publicarem aplicações de sistemas voltados para a automação de SAAs.

Fallside e Perry (1975) introduziram uma abordagem hierárquica para a otimização *on-line* da rede de abastecimento de água de Worcestershire (Inglaterra). Essa abordagem consistiu no uso de computadores para os cálculos de otimização, para a aquisição de dados e para o sistema de controle propriamente dito. O servidor central foi interligado aos principais elementos do sistema por rádio ou telefone fixo. O sistema de controle em tempo real de Coulbeck, Orr e Brdys (1988) foi implementado em um SAA do Reino Unido, possibilitando a programação operacional das bombas com o menor custo, a operação automática e a avaliação do sistema.

Os sistemas SCADA atuais incorporam, geralmente, os subsistemas: (a) um servidor (ou servidores) que fornece serviços à rede de computadores e aos equipamentos eletrônicos, também chamado de *supervisório* ou sistema computacional SCADA; (b) rede de comunicação para transferência de dados entre os dispositivos e os servidores (rádio, satélite, telefone, etc.); (c) estações remotas/controlador lógico programável para aquisição das medições e controle dos atuadores em campo; e (d) instrumentação (sensores e atuadores). De forma geral, o sistema SCADA gerencia os pontos de medição e de automação, alarmes, relatórios e gráficos de acompanhamento, podendo ainda filtrar informações e fornecer subsídios para cada setor da empresa.

Embora os *Controladores Lógicos Programáveis* (CLPs) tenham funcionalidades semelhantes às *Unidades de Transmissão Remota* (UTRs), aqueles apresentam a vantagem de combinar grandes quantidades de dados digitais e analógicos à possibilidade de incorporação de algoritmos de alta complexidade. Em contrapartida, uma UTR normalmente não suporta algoritmos de controle de processos. (BUNN, 2007). Simon Bunn (2007) aplicou o *software Derceto Aquadapt* em dois sistemas reais, *East Bay Municipal Utility District* e o sistema do subúrbio de Washington (EUA). A aplicação no *East Bay Municipal Utility District* resultou em uma redução de 13% nos custos com energia elétrica. No caso do sistema do subúrbio de Washington, foi necessária a substituição das UTRs por CLPs inteligentes. Os resultados mostraram uma redução dos custos de energia de até mil dólares por dia na terceira semana de operação.

Antônio Sérgio Spolaor discutiu a utilização de técnicas de “*inteligência artificial*” na automatização de SAAs. (SPOLAOR, 2011). A metodologia foi aplicada em um projeto desenvolvido pela Companhia de Saneamento Básico do Estado de São Paulo (SABESP), na cidade de Santa Rosa de Viterbo, visando a uma melhor distribuição de água entre os

reservatórios do sistema. A automação foi implantada com sucesso por meio de controladores lógicos programáveis e um sistema SCADA.

Campisano e Modica (2002) apresentaram sistemas de controle que adotaram algoritmos proporcionais (implantados em controladores lógicos programáveis) para controlar a pressão em SAAs. Apesar de a aplicação ter tido resultados satisfatórios, os próprios autores ressaltam que, em algumas redes de distribuição de água, os controladores não são adequados para manter a pressão no valor de referência.

As pesquisas desenvolvidas pela comunidade científica para sistemas de distribuição de água buscaram, principalmente, a redução dos custos e o aumento da eficiência dos sistemas de bombeamento. No entanto, a aceitação de alguns métodos inovadores pelas empresas de saneamento ainda é limitada, principalmente porque algumas técnicas ignoram o desempenho global do sistema, possuem formulação complexa (devido à sofisticação matemática), simplificam demais os sistemas e/ou possuem alto tempo de processamento.

Entre as soluções práticas que podem permitir a redução do consumo de energia, a mudança nos procedimentos operacionais dos sistemas de bombeamento é bastante eficaz, uma vez que necessita de pouco investimento. Os avanços tecnológicos na área computacional aumentaram a qualidade dos trabalhos científicos relacionados com a otimização de processos. No entanto, a maioria dos modelos desenvolvidos foi aplicada somente em casos específicos. (COSTA, L. et al., 2016).

Ao otimizar a operação de sistemas de bombeamento, é possível obter não só a poupança de energia, mas também um melhor desempenho global do SAA, maior confiabilidade nos procedimentos operacionais e redução dos *Custos do Ciclo de Vida* (CCV). (EUROPUMP; HYDRAULIC INSTITUTE, 2004). Atualmente, há um grande número de trabalhos científicos que lidam com a otimização de sistemas de bombeamento. Normalmente, essas pesquisas referem-se à definição da rotina operacional das bombas, como, por exemplo, as realizadas por Blinco et al. (2016), Brion e Mays (1991), Ghaddar et al. (2014), Kang (2014), Kougias e Theodossiou (2013), L. Costa et al. (2016), López-Ibáñez (2009), López-Ibáñez, Prasad e Paechter (2011), Martinez et al. (2007), Pasha e Lansey (2014) e Ramos, L. Costa e Gonçalves (2012).

Os métodos de otimização baseados em gradiente foram os primeiros aplicados para a otimização de programação de bombas. (BRION; MAYS, 1991; CEMBRANO et al., 1988). Em seguida, surgiram os algoritmos evolucionários (GOLDMAN; MAYS, 1999; MÄCKLE;

SAVIC; WALTERS, 1995; SAVIC; WALTERS; SCHWAB, 1997), que se apresentaram mais adequados, uma vez que não há necessidade de simplificação dos problemas. Nos últimos dez anos, uma grande variedade de estudos aplicou uma série de algoritmos meta-heurísticos, que combinaram técnicas de pesquisas globais e locais. (COELHO; ANDRADE-CAMPOS, 2014).

A programação ótima de bombas em sistemas de distribuição de água é um problema de otimização complexo, com diversos tipos de variáveis de decisão. Diversas pesquisas estão adotando o EPANET (ROSSMAN, 2000) concomitantemente com módulos de otimização para a determinação da operação ótima de sistemas de distribuição de água. (CASTRO-GAMA et al., 2016; COSTA, L. et al., 2016; MAMBRETT; ORSI, 2016; SHI; YOU, 2016). Atualmente, um grande número de sistemas de abastecimentos de água europeus emprega modelos de otimização para determinar rotinas de operação de 24 horas.

Entre os simuladores utilizados pelos projetistas, segundo Biscos et al. (2003), o EPANET (ROSSMAN, 2000) é aceito amplamente como “padrão mundial” na modelagem hidráulica e de qualidade de água. O programa foi concebido para ser uma ferramenta de apoio à análise de sistemas de distribuição de água para abastecimento urbano, sistemas de irrigação, de combate a incêndios, etc. O *software* permite obter valores de vazão, de pressão, do nível de água nos reservatórios, da concentração de elementos químicos ao longo da rede hidráulica, e outros. O EPANET auxilia na análise de alternativas de gestão, de modo a melhorar a qualidade do sistema de abastecimento, assim como permite avaliar possíveis ações que possam diminuir o consumo de energia elétrica das estações de bombeamento. (BEZERRA, 2009, p. 12).

Luís Henrique Costa, Helena Ramos e Marco Aurélio Holanda de Castro (2010) propuseram um algoritmo genético híbrido que melhora a qualidade das soluções geradas e diminui substancialmente o tempo de processamento. No entanto, as técnicas heurísticas implicam elevados custos computacionais e não garantem a descoberta de soluções ótimas globais. (COSTA, L. et al., 2016).

A adoção de um *Algoritmo Genético Híbrido* para a otimização de um sistema de bombeamento de um sistema de abastecimento de água de grande porte na China resultou em uma economia nos custos com energia elétrica de 6%. A metodologia desenvolvida considerou uma única função objetivo que incluía os custos de eletricidade com o bombeamento e o custo de produção da água. As restrições do modelo são: os níveis dos

reservatórios de água, a continuidade no fornecimento, os limites de velocidade das bombas de velocidade de rotação variável e o número de paradas das bombas. (SHIHU et al., 2010).

López-Ibáñez, Prasad e Paechter (2011) apresentaram um algoritmo *Branch and Bound* para a definição da estratégia operacional de sistemas de bombeamento visando à redução dos custos com energia. Esses autores definiram que a programação de cada bomba fosse dividida numa série de números inteiros, com cada número inteiro representando o tempo (em horas) em que uma bomba está ligada ou desligada. Isso reduziu o número de potenciais horários em comparação com a representação binária, e permitiu que o algoritmo desenvolvido pudesse considerar a região viável do espaço de busca.

Ghaddar et al. (2014) propuseram uma decomposição lagrangiana ao problema de otimização de rotinas operacionais de sistemas de bombeamento, visando à redução do espaço de busca por meio da dissociação do problema em subproblemas menores. Em cada subproblema, são geradas soluções (viáveis e inviáveis) através de um relaxamento de Lagrange. Para as soluções inviáveis de cada subproblema, um algoritmo de *busca em profundidade intercalada primeiro* (IDFS, do inglês *interleaved depth-first search*). (KORF, 1996) é aplicado para a correção de inviabilidade. O método encontra soluções de alta qualidade, embora sem garantia de otimalidade. As restrições relacionadas com a conservação de energia restringem o modelo desenvolvido para as redes avaliadas; além disso, o relaxamento de Lagrange requer um grande número de parâmetros.

Luís Henrique Costa et al. (2016) apresentaram uma rotina de otimização integrada ao EPANET que permitiu a determinação de regras ótimas de operação para qualquer tipo de sistema de bombeamento de água, segundo os autores. Além disso, um algoritmo *branch and bound* também foi adotado para determinar a melhor solução global, em tempos computacionais admissíveis.

Destaca-se que, para uma melhor aceitação, por parte dos técnicos das empresas, dos “produtos” desenvolvidos pela comunidade científica, é importante desenvolver metodologias e ferramentas computacionais que contemplem uma interface intuitiva e atraente, facilidade de adaptação a novas condições de operação e alterações na infraestrutura do sistema, e que contenham técnicas acopladas que avaliem o desempenho da rede e as necessidades de abastecimento dos consumidores.

Com o crescimento dos sistemas urbanos de abastecimento de água no Brasil e em todo o mundo, surgem crescentes desafios para preservar os recursos hídricos e energéticos.

Esses desafios decorrem de crescentes populações e da migração para os centros urbanos que aumentam a exigência aos sistemas. Essa demanda crescente incentivou o desenvolvimento de numerosas pesquisas que integram os sistemas de aquisição e controle com modelos de simulação de redes de distribuição de água. (BOULOS et al., 2014). Tais capacidades de modelagem em tempo real podem aumentar consideravelmente a capacidade dos prestadores de serviços para gerir, operar e manter seus sistemas de distribuição de água com eficiência, além de fornecer um nível adequado de serviço aos seus clientes.

Os sistemas de modelagem, supervisão e controle mais modernos recorrem a uma visão precisa do estado dos sistemas de distribuição de água, que têm suas informações atualizadas continuamente por meio de sistemas SCADA. Os dados SCADA em tempo real são utilizados como condições de contorno (por exemplo, os níveis de água dos reservatórios) e estados de funcionamento (por exemplo, estado e velocidades de rotação de bombas, e configurações de válvulas) no modelo hidráulico de rede. (HATCHETT et al., 2010). Por exemplo, os operadores podem identificar, antecipadamente, os clientes que serão afetados negativamente pela diminuição de pressão provocada pela redução do nível de água do reservatório que abastece a região. Com essa informação, os técnicos podem conceber e formular cenários operacionais alternativos que podem ser analisados e comparados pelo próprio sistema.

Ingeduld (2007) investigou o uso de EPANET em operações em tempo real. Segundo o pesquisador, a interligação de um sistema SCADA com o simulador em sistemas reais permite que o sistema de distribuição de água opere nos seguintes modos: (a) **Sensor Virtual** – com base nas condições da rede, o sistema estima dados para locais sem medições; (b) **Retrospectivo**¹ – permite a simulação de eventos passados na rede; (c) **Simulação de Evento** – proporciona a simulação de modificações nas condições de operação; e (d) **Preditivo** – fornece uma previsão do comportamento do sistema durante certo horizonte temporal. O módulo hidráulico também pode ser empregado para comparar o desempenho de alternativas durante o processo de otimização dos processos, e para situações não rotineiras ou de emergência. (COULBECK; ORR; BRDYS, 1988).

Para fornecer transferência de dados entre o sistema SCADA e o simulador hidráulico, Ingeduld (2007) apresentou um sistema de integração e gestão de dados desenvolvido em SQL (sigla do inglês *Structured Query Language*)². A solução *on-line*

¹ Em inglês, *hindcasting*.

² Linguagem de consulta estruturada.

apresentada pelo autor foi aplicada em sistemas da República Checa e da Líbia, e adotava um sistema SCADA SCX e o simulador hidráulico MIKE NET.

Kang (2014) desenvolveu um modelo de controle ótimo, em tempo real, para a rede de distribuição de água. O modelo visa a minimizar o custo de operação do sistema de bombeamento, enquanto satisfaz as várias restrições operacionais impostas pela variação da demanda e das tarifas de energia durante todo o período de operação. O controle em tempo real utiliza o sistema SCADA, por meio do qual os dados de campo são monitorados e as decisões de controle são implementadas. Foram impostas as seguintes restrições operacionais: (a) manutenção da pressão do sistema próxima da pressão mínima; (b) manutenção do nível de água do reservatório dentro de um intervalo predeterminado; e (c) limite de consumo de energia no horário de ponta do setor elétrico para cada estação de bomba.

Atualmente, há uma tendência nas empresas de serviços públicos de saneamento em criar redes de água inteligentes (ALLEN et al., 2013; STOIANOV et al., 2007), a fim de melhorar a qualidade do serviço e reduzir os custos de produção e de manutenção de equipamentos. O principal objetivo de implementar uma rede desse tipo é melhorar o desempenho dos sistemas por meio da otimização de rotinas operacionais, em vez de depender exclusivamente de soluções que requeiram grandes investimentos. A Sensus encomendou uma pesquisa que concluiu que as redes de água inteligentes podem poupar, em todo o mundo, até US\$ 12,5 bilhões por ano. (SENSUS, 2012).

Os modelos em tempo real que combinam o uso de ferramentas computacionais (simuladores hidráulicos, modelos de otimização, sistemas de informação geográfica, etc.) e tecnologias de medição, aquisição de dados e comunicação (por exemplo, sistemas SCADA) são denominados por alguns pesquisadores de *redes de água inteligentes* (em inglês, *smart water networks*).

De acordo com o relatório “Smart Water Market Overview”³, da IDC, empresa norte-americana de assessoria, análise e pesquisa de mercado, subsidiária do *International Data Group* (IDG), as soluções inteligentes de gerenciamento de sistemas de distribuição de água vão crescer mais rápido do que a medição de água inteligente, e os principais benefícios correspondem à redução de perdas de água. As soluções apresentadas nesse relatório, especialmente as relacionadas com a operação automatizada e em tempo real de SAAs, contribuem significativamente para o desenvolvimento desse conceito.

³ IDC Energy Insights #EI235229, June 2012.

Boulos e Wiley (2013) descreveram vários sistemas de gerenciamento de informações e monitoramento em tempo real que podem auxiliar as companhias de água a aumentar a eficiência e tornar-se mais proativas na operação de SAAs. Esses sistemas também podem ajudar as empresas a se ajustarem às novas regulamentações, proporcionar maior segurança nos procedimentos operacionais, auxiliar nos processos de tomada de decisão e no planejamento financeiro. (BOULOS; WILEY, 2013).

Recentemente, Candelieri, Archetti e Messina (2013) publicaram uma solução técnica para empresas de saneamento que contempla o uso simultâneo de um sistema SCADA, Sistema de Informação ao Cliente, Sistema de Informação Geográfica e o EPANET. O sistema foi aplicado com bons resultados em um estudo de caso real.

Kartakis et al. (2016) apresentaram um projeto de rede inteligente para um sistema de distribuição de água de Bristol, Reino Unido, que buscava, entre outros objetivos, a implementação de novos dispositivos que possibilitassem a redução dos dados transmitidos e, conseqüentemente, o aumento da vida útil das baterias dos equipamentos.

O custo computacional dos simuladores para a otimização da operação em tempo real ainda é relativamente alto. Para reduzir os requisitos computacionais exigidos pelas simulações hidráulicas, o simulador pode ser substituído por modelos matemáticos baseados em redes neurais artificiais (RNAs). (ORMSBEE; LINGIREDDY, 1995). Nesse caso, a RNA pode ser completamente treinada *off-line* e, em seguida, adotada como modelo da rede hidráulica. Os dados necessários para treinar a rede são oriundos de aplicações múltiplas de um modelo de simulação hidráulico previamente calibrado. Em alternativa, a RNA também pode ser treinada *on-line* por meio dos dados arquivados ou obtidos em tempo real a partir de um sistema SCADA.

Com o objetivo de reduzir o tempo computacional, Rao e Alvarruiz (2007) introduziram a técnica de RNAs como alternativa às simulações hidráulicas realizadas pelo EPANET, o que resultou em um modelo de otimização que combina RNAs com Algoritmos Genéticos (AGs) para atuação em tempo real. Restrições aos valores de pressão, de velocidade e aos níveis dos reservatórios foram incluídas no processo de otimização e controle. Um sistema SCADA foi responsável pela atualização dos dados. Essa metodologia foi aplicada em SAA de Haifa (Monte Carmelo, Israel) e de Valência (Espanha). Comparando os resultados da AG-RNA e do AG-EPANET, verificou-se que, para o SAA de Haifa, o modelo proposto pelos autores foi, aproximadamente, vinte e cinco vezes mais rápido do que o modelo AG-EPANET. (SALOMONS et al., 2007).

Os projetos de operação de sistemas de distribuição de água mais sofisticados incorporaram a previsão de demanda, além da modelagem, simulação e otimização, com todos os elementos coordenados por um sistema SCADA. Coulbeck, Orr e Brdys (1988) descreveram com mais detalhes os procedimentos e módulos básicos (previsão, otimização e simulação) para a implementação de um controle ótimo, em tempo real, totalmente automatizado. O módulo de previsão de demanda envolve os seguintes processos: (a) rastreamento dos dados de telemetria (valores de erro são substituídos por interpolação ou valores preditos anteriormente); (b) tratamento dos dados para remover possíveis perturbações; e (c) uma estimativa de tendência por meio dos dados pesquisados e tratados. O módulo de otimização determina a rotina de operação de cada bomba, considerando os níveis mínimos e máximos dos reservatórios, a demanda dos consumidores e também as limitações gerais relacionadas com a operação do sistema.

Na Figura 2.1, apresenta-se um exemplo de um sistema de automação para controle em tempo real de sistemas de distribuição de água com previsão de demanda. Os sistemas automatizados de controle em tempo real mais modernos permitem a gestão avançada de dados e a transmissão de informação entre os componentes. Um banco de dados é usado para registrar o histórico de consumo de água e energia, e todas as características do SAA ao longo do tempo. (COELHO; ANDRADE-CAMPOS, 2014).




Figura 2.1 – Esquema de um sistema de automação para controle em tempo real de sistemas de distribuição de água. (COELHO; ANDRADE-CAMPOS, 2014).

As RNAs foram adotadas com sucesso numa série de problemas de modelagem e otimização de sistemas de distribuição de água com previsão de demanda. (KOFINAS et al.,

2016; MOUNCE, 2013). Devido às oportunidades oferecidas, nos últimos anos, pelos sistemas de aquisição de dados em tempo real, novas aplicações estão sendo desenvolvidas utilizando esses dados. O desafio das abordagens é aprender e prever a variabilidade normal de séries temporais e, em seguida, usar os modelos na previsão de demanda ou de detecção de anormalidades. As previsões de demanda de água são úteis para estimar demandas futuras de água em diferentes escalas de tempo e avaliar as medidas de gestão da demanda de água em áreas urbanas. Steve Mounce (2013) realizou um estudo comparativo de arquiteturas de redes neurais artificiais para a previsão de demanda em séries temporais de sistemas de distribuição de água.

2.2 Motores de Indução Trifásicos

Os motores de indução com rotor tipo gaiola de esquilo, também chamados de *motores assíncronos*, são os mais empregados no setor industrial, em virtude de sua robustez, alta confiabilidade, simplicidade, boa eficiência e fácil manutenção. Esses motores representam mais de 85% dos motores instalados nas indústrias (MENGHAL; LAXMI, 2014), e seu controle se tornou objeto de muitas pesquisas desde a década de 1970. (GUTIERREZ-VILLALOBOS et al., 2013).

Devido à alta aplicabilidade de motores de indução na indústria, várias pesquisas recentes têm sido publicadas na área de controle de processos — como, por exemplo: (AKHILA; PRAVEEN KUMAR; ISHA, 2016), (ALSOFYANI et al., 2016), (SANTOS et al., 2013), SUETAKE; SILVA, I.; GOEDEL, 2011), (VERMA, R.; VERMA, V.; CHAKRABORTY, 2014) e no diagnóstico de falhas — como, por exemplo: (BACCARINI et al., 2010), (FEKI; CLERC; VELEX, 2013), (IMMOVILLI et al., 2013) e (LI, W. et al., 2015).

O acionamento de motores de indução trifásicos (MITs) requer alta precisão em processos de alto desempenho. As características mecânicas e elétricas desses motores se alteram significativamente quando há mudança de velocidade de rotação, aumento de temperatura e, especialmente, com alterações da carga de serviço. (GUTIERREZ-VILLALOBOS et al., 2015).

As técnicas de controle para MITs disponíveis industrialmente e mais encontradas na literatura são: o controle escalar, o controle vetorial e o controle direto de torque. (LIMA, F., 2010). O processo de cálculo de torque é uma das principais preocupações para o controle de MIT na indústria, e exige a estimativa precisa do estado de diferentes variáveis. (ALSOFYANI et al., 2016).

Os motores convencionais não possuem sensores de fluxo ou locais específicos para montagem destes, pois a medição direta reduz a robustez e aumenta o custo de implementação (SANTOS et al., 2013), que são as principais vantagens desses motores.

Peter Vas (1998) apresentou diversas técnicas para o controle de MITs sem a utilização de sensores. As primeiras técnicas previam modelos de regime permanente e somente se aplicavam a acionamentos de baixo custo. Atualmente, as principais estratégias de controle sem sensores utilizam: estimadores de malha aberta com corrente do estator e monitorização da tensão; observadores de estado; sistemas de referência com modelos adaptativos; e estimadores baseados em redes neurais artificiais (RNAs) e lógica *fuzzy*. A maioria dos estimadores de velocidade é baseada em modelos matemáticos dos motores, e sua estratégia requer um conhecimento preciso dos parâmetros elétricos e mecânicos dos equipamentos. As técnicas podem ser agrupadas nos seguintes métodos (PIZZINO, 2008):

- Análise dos efeitos gerados pelas ranhuras do rotor (*Rotor Slot Ripple*);
- Controle V/f (*Volts-per-hertz Control*);
- Observador não linear (*Nonlinear Observer*);
- Estimador em malha aberta (*Open-loop Estimator*);
- Filtro de Kalman Estendido (*Extended Kalman Filter*);
- Injeção de corrente em alta frequência (*High Frequency Current Injection*);
- Observador de Luenberger (*Luenberger Observer*);
- Sistema Adaptativo (*Adaptive System*);
- Inteligência Artificial (*Artificial Intelligence*).

O controle escalar é um controle de velocidade em malha aberta baseado no modelo em estado estacionário. O controle da velocidade do rotor é alcançado por meio da regulação da frequência e da amplitude das tensões aplicadas pelo inversor. Devido à sua simplicidade, o controle escalar é um dos métodos mais empregados na indústria. No entanto, o seu desempenho dinâmico é limitado, mesmo em circuito fechado, particularmente quando o motor opera em baixa velocidade.

No controle escalar do MIT, adota-se a estratégia de manter constante a razão entre tensão e frequência do estator da máquina. Dessa maneira, o torque eletromagnético pode ser mantido em um valor constante durante toda a faixa de operação de velocidade. Por se tratar de um sistema de controle que não utiliza informações de fase das grandezas do MIT, somente apresenta bons resultados em regime permanente. Durante o transitório, e em operações em baixas velocidades, o seu desempenho é considerado insatisfatório. (LIMA, F.,

2010). Quando os motores operam com baixa velocidade, as perdas no processo têm um efeito significativo sobre o desempenho, reduzindo o binário eletromagnético da máquina. (GUO; PARSA, 2012). Portanto, para alcançar elevado desempenho na operação de MITs, podem ser adotadas técnicas de controle vetorial ou de controle direto de torque. No controle direto de torque, como o próprio nome indica, o conjugado é a variável controlada. A técnica convencional não requer sensores mecânicos ou transformação de coordenadas, e depende somente da resistência do estator da máquina. (BUJA; KAZMIERKOWSKI, 2004).

Os sistemas inteligentes vêm-se destacando no acionamento sem sensores de motores de indução. Entre as diversas técnicas disponíveis para controle e estimação aplicadas aos acionamentos em corrente alternada, destacam-se as redes neurais artificiais, os sistemas *fuzzy* e os sistemas híbridos baseados nas duas técnicas. Particularmente, as RNAs têm recebido grande atenção no meio acadêmico (GOEDEL, 2007), e, comparativamente, aparentam ter tido maior impacto sobre a eletrônica de potência e o acionamento de motores. (BOSE, 2007, p. 14).

Suetake, I. Silva e Goedel (2011) apresentaram um sistema *fuzzy* para o controle de velocidade escalar em motores de indução trifásicos. A estratégia de controle consistiu em manter constante a razão entre a tensão e a frequência de acionamento. Um sistema de controle *fuzzy* é construído sobre um processador de sinal digital, que utiliza a variação do erro de velocidade para alterar a amplitude da tensão fundamental e a frequência do inversor PWM (modulação por largura de pulso). O desempenho do controlador em relação à referência e às variações de conjugado de carga é avaliado experimentalmente. Os resultados foram melhores que os do controlador PI convencional projetado pelos pesquisadores.

Akhila, Praveen Kumar e Isha (2016) apresentaram um controlador *fuzzy* baseado em regras para a operação de motores de indução trifásicos com inversores de frequência PWM. A estratégia de controle é também manter constante a relação tensão/frequência. A velocidade de rotação real do motor e a variação do erro da velocidade são as duas entradas do sistema de controle, enquanto a variação da frequência é a variável de saída. O desempenho do controlador proposto foi superior ao controlador PI projetado pelos autores.

Na Seção 2.4, apresentar-se-ão outras pesquisas baseadas em RNAs para o controle de motores de indução trifásicos.

2.3 Bombas em Operação com Velocidade de Rotação Variável

Certos sistemas de bombeamento requerem algum tipo de controle de vazão e pressão, principalmente quando há variação da demanda na rede de distribuição de água. O controle da vazão/pressão é necessário quando a carga requerida ao sistema de bombeamento varia no tempo, o que ocorre quando o sistema fornece água diretamente para a rede hidráulica. (BEZERRA et al., 2015, p. 72).

Atualmente, a alternativa mais eficiente para o controle de vazão e pressão em sistemas de bombeamento de água é o uso de inversores de frequência⁴ em conjuntos motor-bomba. (EUROPUMP; HYDRAULIC INSTITUTE, 2004; SAIDUR et al., 2012; SILVA, M. et al., 2015).

Apesar de ser recente a sua comercialização em grande escala, os inversores de frequência têm sido usados há décadas. Dewinter e Kedrosky (1989) descreveram a expansão do sistema de bombeamento de petróleo de *Betume Blend Cold Lake Pipeline* (Canadá), que ampliou a capacidade da estação elevatória do sistema de 130 mil barris/dia para 185 mil barris /dia, com a instalação de um novo conjunto motor-bomba de 3.500 HP, com velocidade de rotação variável por meio de um inversor de frequência. Embora o preço da energia elétrica no período fosse baixa, a taxa interna de retorno foi inferior a 18%.

Os inversores de frequência melhoraram muito desde que o primeiro foi lançado no mercado. O desenvolvimento de dispositivos eletrônicos e tecnologias de conversão nas últimas décadas tornou possível o controle eficiente de velocidade de rotação por meio da variação da frequência de alimentação e tensão elétrica, dando origem aos dispositivos que permitem o acionamento de motores de indução com velocidade ajustável. (DING et al., 2013).

