



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

**SISTEMAS DE CONTROLE *FUZZY* NEURAL E
NEURAL ADAPTATIVO DESTINADOS AO
CONTROLE DE PRESSÃO EM REDE DE
DISTRIBUIÇÃO DE ÁGUA**

por

Geraldo de Araújo Moura

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



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

Geraldo de Araújo Moura

**Sistemas de Controle *Fuzzy* Neural e Neural Adaptativo Destinados ao
Controle de Pressão em Rede de Abastecimento de Água**

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.

Orientador: Professor Dr. Heber Pimentel Gomes

João Pessoa – PB

Novembro – 2016

M929s Moura, Geraldo de Araújo.

Sistemas de controle *fuzzy* neural e neural adaptativo destinados ao controle de pressão em rede de abastecimento de água / Geraldo de Araújo Moura.-João Pessoa, 2016.

140f. : il.

Orientador: Heber Pimentel Gomes

Tese (Doutorado) -UFPB/CT

1. Engenharia mecânica. 2. Controle fuzzy. 3. Redes neurais artificiais. 4. Eficiência energética. 5. Rede de distribuição. 6. LabVIEW®

UFPB/BC

CDU: 621(043)

Ao meu filho

*“Essa cova em que estás
Com palmos medida
É a conta menor
Que tiraste em vida
É de bom tamanho
Nem largo nem fundo
É a parte que te cabe neste latifúndio”*

João Cabral de Melo Neto (*Morte e Vida Severina*)

AGRADECIMENTOS

Inicialmente gostaria de agradecer aos órgãos federais responsáveis pela promoção do ensino superior público e gratuito em nosso país.

Ao Programa de Pós Graduação em Engenharia Mecânica PPGEM, em nome do coordenador José Hilton, do corpo administrativo composto por Mônica Rodrigues e Noaldo Sales.

Aos professores, Antônio Cabral, Antônio Riul, Heber Pimentel (orientador), Francisco Belo, Jean Pierre, Rogério Kluppel, Saulo Bezerra, Tarciso Cabral da Silva, Simplício Arnaud pela disponibilidade nos momentos de apoio.

Ao Laboratório de Eficiência Energética e Hidráulica da Universidade Federal da Paraíba LENHS –UFPB, em nome dos coordenadores Heber Pimentel e Moisés Salvino; dos colaboradores Kenny Roger, Renato e Daniel pela contribuição prestada sempre que foram solicitados.

Aos alunos da PPGEM, Arthur Diniz, Anne Monteiro, Emanuel Guerra, Eudisley Gomes, José Kleber, Kamilla Mendonça, Kenny Roger, Lais Salvino, Renato de Souza e Tatiana Simões.

A minha família, em nome das minhas irmãs: Vera, Regina, Leonor e Rosa; da minha mãe Maria José Moura; do meu filho Gabriel Moura e à memória do meu irmão Marcos Moura e do meu pai Geraldo Pinto de Moura e Silva.

SISTEMAS DE CONTROLE *FUZZY* NEURAL E NEURAL ADAPTATIVO DESTINADOS AO CONTROLE DE PRESSÃO EM REDE DE DISTRIBUIÇÃO DE ÁGUA

RESUMO

Este trabalho tem como objetivo o controle de pressão em redes de distribuição de água, a fim promover a otimização das cargas hidráulicas, buscando minimizar as perdas de água nas tubulações e de energia no correspondente sistema de bombeamento. Para tanto foram elaborados um sistema de controle *fuzzy* neural (SCFN) e um sistema de controle neural adaptativo (SCNA). Esses sistemas de controle foram testados e avaliados em uma bancada experimental. O sistema de controle *fuzzy* neural (SCFN) envolve técnicas de rede neural artificial (RNA) e lógica *fuzzy*. O sistema de controle neural adaptativo (SCNA) utilizou uma RNA do tipo Perceptron de múltiplas camadas, através da técnica de retropropagação (*backpropagation*) e gradiente descendente com otimizador de Levenberg-Marquardt. O controle de pressão é realizado através do conversor de frequência, com ajustes da frequência, em tempo real (*on-line*), que atuará sobre conjunto motor bomba (CMB) instalado na rede hidráulica da bancada experimental. Os sistemas de controle SCFN e o SCNA, apresentados neste trabalho, foram confrontados a fim de promover uma análise comparativa entre os controladores. Os resultados demonstraram que o SCNA apresentou especificações superiores ao SCFN em quase sua totalidade. Finalmente foi acrescentado um filtro lógico ao SCADA (*supervisory control system and data acquisition*) para tornar o SCNA capaz de controlar alternadamente a pressão mínima dentre pontos da rede de distribuição da bancada experimental. Ambos os sistemas de controle, SCFN e SCNA foram desenvolvidos em ambiente de programação LabVIEW®.

Palavras-chave: Controle *fuzzy*, Redes Neurais Artificiais, Eficiência Energética, Rede de Distribuição, LabVIEW®.

FUZZY NEURAL AND NEURAL ADAPTATIVE CONTROL SYSTEMS FOR PRESSURE CONTROL IN WATER DISTRIBUTION NETWORK

ABSTRACT

This work deals with pressure control in water distribution networks to promote the optimization of hydraulic loads in order to minimize water losses in the pipes and energy in the corresponding pumping system. Therefore, a neural fuzzy control system (NFCS) beyond the adaptive neural control system (ANCS) were developed. These control systems have been tested and evaluated on experimental bench. The neural fuzzy control system (NFCS) involves techniques of artificial neural network (ANN) and fuzzy logic. The adaptive neural control system (ANCS) used a ANN Perceptron type multilayer by backpropagation technique and gradient descent with Levenberg-Marquardt optimizer. The pressure control will be through the frequency inverter with frequency adjustments in real time, which will act on pump motor assembly installed in the trial bench hydraulic network. Control systems NFCS and ANCS, in this work, were confronted in order to promote a comparative analysis between controllers. The results showed that the ANCS reached a performance index greater than NFCS almost entirely. Finally it was added a logic filter to supervisory control and data acquisition system (SCADA) to make the ANCS able to alternately control the minimum pressure points from the distribution network of experimental bench. Both control systems, ANCS and NFCS were developed in programming environment LabVIEW®.