A Equação 2.1 representa a relação entre a velocidade de rotação do eixo de um motor de indução trifásico e a frequência de acionamento do motor:

$$n_R = \frac{120 \times f}{p} (1 - s) \quad (2.1)$$

onde n_R é a velocidade de rotação do eixo do motor, em rpm; f é a frequência de acionamento do motor, em Hz; p é o número de polos do motor; e s é o escorregamento do motor assíncrono.

⁴ Os inversores também são chamados de **inversores de frequência** e, em inglês, *inverters*, *AC drives*, *adjustable speed drives* e *variable frequency drives*.

Os inversores de frequência podem proporcionar uma economia de 50%, ou mais, da energia em sistemas de bombeamento (SHEEN, 2009), além de permitir o monitoramento *on-line* das grandezas elétricas. A Figura 2.2 mostra o exemplo de um conjunto motor-bomba em operação com a atuação de uma válvula de manobra e de um inversor de frequência para o controle de vazão, apresentado por Bezerra et al. (2015, p. 72). Ressalte-se que a operação com o estrangulamento da válvula de manobra exige uma altura manométrica maior. A diferença (em destaque amarelo na Figura 2.2) pode ser vista como a energia desperdiçada no processo.

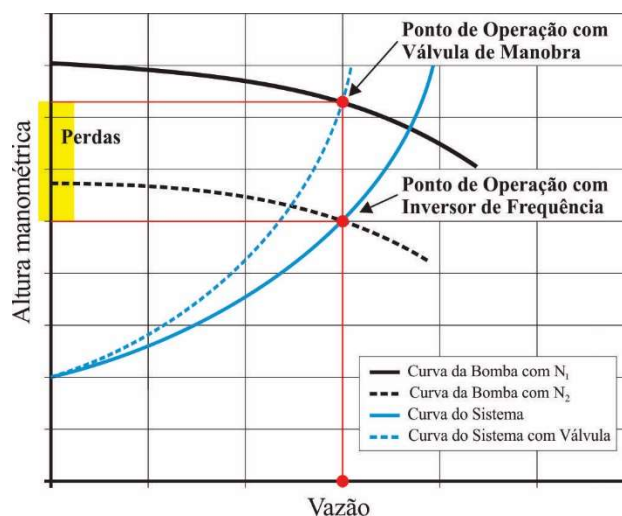


Figura 2.2 – Altura manométrica para os métodos de controle de vazão: estrangulamento de válvula e controle de rotação com inversor de frequência. N_1 e N_2 são velocidades de rotação da bomba, e $N_1 > N_2$. (BEZERRA et al., 2015, p. 72).

Almeida, Ferreira e Both (2005) apresentaram uma comparação do desempenho de dois sistemas diferentes de controle de vazão (v. Figura 2.3).

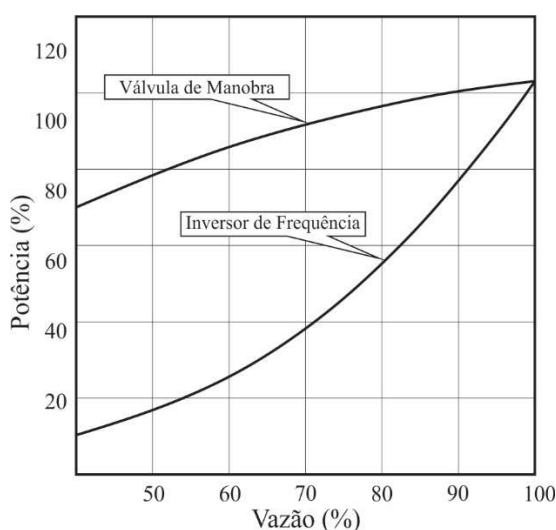


Figura 2.3 – Potência para diferentes métodos de regulação de vazão de uma bomba centrífuga. (ALMEIDA; FERREIRA; BOTH, 2005).

Ferreira, Fong e Almeida (2011) concluíram que a utilização de inversores, em substituição a válvulas de manobras para regular a vazão, pode produzir uma redução substancial no impacto ambiental e nos custos do ciclo de vida (CCVs). Devido principalmente à diminuição do consumo de energia, esses autores estimaram que sistemas de bombeamento acionados com inversores de frequência, que operam mais de 2.000 horas por ano, podem reduzir as emissões de gases de efeito estufa em mais de 35%, e diminuir os CCVs em mais de 25%.

As equações que relacionam a vazão (Q), a altura manométrica (H) e a potência (Pot) com a velocidade de rotação (n) são conhecidas como *Leis de Similaridade* (Equações 2.2 a 2.4), e são apresentadas por numerosos pesquisadores, como, por exemplo, Alves, L. Oliveira e A. M. de Oliveira (2002), Aranto (2008), Bezerra (2009), Everhart (2004), Samora et al. (2016), Struthers (2005) e Theisen (2005). De acordo com a Equação 2.4, pequenas variações na rotação resultam em grandes alterações no consumo de energia.

$$\frac{Q_1}{Q_2} = \frac{n_1}{n_2} \quad \text{Relação vazão x rotação} \quad (2.2)$$

$$\frac{H_1}{H_2} = \left(\frac{n_1}{n_2} \right)^2 \quad \text{Relação altura manométrica x rotação} \quad (2.3)$$

$$\frac{Pot_1}{Pot_2} = \left(\frac{n_1}{n_2} \right)^3 \quad \text{Relação potência x rotação} \quad (2.4)$$

As leis de similaridade representam uma simplificação das condições reais. Apesar de não considerarem as perdas do sistema, demonstram a poupança de energia substancial que pode ser obtida por meio de inversores acionando bombas centrífugas. (SAUER; BRADY, 2009). Simpson e Marchi (2013) apontaram que as leis de similaridade não devem ser aplicadas em bombas de pequenas dimensões. A pesquisa determinou o erro na estimativa do rendimento para uma ampla gama de tamanhos de bombas, e apresentou uma fórmula alternativa para bombas de pequeno e médio portes.

Convém salientar que nem todas as aplicações de motores se podem beneficiar do uso de inversores, uma vez que, para aplicações de velocidade constante, obviamente, estes não só não economizam energia, como também provocam perdas extras e despesas de capital. (BEZERRA et al., 2015, p. 72).

Walski et al. (2003) descreveram experimentos realizados para determinar o quão bem

as leis de similaridade se aplicam a bombas em operação com inversores de frequência. Os ensaios foram realizados com a velocidade de rotação variando de 30% a 100% do valor nominal. Dentro do intervalo adotado, as leis de afinidade representaram satisfatoriamente as curvas características de *vazão versus altura manométrica*. Em contrapartida, os valores de rendimento medidos foram inferiores aos previstos pelas leis de afinidade. A explicação mais provável é que a perda de eficiência tenha ocorrido no inversor de frequência. Como os custos de energia são o maior componente do custo do ciclo de vida (CCV) útil da bomba, as implicações para a seleção da bomba são significativas. Os pesquisadores recomendam que as estimativas de CCV sejam realizadas considerando com precisão a perda de eficiência, uma vez que os inversores têm custos próximos às próprias bombas.

O acionamento de conjuntos motor-bomba em sistemas de distribuição de água com bombeamento direto com inversores de frequência apresenta um grande potencial, e suas principais vantagens, como apontadas por Bezerra et al. (2015, p. 73), são:

- Permite a automação do sistema de bombeamento;
- Economia de energia;
- Elimina a necessidade de válvulas para partir e parar os motores. A partida suave conserva a vida útil do motor e dos rolamentos;
- Melhor controle do funcionamento da rede hidráulica;
- Minimiza a necessidade de paradas do sistema ou elimina os saltos de produção;
- Reduz as falhas ocasionadas pela cavitação da bomba;
- Reduz a manutenção em válvulas;
- Reduz o número de quebras nas tubulações, devido à estabilização da pressão ao longo da rede;
- Controle de corrente elétrica do motor elétrico;
- Melhora o fator de potência.

Como desvantagens de inversores de frequência em sistemas de bombeamento, Bezerra et al. (2015, p. 74) citam:

- Custos de inversores são relativamente altos;
- Mudança das condições de funcionamento de bombas;
- Geração de distorções harmônicas;
- Limitação da distância entre o inversor de frequência e o motor (no entanto, existem dispositivos que eliminam esse problema);

- Os componentes eletrônicos do inversor não são tolerantes aos locais com alta umidade e agentes corrosivos;
- Possibilidade, em alguns casos, de danos para o isolamento dos motores.

Atualmente, o nível tecnológico dos inversores de frequência é satisfatório, mas não ideal. (BEZERRA; SILVA, S.; GOMES, 2012). Burt et al. (2008) e Saidur et al. (2012) apresentaram um estudo detalhado sobre o comportamento dos motores que operam com inversor. Liang e Ilochonwu (2011) investigaram os fatores que podem afetar o desempenho de partida de motores elétricos.

Geralmente, as pesquisas citadas na literatura discutem o uso de inversores de frequência em casos reais ou avaliam o comportamento dos parâmetros elétricos dos motores de indução operados por esses equipamentos. (DABADGAONKAR; IYER et al., 2012; SEN, 2011; SINGH, R. et al., 2012;). Em decorrência de os inversores de frequência influenciarem negativamente a qualidade de fornecimento de energia elétrica e alterarem algumas características dos motores elétricos, muitos pesquisadores buscam o desenvolvimento de metodologias e tecnologias para minimizar esses problemas.

No que diz respeito à faixa de rotação recomendada para a operação de conjuntos motor-bomba, não há consenso no meio científico e entre os técnicos. (BEZERRA, 2009, p. 50). Há uma tendência entre os projetistas para adotar a faixa de 50% a 100% da velocidade de rotação nominal, abalizada por alguns pesquisadores — por exemplo, Europump e Hydraulic Institute (2004); Bezerra e Cheung (2013). A região de operação recomendada por Europump e Hydraulic Institute (2004) é mostrada na Figura 2.4. É certo que, em baixas rotações, existe uma queda substancial no rendimento do sistema de bombeamento. Entretanto, o principal argumento utilizado pelos técnicos é o superaquecimento dos rolamentos do motor.

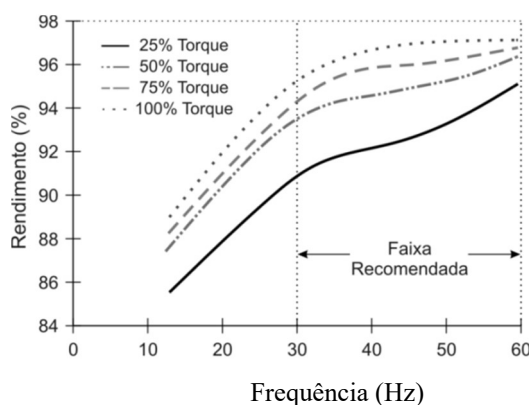


Figura 2.4 – Região de operação recomendada para inversores de frequência — adaptação de Europump e Hydraulic Institute (2004).

Aranto (2008) examinou a eficiência de quatro inversores de frequência, de fabricantes diferentes, como dispositivos de controle de sistemas de bombeamento. A intenção do pesquisador foi analisar os equipamentos do ponto de vista de um usuário de conjuntos motor-bomba, observando especialmente o rendimento do sistema (inversor + motor). Os ensaios foram realizados no Laboratório de Eletrônica de Potência, da Universidade de Tecnologia de Lappeenranta, Finlândia. A bancada experimental era composta por um inversor de frequência, um motor de indução trifásico, dois analisadores de energia e um medidor de torque. Os rendimentos do inversor e do sistema (inversor + motor) foram medidos para diversas frequências de alimentação e diversos valores de torque. Os resultados apontaram pequenas diferenças nos rendimentos do sistema (inversor + motor) em frequências de 35 Hz a 60 Hz, que variaram de 0,82 a 0,76.

Burt et al. (2008) apresentaram uma pesquisa detalhada sobre o comportamento da eficiência de motores em operação com inversor de frequência, a fim de prover informações aos projetistas para uma melhor estimativa da potência de conjuntos motor-bomba acionados por esses equipamentos. Os autores apontaram uma redução, em média, de 8% da eficiência do motor elétrico. Ressalte-se, contudo, que a queda no rendimento não é impactante quando o equipamento é dimensionado corretamente, pois a economia de energia obtida com a aplicação é superior ao consumo e às perdas provocadas pelos dispositivos.

No que diz respeito às aplicações de inversores de frequência, destacam-se os trabalhos recentes de A. Lima et al. (2015), Bezerra et al. (2015), Camboim, S. Silva e Gomes (2014), Daniel Makino (2012), M. Silva et al. (2015), Paulo Sérgio Carvalho (2012), Régis et al. (2014) e Shankar et al. (2016).

Paulo Sérgio de Carvalho (2012) desenvolveu um controlador *fuzzy* para controlar a pressão em um sistema experimental composto por duas zonas de abastecimento com topografias distintas, com um conjunto motor-bomba na origem do sistema e um *booster* que atende a zona alta. Foram realizados diversos testes numa bancada experimental a fim de obter as regras operacionais e utilizá-las no modelo *fuzzy*. O sistema controla a pressão na entrada das zonas através da variação de rotação dos conjuntos motor-bomba e pela alteração no ângulo de abertura de válvulas. Os resultados obtidos indicam uma considerável redução no consumo de energia.

Num programa de reestruturação do sistema de distribuição de água da cidade de Limeira, São Paulo, foi empregado um inversor de frequência para a variação de rotação do sistema de bombeamento, que, aliado a um plano de operação, resultou em uma economia de

18,3% no consumo de energia elétrica. (MAKINO, 2012).

Wil Camboim, Simplício A. da Silva e Heber P. Gomes (2014) desenvolveram um sistema de controle *fuzzy* para o controle de pressão em SAAs abastecidos por bombas associadas em paralelo. O sistema de controle atuou na velocidade de rotação e no estado (ligado ou desligado) dos conjuntos motor-bomba, de modo a manter a pressão de serviço constante num determinado ponto da rede hidráulica. Para avaliar a técnica proposta, foi implantada uma bancada experimental, e os resultados mostraram uma redução significativa do consumo energético, além do controle da pressão. Quando comparado com sistema de injeção direta sem o controle de pressão, a redução no consumo energético foi de 15,5%.

Régis et al. (2014) implementaram um controlador do tipo PID (Proporcional-Integral-Derivativo) convencional, numa bancada experimental que simula o abastecimento de duas zonas com topografias distintas. O controlador atuou nos inversores de frequência do conjunto motor-bomba, *booster* e na válvula redutora de pressão. Os resultados foram obtidos para simulações realizadas com o uso e sem o uso do PID nos cenários de demanda definidos. O estudo concluiu que o sistema possibilitou uma economia de energia de 29% na máxima demanda e de 49,33% na mínima demanda, quando comparado com a situação sem controle.

Bezerra et al. (2015) desenvolveram um sistema de controle *fuzzy* para conjuntos motor-bomba que operam com rotação variável. O sistema foi desenvolvido para demonstrar a economia de energia proporcionada pelo uso de um inversor de frequência em uma bancada experimental. O sistema controlado apresentou uma redução de 35% do consumo de energia elétrica e um erro médio em torno de 1%, para diferentes valores-alvos de pressão. (Ibidem, p. 77).

M. Silva et al. (2015) desenvolveram um controlador adaptativo de Mínima Variância Generalizada para atuar no controle de velocidade de rotação de um sistema de bombeamento e no ângulo de fechamento de uma válvula redutora de pressão. O estudo realizou a identificação do modelo matemático por meio do método dos Mínimos Quadrados Recursivos. O sistema de controle projetado tinha o objetivo de controlar a pressão nos dois ramais da bancada experimental. Os ensaios foram realizados com o sistema atuando de forma acoplada, de forma desacoplada e variando os valores de referência da pressão. O sistema de controle proposto resultou em uma redução de energia elétrica de 19,2% com erro máximo no regime permanente de 2,12%.

Shankar et al. (2016) apresentaram técnicas de controle voltadas para o aumento de

eficiência de sistemas de bombeamento que operam com inversor de frequência. Os autores abordaram também aspectos relacionados com a seleção de componentes e o dimensionamento de sistemas. Por fim, resultados de pesquisas recentes de melhoria da eficiência energética em sistema de bombeamento foram apresentados.

Numerosas pesquisas avaliam o uso de inversores de frequência em sistemas de bombeamento de água fotovoltaicos, como, por exemplo, em (CHERGUI, 2016), (KHLIFI, 2016), (LUJARA, 2016), (SINGH, B.; KUMAR, R., 2016) e (VALER et al., 2016). Esses sistemas estão sendo aperfeiçoados, ao longo dos últimos anos, pela comunidade científica. A aplicação de inversores habilita o uso de bombas convencionais que não são, necessariamente, projetadas especificamente para aplicações fotovoltaicas. (VALER et al., 2016). Com isso, o uso de inversores facilita a implantação de novos sistemas e a manutenção, além de aumentar a competitividade técnica e econômica dos sistemas de bombeamento de água fotovoltaicos.

Roberto Valer et al. (2016) examinaram detalhadamente os aspectos técnicos e econômicos da aplicação de acionamentos de velocidade variável em sistemas de irrigação no Brasil.

2.4 Redes Neurais Artificiais

O controle de sistemas dinâmicos evoluiu do chamado *controle tradicional* até os atuais, ditos *controles “inteligentes”*, assim classificados por emularem aspectos parciais da inteligência humana, tais como o uso de conhecimento heurístico e características relacionadas à adaptação, ao aprendizado e à predição.

As pesquisas sobre redes neurais artificiais (RNAs) iniciaram em 1943, quando o biólogo norte-americano Warren Sturgis McCulloch (1898-1969) e o matemático norte-americano Walter Harry Pitts (1923-1969) apresentaram o primeiro modelo de um neurônio biológico. No trabalho “*A logical calculus of the ideas immament in nervous activity*”, McCulloch e Pitts (1943) apresentam uma discussão elaborada de redes lógicas e novos conceitos sobre máquinas de estados finitos. As RNAs surgiram na comunidade científica na mesma época do surgimento dos primeiros computadores, e é amplamente sabido que John Von Neumann (1903-1957), pesquisador húngaro-americano que formalizou o projeto lógico da maioria dos computadores atuais, foi fortemente influenciado pelo trabalho de McCulloch e Pitts.

O aprendizado de redes biológicas e artificiais se tornou objeto de estudo apenas no final da década de 1950, quando Donald Hebb publica o livro “*The Organization of*

Behavior”, no qual postulou uma técnica qualitativa e plausível para o processo de aprendizagem. O autor apresentou uma teoria que explica “o aprendizado em nodos biológicos fundamentada no reforço das ligações sinápticas entre nodos excitados” (HEBB apud BRAGA; CARVALHO, A.; LUDERMIR, 2000), observando que as conexões sinápticas do cérebro são continuamente alteradas quando um organismo aprende novas tarefas. Conhecido como *Regra de Hebb*, a técnica foi modelada matematicamente, e é atualmente adotada pela comunidade científica em vários algoritmos de aprendizagem.

Em 1951, o norte-americano Marvin Lee Minsky (1927-2016) construiu o primeiro neurocomputador com capacidade de aprendizagem, denominado Snark. (MINSKY, 1954). O neurocomputador operou com sucesso de um ponto de vista técnico, ajustando os pesos automaticamente. Apesar de ter fornecido novas ideias de *design* que foram adotadas por outros investigadores, ele não realizou nenhuma função de processamento de informações.

Aproximadamente quinze anos após a publicação do clássico artigo de McCulloch e Pitts (1943), Frank Rosenblatt (1957) desenvolveu a rede neural *perceptron*, a primeira RNA empregada para o reconhecimento de padrões. Ela pode ser considerada como o tipo mais simples de uma rede neural *feedforward*, um classificador linear. O pesquisador propôs uma regra de aprendizagem, e provou que um *perceptron* pode ser treinado para classificar certos tipos de padrões que sejam linearmente independentes. Segundo Braga, A. Carvalho e Ludermir (2000, p. 3), o que “Rosenblatt buscava — e os ‘novos conexionistas’ continuam buscando — era projetar RNAs que fossem capazes de fazer descobertas interessantes sem a necessidade de regras.” A tentativa de copiar em redes conexionistas as redes neurais do cérebro exigia um comportamento em paralelo de todo o sistema, e não mais sequências de comandos, conforme o modelo cognitivista. (VARELA, 1985).

Em 1960, os engenheiros norte-americanos Bernard Widrow e Marcian Hoff (1960) introduziram o algoritmo de aprendizado *Least Mean-Square*, chamado de Regra de Widrow e Hoff ou *Regra Delta*, e o adotaram na formulação da RNA ADALINE⁵. A Regra Delta ainda é bastante adotada pela comunidade científica, particularmente no campo de processamento de sinais. Ressalte-se que, apesar de os pesquisadores citados terem apresentado abordagens baseadas em estudos analíticos e numéricos, a maioria das pesquisas realizadas nesse campo da ciência foi experimental. A RNA ADALINE foi a primeira rede neural aplicada na indústria.

⁵ Abreviação do inglês *Adaptive Linear Element*.

No final da década de 1960, o livro *Perceptrons* (MINSKY; PAPERT, 1969) foi um grande golpe nas pesquisas fundamentadas na técnica de RNA. Os autores demonstraram matematicamente (por meio da função *ou-exclusivo*) que o *perceptron* proposto por Rosenblatt (1957), com uma única camada, não é capaz de solucionar problemas que não sejam linearmente separáveis. Como os autores do livro não acreditavam no desenvolvimento de um método de treinamento com mais de uma camada, eles concluíram que as RNAs estariam sempre suscetíveis a essa limitação. (COSTA, S.; REVOREDO FILHO, 2013).

O *perceptron*, por exemplo, não consegue detectar paridade, conectividade e simetria, que são problemas não linearmente separáveis. (BRAGA; CARVALHO, A.; LUDERMIR, 2000). Essas afirmações desmotivaram pesquisadores e empresas a investirem nessa área, levando a abordagem conexionista à dormência. (HAYKIN, 2001). O principal argumento de Minsky e Papert foi que o problema do crescimento explosivo, tanto de espaço ocupado quanto do tempo requerido para a solução de problemas complexos, afetaria as RNAs. (BRAGA; CARVALHO, A.; LUDERMIR, loc. cit.).

Em virtude, principalmente, da repercussão da publicação de Minsky e Papert (1969), o desenvolvimento de novas pesquisas com RNA foi reduzido na década seguinte. As exceções citadas na literatura são as obras de Amari (1972, 1977), Anderson (1972), Fukushima (1975) e Grossberg (1972, 1976).

A partir da década de 1980, com o surgimento das redes de Hopfield (HOPFIELD, D.; TANK, 1985; HOPFIELD, J., 1982, 1984) e do algoritmo de retropropagação⁶. (RUMELHART; MCCLELLAND, 1986), houve uma nova explosão de interesse pelas RNAs na comunidade científica. O avanço da microinformática e o fato de a escola simbolista não ter alcançado melhorias significativas na resolução de determinados problemas simples também contribuíram para o desenvolvimento e o fortalecimento da técnica.

John Hopfield (1982) apresentou uma rede com memória associativa que impôs maior credibilidade e exposição à técnica. Sua rede pode recordar padrões previamente armazenados quando padrões de ruído semelhantes são apresentados.

O algoritmo de treinamento de retropropagação foi proposto por diferentes pesquisadores, como Bryson e Ho (1969), LeCun (1985), Parker (1985) e Werbos (1974). Arthur Bryson e Yu-Chi Ho (1969) apresentaram um algoritmo de controle recursivo matematicamente. A maioria da comunidade científica aponta que o algoritmo de

⁶ Em inglês, *back-propagation*.

retropropagação foi originalmente introduzido por Paul J. Werbos (WERBOS, 1974) e redescoberto independentemente por David Parker. (PARKER, 1985). Todavia, somente em meados da década de 1980 que a técnica se apresentou como um verdadeiro avanço nas pesquisas fundamentadas na técnica de RNA, pois Rumelhart e McClelland (1986) demonstraram que é possível treinar eficientemente redes com camadas intermediárias. Não obstante a sua história atribulada, não há dúvida de que o crédito para o desenvolvimento do algoritmo em uma técnica útil, bem como promulgação da arquitetura da Rede Perceptron Multicamadas (PMC) para um grande público, cabe inteiramente a Rumelhart e seu grupo de pesquisa. Anteriormente, “a retropropagação era desvalorizada e ‘obscura’”. (UNAR, 1999, p. 75, tradução e grifo nossos). O progresso apresentado por esse grupo foi reconhecido pela comunidade científica, e resultou no desenvolvimento, ao longo das últimas décadas, de milhares de pesquisas realizadas por acadêmicos, pesquisadores industriais e governamentais. Atualmente, essa é a técnica de aprendizagem mais popular para o treinamento de RNAs de múltiplas camadas, devido principalmente à sua eficiência e à sua simplicidade computacional, estando inserida nos trabalhos que estão na fronteira da ciência.

Em 1987, foi realizada a primeira conferência específica para Redes Neurais, *The IEEE International Conference on Neural Networks*, realizada em San Diego (EUA). Na ocasião, foi fundada a *International Neural Network Society* (INNS). Em 1988, a associação lançou *Neural Networks*, primeiro periódico voltado especificamente para o tema. Nos anos seguintes, foram lançadas a *Neural Computation* e a *IEEE Transactions on Neural Networks*.

Em 1988, David Broomhead e David Lowe introduziram as redes *feedforward* utilizando a técnica *Radial Basis Function*⁷ (RBF). (BROOMHEAD; LOWE, 1988, p. 328). A generalização das redes RBFs, conhecidas como *Local Model Networks*⁸ (LMNs), foi introduzida por Tor Arne Johansen e Bjarne Foss (JOHANSEN; FOSS, 1992a, 1992b, 1992c, 1993) e popularizada também por Roderick Murray-Smith. (MURRAY-SMITH, 1994; MURRAY-SMITH; GOLLEE, 1994). Atualmente, as redes RBF são comumente adotadas em aplicações com aprendizado do tipo supervisionado.

Os pesquisadores citados anteriormente nesta seção contribuíram significativamente para o desenvolvimento e o sucesso das RNAs. Mas novas arquiteturas para as redes estão sendo constantemente desenvolvidas para novas aplicações. O grande alcance do impacto das

⁷ Função de base radial.

⁸ Redes de modelo local.

RNAs na comunidade científica internacional é comprovado quando se verifica a quantidade de trabalhos publicados em periódicos.

As redes neurais artificiais são amplamente empregadas para a resolução de problemas em todas as áreas da sociedade, como, por exemplo, nas áreas de: abastecimento de água (ANDRADE et al.; 2016; MOUNCE, 2013); Agricultura (SANTIN; SILVA, R.; GRZYBOWSKI, 2016); Economia (CHAUDHURI; GHOSH, 2016); Engenharia de Tráfego (ALKHEDER; TAAMNEH, M; TAAMNEH, S., 2016; GALLO et al., 2016; YILMAZ; ACI; AYDIN, 2016); Geração de Energia (RAZA et al., 2016; SALAM et al., 2016); Hidrologia (DUNCAN et al., 2013); Informática (DAHIYA; GILL, 2016; KUMAR, N.; PATEL, P., 2016); Medicina (ANTONY et al., 2016; FARIS; ALJARAH; MIRJALILI, 2016); Meio Ambiente (ARAVIND et al., 2016; LIU, Shaoqing et al., 2016); Química (AZAD et al., 2016; DIL et al., 2016; ORNEDO-RAMOS et al., 2015); e Saneamento (JACOB; BANERJEE, 2016).

As RNAs também têm sido empregadas, com sucesso, em modelos de previsão na área de recursos hídricos. Maier e Dandy (2000) apresentaram uma revisão da literatura abrangente, citando 43 trabalhos que adotaram RNAs para a predição e a previsão de variáveis na área de recursos hídricos. O estudo constatou que, em quase todas as pesquisas, foram utilizadas redes *feedforward*, e que a maioria adotou o algoritmo de treinamento de retropropagação.

O sucesso das RNAs no controle de sistemas em diversas áreas tem conduzido numerosos pesquisadores a empregar essa técnica no desenvolvimento de seus controladores. Aplicados com frequência em sistemas não lineares, as RNAs se apresentam como alternativa eficiente para plantas que exigem linearização de modelos e/ou grandes variações de parâmetros ou condições de operação. A literatura contém diversas aplicações de RNAs em processos que, até então, não tinham obtido resultados satisfatórios.

As teorias de controle “convencionais” se aplicam a uma grande variedade de sistemas em que o processo é bem definido. Entretanto, esses controladores não conseguem resolver problemas reais cuja modelagem matemática é infactível. (BORDON, 2004). Isso ocorre devido à complexidade da determinação das expressões matemáticas (equações diferenciais, equações à diferença, funções de transferência) que relacionam as variáveis do sistema. As redes neurais proporcionam uma alternativa de controle eficiente para sistemas cujas plantas são de modelagem complexa.

Recentemente, Gutierrez-Villalobos et al. (2013) apresentaram o estado da arte do

campo de pesquisa de redes neurais artificiais aplicadas ao controle de rotação de motores de indução. Os autores resumem diversas pesquisas voltadas para motores de indução, e o texto pode auxiliar os leitores a ter um ponto de partida para iniciar a sua própria investigação sobre a escolha de um tipo de RNA. O trabalho fornece uma lista de redes neurais artificiais adotadas em pesquisas que objetivam o uso eficiente de inversores de frequência.

Nesta pesquisa, optou-se por aplicar RNA no controle e automação de sistemas de bombeamento em operação com bombas associadas em paralelo devido à complexidade da modelagem desse tipo de planta e o amplo número de pesquisas na área de controle de processos que empregam essa técnica. Nos casos de sistemas de distribuição de água, a modelagem matemática é complexa, talvez infactível, uma vez que, para cada ponto de operação, as equações que descrevem o sistema se alteram. Esse fato aponta fortemente para a utilização de técnicas de controle não tradicionais.

As RNAs são empregadas frequentemente combinadas com outras técnicas matemáticas, como, por exemplo: RNA + Metodologia de Superfície de Resposta (AZAD et al., 2016; FANAIE et al., 2016; RAHIMPOUR; HATTI-KAUL; MAMO, 2016); RNA + Busca Harmônica (AHMED; HASAN; ALI, 2015; DAS et al., 2015; LEE, A.; GEEM; SUH, 2016); RNA + Colônia Artificial de Abelhas (ANUAR; SELAMAT; SALLEHUDDIN, 2015; EBRAHIMI et al., 2016; VAZQUEZ; GARRO, 2015); RNA + Otimização por Enxame de Partículas (KUMAR, N.; PATEL, P., 2016; PETER; RAGLEND, 2016; RAZA et al., 2016); RNA + Algoritmos Genéticos (JACOB; BANERJEE, 2016; NOURMOHAMMADZADEH; HARTMANN, 2015; SUPREETHA; NAYAK; SHENOY, 2015); *PID Neural* (AL-ZOHAIRY; SALEM, 2016; LIN, Cheng; LIU, W.; REN, 2015; PENG, W. et al., 2015); *Neuro PD* + Otimização por Colônia de Formigas (LEE, D.; KIM, Seungho; KIM, Sangyong, 2016; XU; LI, H.; LIU, Shan, 2015; YU; LI, Y.; LI, J., 2015); RNA + *Multi-Verse Optimizer* (FARIS; ALJARAH; MIRJALILI, 2016).

O uso de redes neurais artificiais com lógica *fuzzy* está bastante difundido na área de controle de processos. De acordo com Anne Magaly de Paula Canuto (2001), a combinação entre a lógica *fuzzy* e as RNAs podem ser agrupadas em três categorias: (a) *Sistemas Difusos Neurais*, que usam RNA para prover sistemas *fuzzy* com um tipo de método de ajuste automático de parâmetros *fuzzy*, sem, entretanto, alterar a sua funcionalidade; (b) *Redes Neurais Fuzzy*, que transformam elementos das redes neurais, utilizando lógica *fuzzy*, criando, dessa forma, neurônios *fuzzy*; e (c) *Sistemas Híbridos Neurais Fuzzy*, em que as técnicas de redes neurais e lógica *fuzzy* são usadas de forma independente, cada qual fazendo o seu

próprio trabalho em servir diferentes funções do sistema, integrando-se e complementando-se a fim de atingir um objetivo comum. O principal problema com os controladores *fuzzy* convencionais é que os parâmetros associados com as funções de adesão e as regras dependem amplamente da intuição dos especialistas. Para ultrapassar esse problema, diversos autores adotaram a combinação de lógica *fuzzy* com redes neurais artificiais.

O *Sistema de Inferência Neurofuzzy Adaptativo* (ANFIS)⁹ pode ser adotado como alternativa ao tradicional controlador PID no acionamento de motor de indução. Fábio Lima et al. (2012) propuseram uma alternativa ao controle de motores de indução sem a utilização de sensores para realimentação da velocidade do motor. Os autores desenvolveram um estimador ANFIS para o controle de velocidade sem sensores aplicado a motores de indução. Simulações para avaliação do desempenho do estimador mediante o acionamento vetorial do motor foram realizadas utilizando o programa MATLAB/SIMULINK. Para a validação do modelo, uma bancada de testes foi implementada, e o motor foi acionado por um inversor de frequência do tipo fonte de tensão.

Menghal e Laxmi (2016) apresentaram um ambiente integrado para controle de velocidade de motores de indução através de controladores inteligentes. Para superar o problema dos controladores *fuzzy* convencionais, acima referido, um *Sistema de Inferência Neurofuzzy Adaptativo* foi proposto pelos autores. A lógica *fuzzy*, a RNA e o ANFIS foram empregados para manter a velocidade do motor constante quando a carga imposta varia. O controlador baseado no ANFIS demonstrou ser mais confiável do que outros métodos de controle. O desempenho da unidade de motor foi analisado para nenhuma carga, para carga constante e para mudanças nas condições de velocidade.

O desenvolvimento de pesquisas com RNA para o controle de motores de indução sem sensores mecânicos¹⁰ tem aumentado consideravelmente nos últimos anos. (NIASAR; KHOEI, 2015).

Gadoue, Giaouris e Finch (2009) aplicaram RNA para estimar o fluxo magnético. A corrente foi estimada pelo observador neural e comparada com a do motor, e o erro foi utilizado para definir as características da rede. Um estimador de velocidade sem sensores para motores de indução, adotando RNA Perceptron Multicamadas com desempenho satisfatório, foi apresentado por Yoksel e Mehmet (2011).

⁹ Sigla do inglês *Adaptive Neuro Fuzzy Inference System*.

¹⁰ Em inglês, *Sensorless Control of Induction Motor*.

Chuan-Kai Lin (2011) e Lusu Guo e Leila Parsa (2012) apresentaram sistemas de controle adaptativos projetados com base em RNA com função de base radial, treinadas *on-line* para se adaptarem às incertezas do sistema. Chuan-Kai Lin (2011) apresentou um controlador adaptativo composto por uma rede de pesquisa associativa, uma rede adaptativa crítica, um controlador de *feedback* e um controlador robusto. Devido a inevitáveis erros de aproximação e incertezas na planta avaliada, uma técnica robusta de controle foi desenvolvida para superar os efeitos das incertezas.

Os resultados de Guo e Parsa (2012) apontaram que a RNA desenvolvida possibilitou que o motor fosse conduzido abaixo da velocidade nominal, mantendo a relação torque/ampère máxima. A unidade completa do motor de indução foi simulada no MATLAB/SIMULINK e implementada experimentalmente por meio de uma placa controladora (sistema dSPACE com controlador DS1104). Niasar e Khoei (2015) também propuseram um controlador adaptativo para o acionamento de motores de indução sem sensores com base na técnica de controle direto de potência.

Oguz e Dede (2011) propuseram uma RNA para estimar a velocidade, sem sensores, em um motor assíncrono de gaiola de esquilo. Ao examinar os dados obtidos a partir do estudo experimental, os pesquisadores apontaram para a validade e o alto desempenho da RNA na estimativa de velocidade em tempo real.

Santos et al. (2013) propuseram uma metodologia alternativa para estimar a velocidade de um motor de indução trifásico acionado por um inversor de frequência, usando modulação vetorial no âmbito da estratégia de controle escalar e com base em redes neurais artificiais. Para validar o desempenho do método proposto, foram apresentados simulações e resultados experimentais.

R. Verma, V. Verma e Chakraborty (2014) apresentaram uma RNA para estimativa de velocidade que resultou na estabilidade do motor em toda a região de operação considerada, independentemente da variação da resistência, da corrente ou das tensões do estator. Os pesquisadores adotaram o algoritmo de treinamento Levenberg-Marquardt. O sistema desenvolvido foi testado considerando várias cargas, com variações de velocidade e alterações na resistência do estator.

A análise da literatura demonstrou que a aplicabilidade de RNA para sistemas de controle de bombeamento de água está em estado embrionário. Não foram encontradas aplicações de RNA direcionadas para o controle ótimo da velocidade de rotação de bombas associadas em paralelo.

CAPÍTULO 3

REDES NEURAIS ARTIFICIAIS

3.1 Introdução

As redes neurais artificiais imitam o processo de aprendizagem humana e podem lidar com problemas altamente complexos, mesmo que os dados avaliados sejam imprecisos e estejam relacionados por funções não lineares. Essa técnica é idealmente adequada para o reconhecimento de padrões, não requer uma compreensão prévia do processo e/ou fenômeno modelado e possui a capacidade de aprender e “agir” perante as mais adversas situações, bem como adquirir conhecimento por meio da “experiência” e da observação. As RNAs também são altamente adequadas para aplicações na área de sistemas de processo, pois contemplam parâmetros variáveis e sistemas que sofrem influência do tempo.

A definição universal de rede neural artificial não está disponível. No entanto, ela pode ser definida como:

[...] um processador paralelamente distribuído composto de unidades de processamento simples, denominados de neurônios, que têm a propensão natural para armazenar conhecimento experimental e torná-lo acessível para uso posterior. A rede adquire o conhecimento a partir de seu ambiente, por meio de um processo de aprendizagem, com as forças de conexão entre neurônios, conhecidas como pesos sinápticos, sendo consideradas no armazenamento do conhecimento adquirido. (HAYKIN, 2001).

A principal característica de uma RNA é adquirir conhecimento durante o treinamento e responder satisfatoriamente a novos dados, concluindo, assim, uma generalização do problema.

As redes neurais artificiais podem ser aplicadas para a identificação e o controle de sistemas, como aproximador universal de funções, no processamento de imagem, no reconhecimento e classificação de padrões, em sistemas de previsão, como otimizador de modelos, na visão computacional, no processamento de sinais, como filtro contra ruídos eletrônicos, entre outros. *A priori*, as redes neurais podem ser aplicadas com qualquer função matemática, tendo a capacidade de modelar relações lineares e não lineares.

De acordo com Decanini (2012), as principais características das RNAs que as capacitam a um comportamento inteligente são:

- **Capacidade de generalização:** produzem resultados mesmo para casos não contidos no banco de dados de treinamento;

- **Representação distribuída do conhecimento:** o conhecimento é armazenado de forma distribuída em seus pesos, tornando-se mais tolerantes a falhas de neurônios individuais;
- **Robustez e tolerância a falhas:** mesmo que as informações a serem analisadas estejam incompletas ou com ruído, é possível obter um raciocínio correto;
- **Não necessitam de regras explícitas:** o processo de aprendizagem se dá através de exemplos;
- **Capacidade de aprendizado continuado:** determinadas redes são capazes de aprender novos cenários sem perda do conhecimento previamente adquirido;
- **Paralelismo:** produzem respostas com alto desempenho computacional.

As redes neurais podem ser divididas em três grandes categorias: *feedforward neural networks* (multicamadas), *feedback neural networks* e *cellular neural networks*. Esta pesquisa aplicou uma rede perceptron multicamadas com saídas recorrentes às entradas. Portanto, outros tipos de RNA não serão descritos no texto.

Este capítulo está organizado da seguinte forma: na Seção 3.2, apresenta-se um modelo simplificado de neurônio biológico, e um modelo matemático de um neurônio artificial inspirado no neurônio biológico é mostrado na Seção 3.3; na Seção 3.4, disserta-se rapidamente sobre as arquiteturas das redes; na Seção 3.5, discutem-se as técnicas de aprendizagem; e na Seção 3.6 é apresentada uma visão geral de rede perceptron multicamadas.

3.2 Neurônio Biológico

Todos os animais, incluindo o homem, obtêm informação sobre o seu entorno por meio de receptores sensoriais. A informação obtida pelos receptores se transforma no encéfalo em percepções ou ordens para o corpo. Respostas notáveis são obtidas exclusivamente com o uso das células nervosas e pelas conexões estabelecidas entre elas. Essa reação corporal à estimulação é denominada na Fisiologia (ramo da Biologia) como *arco reflexo*. As respostas elaboradas e interpretadas por centros nervosos superiores são chamadas de *arco reflexo central*, enquanto os reflexos de sobrevivência (por exemplo, levantar as mãos para proteger o rosto, saltar durante um susto, e retirar a mão de uma superfície quente ou

muito fria), que são respostas imediatas, sem interpretação detalhada e coordenadas pela medula espinal, são denominados de *arco reflexo periférico*.

Não obstante as células nervosas, unidades básicas do encéfalo, serem simples, o encéfalo é capaz de gerar comportamentos extremamente complexos por causa da grande quantidade de células nervosas que se comunicam por meio de interconexões específicas. Um dos descobrimentos mais importantes para a compreensão do encéfalo foi que o potencial para produzir ações complexas não está sujeito, em grande parte, à variedade das células nervosas, mas, sim, à sua quantidade e suas conexões específicas entre si e com receptores sensoriais e músculos.

A célula neural é o bloco de construção básico de todos os cérebros, onde cada neurônio atua como uma unidade de processamento simplificado. Os neurônios biológicos são compostos por um corpo, dendritos, axônios e sinapses. Na Figura 3.1, mostra-se uma visão simplificada de um neurônio biológico (real).




Figura 3.1 – Neurônio biológico.

As partes fundamentais da célula podem ser definidas como:

- **Soma** ou **corpo celular**: é a parte central de um neurônio; seu objetivo é processar as informações captadas pelos dendritos e produzir um potencial de ativação que poderá disparar um impulso elétrico. O tamanho da soma de um neurônio típico é cerca de 10 μm a 80 μm . (MÜLLER; REINHARDT; STRICKLAND, 1995). Quase todas as funções lógicas são realizadas nessa parte do neurônio.
- **Dendritos** ou **dendrites**: filamentos nervosos dos neurônios que atuam na recepção de estímulos nervosos do ambiente ou de outros neurônios e na transmissão desses

estímulos para o corpo da célula. Os dendritos representam uma árvore altamente ramificada de fibras e estão associados à soma. A palavra dendrite foi originária de *déndron* (*δένδρον*), vocábulo grego que significa árvore.

- **Sinapse:** termo originário da palavra grega *synapsis*, que significa “ação de juntar”, é a comunicação (junção) estabelecida entre um neurônio com outro(s) neurônio(s) ou com outros tecidos. A sinapse foi introduzida, em 1897, pelo neurofisiologista inglês Charles Scott Sherrington (1857-1952), Prêmio Nobel de Fisiologia ou Medicina de 1932. (SHERRINGTON, 1897, p. 929). A condução de estímulos elétricos pela membrana celular dos neurônios é unidirecional. Sendo assim, numa comunicação entre um neurônio e outra célula, observa-se a distinção entre o neurônio que faz a sinapse e o elemento subsequente. Uma sinapse não é uma ligação física. O espaço entre os elementos pré-sináptico e pós-sináptico é denominado de *fenda sináptica*, em torno de 20 nm a 50 nm. (UNAR, 1999). Na fenda sináptica é onde são liberados os mediadores químicos inibidores ou excitadores de membrana. A força de conexão sináptica entre os neurônios pode ser quimicamente alterada pelo cérebro em resposta aos estímulos do ambiente.
- **Axônio:** é uma fibra tubular longa e fina que se divide em ramos, cuja função é transmitir a atividade neuronal gerada para outros neurônios ou para fibras musculares. O seu comprimento pode variar de 100 µm a alguns metros. (ANDERSON, 1995).

O cérebro humano é um feixe de muitos bilhões de neurônios, todos fortemente interligados e operando em paralelo. Estima-se que o córtex cerebral humano contenha 10 bilhões de neurônios, que resulta em mais de 10 trilhões de sinapses. (DAMÁSIO, 1996). O comportamento do sistema nervoso real é muito complexo, e não é ainda totalmente conhecido. Por conseguinte, é quase impossível e ineficiente emular todo o comportamento de um cérebro humano. Ressalte-se que os modelos de redes neurais artificiais não são exatamente iguais aos processos realizados por neurônios reais e se baseiam apenas vagamente na biologia. As pesquisas científicas buscam constantemente aproximar o processamento das redes neurais artificiais às biológicas, na tentativa de emular a habilidade com que o cérebro humano desempenha suas funções. Afortunadamente, um grande corpo de pesquisas publicadas indica que modelos relativamente simples, que representam apenas a

maioria dos processos básicos de neurônios, podem fornecer excelentes soluções para problemas complexos e práticos.

3.3 Modelo de um Neurônio Artificial

As redes neurais artificiais (RNAs) podem ser definidas como um conjunto de múltiplas unidades interconectadas (similar à estrutura do cérebro), nomeadas de *neurônios artificiais*, cada qual contendo uma pequena amostra local de memória.

De modo análogo ao neurônio biológico, o neurônio artificial possui um ou mais sinais de entrada e apenas um sinal de saída, conforme mostrado na Figura 3.2, onde x_i , $i= 1, 2, \dots, n$, são sinais de entrada ou simplesmente entradas; w_i , $i= 1, 2, \dots, n$, se referem aos pesos sinápticos; n é o número total de entradas; y é o valor de saída produzido pelo neurônio; Σ é o combinador linear, que tem a função de agregar as entradas pelos respectivos pesos; Θ é o limiar de ativação; u é o resultado da soma entre o combinador linear e o limiar de ativação; e $f(.)$ é a função de ativação.




Figura 3.2 – Neurônio de McCulloch e Pitts.

As informações podem ser recebidas por meio de sensores ou de outros neurônios artificiais que compõem a RNA. As entradas de um neurônio artificial representam as entradas da rede, a saída de outro neurônio ou a sua própria saída. Enquanto os neurônios naturais emitem um pulso com duração de aproximadamente 1 ms, os neurônios de McCulloch e Pitts geram uma saída digital que permanece ativa até a próxima iteração da rede.

Nas camadas intermediárias, está presente o combinador linear Σ , cujo objetivo é produzir um valor de potencial de ativação a partir do somatório de todos os sinais de entrada ponderados pelos pesos sinápticos; o limiar de ativação, Θ , conhecido como *bias*, tem a função de ajustar o valor de saída do neurônio e o potencial de ativação u , que é a diferença entre o valor gerado pelo combinador linear e o limiar de ativação. A camada intermediária

equivale ao corpo celular do neurônio biológico. A função de ativação $f(\cdot)$ limita o sinal de saída do neurônio dentro de um intervalo de acordo com o tipo de função escolhido. O sinal de saída, y , é o valor de resposta resultante da função de ativação.

O neurônio artificial ilustrado na Figura 3.2 pode ser expresso, matematicamente, por:

$$y = f\left(\sum_{i=1}^n w_i \cdot x_i - b\right) \quad (3.1)$$

Os elementos x_i representam os sinais de entrada que consistem na primeira camada do neurônio artificial. Biologicamente, essa camada representa a função dos dendritos, pois essa parte do neurônio biológico é responsável por captar os estímulos do meio externo ou de outros neurônios.

Os pesos, conhecidos por *pesos sinápticos* e representados geralmente pela letra w (do inglês *weight*), representam o grau de importância que a entrada possui em relação ao neurônio. Os valores de tais pesos podem ser negativos ou positivos, dependendo de as conexões serem inibitórias ou excitatórias.

Cada entrada x_i tem o seu próprio peso w_i , em analogia às sinapses neurobiológicas. A função dos pesos consiste em ponderar a relevância de cada sinal de entrada da rede, e, dessa forma, o peso modifica o seu valor representativo para a rede (processo de aprendizagem). Tais elementos são as representações das junções sinápticas presentes no neurônio biológico. O neurônio calcula a soma de todas as entradas ponderadas. Em outras palavras, o neurônio calcula a combinação linear dos valores apresentados para as suas entradas.

O neurônio também tem a função de verificar se o campo local induzido é nulo ou positivo. Se sim, a saída de um neurônio assume o valor 1; caso contrário, o valor de saída será nulo. A Equação 3.2 descreve a propriedade do “tudo ou nada” do modelo de McCulloch e Pitts:

$$\sum_{i=1}^n w_i \cdot x_i \geq 0 \quad (3.2)$$

Essa decisão tem efeito somente para o respectivo neurônio artificial, e impõe, na prática, que a saída do neurônio somente é transferida (considerada) se o valor calculado

atingiu o limiar lógico¹¹. Em modelos mais elaborados, a função de ativação pode ter um processamento atribuído, o qual pode ser, por exemplo, o uso de um valor prévio de saída como uma entrada para o próprio neurônio, servindo de autoexcitação para ele. (TAFNER; XEREZ; RODRIGUES, 1996).

A partir do modelo proposto originalmente por McCulloch e Pitts (1943), foram derivados vários outros modelos que admitem a definição de uma saída qualquer, que não seja obrigatoriamente igual ao valor zero ou ao valor um, e com distintas funções de ativação. A etapa final é a aplicação de uma função de ativação $f(\cdot)$ à soma ponderada.

As funções de ativação podem ser classificadas em *parcialmente diferenciáveis* e *totalmente diferenciáveis*. As funções degrau, bipolar e rampa simétrica são exemplos de funções parcialmente diferenciáveis (v. Figura 3.3), enquanto as funções tangente hiperbólica, logística e gaussiana são totalmente diferenciáveis (v. Figura 3.4).




Figura 3.3 – Funções de ativação parcialmente diferenciáveis: (a) função degrau, (b) função degrau bipolar e (c) função rampa simétrica.




Figura 3.4 – Funções de ativação totalmente diferenciáveis: (a) função tangente hiperbólica, (b) função logística e (c) função gaussiana.

¹¹ Em inglês, *threshold*.

3.4 Arquitetura de uma RNA

O conjunto de vários neurônios artificiais interconectados formam as redes neurais artificiais, que são semelhantes às redes neurais biológicas. A arquitetura de uma rede neural restringe o tipo de problema no qual a rede poderá ser empregada, e é definida pelo número de camadas (camada única ou múltiplas camadas), pelo número de nós em cada camada, pelo tipo de conexão entre os nós (*feedforward* ou *feedback*) e por sua topologia. (HAYKIN, 2001). Em uma arquitetura típica, os neurônios artificiais são ligados em camadas e operam em paralelo. Os pesos ou a força da conexão entre os neurônios são adaptados durante o processo para resultar em um bom desempenho.

Os modelos baseados em redes neurais artificiais, em sua maioria, são compostos por unidades não lineares que atuam em paralelo, e são classificados de acordo com modelos ou padrões pautados na biologia. As singularidades de novas aplicações levam os pesquisadores a desenvolver novas arquiteturas de redes neurais com novos algoritmos de treinamento e estruturas de interconexões entre os neurônios. Exemplos de arquiteturas de RNA são apresentados na Figura 3.5.




Figura 3.5 – Exemplos de redes neurais artificiais.

No encéfalo, os neurônios são componentes microscópicos, organizados em enormes redes tridimensionais. Nas RNAs, as limitações computacionais e metodológicas impõem uma forte restrição ao número de camadas que a estrutura pode conter, limitando o tipo e a

finalidade de sua implementação. As redes que contêm uma única camada são aquelas que possuem um único nó entre uma entrada e uma saída da rede (v. Figura 3.6). Essa rede é indicada para problemas linearmente separáveis. Já as redes multicamadas possuem mais de uma camada entre as já existentes camadas de entrada e saída.




Figura 3.6 – Rede neural artificial de uma única camada.

Nas redes com arquitetura multicamadas (v. Figura 3.7), a primeira camada é denominada de *camada de entrada*, e é onde os valores/padrões representam os dados de entrada da RNA. Essa camada é externa, e não executa processamentos. Depois, segue-se uma camada oculta ou seguem-se mais camadas ocultas, também chamadas de *escondidas* ou *intermediárias*, as quais, como o próprio nome indica, não possuem “contato” com agentes externos à rede. As camadas ocultas permitem que a rede aprenda tarefas complexas, extraindo progressivamente características mais significativas dos padrões de entrada. Esse número de camadas é indeterminado. Essas camadas ocultas estão situadas entre a camada de entrada e a camada de saída. A camada de saída é externa, e pode conter um ou mais neurônios.

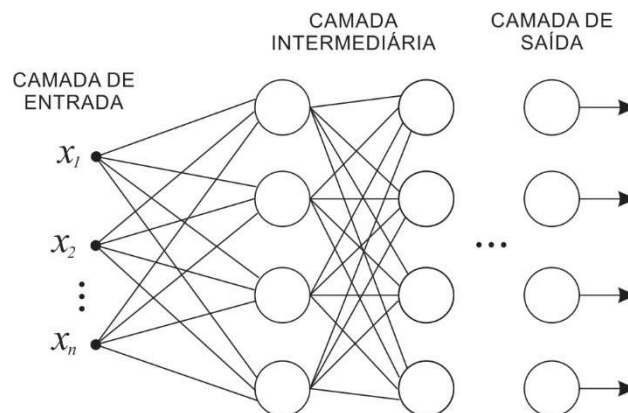


Figura 3.7 – Rede neural artificial multicamada.

Determinados modelos de redes neurais artificiais possuem muitos neurônios conectados numa estrutura de pesos de conexão, resultando em uma estrutura paralela com facilidade de adaptação. A estrutura paralela é desejável e tolerante às falhas porque, se um neurônio falhar, os efeitos na RNA não serão significativos para o desempenho se outros caminhos não falharem.

Na maioria dos casos, todos os neurônios em uma determinada camada de uma RNA contêm a mesma função de ativação; no entanto, neurônios em camadas diferentes podem ter diferentes funções de ativação. Ao se propagar através de uma rede, um sinal sempre se propaga de uma camada para a seguinte, e não para os outros neurônios na mesma camada.

Os nós que compõem a rede neural artificial podem ter conexões do tipo *feedback* ou *feedforward*. Na propagação de sinais em redes *feedforward* ou cíclicas (puramente unidirecionais), os sinais são propagados apenas da entrada para a saída, e nunca em sentido contrário (v. Figura 3.8). Se todas as ligações entre os nós são cíclicas, a rede é chamada *autoassociativa*. Esse tipo de arquitetura permite a filtragem de ruídos nas medidas, a autocorreção do sinal com falha quando o sensor apresenta um erro do tipo *desvio*¹² — definido como uma baixa taxa de variação do valor esperado do sinal no tempo — e o tratamento de falhas grosseiras, definidas como falhas drásticas no sensor. (REYES; VELLASCO; TANSCHKEIT, 2012).

A arquitetura *feedforward* ou acíclica (v. Figura 3.9) é provavelmente a arquitetura de RNA mais popular, e tem encontrado numerosas aplicações bem-sucedidas na Engenharia, em particular na área de sistemas de controle. A razão pela qual essa arquitetura é tão popular é, em parte, porque é muito fácil de implementar, não tem problemas de estabilidade (CICHOCKI; UNBEHAUEN, 1993) e possui propriedade de aproximação universal.




Figura 3.8 – Rede neural artificial *feedback* ou cíclica.

¹² Em inglês, *drift fault*.




Figura 3.9 – Rede neural artificial *feedforward* ou acíclica.

Nas conexões *feedforward*, a saída de um neurônio na i -ésima camada da rede não pode ser empregada como entrada de nós em camadas anteriores. As redes neurais artificiais *feedforward* são aplicadas, tipicamente, em modelos não lineares, e também são adotadas para o reconhecimento e classificação de padrões.

Desde o trabalho pioneiro de Rumelhart e McClelland (1986), um grande número de pesquisas sobre a aplicação de redes neurais *feedforward* foi publicado. Essas aplicações podem ser divididas em dois grandes grupos: a função de aproximação e a de classificação. Essa divisão é baseada no tipo de saída necessária para realizar as tarefas.

Uma rede neural multicamadas *feedforward* pode ser dividida em duas categorias principais: as Redes Perceptron Multicamadas (PMCs) e as Redes Neurais de Base Radial (RBFs). Conforme citado anteriormente, esta pesquisa adotou a Rede Perceptron Multicamadas, que será descrita na próxima seção.

3.5 Aprendizagem

A principal característica de uma rede neural artificial é adquirir conhecimento durante o treinamento e responder satisfatoriamente a novos dados, buscando a generalização do problema. A aplicação de RNA se inicia com o processo de aprendizagem, em que a rede procura extrair informações relevantes de padrões de informação. Uma vez que a entrada para a rede é conhecida, e as funções de ativação são definidas, as saídas são calculadas como uma função dos pesos. Assim, alterando os pesos sinápticos da rede, pode-se ajustar o processo de cálculo para a saída resultar no valor desejado.

A aprendizagem pode ser definida como:

[...] o processo pelo qual os parâmetros livres de uma rede neural são adaptados por meio de um processo de estimulação pelo ambiente no qual a rede está atuando, sendo o tipo específico de aprendizagem definido pela maneira particular como ocorrem os ajustes realizados nos parâmetros. (MENDEL; MCLAREN, 1970).

A definição clássica apresentada por Mendel e McLaren (1970) aponta que o processo de aprendizagem de RNA se dá fundamentalmente por meio dos seguintes passos: estimulação da rede neural por um ambiente; modificações nos parâmetros livres da rede como resultado do primeiro passo; nova resposta da rede neural ao ambiente, devido às modificações ocorridas em sua estrutura interna.

Para o aprendizado das RNAs, a literatura expõe vários métodos de treinamento, subdivididos em dois grandes grupos: o *aprendizado supervisionado* e o *aprendizado não supervisionado*. Os algoritmos de treinamento de RNA também podem ser classificados em *estáticos* e *dinâmicos*. Enquanto os algoritmos estáticos não modificam a estrutura da rede, variando somente os valores dos pesos sinápticos, os algoritmos dinâmicos podem reduzir ou aumentar o tamanho da rede (número de camadas, número de nós nas camadas intermediárias e número de conexões).

A grande maioria das redes neurais artificiais emprega o treinamento supervisionado. Essencialmente, o PMC é uma rede *feedforward* multicamadas que adota um mecanismo de aprendizagem supervisionado baseado no ajuste de seus parâmetros de acordo com o erro entre as saídas desejadas e as calculadas pela rede. Ou seja, o PMC adota um mecanismo que modifica os pesos das conexões da RNA a fim de minimizar o erro quadrático médio entre as saídas desejadas e as calculadas. Os pesos têm seus valores iniciais atribuídos aleatoriamente, e são ajustados, por meio do algoritmo de aprendizagem, pela rede na próxima iteração. A iteração também é chamada de *ciclo* ou *época*.

Com o aprendizado supervisionado, as redes neurais artificiais devem ser treinadas antes de, propriamente, ser empregadas. A quantidade de dados para treinamento deve estar dentro de um intervalo ideal. Se a rede for treinada com poucas informações, os pesos são atribuídos com resultados aparentemente muito bons, mas o algoritmo provavelmente se comportará satisfatoriamente em toda a gama de atuação do controlador. Ressalte-se, porém, que uma gama abrangente de dados para o treino é, geralmente, mais importante do que uma quantidade elevada.

O treinamento é considerado satisfatório quando a RNA alcança um nível de desempenho predeterminado. Esse nível significa que a rede alcançou uma precisão estatística, e os pesos, praticamente, permanecerão constantes. Alguns tipos de RNA permitem um treinamento contínuo, enquanto a planta está em operação, com uma taxa muito baixa de aprendizado. Esse processo auxilia a rede a se adaptar gradualmente às modificações no sistema.

O aprendizado supervisionado pode ser implementado de duas formas: *off-line* e *on-line*. No aprendizado *off-line*, os dados do conjunto de treinamento não se alteram, resultando em uma solução fixa. Se novos dados forem adicionados, um novo treinamento deverá ser realizado. No aprendizado *on-line*, os dados mudam continuamente, e a rede está em contínuo processo de adaptação.

O aprendizado não supervisionado é aquele que não sofre influências externas para indicar a resposta desejada para os padrões de entrada. Esse tipo de aprendizado também é conhecido como *aprendizado autossupervisionado* ou *aprendizado de auto-organização*, justamente porque são utilizados no processo apenas valores de entrada. Nele, os ajustes são realizados por meio de critérios que monitoram o desempenho interno e analisam as regularidades e/ou tendências dos sinais de entrada, e, conseqüentemente, a rede se adapta automaticamente às suas necessidades.

Esse tipo de rede utiliza os neurônios como classificadores, e os dados de entrada, como elementos para classificação. O processo de classificação é realizado pela rede neural e pelo seu algoritmo de aprendizado. Há numerosos tipos de algoritmo de aprendizado adotados no processo de aprendizagem, e que diferem entre si principalmente pelo modo como os pesos são ajustados.

O autoaprendizado característico das redes neurais não supervisionadas envolve processos de competição e de cooperação entre os neurônios. A competição entre essas unidades é a base de aprendizado da rede. Normalmente, quando ocorre a competição pelo aprendizado, somente os pesos pertencentes à unidade de processamento “vencedora” são ajustados. Muitos pesquisadores têm adotado esse tipo de rede como detector de características, dada a sua capacidade de aprender a discriminar estímulos que ocorrem em partes especialmente diferentes.

A literatura apresenta diversas leis de aprendizado, as quais, em sua maioria, são variações da técnica mais difundida, que é a *Lei de Hebb*. O estado da arte aponta que as pesquisas em torno das funções de aprendizado continuam, e buscam aproximar os modelos matemáticos dos padrões biológicos. Embora a ciência esteja muito distante de compreender completamente o processo biológico de aprendizado, diversas simplificações e morfologias matemáticas foram apresentadas com bons resultados, e continuam em pleno desenvolvimento.

As duas leis mais conhecidas e difundidas de aprendizado são a de Hebb (1949) e de Widrow e Hoff (1960). A *Lei de Hebb* foi a primeira e, indiscutivelmente, a mais conhecida

regra de aprendizado. Foi apresentada pelo biólogo e psicólogo canadense Donald Olding Hebb (1904-1985), que propôs, como base do aprendizado associativo em âmbito celular, que:

[...] quando um axônio da célula A está próximo o suficiente para excitar a célula B e repetidamente ou persistentemente toma parte em seu disparo, algum processo crescente ou alteração metabólica toma parte em uma ou ambas as células de modo que a eficiência de A como uma das células que dispara B é aumentada. (HEBB, 1949, p. 62).

Na prática, essa regra parte do pressuposto de que, se um neurônio recebe uma entrada originária de outro neurônio, e ambos estão ativos, ou seja, possuem o mesmo sinal, os pesos entre os neurônios precisam ser excitados. A formulação matemática mais simples dessa hipótese é dada por:

$$\Delta w_{ij}(t) = \alpha a_i(t) a_j(t) \quad (3.3)$$

onde $a_i(t)$ representa a atividade pós-sináptica, $a_j(t)$ representa a atividade pré-sináptica e α é a taxa de aprendizagem.

Essa regra fez surgir alguns modelos elementares de memória associativa denominados de *memória de matriz de correlação*. (NAKANO, 1972).

A *Regra Delta de Widrow-Hoff* é uma variação do princípio de aprendizado proposto por Hebb (1949). A Regra Delta foi apresentada por Widrow e Hoff em 1960 (WIDROW; HOFF, 1960), e é a mais empregada atualmente. Essa regra se baseia na simples ideia de minimizar a diferença entre o valor de saída desejado e o valor atual de saída da unidade de processamento — no caso, o neurônio artificial. Na prática, adota-se a soma dos erros (e) quadráticos de todas as saídas como parâmetro de desempenho da rede, e também como função de custo, $E(t)$, descrita por:

$$E(t) = \frac{1}{2} \sum e^2(t) \quad (3.4)$$

A função de custo pode ser visualizada como uma superfície de erro, com os parâmetros livres do sistema (pesos e *bias*) como coordenadas. Essa pode apresentar um único ponto de mínimo, quando possui somente funções de ativação lineares, ou pode apresentar vários mínimos locais, além do mínimo global, se houver nós não lineares (BRAGA; CARVALHO, A.; LUDERMIR, 1998). O objetivo é que, ao longo do treinamento, o erro parta de um ponto arbitrário da superfície e se desloque até o mínimo global. No entanto, quando há saídas não lineares, o treinamento da RNA pode-se estabilizar em uma região de mínimo local, porém com erro maior que o seu mínimo global. (FIORIN et al., 2011). Quando

se usa a Regra Delta, é importante assegurar que o conjunto de dados de entrada esteja disposto ou gerado de forma aleatória.

A velocidade com que uma rede neural artificial aprende depende de múltiplos fatores. A taxa de aprendizagem, α , influencia diretamente nas mudanças nos pesos entre as conexões dos neurônios artificiais. Taxas de aprendizagem muito pequenas (próximas de zero) implicam tempo de treinamento longo; contudo, taxas de aprendizagem elevadas podem provocar oscilações em torno da solução. (VENTURA et al., 2012).

3.6 Rede Perceptron Multicamadas

As redes perceptron foram originalmente aplicadas para a classificação de problemas que geralmente tinham imagens binárias de caracteres ou simplesmente moldes de informações, como fonte de alimentação. (BISHOP, 1995). A primeira aplicação das redes perceptron foi na simulação da retina de um olho, e que demonstrou como o sistema nervoso reconhece padrões. (TAFNER; XEREZ; RODRIGUES, 1996).

A topologia original do perceptron descrita por Rosenblatt era composta por unidades de entrada (retina), por um nível intermediário formado pelas unidades de associação e por um nível de saída formado pelas respostas. Conquanto essa topologia original possuía três níveis, esta é uma rede perceptron de uma única camada, já que somente a saída (resposta) tem propriedades adaptativas. A retina representa unidades sensoras, e as unidades intermediárias de associação têm pesos fixos, definidos antes do processo de aprendizagem. Na Figura 3.10, é mostrada a topologia do perceptron de Rosenblatt.




Figura 3.10 – Topologia do perceptron de Rosenblatt.

Não obstante ter causado grande euforia na comunidade científica da época, a perceptron “original” não teve vida muito longa, e as severas críticas de Minsky e Papert (1969) à sua capacidade computacional ocasionaram impacto sobre as pesquisas. Mas os problemas das perceptron originais foram resolvidos pelo acréscimo de uma ou mais camadas intermediárias. As redes perceptron multicamadas são RNAs que apresentam, pelo menos, uma camada intermediária. A grande popularidade da PMC deve-se à publicação, em 1986, do livro “Parallel distributed processing: explorations in the microstructure of cognition foundations”, de Rumelhart e McClelland.

A rede perceptron multicamadas é o tipo mais conhecido de rede neural *feedforward*. A literatura apresenta numerosas aplicações de RNA em quase todos os campos da ciência e da engenharia: agricultura (ABDULLAH; QUTEISHAT, 2015), geração de energia (MEMON et al., 2013), medicina (BAXT, 1992; FARIS; ALJARAH; MIRJALILI, 2016), mineração (SOOFASTAEI et al., 2016), meio ambiente (ZARE et al., 2013), química (LASHKARBLOOQI et al., 2012), reconhecimento de voz (COHEN et al., 1993; PATEL, S.; ALEX; VENKATESAN, 2015), recursos hídricos (CHOUBIN et al., 2014), robótica (KIM, Sung; LEE, J., 1996; VIDAL; ROSA; MELO NETO, 2013), saneamento (BAGHERI et al., 2015).

A estrutura típica de uma rede PMC é mostrada na Figura 3.11. Ela é constituída por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. O número de camadas ocultas e o número de neurônios em cada camada não são fixos. Cada camada pode ter um número diferente de neurônios, dependendo da aplicação. O desenvolvedor terá de determinar quantas camadas e quantos neurônios por camada deverá adotar, o que implicará diretamente a eficiência do processo de aprendizagem da rede.




Figura 3.11 – Rede PMC típica com duas camadas intermediárias (ocultas).

Segundo Ana Régia Neves (2007), o número de camadas intermediárias e de neurônios presentes deve ser projetado mantendo o compromisso com a convergência para uma solução, sem, no entanto, prejudicar a habilidade de generalização da rede neural. Alguns pesquisadores investigaram o número de camadas intermediárias necessárias para a implementação de classes de funções em uma rede neural artificial. Os resultados obtidos indicam que uma rede neural com uma camada intermediária pode aproximar qualquer função contínua, dado suficiente grau de liberdade (HORNIK; STINCHCOMBE; WHITE, 1989), e que duas camadas intermediárias são suficientes para aproximar qualquer função matemática. (CYBENKO, 1988).

Em muitas aplicações, uma única camada oculta é capaz de responder, com sucesso, aos mais variados problemas, conforme demonstrado em diferentes pesquisas apresentadas na literatura — *e.g.*, Abdullah e Quteishat (2015); Anzy Lee, Geem e Suh (2016); Memon et al. (2013) e Salam et al. (2016). Holger Maier e Graeme Dandy (2000) afirmaram que redes com uma camada oculta foram utilizadas na maioria dos estudos de casos publicados.

Estudos demonstram que uma rede com mais de uma camada pode fornecer maior flexibilidade e permitir aproximações de funções complexas com menos conexões. (FLOOD; KARTAM, 1994). Mas a utilização de um grande número de camadas intermediárias não é recomendada, pois, quando o erro medido durante o treinamento é propagado para a camada anterior, o desempenho do sistema é prejudicado. A última camada intermediária recebe apenas uma estimativa sobre o erro; a penúltima camada intermediária, uma estimativa da estimativa; e assim por diante. A única camada que tem uma noção precisa do erro cometido pela rede é a camada de saída.

A quantidade de neurônios que compõem as camadas intermediárias é definida empiricamente, e, normalmente, depende da distribuição dos padrões de treinamento e da validação da rede. O uso excessivo de neurônios poderá resultar em uma RNA limitada ao padrão das características do conjunto de treinamento, em vez de extrair as características generalistas. Todavia, um número pequeno de neurônios induzirá a rede a aumentar o tempo de treinamento, dificultando a representação do problema. Nesse caso, alguns neurônios poderão ficar sobrecarregados por possuírem um número elevado de restrições a serem analisadas.

Geralmente, uma rede PMC tem um número diferente de neurônios e diferentes pesos sinápticos para diferentes camadas. Todos os neurônios da(s) camada(s) oculta(s)

possuem não linearidades, que podem ser representadas por uma função logística (Equação 3.5) ou por uma função tangente hiperbólica (Equação 3.6).

$$y_i = \frac{1}{1 + \exp(-u_i)} \quad (3.5)$$

$$y_i = a \tanh b(u_i) \quad (3.6)$$

onde u_i é o nível de atividade interna do neurônio; y_i é a saída do neurônio; a e b são constantes.

Geralmente, uma rede PMC aprende mais rápido com uma função tangente hiperbólica do que com uma função logística. (HAYKIN; LIPPMANN, 1994). Os neurônios da camada de saída também podem ter a mesma função de ativação, como os neurônios ocultos. No entanto, muitas aplicações utilizam uma função linear, tal como a função de ativação dos neurônios da camada de entrada.

Mais de uma centena de diferentes algoritmos de aprendizado estão disponíveis, sendo mais popular o *algoritmo de retropropagação* (ABDULLAH; QUTEISHAT, 2015) e suas variações. O algoritmo representa um marco na RNA, pois fornece um método computacionalmente eficiente para a formação de redes PMCs, e foi um dos principais responsáveis pelo ressurgimento do interesse em RNAs por ocasião da publicação de Rumelhart e McClelland (1986).

A técnica de retropropagação é um algoritmo supervisionado que emprega pares entrada/(saída desejada) para, por meio de um mecanismo de correção de erros, ajustar os pesos da rede. O algoritmo também é chamado de *Regra Delta Generalizada*, pois é baseado na Regra Delta apresentada por Widrow e Hoff (1960). O treinamento ocorre em duas fases, em que cada fase percorre a rede em um sentido. Essas duas fases são chamadas de fase *forward* e fase *backward*. A fase *forward* é empregada para definir a saída da RNA para um dado padrão de entrada, enquanto a fase *backward* adota a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões.

CAPÍTULO 4

MATERIAIS E MÉTODOS

Propõe-se, nesta pesquisa, uma rede neural artificial para o controle de pressão em redes de distribuição de água e para o aumento da eficiência energética de sistemas de bombeamento que operam com bombas associadas em paralelo. A fim de testar o sistema de controle desenvolvido, foi projetada e implantada uma bancada experimental de distribuição de água (com exceção do reservatório circular) totalmente instrumentalizada, capaz de emular o bombeamento em diversas configurações e/ou cenários, além de permitir o monitoramento dos parâmetros hidráulicos, característicos de redes hidráulicas (pressão e vazão), e dos parâmetros elétricos de motores (tensão, potência e corrente elétrica).

O arranjo experimental emula um sistema de distribuição de água que opera com bombeamento direto para a rede hidráulica, devendo este atender à vazão com a manutenção da pressão no ponto de medição dentro de uma faixa preestabelecida. Determinaram-se também quantos conjuntos motor-bomba devem ser acionados simultaneamente, uma vez que, devido à variação da demanda, em algumas condições será mais eficiente o acionamento de apenas uma bomba.

4.1 Sistema Experimental

A bancada experimental (v. Figura 4.1) é composta de um reservatório circular de $7,64 \text{ m}^3$, dois conjuntos motor-bomba (PUMP), dois inversores de frequência, uma válvula de controle (CV), cinco transdutores de pressão (o transdutor responsável pela medição da variável controlada está identificado na Figura 4.1 por PT), dois transdutores de vazão (FT), uma fonte de alimentação, além das instalações elétricas e eletrônicas, e conexões e tubos de PVC (DN 50, DN 75 e DN 100) da rede hidráulica. Também foram empregados nos ensaios experimentais um computador portátil e uma interface de aquisição de dados.

O sistema de bombeamento é responsável pelo fornecimento de energia hidráulica ao sistema experimental na forma de vazão e pressão. Os conjuntos motor-bomba adotados são monoblocos, constituídos de um motor de indução trifásico e uma bomba Dancor, modelo CAM-W10, instalados em uma cota inferior ao nível do reservatório (“afogada”). As bombas são centrífugas, monoestágio, com altura de sucção máxima de 6 metros, diâmetro do rotor de 162 mm, altura manométrica máxima de 45 mca, vazão máxima de $12 \text{ m}^3/\text{h}$. As principais

características dos motores são fornecidas na Tabela 4.1. Na Figura 4.2, apresenta-se um conjunto motor-bomba do tipo adotado no sistema experimental.




Figura 4.1 – Sistema experimental de distribuição de água.

Tabela 4.1 – Principais características dos motores.

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



Figura 4.2 – Conjunto motor-bomba modelo CAM-W10.
(Fonte: <http://www.lojatropicalrio.com.br>).

Na Figura 4.3, mostram-se as curvas características da bomba fornecidas pelo fabricante, enquanto na Figura 4.4 são apresentadas as curvas características determinadas experimentalmente.




Figura 4.3 – Curvas características da bomba CAM-W10.
(Fonte: <http://www.dancor.com.br>).

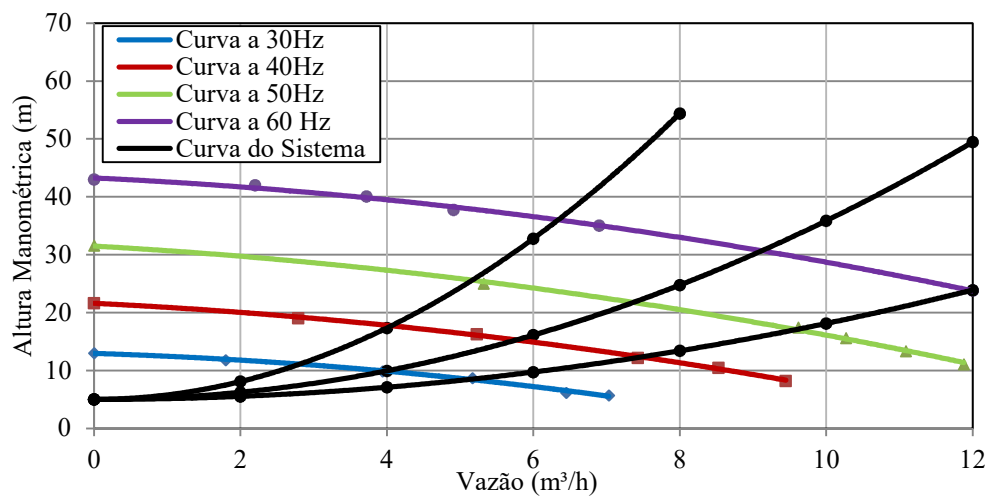


Figura 4.4 – Curvas características das bombas do sistema experimental.

Os inversores de frequência são responsáveis pela variação e controle da velocidade de rotação dos motores, alterando o ponto de operação das bombas. Foi instalado um inversor de frequência para cada conjunto motor-bomba. Os inversores são modelo CFW-11, do fabricante WEG, com tecnologia PWM (modulação por largura de pulso), alimentação trifásica 380/480 Vca, corrente nominal de 16 A, frequência da tensão de alimentação 50/60 Hz, e frequência de saída variável de 0 a 300 Hz. Os dispositivos semicondutores (transistores de potência) neles adotados são do tipo IGBT (transistor bipolar com porta isolada).

Na Figura 4.5, é mostrado um inversor de frequência idêntico ao utilizado na bancada experimental.



Figura 4.5 – Inversor de frequência CFW-11.
(Fonte: <http://ecatalog.weg.net>).

Os inversores de frequência também foram usados para medir e monitorar as grandezas elétricas de entrada e de saída do conjunto inversor mais motor elétrico (potência, corrente, tensão, fator de potência e distorção harmônica). Todas as grandezas foram medidas em “valor eficaz” (*true rms*).

As definições e alterações nas condições de operação são realizadas pelo sistema de controle por meio da interface de aquisição de dados (DAQ), a qual envia um sinal de tensão entre 0 e 10 V para os inversores de frequência. A relação entre o sinal e a frequência de acionamento é linear. Quando o sinal emitido for de 0 V significa que a velocidade de rotação do motor é zero; se o sinal de tensão emitido for igual a 10 V, o motor opera com frequência de 60 Hz, que corresponde à velocidade de rotação nominal (3450 rpm).

A válvula de controle tem a função de emular experimentalmente a variação de demanda de um sistema de distribuição de água. A variação dessa demanda ocorre com a mudança no ângulo de abertura da válvula. O componente utilizado é do modelo ARN24-SR,

do fabricante BELIMO (v. Figura 4.6). A válvula é proporcional, tipo esfera, acionada por um motor elétrico que é alimentado por uma tensão de alimentação de $24 V_{ca} \pm 20\%$ ou $24 V_{cc} \pm 10\%$ e torque de 20 Nm. O ângulo de fechamento varia de 0° a 90° (podendo ser ajustado mecanicamente), e a pressão máxima de operação é 140,62 mca.



Figura 4.6 – Válvula de controle ARB24-SR.
(Fonte: <http://webmercato.com.br>).

A válvula acrescenta perda de carga à rede hidráulica. Quanto menor for a perda de carga, menor será a altura manométrica das bombas e, conseqüentemente, maior a vazão fornecida ao sistema. O ângulo de fechamento real (retroalimentação da posição) *versus* o sinal de controle foi examinado experimentalmente.

Foram utilizados nesta pesquisa cinco transdutores de pressão modelo Druck PTX 7217 (v. Figura 4.7). O primeiro transdutor foi instalado a montante da válvula de controle para representar a pressão de serviço atuante no sistema de distribuição de água. Os demais transdutores foram dispostos a montante e a jusante dos conjuntos motor-bomba para o cálculo da altura manométrica de cada bomba. Os transdutores de pressão são do tipo piezorresistivo de silício, cujas principais características são mostradas na Tabela 4.2.



Figura 4.7 – Transdutor de pressão Druck PTX 7217.
(Fonte: <http://www.davis.com>).

Tabela 4.2 – Características dos transdutores de pressão Druck PTX 7217.

Fabricante	General Electric
Faixa de medição	0 a 42,18 mca
Sinal de saída	4 a 20 mA
Tempo de resposta	1 ms
Precisão	± 0,2% (fundo de escala)
Tensão de alimentação	24 V

Os dois transdutores de vazão eletromagnéticos (v. Figura 4.8) foram instalados a jusante de cada conjunto motor-bomba, respeitando os trechos retos de medição (comprimento mínimo de trecho reto, sem singularidades, a montante e a jusante do medidor) exigidos pelo fabricante. Na Tabela 4.3 são mostradas as propriedades desse equipamento.



Figura 4.8 – Medidor de vazão eletromagnético VMS Pro.
(Fonte: www.incontrol.ind.br).

Tabela 4.3 – Principais propriedades do transdutor de vazão eletromagnético VMS 038.

Fabricante	Incontrol
Tensão de alimentação	24 V
Sinal de saída	4 a 20 mA
Vazão mínima	1,24 m ³ /h
Vazão máxima	40,8 m ³ /h

As curvas de pressão *versus* ângulo de fechamento da válvula são apresentadas nas Figuras 4.9 a 4.12 para as frequências de 30 e 60 Hz. O sistema foi avaliado com apenas uma bomba em operação e com dois conjuntos, simultaneamente.

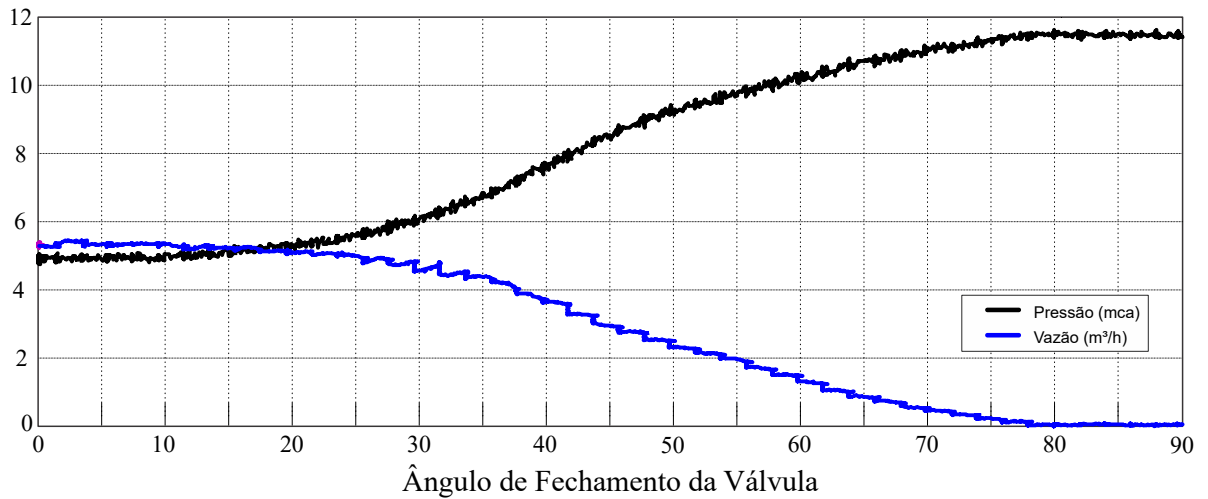


Figura 4.9 – Variação do ângulo de fechamento da válvula *versus* a pressão para o conjunto PUMP-1 em operação com frequência de 30 Hz.




Figura 4.10 – Variação do ângulo de fechamento da válvula *versus* a pressão para o conjunto PUMP-1 em operação com frequência de 60 Hz.




Figura 4.11 – Variação do ângulo de fechamento da válvula *versus* a pressão para os conjuntos PUMP-1 e PUMP-2 associados em paralelo, com frequência de 30 Hz.




Figura 4.12 – Variação do ângulo de fechamento da válvula *versus* a pressão para os conjuntos PUMP-1 e PUMP-2 associados em paralelo, com frequência de 60 Hz.

Avaliando a pressão nos gráficos das Figuras 4.9 a 4.12, observa-se que, entre 78° e 90°, a válvula está praticamente fechada, e, no intervalo de 0° a 16°, a válvula está praticamente aberta (perda de carga se aproxima de zero). Essa análise foi imprescindível para a definição das vazões mínima e máxima adotadas nos ensaios.

O sistema de aquisição de dados é composto de um computador portátil equipado com um processador *Intel® Core™ i3* de 2,27 GHz, com 4 GB de RAM, sistema operacional *Windows 7 de 64 bits* e uma interface de aquisição de dados (DAQ). A DAQ adotada é a USB-6229, fabricada pela *National Instruments*, que possui 32 entradas analógicas e 4 saídas analógicas, com taxa de transferência de 1,25 MS/s para as entradas e de 2,86 MS/s para as saídas, e as tensões elétricas variam entre -10 e +10 Vcc.

O programa computacional utilizado para o gerenciamento do sistema foi o LabVIEW™ – *Laboratory Virtual Instruments Engineering Workbench*, que utiliza uma linguagem de programação desenvolvida pela *National Instruments*. O LabVIEW™ é diferente das usuais linguagens de programação porque utiliza linguagem gráfica conhecida como *Linguagem G* e tem um compilador gráfico aperfeiçoado para maximizar o desempenho dos sistemas, em vez de utilizar linhas de código. O fato de ser totalmente compatível com a DAQ (v. Figura 4.13) e a facilidade para processar, armazenar e analisar os dados foram imperativos para a sua escolha na pesquisa. Os programas gerados no LabVIEW™ são chamados de *instrumentos virtuais*, porque possuem a aparência e as operações que emulam equipamentos reais. (BEZERRA, 2009, p. 77).



Figura 4.13 – Interface de aquisição de dados NI USB-6229.
(Fonte: <http://www.ni.com>).

4.2 Sistema de Controle

Devido à complexidade do funcionamento de um sistema de abastecimento de água e a ampla pesquisa na área de sistemas de controle que utilizam redes neurais artificiais (RNAs), este foi o tipo de controlador adotado para automatizar a bancada experimental em estudo.

A técnica adotada para o controle do sistema experimental permitiu o desenvolvimento de um controlador sem o conhecimento prévio do modelo matemático da planta. O controlador atua na definição das frequências da tensão de alimentação dos conjuntos motor-bomba associados em paralelo, visando ao controle de pressão no ponto de medição do sistema de distribuição de água.

Para o controle do sistema experimental descrito, foi desenvolvido um *software* supervisório no LabVIEW™, cuja interface é apresentada na Figura 4.14. O programa de gerenciamento adota um conceito de linguagem de programação gráfica desenvolvida pela *National Instruments*, denominada de *Linguagem G*. Foram desenvolvidas aplicações que agrupam tarefas como aquisição de dados, análise e operações lógicas, além de acompanhar *on-line* o comportamento dos dados. A linguagem possui um fluxo de dados cujos nós (operações ou funções) operam sobre os dados assim que eles estejam disponíveis, o que pode ser considerado mais eficiente para o controle de processos do que a programação tradicional por linhas de código. A distribuição do “fluxo” de dados graficamente é realizada por meio das ligações que conectam a saída de um nó à entrada de outro nó.




Figura 4.14 – Supervisório da Bancada Experimental.

O supervisório permitiu automatizar a operação do sistema, a operação manual, a aquisição e o salvamento dos dados dos ensaios, a alteração das condições de operação da bancada (*e.g.*, ativação ou não de atuadores) e o ajuste dos parâmetros neurais do controlador. O código completo do programa utilizado na pesquisa está descrito no Apêndice A.

As ferramentas desenvolvidas no LabVIEW® possibilitam que o supervisório apresente a visualização das variáveis de estado (pressão, vazão, potência e o consumo específico de energia) e das variáveis de controle (frequência da bomba e o ângulo de fechamento da válvula proporcional). Foi desenvolvida uma sub-rotina para salvar os dados experimentais no formato de arquivo de texto compatível com os *softwares* Excel® e MATLAB®.

O sistema supervisorio possui oito entradas e três saídas analógicas. As entradas analógicas recebem o sinal dos cinco transdutores de pressão, dos dois medidores de vazão e da retroalimentação do ângulo de fechamento da válvula proporcional. As saídas analógicas são utilizadas para variar a posição de abertura da válvula e a frequência da tensão de alimentação dos motores elétricos.

O sistema de controle desenvolvido foi responsável pela definição e controle das ações referentes à velocidade de rotação (frequência de alimentação de tensão) dos conjuntos motor-bomba e a determinação de quantos motores devem operar, simultaneamente, ao longo dos ensaios. A rede de neurônios artificiais (RNA) adotada possui arquitetura *feedforward* multicamadas, denominada de rede perceptron multicamadas. Na Figura 4.15, apresenta-se o diagrama de blocos do Sistema de Controle.




Figura 4.15 – Diagrama de Blocos do Sistema de Controle.

Não obstante a variação de demanda em sistemas de abastecimento de água ser lenta, da ordem de dezenas de minutos ou horas, os ensaios foram realizados com tempos totais da ordem de segundos. Na prática, avaliar o uso da RNA na planta experimental com a variação de demanda ocorrendo num intervalo de tempo relativamente menor representa uma condição de operação mais crítica do que a dos sistemas reais.

Foram realizados quatro tipos de experimentos diferentes, a fim de avaliar o desempenho do sistema de controle e a eficiência energética. Os critérios de avaliação do sistema de controle são o *tempo de subida*, o *tempo de assentamento*, o *sobressinal* e o *erro de regime permanente*.

O tempo de subida¹³ é o tempo necessário para o sinal de saída (resposta do sistema) variar de 10% a 90%, 5% a 95% ou 0% a 100% do seu valor final. Nesta pesquisa, foi considerado o intervalo de 0% a 100%.

O tempo de assentamento¹⁴ é definido como o tempo para a variável controlada alcançar e permanecer dentro da faixa aceitável (valor de referência \pm erro estacionário). A faixa de acomodação recomendada na literatura varia de $\pm 2\%$ a $\pm 5\%$. Foi adotado o valor de $\pm 3\%$ da amplitude do sinal de referência.

O sobressinal¹⁵ é a diferença entre o valor máximo atingido pela variável controlada e o valor de referência¹⁶. O erro de regime permanente, também chamado de *erro de estado estacionário*, é a diferença entre a entrada e a saída para uma determinada entrada. Geralmente, o erro de regime permanente é um parâmetro de entrada, enquanto o tempo de assentamento e o sobressinal são parâmetros de saída.

Para avaliar a eficiência energética do sistema experimental, com a atuação e sem a atuação do controlador, foi medida *on-line* a potência consumida e calculado o índice de Consumo Específico de Energia Elétrica (CE). O CE é um indicador amplamente utilizado na literatura, e é definido como a relação entre o consumo de energia (kWh) do sistema de bombeamento e o volume bombeado (m^3) num determinado tempo (v. Equação 4.1). Esse indicador é o principal parâmetro para a avaliação da operação de sistemas de bombeamento, pois permite ponderar o impacto de ações de eficiência na qualidade destes (BEZERRA et al., 2015), sendo dado por:

$$CE = \frac{E}{V} \quad (4.1)$$

onde:

E é a energia consumida no tempo t , em kWh; e

V é o volume bombeado no tempo t , em m^3 .

4.3 Modelagem da RNA

A rede de neurônios artificiais adotada possui arquitetura *feedforward* multicamadas, denominada de rede perceptron multicamadas. O método de aprendizagem adotado na

¹³ Em inglês, *rise time*.

¹⁴ Em inglês, *settling time*.

¹⁵ Em inglês, *overshoot*.

¹⁶ Em inglês, *setpoint*.

pesquisa é baseado na metodologia da retropropagação do erro¹⁷, que possui uma aprendizagem dinâmica.

Para uma RNA ser considerada dinâmica, é preciso que possua memória. (ELMAN, 1990). Existem basicamente dois modos de prover memória a uma RNA. O primeiro modo é introduzir um atraso no tempo; técnica adotada nos métodos *Time Delay Neural Network* e *FIR Multilayer Perceptron*. O segundo modo, abordado neste trabalho, é o emprego de RNAs recorrentes, tais como retropropagação através do tempo, aprendizagem recorrente em tempo real, correlação em castata recorrente,¹⁸ Rede de Jordan¹⁹ e Rede de Elman²⁰. (CARVALHO et al., 1998).

A configuração recorrente permite que a RNA recupere respostas passadas a partir da retroalimentação dos sinais produzidos em instantes anteriores. A arquitetura adotada nesta pesquisa é conhecida como Rede de Elman (ELMAN, 1990), onde apenas os sinais de saída da rede são retroalimentados às suas entradas. Esse tipo de RNA foi selecionado como estimador do comportamento da planta porque possui boa aplicabilidade na área de sistemas de controle.

O procedimento para o desenvolvimento da rede PMC resume-se a:

1. Definição do número de camadas intermediárias;
2. Definição do número de neurônios da camada intermediária;
3. Geração de dados aleatórios para os pesos da rede neural;
4. Execução do algoritmo de operação com aprendizagem em tempo real;
5. Verificação do índice de desempenho. Se este for superior a zero, aplica-se uma metodologia de cálculo para a atualização das matrizes de peso, denominada de *propagação retroativa do erro*.

Na Figura 4.16, apresenta-se a arquitetura final da RNA proposta. Adotou-se uma única camada intermediária para a rede neural, que foi capaz de uma boa aproximação universal. Ressalte-se que a seleção apropriada da estrutura da rede neural é imprescindível para uma aplicação bem-sucedida.

¹⁷ Em inglês, *error backpropagation*.

¹⁸ Em inglês, *Backpropagation Through Time* (BPTT), *Real-Time Recurrent Learning* (RTRL) e *Recurrent Cascade Correlation* (RCC), respectivamente.

¹⁹ Proposta em 1986 por Michael Irwin Jordan (n. 1966), cientista de computação norte-americano.

²⁰ Proposta em 1990 por Jeffrey Locke Elman (n. 1948), psicolinguista norte-americano.

Como o objetivo da rede PMC é controlar a pressão em redes de distribuição de água, os sinais de entrada empregados foram: a própria variável de controle — pressão (PT) — e as variáveis que influenciam diretamente a variável controlada — a soma das vazões aduzidas (FT), ângulo da válvula proporcional (CV), que controla a demanda, e o atraso das frequências de alimentação dos motores (PUMP-01 e PUMP-02). Desse modo, a arquitetura da rede neural PMC desta investigação é composta por cinco entradas e duas saídas (v. Figura 4.16).




Figura 4.16 – Arquitetura da rede neural artificial PMC.

O $bias_{\Theta}$, da RNA, foi 1 (um), e a função de ativação escolhida foi a tangente hiperbólica para os neurônios da camada intermediária, e função linear para os neurônios das camadas de entrada e de saída. Essas funções de ativação foram atribuídas com base em diversas pesquisas da literatura, que apontam para um baixo tempo de aprendizagem e bons índices de desempenho.

A escolha dos dados de treinamento tem uma forte influência no êxito do sistema de controle, uma vez que a RNA é “ensinada” a ter a mesma resposta da relação de entrada/saída

determinada com os dados de treino. Apesar de os resultados da aplicação da RNA não poderem ser mais precisos do que os encontrados com os dados de treinamento, pois o treinamento não abrange todas as possíveis relações *input/output* futuras, a escolha dos dados foi determinada de modo que o treinamento abrangesse o universo de operação da planta. A grande vantagem da RNA deve ser a capacidade de generalização, que torna possível obter bons resultados mesmo para entradas para as quais uma rede neural não tenha sido treinada.

A RNA proposta foi treinada a partir de dados de entrada e saída medidos diretamente na bancada experimental. O treinamento foi realizado ativando a RNA e operando a planta de forma manual, ou seja, tanto as bombas quanto a válvula de controle sofreram alterações predefinidas, de modo que esses dados fossem assimilados pelo algoritmo de aprendizado.

O conjunto de dados adotados nos treinamentos foi relativamente pequeno. Os resultados demonstraram que, no caso do arranjo experimental, não é necessário uma grande amostra para que o sistema de controle tenha um desempenho global satisfatório. A RNA desta pesquisa usou o aprendizado *on-line*, e o treinamento do sistema experimental foi realizado em um tempo de, aproximadamente, 30 segundos. Basicamente, os valores de saída da rede neural foram comparados, em tempo real, com os valores desejados. Os pesos sinápticos foram atribuídos aleatoriamente, e ajustados, por meio do algoritmo de aprendizagem, pela RNA.

O número de neurônios da camada intermediária e o coeficiente de aprendizado, α , foram 10 e 0,1, respectivamente. Ambos os valores foram determinados experimentalmente por tentativa e erro. Ressalte-se que cada processo e/ou planta requer uma RNA na medida certa. Redes neurais com muitas camadas intermediárias e neurônios são indicadas para sistemas muito complexos. Diante disso, se o sistema não possuir complexidade compatível com a rede, o tempo de convergência será enorme, o que inviabiliza o controle. Todavia, se o número de neurônios for baixo, a rede neural será instável, e não controlará a planta.

A primeira fase do algoritmo de propagação retroativa do erro, propriamente dita, é denominada de *propagação adiante*²¹, e é responsável pela definição da saída da rede neural. Esta fase envolve os passos seguintes.

Cada neurônio da camada de entrada, A (v. Figura 4.16), possui uma função de ativação linear descrita por:

²¹ Em inglês, *forward propagation*.

$$y_a = x_a \quad (4.2)$$

A variável de entrada dos neurônios da camada intermediária, B (v. Figura 4.16), é resultante desta equação:

$$x_b = \sum y_a \cdot w_{ab} \quad (4.3)$$

onde w_{ab} é a matriz de pesos entre a camada de entrada e a camada intermediária.

O valor de saída de cada neurônio da camada intermediária é calculado pela seguinte equação:

$$y_b = f(x_b) + \Theta \quad (4.4)$$

onde $f(\cdot)$ é a função de ativação do tipo tangente hiperbólica definida pela Equação 4.5 e Θ é o *bias* cujo valor foi definido como 1 (um).

$$f(x_b) = \frac{1 - \exp(-\beta x_b)}{1 + \exp(-\beta x_b)} \quad (4.5)$$

A entrada da camada de saída, C (v. Figura 4.16), é dada por:

$$x_c = \sum y_b \cdot w_{bc} \quad (4.6)$$

onde w_{bc} é a matriz de pesos sinápticos que ligam os neurônios da camada intermediária aos neurônios da camada de saída.

O sinal de saída da RNA é dado por:

$$y_c = x_c \quad (4.7)$$

Ao final desta fase, existe uma comparação entre o sinal de saída calculado pela rede neural, y_c , e o valor desejado, y_d , resultado esse que gera o valor do erro, e , dado por:

$$e = y_c - y_d \quad (4.8)$$

A segunda etapa do algoritmo é chamada de *retropropagação*. É nesta fase que são atualizadas as matrizes de pesos w_{bc} e w_{ab} . O método de cálculo utilizado nesta etapa foi o método do Gradiente Descendente desenvolvido por William Press et al. (1990).

Após a comparação entre a resposta calculada pela rede neural e a resposta desejada, atualiza-se a matriz de pesos w_{bc} utilizando a Equação 4.9:

$$(w_{bc})_{t+1} = (w_{bc})_t + \alpha \cdot [E \cdot w_{bc} \cdot y_b] \quad (4.9)$$

onde $(w_{bc})_{t+1}$ é a matriz de peso a ser calculada; $(w_{bc})_t$ é a matriz de peso atual, e α é a taxa de aprendizagem igual a 0,1.

O ajuste do valor do *bias* é dado por:

$$\Theta_{t+1} = \Theta_t + \alpha \cdot \left[E \cdot w_{bc} \cdot \frac{x_b}{2} (1 - y_b^2) \right] \quad (4.10)$$

A matriz de pesos entre a camada intermediária e a camada de entrada é ajustada através desta equação:

$$(w_{ab})_{t+1} = (w_{ab})_t + \alpha \cdot \left[E \cdot w_{bc} \cdot \frac{\Theta_t}{2} (1 - y_b^2) \cdot x_a \right] \quad (4.11)$$

Após a finalização do ajuste da matriz de pesos sinápticos, acaba a primeira iteração (época). Se, após esse ajuste, o valor de saída divergir do valor desejado, este será inserido como entrada na próxima iteração. Isso fará com que os pesos sejam reajustados, e essa diferença será reduzida a cada época.

Como citado anteriormente, no final de cada iteração da rede neural, a informação de frequência do conjunto motor-bomba é armazenada e torna-se a entrada na iteração seguinte (v. Figura 4.16).

Desse modo, o método de aprendizado minimizou o fluxo corrente de erros de todos os elementos em processamento. Essa redução global de erros modificou continuamente os pesos até que a RNA alcançou o critério de parada, ou seja, o treinamento foi considerado completo quando a rede neural alcançou um determinado nível de desempenho.

CAPÍTULO 5

RESULTADOS E DISCUSSÃO

Neste Capítulo, são apresentados os resultados dos experimentos realizados, a fim de validar o sistema de controle proposto. São eles:

✓ **Experimento Tipo 1** – Ensaio em malha fechada com entrada tipo degrau igual a 15, 25 e 35 mca para o sistema experimental em operação com a vazão mínima.

✓ **Experimento Tipo 2** – Ensaio em malha fechada com uma entrada tipo degrau igual a 10 mca para o sistema experimental em operação com vazão máxima.

✓ **Experimento Tipo 3** – Ensaio em malha aberta com a válvula proporcional variando seu fechamento de forma a emular a variação de demanda de sistemas de abastecimento de água. Excepcionalmente para este conjunto de experimentos, a frequência de alimentação dos motores foi igual a 60 Hz.

✓ **Experimento Tipo 4** – Ensaio em malha fechada com a válvula proporcional variando seu fechamento de forma a emular a variação de demanda de sistemas de abastecimento de água.

Foram realizados diversos testes, constatando-se que as respostas seguem, em cada experimento, um mesmo padrão.

5.1 Experimento Tipo 1

O Experimento Tipo 1 demonstra a atuação da rede neural artificial quando a vazão aduzida pelo sistema experimental é mínima. A fim de verificar a eficiência do controlador desenvolvido, foram realizados neste Experimento três ensaios com diferentes valores de degrau na entrada de referência (*setpoint*) e de distúrbios. Os valores de referência para a variável de controle (pressão) dos Ensaios 1, 2 e 3 foram iguais a 15, 25 e 35 mca, respectivamente.

A RNA definiu a frequência de alimentação dos motores e determinou quantos motores devem operar, simultaneamente, ao longo dos ensaios. O processo de tomada de decisão do algoritmo foi baseado, prioritariamente, no controle das pressões e, em seguida, na eficiência energética do sistema (Consumo Específico de Energia Elétrica).

Os ensaios foram realizados com o conjunto motor-bomba partindo do repouso (frequência igual a zero) e com ângulo de fechamento da válvula proporcional igual a 60° , o que corresponde à demanda mínima. Com esse procedimento, foram obtidos os critérios de avaliação do sistema de controle — tempo de subida, tempo de assentamento, sobressinal e erro de regime permanente —, que são apresentados resumidamente na Tabela 5.1. O tempo de assentamento considerou uma faixa de acomodação de $\pm 3\%$ da amplitude do sinal de referência. Os resultados demonstram a robustez do sistema, que apresentou resultados satisfatórios para os diversos valores de referência (*setpoints*). Na Figura 5.1, apresenta-se o comportamento da variável de controle de pressão para os Ensaios 1, 2 e 3.

Tabela 5.1 – Critérios de avaliação do sistema de controle.

ID Ensaio	Tempo de subida (s)	Tempo de assentamento (s)	Sobressinal (mca)	Erro médio (%)
1	4,6	4,6	–	2,00
2	4,2	4,2	–	2,00
3	3,0	3,0	–	1,71




Figura 5.1 – Comportamento da variável de controle (pressão) – Experimento Tipo 1.

O sistema de controle apresentou uma resposta bastante satisfatória, pois conseguiu atingir o valor de pressão desejado com um tempo de assentamento relativamente baixo. Observa-se nos gráficos da Figura 5.1 que as respostas do sistema de controle não apresentaram sobressinal e que o tempo de subida de 0% a 100% da amplitude do sinal de

referência foi inferior a 9 segundos em todos os ensaios. Por se tratar de dados experimentais, os resultados não foram submetidos a tratamentos estatísticos. Portanto, os valores apresentados correspondem aos coletados pelos equipamentos (medidores).

Na Figura 5.2, mostra-se o comportamento das variáveis de saída — frequências de alimentação de tensão dos motores — para os ensaios. Nos Ensaios 1 e 2, apenas o conjunto PUMP-01 esteve em operação, pois a pressão de referência imposta ao controlador não é, em termos relativos, alta. No Ensaio 3, o sistema de controle determinou o acionamento do conjunto PUMP-02 porque somente uma bomba não é suficiente para satisfazer a exigência de pressão predeterminada, igual a 35 mca. Os ensaios demonstraram que, quanto maior a pressão requerida, maior a frequência de acionamento dos motores, conforme o esperado. No sistema em regime permanente, as duas variáveis de saída — velocidades de rotação das bombas — permanecem constantes, tendo em vista a não existência de perturbações no sistema de bombeamento.




Figura 5.2 – Comportamento da frequência de acionamento dos motores – Experimento Tipo 1.

O controle também repercutiu na minimização dos transientes hidráulicos e na redução da corrente de partida dos conjuntos motor-bomba. Nos demais testes realizados, a variável pressão apresentou o mesmo padrão de comportamento. O erro de regime permanente máximo dos Ensaios 1, 2 e 3 foi de 2,9% (0,45 mca), sem transitórios. As curvas do erro de regime permanente do experimento são apresentadas na Figura 5.3.

Um sistema de controle é considerado robusto quando é capaz de manter a estabilidade do sistema mesmo quando submetido a distúrbios. Para promover distúrbios no sistema experimental, foi fechado bruscamente o registro tipo globo, localizado a jusante da válvula proporcional. Observa-se na Figura 5.4 que, no instante 12,5 segundos, foi provocado um distúrbio no sistema experimental, e o controlador manteve, após o distúrbio, as mesmas

condições operacionais anteriores, restabelecendo rapidamente a pressão no valor desejado. Na Figura 5.5, apresenta-se o comportamento das variáveis de saída — frequências de alimentação de tensão dos motores.

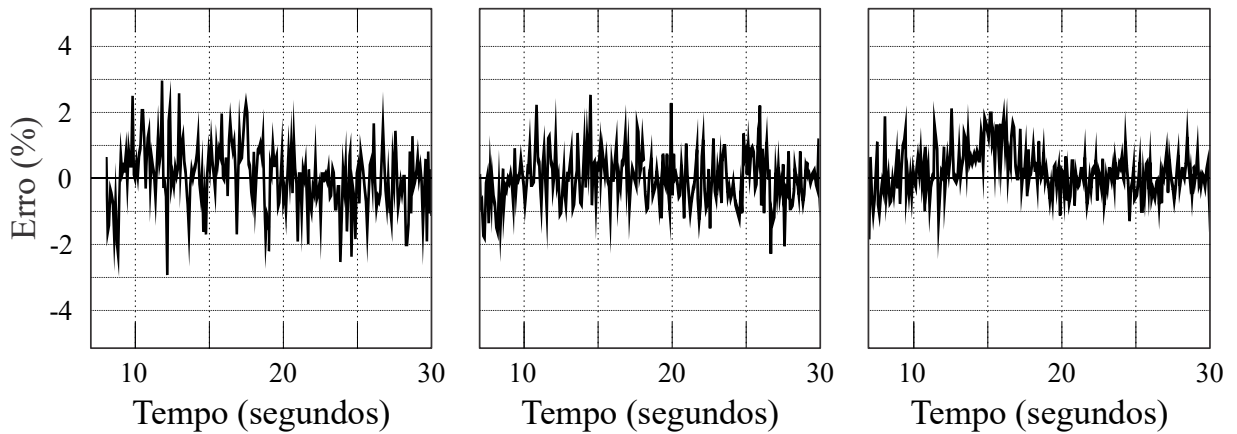


Figura 5.3 – Comportamento do Erro no Regime Permanente – Experimento Tipo 1.




Figura 5.4 – Resposta do controlador RNA a distúrbios – Experimento Tipo 1.




Figura 5.5 – Comportamento da frequência de alimentação de tensão após distúrbios – Experimento Tipo 1.

5.2 Experimento Tipo 2

O Experimento Tipo 2 foi realizado para verificar a eficiência da RNA em atuação quando a vazão aduzida pelo sistema experimental for máxima. O valor de referência (*setpoint*) para a variável de controle (pressão) do ensaio igual a 10 mca. Não foi possível realizar ensaios com valores de referência maiores porque as bombas não possuem altura manométrica suficiente.

A RNA definiu a frequência de alimentação dos motores e determinou quantos motores devem operar simultaneamente ao longo dos ensaios. O processo de tomada de decisão do algoritmo foi baseado na eficiência energética do sistema.

O ensaio foi realizado com o conjunto motor-bomba partindo do repouso (frequência igual a zero) e com ângulo de fechamento da válvula proporcional igual a 0° , o que corresponde à demanda máxima.

O sistema de controle apresentou uma resposta bastante satisfatória, pois conseguiu atingir o valor de pressão desejado com um tempo de assentamento relativamente baixo. O sobressinal foi de 1,45 mca, com um tempo de subida de 19 segundos. O tempo de assentamento foi 37 segundos, considerando-se uma faixa de acomodação de $\pm 3\%$ da amplitude do sinal de referência. Por se tratar de dados experimentais, os resultados não foram submetidos a tratamentos estatísticos. Portanto, os valores apresentados correspondem aos coletados pelos equipamentos (medidores). Na Figura 5.6, mostra-se o comportamento da variável de controle (pressão) para o ensaio realizado.




Figura 5.6 – Comportamento da variável de controle (pressão) – Experimento Tipo 2.

O controle também repercutiu na minimização dos transientes hidráulicos e na redução da corrente de partida dos conjuntos motor-bomba. Nos demais testes realizados, as variáveis apresentaram o mesmo padrão de comportamento. O erro de regime permanente máximo do ensaio foi de 2,9% (0,29 mca), sem transitórios. Na Figura 5.7, mostra-se o comportamento do erro de regime permanente, cujo valor médio foi de 1,5%.

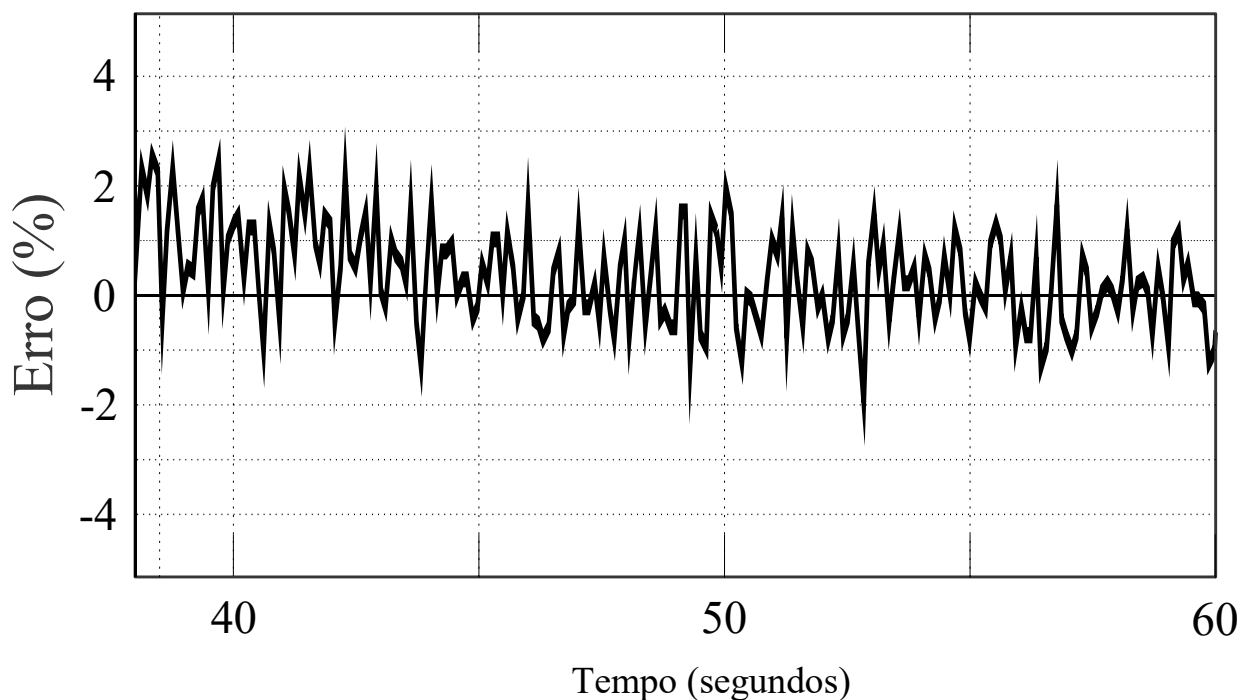


Figura 5.7 – Comportamento do Erro no Regime Permanente – Experimento Tipo 2.

Na Figura 5.8, apresenta-se o comportamento das variáveis de saída — frequências de alimentação de tensão dos motores — para o ensaio. Neste ensaio, o conjunto PUMP-02 atua com um atraso em relação ao conjunto PUMP-01, porque este somente é acionado quando a RNA “percebe” que uma única bomba não é suficiente para atender as condições impostas. A partir do instante 45 segundos, as duas variáveis de saída — velocidades de rotação das bombas — permanecem constantes, tendo em vista a não existência de perturbações no sistema de bombeamento.

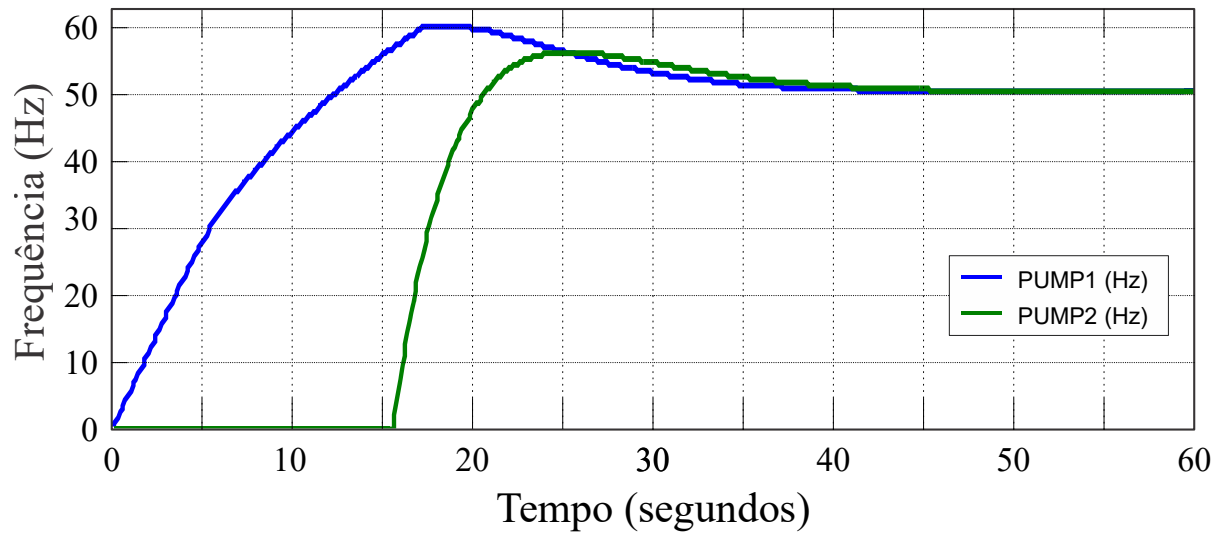


Figura 5.8 – Comportamento da Frequência de Alimentação de Tensão – Experimento Tipo 2.

De forma semelhante aos ensaios do Experimento Tipo 1, para promover distúrbios no sistema experimental, foi fechado bruscamente o registro tipo globo, localizado a jusante da válvula proporcional. Observa-se na Figura 5.9 que, no instante 16 s, foi provocado um distúrbio no sistema experimental, e o controlador manteve, após o distúrbio, as mesmas condições operacionais anteriores, restabelecendo a pressão no valor desejado. A Figura 5.10 apresenta o comportamento das variáveis de saída — frequências de alimentação de tensão dos motores.




Figura 5.9 – Resposta do controlador RNA ao distúrbio – Experimento Tipo 2.




Figura 5.10 – Comportamento da frequência de alimentação após distúrbios – Experimento Tipo 2.

5.3 Experimento Tipo 3

O Experimento Tipo 3 foi realizado com o sistema em malha aberta. O experimento emula a operação de um sistema de abastecimento urbano de água. Destarte, foi desenvolvido no LabVIEW™ um instrumento virtual para emular a variação de demanda por meio da operação remota da válvula proporcional. Os resultados desse experimento foram comparados com o sistema em malha fechada (Experimento Tipo 4).

Na Figura 5.11, apresenta-se a curva de fechamento da válvula proporcional. O tempo do ensaio foi de 30 minutos. Inicialmente, a válvula estava fechada (60°), representando a demanda mínima, e a cada 30 segundos, aproximadamente, foi imposta uma variação de 2° no ângulo até atingir a demanda máxima (0°). Em seguida, a posição de abertura da válvula retorna para a posição de demanda mínima seguindo a mesma metodologia.




Figura 5.11 – Curva de fechamento da válvula proporcional – Experimento Tipo 3.

O comportamento da vazão do Experimento 3 é mostrado na Figura 5.12, cujo valor médio foi de $11,65 \text{ m}^3/\text{h}$. Como se esperava, a vazão do sistema acompanha o mesmo padrão da curva de fechamento da válvula de controle. A válvula tem a função de emular consumidores. Logo, à medida que a válvula abre, a vazão aumenta, e a pressão tende a diminuir, e vice-versa. Conforme se observa na Figura 5.13, o comportamento da pressão segue um padrão inverso ao da vazão, ou seja, quanto maior a vazão, menor a pressão.




Figura 5.12 – Curvas de vazão total – Experimento Tipo 3.




Figura 5.13 – Comportamento da pressão – Experimento Tipo 3.

Na Figura 5.14, apresenta-se o comportamento da potência no ensaio, e na Figura 5.15 exibe-se a curva do Consumo Específico de Energia Elétrica (CE).




Figura 5.14 – Consumo energético dos conjuntos motor-bomba – Experimento Tipo 3.




Figura 5.15 – Curva do comportamento do CE – Experimento Tipo 3.

5.4 Experimento Tipo 4

O Experimento 4 foi realizado nas mesmas condições de operação do Experimento 3, porém com a rede neural artificial atuando no controle da pressão. Trata-se de um ensaio em malha fechada, com uma entrada tipo degrau igual a 10 mca para a variável de controle.

A RNA definiu a frequência de alimentação dos motores e determinou quantos motores devem operar, simultaneamente, ao longo dos ensaios. O processo de tomada de decisão do algoritmo se baseou, prioritariamente, no controle das pressões e, em seguida, na eficiência energética do sistema.

Na Figura 5.16, apresenta-se a curva de fechamento da válvula proporcional. O tempo do ensaio foi de 30 minutos. Inicialmente, a válvula estava fechada (60°), representando a demanda mínima, e a cada 30 segundos, aproximadamente, foi imposta uma variação de 2 graus no ângulo até atingir a demanda máxima (0°). Em seguida, a posição de abertura da válvula retorna para a posição de demanda mínima seguindo a mesma metodologia.




Figura 5.16 – Curva de fechamento da válvula proporcional – Experimento Tipo 4.

O comportamento da vazão no Experimento 4 é apresentado na Figura 5.17, cujo valor médio foi de $8,19 \text{ m}^3/\text{h}$. Como se esperava, a vazão do sistema acompanha o mesmo padrão da curva de fechamento da válvula de controle. De forma análoga ao Experimento 3, a válvula tem a função de emular consumidores. Logo, à medida que a válvula abre, a vazão aumenta e a pressão tende a diminuir, e vice-versa.




Figura 5.17– Curva de vazão total – Experimento Tipo 4.

Com base no comportamento da pressão no Experimento 3, foi estabelecida nos ensaios do Experimento 4 uma excitação tipo degrau, igual a 10 mca, para a variável pressão, a fim de analisar a resposta da RNA à alteração nas condições de operação do sistema experimental e o consumo de energia elétrica.

O sistema de controle apresentou uma resposta bastante satisfatória nos ensaios, pois, apesar da variação da vazão, o controlador atuou para ajustar a pressão de serviço à sua referência (v. Figura 5.18). A pressão média no experimento foi igual a 9,758 mca, o que indica que o objetivo principal do controlador foi alcançado. O erro médio foi de 2,42% (0,242 mca).




Figura 5.18 – Comportamento da variável de controle (pressão) – Experimento Tipo 4.

Na Figura 5.19, apresenta-se o comportamento das variáveis de saída — frequências de alimentação de tensão dos motores. Os ensaios apresentaram o mesmo padrão de comportamento, com o acionamento do segundo conjunto motor-bomba somente quando a demanda atingiu o valor de $13 \text{ m}^3/\text{h}$. De forma semelhante aos ensaios anteriores, a frequência de alimentação dos motores permanece igual. Esse fato corrobora com a afirmação da literatura, que indica que bombas em paralelo devem funcionar nas mesmas condições operacionais. No instante 1358 s, com a redução da vazão demandada, o sistema de controle decidiu por desligar um dos conjuntos motor-bomba, deixando o sistema operar, a partir de então, apenas com uma bomba.




Figura 5.19 – Comportamento das variáveis de saída - Frequências de Alimentação de Tensão – Experimento Tipo 4.

De acordo com a decisão da RNA, os motores oscilaram suas rotações durante os ensaios. Por se tratar de um sistema com injeção direta na rede hidráulica, o conjunto PUMP-01 funcionou durante todo o período do experimento, oscilando sua rotação entre 30 Hz (menor vazão) e 58 Hz no momento do pico da vazão. O conjunto PUMP-02 foi acionado no instante 642 s, e foi desligado no instante 1358 s, com variação de rotação entre 70% e 97% da sua rotação nominal.

Para avaliar a eficiência energética do sistema experimental, com o controlador RNA e sem ele (Experimentos 3 e 4), foi medida *on-line* a potência consumida e foi calculado o índice de Consumo Específico de Energia Elétrica (kWh/m³). Na Figura 5.20, apresentam-se as curvas de potência, enquanto na Figura 5.21 é mostrada a curva do Consumo Específico de Energia Elétrica (CE) do Experimento 4.




Figura 5.20 – Consumo energético do conjunto motor-bomba – Experimento Tipo 4.




Figura 5.21 Comportamento do CE – Experimento Tipo 4.

Na Tabela 5.2, apresentam-se os valores dos parâmetros de avaliação energética. Apesar de o inversor de frequência consumir cerca de 5% da energia total e ocasionar um decréscimo de rendimento do conjunto motor-bomba (BEZERRA et al., 2015, p. 72), verificou-se que o controle de rotação proporcionou uma redução no consumo de energia elétrica de 4,143 kWh para 1,401 kWh, resultando numa economia de 66,18%, com uma diminuição de 73,66% no indicador CE. A redução no CE expressa a melhoria da eficiência do sistema. Como se trata de um sistema com uma demanda variável no tempo e com bombeamento direto na rede, a redução significativa no consumo energético era esperada, sendo este estudo mais uma pesquisa que comprova a viabilidade do uso de inversores nesses casos.

Tabela 5.2 – Indicadores dos Experimentos Tipo 3 e Tipo 4.

Indicador	Experimento 3	Experimento 4	Diferença (%)
Vazão (m ³ /h)	11,65	8,19	29,7
Consumo de energia (kWh/ano)	36292,68	12272,76	66,2
CE (kWh/m ³)	0,5167	0,1361	73,7

O consumo específico de energia (CE) é um indicador de desempenho operacional bastante utilizado no setor de saneamento em estações elevatórias de água bruta ou tratada. Esse indicador representa a quantidade média de energia requerida para elevar um metro cúbico de água. Portanto, a eficiência da estação elevatória pode ser avaliada calculando-se esse indicador. Existe uma limitação no uso desse indicador quando for necessário comparar a eficiência de dois sistemas elevatórios distintos, mas, nesse caso, o indicador é aplicável, tendo em vista que se está comparando a mesma elevatória em diversos pontos operacionais.

Por se tratar de dados experimentais, os resultados dos Experimentos não foram submetidos a tratamentos estatísticos. Portanto, os valores apresentados correspondem aos coletados pelos equipamentos (medidores).

CAPÍTULO 6

CONCLUSÕES

Esta tese objetivou o desenvolvimento de um sistema de controle inteligente, baseado em uma rede neural artificial (RNA) com arquitetura *feedforward* multicamadas, denominada de Rede Perceptron Multicamadas (PMC), com saídas recorrentes às entradas. A PMC foi proposta para a operação de sistemas de bombeamento com conjuntos motor-bomba associados em paralelo e acionados por inversores de frequência. As PMCs já foram utilizadas com sucesso em diversas aplicações da área de sistemas de controle, porém é desconhecida a aplicação delas no caso específico desta tese.

A principal conclusão da pesquisa é que a arquitetura da RNA proposta é adequada para essa aplicação, e tem um desempenho robusto para a gama de operações do arranjo experimental. O controlador respondeu satisfatoriamente à imposição de diversos valores de entrada tipo degrau e aos distúrbios.

O sistema inteligente desenvolvido foi aplicado a uma bancada experimental que emula um sistema real de abastecimento de água. Testou-se experimentalmente o desempenho da RNA em diferentes condições de operação, incluindo até a presença de perturbações ambientais. O sistema proporcionou uma partida suave e manteve satisfatoriamente a pressão de serviço dentro dos limites preestabelecidos. O tempo de assentamento foi, em todos os experimentos, inferior a 30 segundos, e o erro máximo em regime permanente foi de 2,9% (0,45 mca, em valores absolutos).

Com base nos resultados experimentais, podem ser extraídas desta pesquisa as seguintes conclusões sobre a aplicabilidade das Redes Perceptron Multicamadas para o controle do sistema de bombeamento experimental:

(a) em princípio, se há disponibilidade de um conjunto de dados experimentais em diferentes condições de funcionamento, o desenvolvimento de controladores robustos baseados em redes PMCs é viável para sistemas de bombeamento de água;

(b) redes PMCs com somente uma camada intermediária são suficientes para um desempenho satisfatório, desde que o número de neurônios adotado seja o adequado. Ressalte-se que as variáveis de saída dos controladores se mantiveram coerentes quando comparados os ensaios experimentais entre si;

(c) Uma desvantagem significativa das redes PMCs é que não existe uma regra para a escolha do número apropriado de neurônios da camada oculta para um desempenho ótimo. Esse número é estabelecido por métodos de tentativa e erro, começando com dois ou três neurônios, e, em seguida, aumentando o número gradualmente até que o desempenho seja satisfatório. Esse procedimento é, naturalmente, fastidioso e demorado. No entanto, convém ressaltar que essa aplicação necessitou de apenas 10 neurônios da camada oculta para a rede PMC desenvolvida.

Pesquisas científicas, como as apresentadas nesta tese, desenvolvidas para companhias de saneamento, apresentam maior probabilidade de sucesso e viabilidade em sistemas reais, uma vez que são flexíveis e permitem adaptações importantes durante o desenvolvimento e a implementação. Espera-se que o controlador proposto possa ser aplicado em outros sistemas de distribuição de água similares sem a necessidade de modelagem do sistema a ser controlado. A atuação em sistemas reais poderá proporcionar:

- aumento da eficiência hidráulica e energética da operação dos sistemas de bombeamento por meio do controle de pressões na rede de distribuição;
- redução do consumo de energia;
- diminuição do volume de água consumido e do volume perdido por vazamento;
- melhoria do acionamento dos motores (redução da corrente de partida);
- minimização dos transientes hidráulicos;
- aumento da confiabilidade dos procedimentos operacionais; e
- modernização das plantas.

Ressalte-se que o uso de inversores de frequência é indicado para sistemas de bombeamento com injeção direta na rede de distribuição de água que estão sujeitos a variações da vazão. Apesar de o inversor de frequência consumir cerca de 5% da energia total e ocasionar um decréscimo de rendimento do conjunto motor-bomba, verificou-se que, para o arranjo experimental e para as condições operacionais adotadas, o controle da velocidade de rotação dos conjuntos motor-bomba proporcionou uma redução no consumo de energia elétrica de 4,143 kWh para 1,401 kWh, resultando numa economia de 66,18%, com uma diminuição de 73,66% no Consumo Específico de Energia Elétrica (kWh/m³).

REFERÊNCIAS

- ABDULLAH, N. A.; QUTEISHAT, A. M. **Wheat seeds classification using multi-layer perceptron artificial neural network.** *International Journal of Electronics Communication and Computer Engineering (IJECCCE)*, v. 6, n. 2, pp. 306-309, 2015. ISSN (Online): 2249-071X, ISSN (Print): 2278-4209.
- AHMED, M. H.; HASAN, S.; ALI, A. **Learning enhancement of radial basis function neural network with Harmony Search Algorithm.** *International Journal of Soft Computing and Its Applications*, v. 7, n. 1, Mar. 2015. ISSN 2074-8523.
- AKHILA, E.; PRAVEEN KUMAR, N.; ISHA, T. B. **Fuzzy Logic and PI Controls in Speed Control of Induction Motor.** In: INTERNATIONAL CONFERENCE ON SOFT COMPUTING SYSTEMS (ICSCS), 5., 20-21 Apr. 2016, Kumaracoil (India). **Proceedings...** New Delhi: Springer, 2016. p. 987-1001. ISBN: 978-81-322-2669-7.
- ALKHEDER, S.; TAAMNEH, M.; TAAMNEH, S. **Severity prediction of traffic accident using an artificial neural network.** *Journal of Forecasting*. [S.l.]: Wiley, 2016.
- ALLEN, M.; PREIS, A.; IQBAL, M.; WHITTLE, A. J. **Water distribution system monitoring, decision support using a wireless sensor network.** In: INTERNATIONAL CONFERENCE ON SOFTWARE ENGINEERING, ARTIFICIAL INTELLIGENCE, NETWORKING AND PARALLEL/DISTRIBUTED COMPUTING, 14., 2013, **Proceedings...** [S.l.]: IEEE, 2013. p. 641-646.
- ALMEIDA, A. T.; FERREIRA, F. J. T. E.; BOTH, D. **Technical, economical considerations in the application of variable-speed drives with electric motor systems.** *IEEE Transactions on Industry Applications*, v. 41, n. 1, p. 188-199, Jan.-Feb. 2005.
- ALSOFYANI, I. M. et al. **Improving start-up operation of sensorless DTC of induction machines using simple flux regulation.** In: ANNUAL CONFERENCE OF THE IEEE INDUSTRIAL ELECTRONICS SOCIETY, 41., 9-12 Nov., 2015, Yokohama, Japan. **Proceedings...** [S.l.]: Curran Associates, 2016. p. 4714-4719. ISBN: 9781479917631.
- ALVES, A. J.; OLIVEIRA, L. F. C. de; OLIVEIRA, A. M. de. **Verificação das relações de Râteaux pelo emprego de um inversor de frequência.** *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 6, n. 3, p. 523-525, 2002.
- AL-ZOHAIRY, T. A.; SALEM, K. S. **Model following control of SISO nonlinear systems using PID neural networks.** *International Journal of Computer Applications*, v. 140, n. 10, 2016.
- AMARI, S. **Characteristics of random nets of analog neuron-like elements.** *IEEE Transactions on Systems, Man and Cybernetics*, p. 643-657, 1972.
- _____. **A mathematical approach to neural systems.** In: METZLER, J. (Ed.), *Systems Neuroscience*. New York: Academic Press, 1977.

ANDERSON, J. A. **A simple neural network generating an interactive memory.** *Mathematical Biosciences*, v. 14, p. 197-220, 1972.

_____. **An introduction to neural networks.** Cambridge, USA: MIT Press, 1995. 672p.

ANDRADE, M. et al. **Enhanced artificial neural networks estimating water quality constraints for the optimal water distribution systems design.** *Journal of Water Resources Planning and Management*, v. 142, n. 9, 2016.

ANTONY, A. et al. **Skin cancer detection using artificial neural networking.** *International Journal of Innovative Research in Electrical, Electronics, Instrumentation and Control Engineering (IJIREEICE)*, v. 4, n. 4, p. 305-309, 2016.

ANUAR, S.; SELAMAT, A.; SALLEHUDDIN, R. **Hybrid artificial neural network with artificial bee colony algorithm for crime classification.** *Computational Intelligence in Information Systems*, v. 331, p. 31-40, 2015.

ARANTO, N. **Competitor comparison: Variable speed drives in pumping applications.** 2008. 100 f. Dissertação (Mestrado) – Department of Energy- and Environmental Technology, Faculty of Technology, Lappeenranta University of Technology, Lappeenranta, Finlândia, 2008.

ARAVIND, T. P. A. et al. **Monitoring, analysis and modelling of ambient air quality status at Indoshell Mould Ltd., Sidco, Coimbatore using artificial neural network.** Themed Section: Engineering and Technology, v. 2, n. 2, p. 1172-117, 2016.

AZAD, F. N. et al. **Optimization of the process parameters for the adsorption of ternary dyes by Ni doped FeO (OH)-NWs-AC using response surface methodology and an artificial neural network.** *RSC Advances*, v. 6, n. 24, p. 19768-19779, 2016.

BACCARINI, L. M. R. et al. **Sliding mode observer for on-line broken rotor bar detection.** *Electric Power Systems Research*, v. 80, p. 1089-1095, 2010.

BAGHERI, Majid et al. **Modeling of a sequencing batch reactor treating municipal wastewater using multi-layer perceptron, radial basis function artificial neural networks.** *Process Safety and Environmental Protection*, v. 93, p. 111-123, 2015.

BARRY, J. A. **WATERGY: Energy and Water Efficiency in Municipal Water Supply and Wastewater Treatment. Cost-Effective Savings of Water and Energy.** Washington, D.C.: Alliance to Save Energy, Feb. 2007. 44 p.

BAXT, W. **The applications of the artificial neural network to clinical decision-making.** In: CONFERENCE ON NEURAL INFORMATION PROCESSING SYSTEMS – NATURAL AND SYNTHETIC, Nov. 30 – Dec. 3, 1992, Denver, CO, USA. 1992.

BEZERRA, S. T. M. **Sistema fuzzy para controle piezométrico de sistemas de distribuição de água visando à economia de água e energia.** 2009. 163 f. Tese (Doutorado em Engenharia Mecânica) – Programa de Pós-Graduação em Engenharia Mecânica (PPGEM), UFPB, João Pessoa, PB, 2009.

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

BEZERRA, S. T. M.; SILVA, S. A.; GOMES, H. P. **Controle automático de pressão em sistemas de distribuição de água**. In: GOMES, H. P. (Org). **Sistemas de Saneamento – Eficiência Energética**. 1. ed. João Pessoa: Editora Universitária/UFPB, 2010. p. 9-28.

_____. **Operational otimisation of water supply networks using a fuzzy system**. *Water SA*, v. 38, n. 4, p. 565-572, 2012.

BEZERRA, S. T. M.; SILVA, S. A.; GOMES, H. P.; SALVINO, M. M. **Energy savings in pumping systems: application of a fuzzy system**. *Ciência & Engenharia*, v. 24, n. 1, p. 71-78, jan.-jun. 2015. ISSN 1983-4071.

BISCOS, C. et al. **Optimal operation of water distribution networks by predictive control using MINLP**. *Water SA*, v. 29, n. 4, p. 393-404, 2003.

BISHOP, C. M. **Neural networks for pattern recognition**. Oxford: Clarendon Press, 1995.

BLINCO, L. et al. **Comparison of pumping regimes for water distribution systems to minimize cost and greenhouse gases**. *Journal of Water Resources Planning and Management*, v. 142, n. 6, 2016.

BORDON, M. E. **Controlador Nebuloso de Arquitetura Simplificada – Estudo de Caso: Acionamento de Motor de Indução Trifásico**. 2004. 196 f. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica e de Computação, Programa de Pós-Graduação em Engenharia Elétrica, UNICAMP, Campinas, SP, 2004.

BOSE, B. K. **Neural network applications in power electronics and motor drives – An introduction and perspective**. *IEEE Transactions on Industrial Electronics*, v. 54, n. 1, p. 14-33, Feb. 2007.

BOULOS, P. F. et al. **Real-time modeling of water distribution systems: A case study**. *Journal AWWA*. E391-E401. 2014.

BOULOS, P. F.; WILEY, A. N. **Can we make water systems smarter? Automated Systems**, 2013.

BRAGA, A. P.; CARVALHO, A. C. P. F.; LUDERMIR, T. B. **Fundamentos de Redes Neurais Artificiais**. Rio de Janeiro: XI Escola de Computação, 1998, v. 1. 245 p.

_____. **Redes Neurais Artificiais: Teoria e Aplicações**. Rio de Janeiro: LTC, 2000.

BRASIL. Ministério das Cidades. Secretaria Nacional de Saneamento Ambiental (Org.). **Abastecimento de água: Gerenciamento de perdas de água e energia elétrica em sistemas de abastecimento**. Brasília: Ministério das Cidades, 2009. 83 p.

_____. Ministério de Minas e Energia. Empresa de Pesquisa Energética (Org.). **Anuário Estatístico de Energia Elétrica 2015 – ano base 2014**. Brasília: MME, set. 2015.

BRION, L. M.; MAYS, L. W. **Methodology for optimal operation of pumping stations in water distribution systems**. *Journal of Hydraulic Engineering*, v.117, n. 11, p. 1551-1569, 1991.

BROOMHEAD, David S.; LOWE, David. **Multivariable Functional Interpolation and Adaptive Networks**. *Complex Systems*, v. 2, pp. 321–355, 1988.

BRYSON, A. E., Jr.; HO, Y. C. **Applied optimal control: Optimization, Estimation, and Control**. Waltham, MA: Blaisdell, 1969. 481 p.

BUJA, G.; KAZMIERKOWSKI, M. **Direct torque control of pwm inverter-fed AC motors – A survey**. *IEEE Transactions on Industrial Electronics*, v. 51, n. 4, p. 744-757, 2004.

BUNN, S. **Closing the loop in water supply optimisation**. In: INSTITUTION OF TECHNOLOGY AND ENGINEERING WATER EVENT, 2007, Coventry, UK. **Proceedings...** Coventry, UK: IEE, 2008. ISBN: 978/0-86341-791-7. ISSN: 0537-9989.

BURT, C. M. et al. **Electric motor efficiency under variable frequencies and loads**. *Journal of Irrigation and Drainage Engineering*, v. 134, n. 2, p. 129-136, 2008.

CAMBOIM, W. L. L.; SILVA, S. A.; GOMES, H. P. **Aplicação de técnicas fuzzy no controle de pressão em sistemas de abastecimento de água**. *Engenharia Sanitária e Ambiental*, v. 19, n. 1, p. 67-77, 2014.

CAMPISANO, A.; MODICA, C. **PID and PLC units for the real-time control of sewer system**. *Water Science and Technology*, v. 45, n. 7, p. 95-104, 2002.

CANDELIERI, A.; ARCHETTI, F.; MESSINA, E. **Improving leakage management in urban water distribution networks through data analytics and hydraulic simulation**. *WIT Transactions on Ecology and The Environment*, vol 171, p. 107-116, 2013.

CANUTO, A. M. P. **Combining neural networks, fuzzy logic for applications in character recognition**. 2001. 196 f. Tese (Doutorado em Engenharia Eletrônica) – University of Kent, Canterbury, Inglaterra, 2001.

CARVALHO, P. S. O. **Controle para bombeamento distribuído com vistas à minimização dos custos energéticos aplicado a sistemas de abastecimento de água**. 2012. 150 f. Tese (Doutorado em Engenharia Mecânica) – Programa de Pós Graduação em Engenharia Mecânica, UFPB, João Pessoa, PB, 2012.

CASTRO GAMA, M. E. et al. **A Graph Theoretical Sectorization Approach for Energy Reduction in Water Distribution Networks**. In: INTERNATIONAL CONFERENCE ON HYDROINFORMATICS, 12., Aug. 21-26, 2016, Incheon, South Korea. **Procedia Engineering...** Incheon, South Korea: Elsevier, v. 154, 2016. p. 19-26.

CEMBRANO, G. et al. **Optimization of a multi-reservoir water network using a conjugate gradient technique: A case study**. *Lecture Notes in Control and Information Sciences*, v. 111, p. 987-999, 1988.

CHAUDHURI, T. D.; GHOSH, I. **Artificial neural network and time series modeling based approach to forecasting the exchange rate in a multivariate framework**. *Journal of Insurance and Financial Management*, v. 1, n. 5, p. 92-123, 2016.

CHERGUI, M. I. **Improved control of a photovoltaic pumping system by DTC-SVM to optimize the water flow**. *Journal of Electrical Engineering and Computer Sciences*, v. 24, n. 3, p. 1474-1486, 2016.

CHOUBIN, B. et al. **Multiple linear regression, multi-layer perceptron network, adaptive neuro-fuzzy inference system for forecasting precipitation based on large-scale climate signals.** *Hydrological Sciences Journal*, v. 61, n. 6, p. 1001-1009, 2016.

CICHOCKI, A.; UNBEHAUEN, R. **Neural networks for optimization and signal processing.** John Wiley, 1993. 548 p. ISBN: 978-0-471-93010-5.

COELHO, B.; ANDRADE-CAMPOS, A. **Efficiency achievement in water supply systems – A review.** *Renewable and Sustainable Energy Reviews*, v. 30, p. 59-84, Feb. 2014.

COHEN, M. et al. **Context- dependent multiple distribution phonetic modelling with MLPs.** *Advances in Neural Information Processing Systems*, p. 649-657, 1993.

COSTA, L. H. M. K.; PRATA, B. A.; RAMOS, H. M.; CASTRO, M. A. H. **A Branch-and-Bound Algorithm for Optimal Pump Scheduling in Water Distribution Networks.** *Water Resources Management*, v. 30, n. 3, p. 1037-1052, 2016.

COSTA, L. H. M. K.; RAMOS, H. M.; CASTRO, M. A. H. **Hybrid genetic algorithm in the optimization of energy costs in water supply networks.** *Water Science and Technology: Water Supply*, v. 10, n. 3, p. 315-326, 2010.

COSTA, S. M. B. S.; REVOREDO FILHO, R. P. **Potencialidade de aplicação de redes neurais na gestão da logística empresarial.** *Revista Processus de Estudo de Gestão, Jurídicos e Financeiros*, ano IV, n. 12, p. 1-18, 2013.

COULBECK, B.; ORR, C. H.; BRDYS, M. **Real-time optimized control of water distribution systems.** In: INTERNATIONAL CONFERENCE ON CONTROL, 1988, Oxford. **Proceedings...** Oxford: IET, 1988. p. 634-640.

CUNHA, E. N. **Modelagem, simulação e controle de sistemas de abastecimento de água: Um estudo de caso do campus da Universidade Federal do Rio Grande do Norte.** 2015. 70 f. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica e de Computação, Centro de Tecnologia, UFRN, Natal, 2015.

CYBENKO, G. **Continuous valued neural networks with two hidden layers are sufficient.** Technical Report. Department of Computer Science, Tufts University, 1988.

DABADGAONKAR, S.; SEN, A. K. **Controlling of pump onboard ship using variable frequency drive with three-phase inverter and three phase induction motor.** *MIT International Journal of Electrical and Instrumentation Engineering*, v. 1, n. 2, p. 87-92, 2011.

DAHIYA, M.; GILL, S. **Secured bluetooth authentication using artificial neural networks.** *International Journal of Research in Computer and Communication Technology*, v. 5, n. 5, p. 244-248, 2016.

DAI, P. D.; LI, P. **Optimal pressure regulation in water distribution systems based on an extended model for pressure reducing valves.** *Water Resources Management*, v. 30, n. 3, p. 1239-1254, 2016.

DAMÁSIO, A. **O erro de Descartes: Emoção, razão e o cérebro humano.** São Paulo, SP: Companhia das Letras, 1996.

- DAS, S. et al. **A harmony search-based artificial neural network for stock market prediction.** *International Journal of Business Forecasting and Marketing Intelligence*, v. 2, n. 1, 2015.
- DECANINI, J. G. M. S. **Detecção, classificação e localização de faltas de curto-circuito em sistemas de distribuição de energia elétrica usando sistemas inteligentes.** 2012. 124 f. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia, UNESP, Ilha Solteira, SP, 2012.
- DEWINTER, A. D.; KEDROSKY, B. J. **The application of a 3500-hp variable frequency drive for pipeline pump control.** *IEEE Transactions on Industry Applications*, v. 25, n. 6, p. 1019-1024, 1989.
- DIL, E. A. et al. **Modeling of quaternary dyes adsorption onto ZnO-NR-AC artificial neural network: Analysis by derivative spectrophotometry.** *Journal of Industrial and Engineering Chemistry*, v. 34, n. 25, p. 186-197, 2016.
- DING, Y.; ZHOU, S.; MEI, C.; JIANG, H. **Low pass filtering based artificial neural network stator flux estimator for AC induction motors.** *Sensors and Transducers*, v. 161, n. 12, p. 219-224, 2013.
- DUNCAN, A. et al. **RAPIDS: Early Warning System for Urban Flooding and Water Quality Hazards.** In: MACHINE LEARNING IN WATER SYSTEMS SYMPOSIUM, 2013, Exeter, UK. **Proceedings...** Exeter, UK: AISB, 2013. p. 25-29. ISBN: 978-1-908187-33-8.
- EBRAHIMI, E. et al. **Prediction and optimization of back-break and rock fragmentation using an artificial neural network and a bee colony algorithm.** *Bulletin of Engineering Geology and the Environment*, v. 75, n. 1, pp. 27-36, 2016.
- ELMAN, J. L. **Finding structure in time.** *Cognitive Science*, v. 14, p. 179-211, 1990.
- EUROPUMP; HYDRAULIC INSTITUTE. **Variable speed pumping: A guide to successful applications.** 1. ed. Bodmin, Cornwall: Elsevier, 2004. 170 p.
- EVERHART, J. **Sensing significant savings with VFD systems.** *World Pumps Magazine*, p. 18-21, 2004.
- FALLSIDE, F.; PERRY, P. F. **Hierarchical optimisation of a water-supply network.** *Proceedings of the Institution of Electrical Engineers*, v. 122, n. 2, p. 202-208, Feb. 1975.
- FANAIE, Vahidreza et al. **Application of response surface methodology and artificial neural network for analysis of p-chlorophenol biosorption by dried activated sludge.** *Journal of Applied Chemical Research*, vol. 10, n. 2, pp. 25-37, June 2016.
- FARIS, H.; ALJARAH, I.; MIRJALILI, S. **Training feedforward neural networks using multi-verse optimizer for binary classification problems.** *Applied Intelligence*, v. 45, n. 2, p. 322-332, 2016.
- FEKI, N.; CLERC, G.; VELEX, P. **Gear and motor fault modeling and detection based on motor current analysis.** *Electric Power Systems Research*, v. 95, p. 28-37, 2013.

FERREIRA, F. J. T. E.; FONG, J. A. C.; ALMEIDA, A. T. **Ecoanalysis of variable-speed drives for flow regulation in pumping systems.** *IEEE Transactions on Industrial Electronics*, v. 58, p. 2117-2125, 2011.

FIORIN, D. V. et al. **Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares.** *Revista Brasileira de Ensino de Física*, v. 33, n. 1, p. 1-20, 2011.

FLOOD, I.; KARTAM, N. **Neural networks in Civil Engineering.** I: Principles and understanding. *Journal of Computing in Civil Engineering*, v. 8, n. 2, p. 131-148, 1994.

FUKUSHIMA, K. **Cognitron: A self-organizing multilayered neural network.** *Biological Cybernetics*, v. 20, p. 121-136, 1975.

GADOUE, S. M.; GIAOURIS, D.; FINCH, J. W. **Sensorless control of induction motor drives at very low and zero speeds using neural network flux observers.** *IEEE Transactions on Industrial Electronics*, v. 56, n. 8, p. 3, 2009.

GALLO, M.; SIMONELLI, F.; DE LUCA, G.; PORTA, C. D. **An artificial neural network approach for spatially extending road traffic monitoring measures.** In: IEEE WORKSHOP ON ENVIRONMENTAL, ENERGY, AND STRUCTURAL MONITORING SYSTEMS (EESMS), 13-14 June 2016, Bari, Italy. **Proceedings...** [s.n.]: IEEE, 2016. ISBN: 9781509023714.

GELLINGS, C. W. **Program on technology innovation: electric efficiency through water supply technologies – A roadmap.** California, USA: Electric Power Research Institute, 2009.

GHADDAR, B. et al. **A lagrangian decomposition approach for the pump scheduling problem in water networks.** *European Journal of Operational Research*, v. 241, n. 2, p. 490-501, 2014.

GOEDEL, A. **Estimador neural de velocidade para motores de indução trifásicos.** 2007, 133 f. Tese (Doutorado em Engenharia Elétrica) – Escola de Engenharia de São Carlos, USP, São Carlos, 2007.

GOLDMAN, F. E.; MAYS, L.W. **The application of simulated annealing to the optimal operation of water systems.** In: ANNUAL WATER RESOURCES PLANNING AND MANAGEMENT CONFERENCE (WRPMD), 26., 1999, Tempe, Arizona, USA. **Proceedings...** [S.l.]: ASCE, 1999.

GOMES, H. P. **Eficiência hidráulica e energética em saneamento: Análise econômica de projetos.** Rio de Janeiro, RJ: ABES Nacional, 2005.

GROSSBERG, S. **Neural expectation: Cerebellar and retinal analog of cells fired by learnable or unlearned pattern classes.** *Kybernetik*, v. 10, n. 1, p. 49-57, 1972.

_____. **Adaptive Pattern Classification and Universal Recoding: I. Parallel Development and Coding of Neural Feature Detectors & II: Feedback, expectation, olfaction, and illusions.** *Biological Cybernetics*, vol. 23, n. 3, pp. 121-134 & 187-202, 1976.

GUO, L.; PARSA, L. **Model reference adaptive control of five-phase IPM motors based on neural network.** *IEEE Transactions on Industrial Electronics*, v. 59, n. 3, p. 1500-1508, 2012.

GUPTA, R.; NAIR, A.; ORMSBEE, L. **Leakage as pressure-driven demand in design of water distribution networks.** *Journal of Water Resources Planning and Management*, v. 142, n. 6, 2016.

GUTIERREZ-VILLALOBOS, J. M.; RODRIGUEZ-RESENDIZ, J.; RIVAS-ARAIZA, E. A.; MUCINO, V. H. **A review of parameter estimators and controllers for induction motors based on artificial neural networks.** *Neurocomputing*, v. 118, p. 87-100, 2013.

GUTIERREZ-VILLALOBOS, J. M.; RODRIGUEZ-RESENDIZ, J.; RIVAS-ARAIZA, E. A.; MARTÍNEZ-HERNÁNDEZ, M. A. **Sensorless FOC performance improved with on-line speed and rotor resistance estimator based on an artificial neural network for an induction motor drive.** *Sensors*, v. 15, n. 7, p. 15311-15325, 2015.

HATCHETT, S. et al. **How Accurate Is a Hydraulic Model?** In: CONFERENCE OF THE WATER DISTRIBUTION SYSTEMS ANALYSIS, 12., 2010, Tucson, USA. **Proceedings...** Tucson: [s.n.], 2010.

HAYKIN, S. **Redes neurais: Princípios e prática.** 2. ed. Trad. Paulo Martins Engel. Porto Alegre, RS: Bookman, 2001.

HAYKIN, S.; LIPPMANN, R. **Neural networks, a comprehensive foundation.** *International Journal of Neural Systems*, v. 5, n. 4, p. 363-364, 1994.

HEBB, D. O. **The organization of behaviour: A neuropsychological theory.** New York: Wiley, 1949.

HOPFIELD, J. J. **Neural networks and physical systems with emergent collective computational abilities.** *Proceedings of the National Academy of Science*, v. 79, p. 2554-2558, 1982.

_____. **Neurons with graded response have collective computational properties like those of two-state neurons.** *Proceedings of the National Academy of Sciences*, v. 81, p. 3088-3092, 1984.

HOPFIELD, D. W.; TANK, J. J. **Neural computation of decisions in optimization problems.** *Biological Cybernetics*, v. 52, p. 141-152, 1985.

HORNIK, K.; STINCHCOMBE, M.; WHITE, H. **Multilayer feedforward networks are universal approximators.** *Neural Networks*, v. 2, n. 5, p. 359-366, 1989.

HOVSTADIUS, G. **Tackling soaring energy costs in North America.** *World Pumps*, p. 38-40, 2007.

IMMOVILLI, F. et al. **Bearing fault model for induction motor with externally induced vibration.** *IEEE Transactions on Industrial Electronics*, v. 60, n. 8, p. 3408-3418, 2103.

INGEDULD, P. **Real-time forecasting with EPANET**. In: WORLD ENVIRONMENTAL AND WATER RESOURCES CONGRESS, 2007, Tampa, Florida, USA. **Proceedings...** Tampa, Florida: ASCE, 2007. pp. 1-9.

IYER, J. et al. **Improved torque sharing in multi induction motor VFD systems using current feedback**. In: IEEE CANADIAN CONFERENCE ON ELECTRICAL AND COMPUTER ENGINEERING (CCECE), 25., 2012, Montreal, Canada. **Proceedings...**Montreal, Canada: IEEE, 2012.

JACOB, S.; BANERJEE, R. **Modeling, optimization of anaerobic codigestion of potato waste and aquatic weed by response surface methodology and artificial neural network coupled genetic algorithm**. *Bioresource Technology*, v. 214, p. 386-395, 2016.

JAMES, K.; CAMPBELL, S. L.; GODLOVE, C. E. **Água e energia** - Aproveitando as oportunidades de eficiência de água e energia não exploradas nos sistemas municipais. Washington, USA: Alliance to Save Energy, 2002.

JIANG, G.; KELLER, J.; BOND, P. L.; YUAN, Z. **Predicting concrete corrosion of sewers using artificial neural network**. *Water Research*, v. 92, p. 52-60, 2016.

JOHANSEN, T. A.; FOSS, B. A. **A NARMAX model representation for adaptive control based on local models**. *Modelling, Identification and Control*, v. 13, n. 1, p. 25-39, 1992a.

_____. **A. Nonlinear local model representation for adaptive systems**. In: SINGAPORE INTERNATIONAL CONFERENCE ON INTELLIGENT CONTROL AND INSTRUMENTATION, 1992, Singapore. **Proceedings...** Singapore: BAC, v. 2, 1992b. p. 677-682.

_____. **A. Representing and learning unmodelled dynamics with neural network memories**. In: AMERICAN CONTROL CONFERENCE, 1992, Chicago, Illinois. **Proceedings...** 1992c. p. 3037-3043.

_____. **A. Constructing NARMAX models using ARMAX models**. *International Journal of Control*, v. 58, p. 1125-1153, 1993.

KANG, D. **Real-time optimal control of water distribution systems**. *Procedia Engineering*, v. 70, p. 917-923, 2014.

KARTAKIS, S. et al. **Energy-based adaptive compression in water network control systems**. In: INTERNATIONAL WORKSHOP ON CYBER-PHYSICAL SYSTEMS FOR SMART WATER NETWORKS, 2., 2016, Vienna, Austria. **Proceedings...** Vienna: [s.n.], 2016.

KHLIFI, M. A.. **Study and control of photovoltaic water pumping system**. *Journal of Electrical Engineering and Technology*, v.11, n. 1, p. 117-124, 2016.

KIM, Sung-Woo; LEE, Ju-Jung. **Filter-error-learning neural networks for stable trajectory tracking control**. *Mechatronics*, v. 6, n. 2, p. 181-192, 1996.

KOFINAS, D. et al. **Daily multivariate forecasting of water demand in a touristic island with the use of artificial neural network and adaptive neuro-fuzzy inference system**. In:

INTERNATIONAL WORKSHOP ON CYBER-PHYSICAL SYSTEMS FOR SMART WATER NETWORKS, 2., 2016, Vienna, Austria. **Proceedings...** Vienna: [s.n.], 2016.

KORF, R. E. **Improved limited discrepancy search**. In: NATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE, 13., 1996, Portland, Oregon. **Proceedings...** Portland, Oregon: AAAI Press, vol. 1, 1996. p. 286-291.

KOUGIAS, I. P.; THEODOSSIOU, N. P. **Multiobjective pump scheduling using Harmony Search Algorithm (HAS) and Polyphonic HSA**. *Water Resources Management*, v. 27, n. 5, p. 1249-1261, 2013.

KUMAR, Narander; PATEL, Pooja. **Resource management using ANN-PSO techniques in cloud computing environment**. In: INTERNATIONAL CONGRESS ON INFORMATION AND COMMUNICATION TECHNOLOGY (ICICT), 2., 2015, Udaipur, India. **Proceedings...** [S.l.]: Springer, vol. 2, 2016. p. 419-428. ISBN 978-1-4503-3962-9.

LASHKARBLOOQI, M. et al. **Viscosity prediction of ternary mixtures containing ILs using multi-layer perceptron artificial neural network**. *Fluid Phase Equilibria*, v. 326, p. 15-20, 2012.

LECUN, Yann A. **Learning scheme for asymmetric threshold networks**. *Proceedings of Cognitiva*, v. 85, p. 599-604, 1985.

LEE, A.; GEEM, Z. W.; SUH, K.-D. **Determination of optimal initial weights of an artificial neural network by using the Harmony Search Algorithm: Application to breakwater armor stones**. *Applied Sciences*, v. 6, n. 164, p.1-17, 2016.

LEE, D.; KIM, Seungho; KIM, Sangyong. **Development of hybrid model for estimating construction waste for multifamily residential buildings using artificial neural networks and Ant Colony Optimization**. *Sustainability*, v. 8, n. 9, p. 1-14, 2016.

LEWIS, C.; HENDRIX, M. **Smart grid and AMI for water utilities**. *Journal American Water Works Association*, v. 104, n. 9, 2012.

LI, W.; ZHAO, Z.; YANG, X.; DENG, W. **Modularized fault diagnosis model of induction motor based on radial basis function neural network**. *Journal of Process Mechanical Engineering*, v. 229, n. 1, p. 3-10, 2015.

LIANG, X.; ILOCHONWU, O. **Induction motor starting in practical industrial applications**. *IEEE Transactions on Industry Applications*, v. 47, p. 271-280, 2011.

LIMA, A. S. et al. **Desempenho operacional no bombeamento em pivô central utilizando inversor de frequência**. *Brazilian Journal of Applied Technology for Agricultural Science*, v. 8, n. 2, p. 51-61, 2015.

LIMA, Fábio. **Estimador neuro-fuzzy de velocidade aplicado ao controle vetorial sem sensores de motores de indução trifásicos**. 2010. 145 f. Tese (Doutorado em Sistemas de Potência) – Departamento de Engenharia de Energia e Automação Elétricas, Escola Politécnica, USP, 2010.

- LIMA, Fábio; KAISER, W.; SILVA, I. N.; OLIVEIRA, A. A. **Speed neuro-fuzzy estimator applied to sensorless induction motor control.** *IEEE Latin America Transactions*, v. 10, n. 5, p. 2065-2073, 2012.
- LIN, Cheng; LIU, W.; REN, H. **Neutral network-PID control algorithm for semi-active suspensions with magneto-rheological damper.** *Journal of Vibroengineering*, v. 17, n. 8, p. 4432-4444, 2015.
- LIN, Chuan-Kai. **Radial basis function neural network-based adaptive critic control of induction motors.** *Applied Soft Computing*, v. 11, n. 3, p. 3066-3074, 2011.
- LIU, Shaoqing et al. **Evaluating atmospheric CO2 effects on gross primary productivity and net ecosystem exchanges of terrestrial ecosystems in the conterminous United States using the AmeriFlux data and an artificial neural network approach.** *Agricultural, Forest Meteorology*, v. 220, n. 15, p. 38-49, 2016.
- LÓPEZ-IBÁÑEZ, M. **Operational optimisation of water distribution networks.** 2009. 222 f. Thesis (Doctor of Philosophy) – Edinburgh Napier University, 2009.
- LÓPEZ-IBÁÑEZ, M.; PRASAD, T. D.; PAECHTER, B. **Representations, evolutionary operators for the scheduling of pump operations in water distribution networks.** *Evolutionary Computation, MIT Press Journals*, v.19, n. 3, p. 429-467, 2011.
- LUJARA, N. J. **Optimal operation of a photovoltaic induction motor drive water pumping system.** *International Journal of Energy and Power Engineering*, v. 3, n. 4, p. 502-506, 2016.
- MÄCKLE, G.; SAVIC, D.; WALTERS, G. **Application of Genetic Algorithms to Pump Scheduling for Water Supply.** In: IEE/IEEE INTERNATIONAL CONFERENCE ON GENETIC ALGORITHMS IN ENGINEERING SYSTEMS: INNOVATIONS AND APPLICATIONS (GALESIA), 1., 1995, Sheffield, UK. **Proceedings...** London: IEE, 1995. p. 400-405.
- MADONSKI, R.; NOWICKI, M.; HERMAN, P. **Application of active disturbance rejection controller to water supply system.** In: CHINESE CONTROL CONFERENCE, 33., 2014, Nanjing, China. **Proceedings...** Nanjing, China: IEEE, 2014. p. 4401-4405. ISSN: 1934-1768.
- MAIER, H. R.; DANDY, G. C. **Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications.** *Environmental Modelling and Software*, v. 15, 2000. p. 101-124.
- MAKINO, D. L. **Eficiência energética em sistemas de abastecimento de água usando bombas de rotação variável.** 2012. 152 f. Dissertação (Mestrado em Tecnologia) – UNICAMP, Campinas, SP, 2012.
- MAMBRETT, S.; ORSI, E. **Optimizing pump operations in water supply networks through genetic algorithms.** *Journal American Water Works Association*, v. 108, n. 2, p. E119-E125, 2016.

MANOHAR, Usha.; MOHAN KUMAR, M. S. **Modeling equitable distribution of water: Dynamic inversion-based controller approach.** *Journal of Water Resources Planning and Management*, v. 140, n. 5, 2014.

MARTINEZ, F. et al. **Optimizing of the operation of the Valencia waterdistribution network.** *Journal Hydroinformatics*, v. 9, n. 1, 2007.

MCCULLOCH, W. S.; PITTS, W. **A logical calculus of the ideas immanent in nervous activity.** *Bulletin of Mathematical Biophysics*, v. 5, p. 115-133, 1943.

MEMON, A. P. et al. **Multilayer perceptrons neural network automatic voltage regulator with applicability and improvement in power system transient stability.** *International Journal of Emerging Trends in Electrical and Electronics (IJETEE)*, v. 9, p. 30-38, Nov. 2013. ISSN: 2320-9569.

MENDEL, J. M.; MCLAREN, R. W. **Reinforcement-learning control and pattern recognition systems.** In: MENDEL, J. M.; FU, K. S. (Ed.). **Adaptive, learning, pattern recognition systems: theory and applications.** New York: Academic Press, p. 287-318, 1970.

MENGHAL, P. M.; LAXMI, A. J. **Neural network based dynamic performance of induction motor drives.** In: INTERNATIONAL CONFERENCE ON SOFT COMPUTING FOR PROBLEM SOLVING, 3., 2013, India. **Proceedings...** India: Springer, v. 2, 2014. p. 539-551. ISBN: 978-81-322-1767-1.

_____. **Modelling, simulation and analysis of induction motor using artificial intelligent controller.** *International Journal of Modelling and Simulation*, v. 36, n. 4, 2016.

MINSKY, M. L. **Theory of neural-analog reinforcement systems and its application to the brain model problem.** Thesis (Doctor of Philosophy) – Princeton University, University Microfilms, Ann Arbor, 1954.

MINSKY, M. L.; PAPERT, S. A. **Perceptrons: an introduction to computational geometry.** Cambridge, MA: MIT Press, 1969.

MOHAMMED, N. G. N.; ABDULRAHMAN, A. **Water supply network system control based on model predictive control.** In: INTERNATIONAL MULTICONFERENCE OF ENGINEERS AND COMPUTER SCIENTISTS (IMECS), Mar. 18-20, 2009, Hong Kong. **Proceedings...** Hong Kong, China: [s.n.], vol. II, 2009. ISBN: 978-988-17012-7-5.

MOUNCE, S. R. **A comparative study of artificial neural network architectures for time series prediction of water distribution system flow data.** In: SYMPOSIUM MACHINE LEARNING IN WATER SYSTEMS, Apr. 2-5, 2013, Exeter, UK. **Proceedings...** University of Exeter, UK: [s.n.], 2013.

MÜLLER, B.; REINHARDT, J.; STRICKLAND, M. T. **Neural networks – An Introduction.** Secaucus, New Jersey, U.S.A.: Springer Verlag, 1995. 330 p. ISBN 10: 3540602070 / ISBN 13: 9783540602071.

MURRAY-SMITH, R. **A local model network approach to nonlinear modeling.** 1994. Thesis (Doctor of Philosophy) – Department of Computer Science, University of Strathclyde, Glasgow, Scotland, 1994.

MURRAY-SMITH, R.; GOLLEE, H. **A constructive learning algorithm for local model networks**. In: IEEE WORKSHOP ON COMPUTER-INTENSIVE METHODS IN CONTROL AND SIGNAL PROCESSING, 1994, Prague. **Proceedings...** Prague, Czech Republic: [s.l.], 1994. p. 21-29.

NAKANO, K. **Associatron** – A model of associative memory. *IEEE Transactions on Systems, Man and Cybernetics*, v. 2, p. 380-388, 1972.

NEVES, Ana Régia de M. **Aplicação de redes neurais artificiais na predição de valores genéticos em bovinos de leite da raça Pardo-Suíça**. 2007. Dissertação (Mestrado em Engenharia Elétrica) – Instituto de Tecnologia, Universidade Federal do Pará, Belém, PA, 2007.

NIASAR, A. H.; KHOEI, H. R. **Sensorless direct power control of induction motor drive using artificial neural network**. *Advances in Artificial Neural Systems*, p. 1-9, 2015.

NOURMOHAMMADZADEH, A.; HARTMANN, S. **Fault classification of a centrifugal pump in normal, noisy environment with artificial neural network and support vector machine enhanced by a genetic algorithm**. In: INTERNATIONAL CONFERENCE ON THEORY AND PRACTICE OF NATURAL COMPUTING, 4., 2015, Mieres, Spain. **Proceedings...** New York, NY: Springer-Verlag, v. 9477, 2015. p. 58-70. ISBN: 978-3-319-26840-8.

OGUZ, Y.; DEDE, M. **Speed estimation of vector controlled squirrel cage asynchronous motor with artificial neural networks**. *Energy Conversion and Management*, v. 52, n. 1, p. 675-686, Jan. 2011.

ORMSBEE, L. E.; REDDY, S. L. **Nonlinear heuristic for pump operations**. *Journal of Water Resources Planning and Management*, ASCE, v. 121, n. 4, p. 302-309, 1995.

ORNEDO-RAMOS, K. F. P. et. al. **Prediction of density of binary mixtures of ionic liquids with alcohols (Methanol/Ethanol/1-Propanol) using artificial neural network**. *ASEAN Journal of Chemical Engineering*, v. 15, n. 2, p. 262-265, 2015.

PARKER, D. B. **Learning-logic**. Technical Report TR-47. Sloan School of Management, Massachusetts Institute of Technology, Cambridge, MA, EUA, 1985.

PASHA, M. F. K.; LANSEY, K. **Strategies to develop warm solutions for real-time pump scheduling for water distribution systems**. *Water Resources Management*, v. 28, n. 12, p. 3975-3987, July 12, 2014.

PATEL, S.; ALEX, J. S. R.; VENKATESAN, N. **Low-Power Multi-Layer Perceptron Neural Network Architecture for Speech Recognition**. *Indian Journal of Science and Technology*, v. 8, n. 20, p. 2-6, 2015.

PELLI, T.; HITZ, H. U. **Energy indicators and savings in water supply**. *Journal American Water Works Association*, v. 92, n. 6, p. 55-62, 2000.

PEMBERTON, M. **Variable speed pumping: Myths and legends**. *World Pumps*, p. 22-24, 2005.

- PENG, W.; HAO, M.; PENG, D.; RI-HUI, D. **Decoupling control based on PID neural network for deaerator and condenser water level control system.** In: CHINESE CONTROL CONFERENCE (CCC), 34., 28-30 July 2015, Hangzhou, China. **Proceedings...** [S.l.]: IEEE, 2015. ISBN: 978-9-8815-6389-7.
- PETER, S. E.; RAGLEND, I. J. **Sequential wavelet-ANN with embedded ANN-PSO hybrid electricity price forecasting model for Indian energy exchange.** *Neural Computing and Applications*, p. 1-16, 2016.
- PIZZINO, C. A. P. **Controle não-linear adaptativo sensorless de um motor de indução baseado na corrente rotórica.** 2008. 192 f. Dissertação (Mestrado em Engenharia Elétrica) – Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia, UFRJ, Rio de Janeiro, RJ, 2008.
- PRASANNA KUMAR, M.; MOHAN KUMAR, M. S.. **Comparative study of three types of controllers for water distribution networks.** *Journal American Water Works Association*, v. 101, n. 1, p. 74-86, 2009.
- PRESS, W. H.; FLANNERY, B. P.; TEUKOLSKY, S. A.; VETTERLING, W. T. **Numerical recipes: The art of scientific computing (Fortran Version).** New York: Cambridge University Press, 1990.
- RAHIMPOUR, F.; HATTI-KAUL, R.; MAMO, G. **Response surface methodology and artificial neural network modelling of an aqueous two-phase system for purification of a recombinant alkaline active xylanase.** *Process Biochemistry*, v. 51, n. 3, p. 452-462, 2016.
- RAMOS, H. M.; COSTA, L. H. M.; GONÇALVES, F. V. **Energy efficiency in water supply systems: GA for pump schedule optimization and ANN for hybrid energy prediction.** *Water Supply System Analysis - Selected Topics*. 1. ed. [S.l.]: InTech, p. 75-103, 2012. ISBN 978-953-51-0889-4
- RAO, Z.; ALVARRUIZ, F. **Use of an artificial neural network to capture the domain knowledge of a conventional hydraulic simulation model.** *Journal Hydroinformatics*, v. 9, n. 1, p. 15-24, 2007.
- RAZA, Safdar et al. **Minimum-features-based ANN-PSO approach for islanding detection in distribution system.** *IET Renewable Power Generation*, vol. 10, n. 9, pp. 1255-1263, Oct. 2016. ISSN 1752-1416.
- RÉGIS, L. P. et al. **Aplicação de um controle PID na operação de sistemas de distribuição de água.** In: SIMPÓSIO IBERO-AMERICANO DE REDES DE ÁGUA, ESGOTO E DRENAGEM, 13., 2014, Fortaleza, CE. **Anais...** Fortaleza: UNIFOR, 2014.
- REYES, J.; VELLASCO, M.; TANSCHIT, R. **Monitoramento e diagnóstico de múltiplos sensores por redes neurais autoassociativas.** *SBA Controle e Automação*, v. 23, n. 2, 2010.
- ROSENBLATT, F. **The Perceptron – a perceiving and recognizing automaton.** Report 85-460-1, Cornell Aeronautical Laboratory, 1957.
- ROSSMAN, L. A. **EPANET 2 - Users manual.** Cincinnati, OH: U.S. Environmental Protection Agency, 2000.

- RUMELHART, D. E.; MCCLELLAND, J. L. **Parallel distributed processing: explorations in the microstructure of cognition foundations.** *MIT Press*, 1986.
- SAIDUR, R. et al. **Applications of variable speed drive (VSD) in electrical motors energy savings.** *Renewable, Sustainable Energy Reviews*, v. 16, 2012. p. 543-550.
- SALAM, M. D. A. et al. **Estimation of magnetic field strength near substation using artificial neural network.** *International Journal of Electronics and Electrical Engineering*, vol. 4, n. 2, pp. 166-171, Apr. 2016.
- SALOMONS, E. et al. **Optimizing the operation of the Haifa – A water-distribution network.** *Journal of Hydroinformatics*, v. 9, n. 1, p. 51-63, 2007.
- SAMORA, I. et al. **Energy recovery using micro-hydropower technology in water supply systems: The case study of the city of Fribourg.** *Water*, v. 8, n. 8, p. 1-16, 2016.
- SANKAR, G. S.; KUMAR, S. M.; NARASIMHAN, Sridharakumar; NARASIMHAN, Shankar; BHALLAMUDI, S. M. **Optimal control of water distribution networks with storage facilities.** *Journal of Process Control*, v. 32, p. 127-137, 2015.
- SANTIN, F. M.; SILVA, R. V. da; GRZYBOWSKI, J. M. V. **Artificial neural network ensembles and the design of performance-oriented riparian buffer strips for the filtering of nitrogen in agricultural catchments.** *Ecological Engineering*, v. 94, p. 493-502, 2016.
- SANTOS, T. H.; GOEDEL, A.; SILVA, S. A. O.; SUETAKE, M. **Scalar control of an induction motor using a neural sensorless technique.** *Electric Power Systems Research*, v. 108, p. 322-330, 2014.
- SAUER, B. J.; BRADY, P. A. **Application of AC induction motors with variable frequency drives.** In: CEMENT INDUSTRY TECHNICAL CONFERENCE, 2009, Palm Springs, USA. **Proceedings...** Palm Springs: IEEE, 2009. p. 1-10.
- SAVIC, D. A.; WALTERS, G. A.; SCHWAB, M. **Multiobjective genetic algorithms for pump scheduling.** *Lecture Notes in Computer Science*, v. 1205, p. 227-235, 1997.
- SENSUS. **Water 20/20: Bringing Smart Water Networks Into Focus.** 2012.
- SHANKAR, V. K. A. et al. **A comprehensive review on energy efficiency enhancement initiatives in centrifugal pumping system.** *Applied Energy*, v. 181, n. 1, p. 495-513, 2016.
- SHEEN, J. N. **Economic feasibility of variable frequency driving pump by fuzzy financial model.** In: INTERNATIONAL CONFERENCE ON INNOVATIVE COMPUTING, INFORMATION AND CONTROL (ICICIC), 4., 2009, Kaohsiung, Taiwan. **Proceedings...** [S.l.]: IEEE, 2009. p. 934-937.
- SHERRINGTON, C. S. **The Central Nervous System.** In: FOSTER, M. (Ed.). **A Text Book of Physiology.** 7th ed., Part III. London: Macmillan, 1897.
- SHI, H.; YOU, F. **Energy optimization of water supply system scheduling: Novel MINLP model and efficient global optimization algorithm.** *AIChE Journal*, 2016.

SHIHU, S. et al. **Power saving in water supply system with pump operation optimization.** In: ASIA-PACIFIC POWER AND ENERGY ENGINEERING CONFERENCE (APPEEC), 2010, Chengdu, China. **Proceedings...** Chengdu, China: IEEE, 2010. pp. 1-4.

SIGNORETI, R. O .S. et al. **Importance of pressure reducing valves (PRVs) in water supply networks.** *Journal of Physics: Conference Series*, v. 738, n. 1, p.1-4, 2016.

SILVA, M. J. G.; ARAÚJO, C. S.; BEZERRA, S. T. M.; SOUTO, C. R.; SILVA, S. A.; GOMES, H. P. **Generalized Minimum Variance Control for Water Distribution System.** *Jornal IEEE Latin America Transactions*, v. 13, n. 3, p. 651-658, 2015.

SIMPSON, Angus R.; MARCHI, Angela. **Evaluating the Approximation of the Affinity Laws and Improving the Efficiency Estimate for Variable Speed Pumps.** *Journal of Hydraulic Engineering*, vol. 139, n. 12, 2013.

SINGH, B.; KUMAR, R. **Solar photovoltaic array fed water pump driven by brushless DC motor using Landsman converter.** *IET Renewable Power Generation*, v. 10, n. 4, p. 474-484, 2016.

SINGH, R.; CHOUDHARY, N.; MISHRA, A.; JAMWAL, K.; MADHAV, M. **Commissioning of a VFD controller for the performance analysis of a 2 pole induction motor.** *International Journal of Application or Innovation in Engineering and Management*, v. 1, p. 62-68, 2012.

SOOFASTAEI, A.;AMINOSSADATI, S. M.; AREFI, M. M.; KIZIL, M. S. 2016. **Development of a multi-layer perceptron artificial neural network model to determine haul trucks energy consumption.** *International Journal of Mining Science and Technology*, v. 26, n. 2, p. 285-293, 2016.

SPOLAOR, A. S. **Automação nos sistemas de abastecimento de água – Caso do controle da reservação de distribuição.** 2011. 120 f. Dissertação (Mestrado em Engenharia Civil) – Faculdade de Engenharia Civil, Arquitetura e Urbanismo, UNICAMP, Campinas, SP, 2011.

STOIANOV, I.; NACHMAN, S. M.; TOKMOULINE, T.; CSAIL, M. 2007. **Pipenet: A wireless sensor network for pipeline monitoring.** In: INTERNATIONAL CONFERENCE ON INFORMATION PROCESSING IN SENSOR NETWORKS (IPSN), 6., 2007, Cambridge, Massachusetts. **Proceedings...** New York, NY: ACM, 2007. p. 264-273.

STRUTHERS, C. **Real-time monitoring and control of a pressure control system.** 2005. 85 f. Research Project (Bachelor of Engineering) – Faculty of Engineering and Surveying, University of Southern Queensland. 2005.

SUETAKE, M.; SILVA, I. N.; GOEDEL, A. **Embedded DSP-based compact fuzzy system and its application for induction-motor V/F speed control.** *IEEE Transactions on Industrial Electronics*, v. 58, n. 3, p. 750-760, 2011.

SUPREETHA, B. S.; NAYAK, P.K.; SHENOY, N. K. **Groundwater level prediction using hybrid artificial neural network with genetic algorithm.** *International Journal of Earth Sciences and Engineering*, v. 8, n. 6, p. 2609-2615, 2015.

TAFNER, M.; XEREZ, M.; RODRIGUES, I. **Redes neurais artificiais: Introdução e princípios de neurocomputação.** Blumenau: EKO/FURB, 1996.

THEISEN, J. **Upping the efficiency of pumps and fans.** *Machine Design*, v. 77, n. 19, p. 86-90, 2005.

UNAR, M. A. **Ship steering control using feedforward neural networks.** 1999. 219 f. Thesis (Doctor of Philosophy) – Department of Electronics and Electrical Engineering, University of Glasgow, 1999.

VALER, L. R. et al. **Variable-speed drives in photovoltaic pumping systems for irrigation in Brazil.** *Sustainable Energy Technologies and Assessments*, v. 15, p. 20-26, 2016.

VARELA, Francisco. **Conhecer: As ciências cognitivas – Tendências e perspectivas.** Lisboa, Portugal: Instituto Piaget, 1985.

VAS, P. **Sensorless vector and direct torque control.** New York: Oxford University Press, 1998.

VAZQUEZ, R. A.; GARRO, B. A. **Training spiking neural models using Artificial Bee Colony.** *Computational Intelligence, Neuroscience*, vol. 2015, 2015. 14 p.

VENTURA, R.V. et al. **Uso de redes neurais artificiais na predição de valores genéticos para peso aos 205 dias em bovinos da raça Tabapuã.** *Arquivo Brasileiro de Medicina Veterinária e Zootecnia*, v. 64, n. 2, p. 411-418, 2012.

VERMA, R.; VERMA, V.; CHAKRABORTY, C. **ANN based sensorless vector controlled induction motor drive suitable for four quadrant operation.** In: Proceedings of the IEEE Students' Technology Symposium (TechSym). 2014.

VIDAL, F. S.; ROSA, P. F. F.; MELO NETO, A. **Multilayer perceptron use in a mapping task by cooperating robots.** In: BRICS CONGRESS ON COMPUTATIONAL INTELLIGENCE AND BRAZILIAN CONGRESS ON COMPUTATIONAL INTELLIGENCE, 11., 2013, Recife, Brazil. **Proceedings...** Los Alamos, California: Conference Publishing Services, IEEE Computer Society, 2013.

VIEIRA, F.; RAMOS, H. M. **Hybrid solution and pump-storage optimization in water supply system optimization: A case study.** *Energy Policy*, v. 36, p. 4142-4148, 2008.

VITKOVSKY, J. P.; SIMPSON, A. R.; LAMBERT, M. F. **Leak detection, calibration using transients, genetic algorithms.** *Journal of Water Resources Planning and Management*, v. 126, n. 4, 2000.

WALSKI, T. M. et al. **Some surprises in estimating the efficiency of variable speed pumps with the pump affinity laws.** In: WORLD WATER AND ENVIRONMENTAL RESOURCES CONGRESS, 2003, Philadelphia, Pennsylvania. **Proceedings...** New York: ASCE, 2003. p. 1-10.

WERBOS, P. J. **Beyond regression: New tools for prediction, analysis in the behavioural sciences.** 1974. Ph.D. Thesis – Harvard University, Cambridge, MA, USA. 1974.

WIDROW, B.; HOFF, M. E. **Adaptive switching circuits.** In: IRE WESCON CONVENTION RECORD, v. 4, n. 1, p. 96-104. 1960.

WOOD, D. J.; REDDY, L. S. 1994. **Control de bombas de velocidad variable y modelos en tiempo real para minimizar fugas y costes energéticos.** In: CABRERA, E.; VELA, A. F. **Mejora del Rendimiento y de la Fiabilidad en Sistemas de Distribución de Agua.** Valência, Espanha: Universidad Politécnica de Valencia, Universitat Jaume I de Castellón, 1994. p.173-207.

XU, K.; LI, H. L.; LIU, Shan Chao. **Speed sensorless control with ANN-MRAS based on modified ACO for induction motor drives.** *Applied Mechanics and Materials*, v. 705, pp. 341-344, 2015.

YILMAZ, Ali Can; ACI, C.; AYDIN, K. **Traffic accident reconstruction and an approach for prediction of fault rates using artificial neural networks: A case study in Turkey.** *Traffic Injury Prevention*, v. 17, n. 6, p. 585-589, 2016.

YOKSEL, O.; MEHMET, D. **Speed estimation of vector controlled squirrel cage asynchronous motor with artificial neural networks.** *Energy and Management*, v. 52, n. 1, p. 675-686, 2011.

YU, T.; LI, Y.; LI, J. **Nonparametric modeling of magnetorheological elastomer base isolator based on artificial neural network optimized by ant colony algorithm.** *Journal of Intelligent Material Systems and Structures*, v. 26, p.1789-1798, 2015.

ZAHED FILHO, K. **Previsão de demanda de consumo em tempo real no desenvolvimento operacional de sistemas de distribuição de água.** 1990. 135 f. Tese (Doutorado em Engenharia Hidráulica e Sanitária) – Escola Politécnica, USP, São Paulo, SP, 1990.

ZARE, M.; POURGHASEMI, H. R.; VAFAKHAH, M.; PRADHAN, N. **Landslide susceptibility mapping at Vaz Watershed (Iran) using an artificial neural network model: A comparison between multilayer perceptron (MLP) and radial basic function (RBF) algorithms.** *Arabian Journal of Geosciences*, v. 6, n. 8, p. 2873-2888, 2013.

APÊNDICE A
DESENVOLVIMENTOS EM LabVIEW®

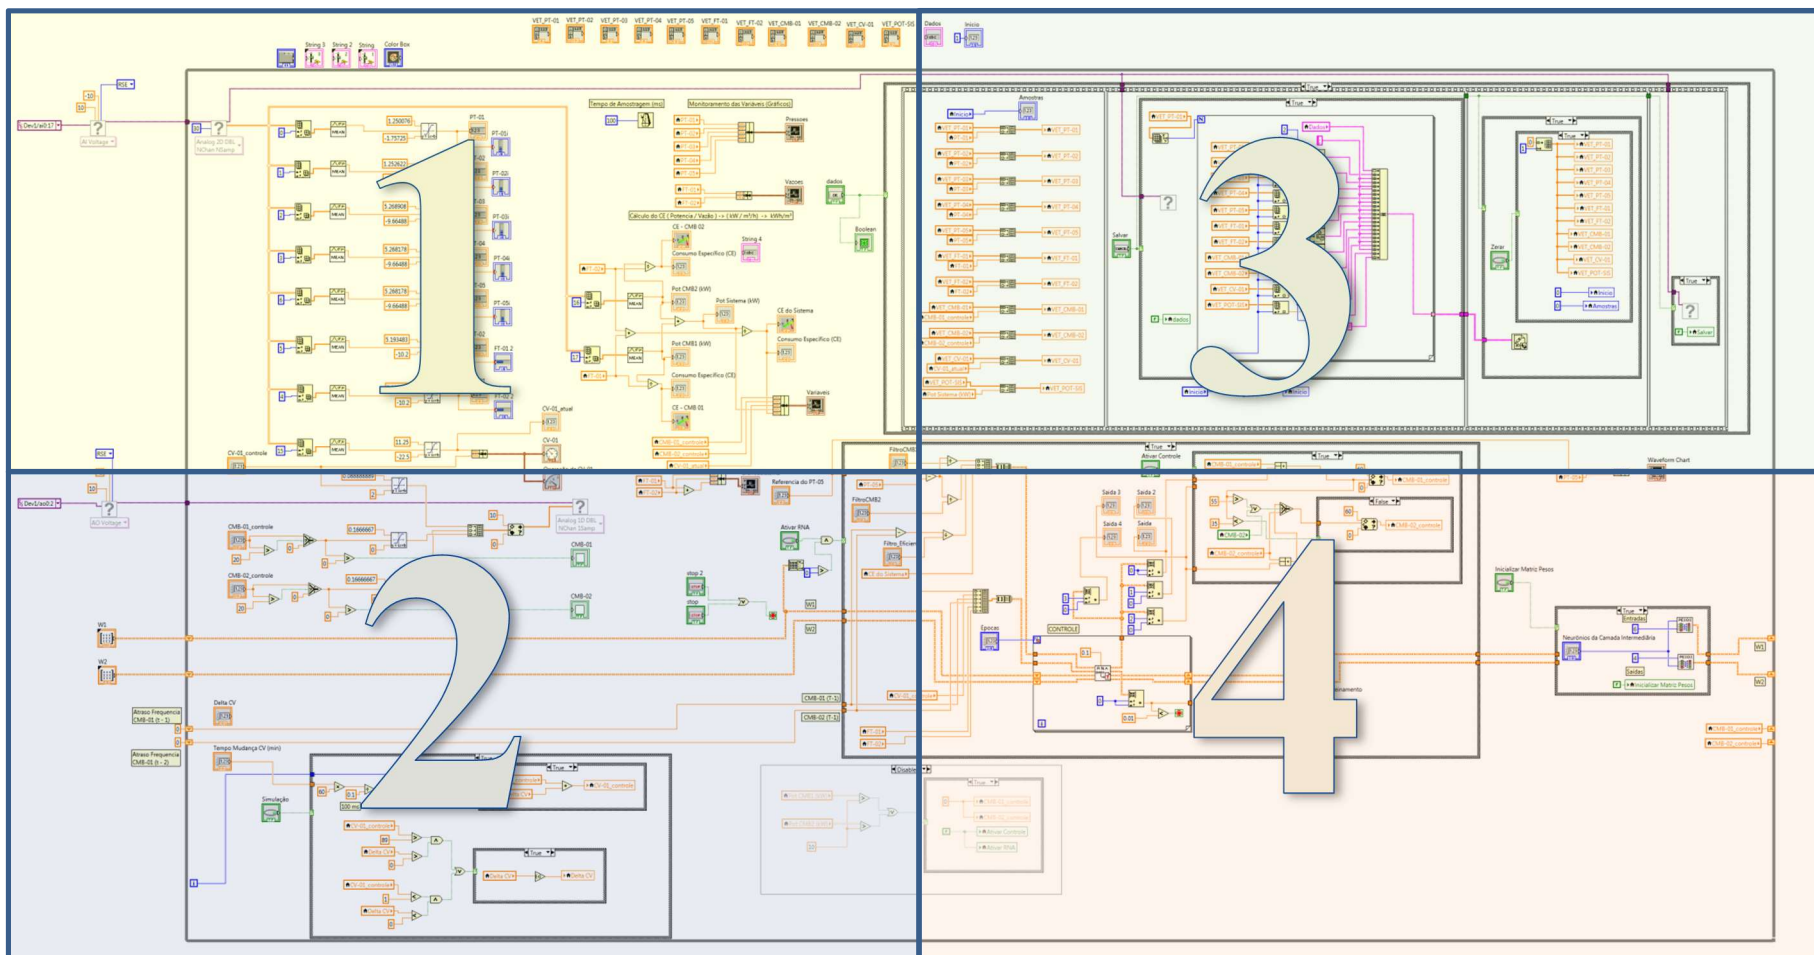


Figura A.1 – Programa principal desenvolvido em LabVIEW.




Figura A.2 – Primeira parte do programa principal em LabVIEW.




Figura A.3 – Segunda parte do programa principal em LabVIEW.

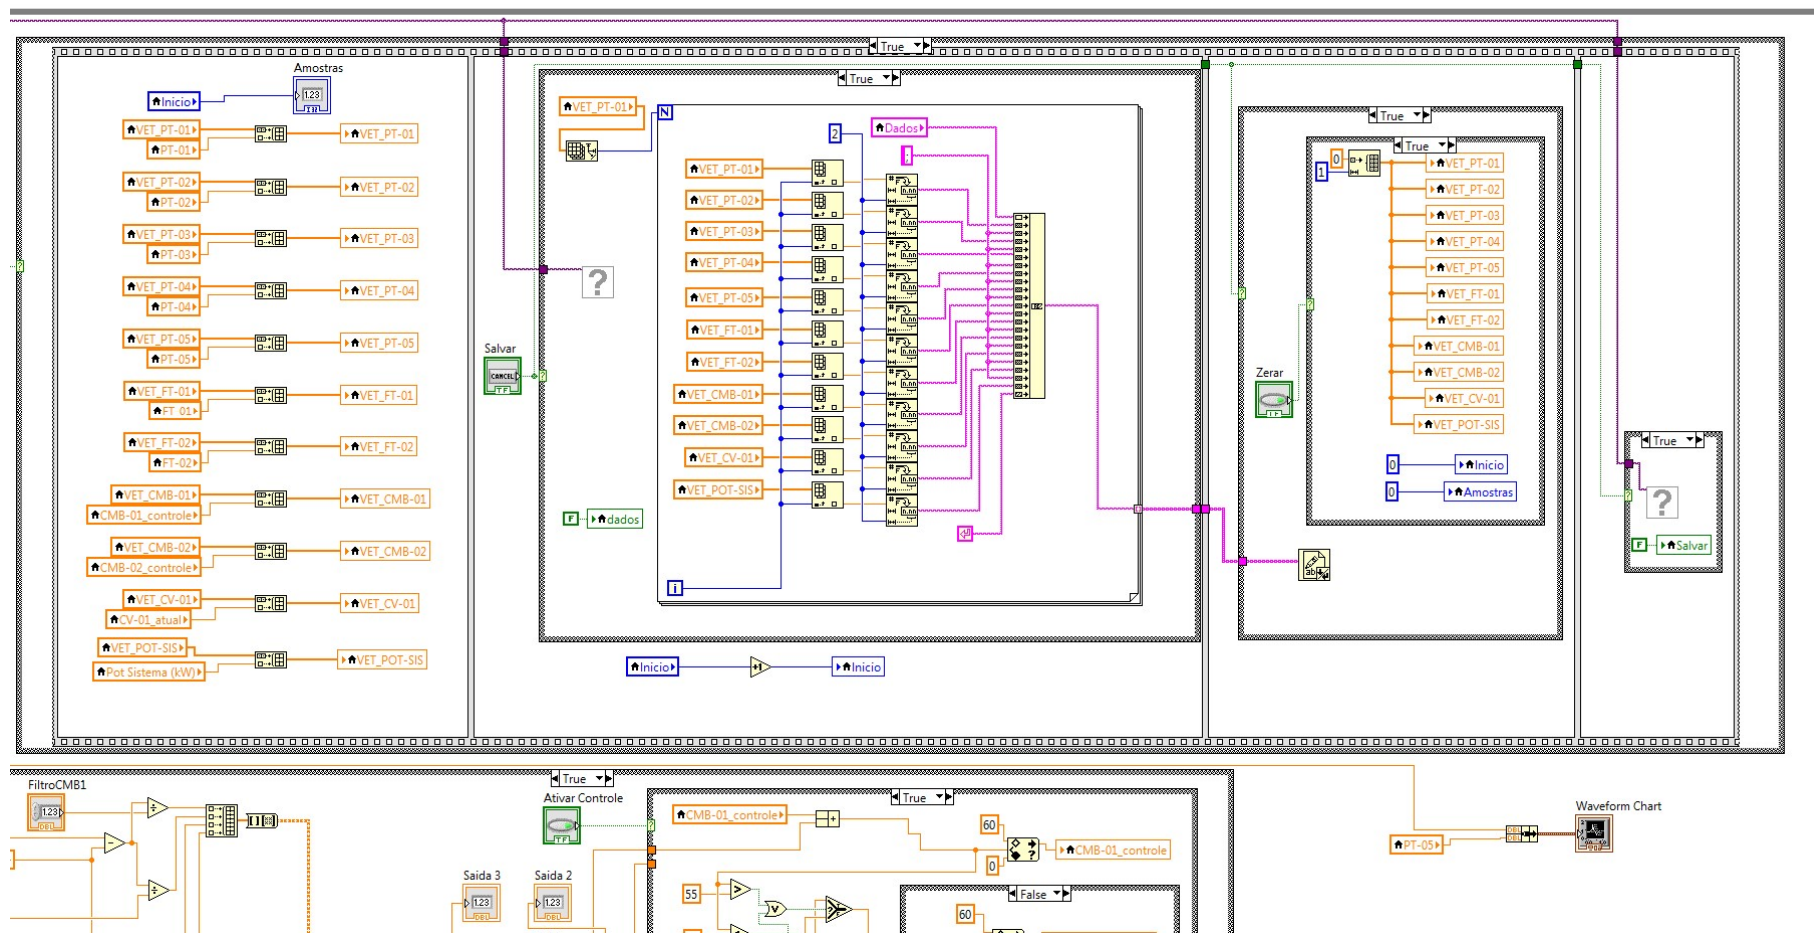



Figura A.4 – Terceira parte do programa principal em LabVIEW.



FiguraA.5 – Quarta parte do programa principal em LabVIEW.

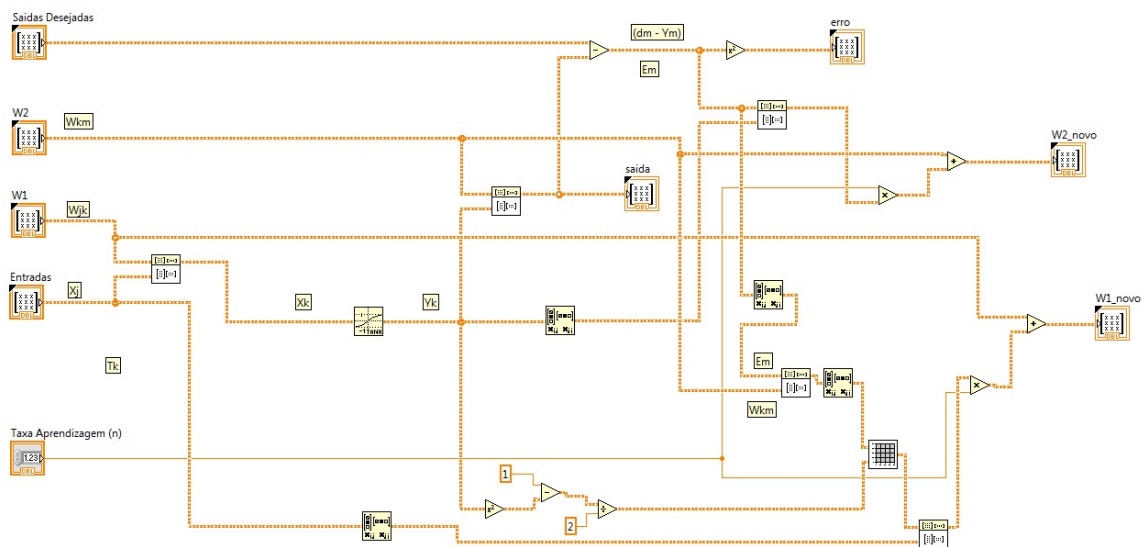


Figura A.6 – Algoritmo da RNA desenvolvida em LabVIEW.