Key-words: Fuzzy Control, Artificial Neural Network, Energy Efficiency, Distribution Network, LabVIEW®.

SUMÁRIO

1. INTRODUÇÃO	1
1.1. OBJETIVOS GERAIS.....	3
1.2. OBJETIVOS ESPECÍFICOS.....	4
2. REVISÃO BIBLIOGRÁFICA	5
2.1. SISTEMA DE DISTRIBUIÇÃO DE ÁGUA.....	5
2.2. SISTEMAS <i>FUZZY</i>	13
2.2.1. Aspectos Históricos	13
2.2.2. Lógica e Sistema de Controle.....	14
2.2.3. Método Mandani	20
2.2.4. Método de Larsen	20
2.2.5. Método de Tsukamoto.....	21
2.2.6. Método de Takagi-Sugeno-Kang.....	22
2.3. REDES NEURAIAS ARTIFICIAIS	23
2.3.1. Aspectos Históricos	23
2.3.2. Considerações Gerais	25
2.3.3. Rede Perceptron de Única Camada	27
2.3.4. Rede Andaline	30
2.3.5. Rede Perceptron de Múltiplas Camadas.....	32
2.3.5. Otimizador de Levenberg-Marquardt Aplicado as Redes Neurais Artificiais.....	34
3. ESTADO DA ARTE.....	37
3.1. OPERAÇÃO E AUTOMAÇÃO EM SISTEMAS DE DISTRIBUIÇÃO DE ÁGUA.....	

.....	37
3.2. CONVERSOR DE FREQUÊNCIA APLICADO À CMB.....	40
3.3. SISTEMAS <i>FUZZY</i> E REDES NEURAS ARTIFICIAIS - RNA.....	43
3.3.1. Sistemas de Distribuição de Água.....	44
3.3.2. Níveis de Reservatórios Superficial e Subterrâneo	46
3.3.3. Previsões de Vazão e Demandas de Água.....	47
3.3.4. Previsões de Precipitação e Preenchimento de Falhas Hidrológicas.....	49
3.3.5. Qualidade da Água	50
4. MATERIAIS E MÉTODOS.....	51
4.1. INTRODUÇÃO	51
4.2. BANCADA EXPERIMENTAL	52
4.3. EQUIPAMENTOS	55
4.4. SISTEMAS SUPERVISÓRIO E DE AQUISIÇÃO DE DADOS.....	57
4.5. SISTEMA DE CONTROLE NEURAL NÃO ADAPTATIVO	59
4.6. SISTEMA DE CONTROLE <i>FUZZY</i>	63
4.7. SISTEMA DE CONTROLE <i>FUZZY</i> NEURAL.....	67
4.8. SISTEMA DE CONTROLE NEURAL ADAPTATIVO COM OTIMIZADOR DE LEVENBERG-MARQUARDT.....	75
5. RESULTADOS E DISCUSSÕES	79
5.1. SISTEMA DE CONTROLE NEURAL NÃO ADAPTATIVO (SCN).....	79
5.2. SISTEMA DE CONTROLE <i>FUZZY</i> (SCF).....	83
5.3. SISTEMA DE CONTROLE <i>FUZZY</i> NEURAL (SCFN).....	84
5.4. SISTEMA DE CONTROLE NEURAL ADAPTATIVO (SCNA)	88
5.5. COMPARATIVO ENTRE OS CONTROLADORES: NEURAL ADAPTATIVO (SCNA) E <i>FUZZY</i> NEURAL (SCFN).....	92
5.6. SCNA PARA O CONTROLE ALTERNADO DE PRESSÃO MÍNIMA SOBRE QUATRO PONTOS DA REDE DE DISTRIBUIÇÃO DA BANCADA	

EXPERIMENTAL (BE)	94
6. CONCLUSÕES E RECOMENDAÇÕES	96
6.1. CONCLUSÕES	96
6.2. RECOMENDAÇÕES	98
7. REFERÊNCIAS BIBLIOGRÁFICAS	100
APÊNDICES A – APLICATIVOS	109
APÊNDICE - A.1 LIMPADOR DE ZERO	109
APÊNDICE - A.2. ELIMINADOR DE DADOS INCONSISTENTES	111
APÊNDICE - A.3. MULTIPLICADOR DE DADOS	113
APÊNDICE - A.4 MISTURADOR DE DADOS	114
APÊNDICE - A.5. TREINAMENTO DA RNA	115
APÊNDICE - A.6. VALIDAÇÃO DA RNA.....	119
APÊNDICE - A.7. SISTEMA <i>FUZZY</i> MANDANI	122
APÊNDICE - A.8. TREINAMENTO DA RNA ADAPTATIVA.....	126
ANEXO A – MÉTODO DO GRADIENTE DESCENDENTE COM RETROPROPAGAÇÃO (<i>BACKPROPAGATION</i>) APLICADO AS REDES NEURAS ARTIFICIAIS - RNA	130
ANEXO B – MÉTODO DE LEVENBERG-MARQUARDT APLICADO AS REDES NEURAS ARTIFICIAIS - RNA	137

LISTA DE FIGURAS

Figura 2.1 – Conjunto Motor-Bomba Acima do Nível do Reservatório Inferior.....	6
Figura 2.2 – Conjunto Motor-Bomba Abaixo do Nível do Reservatório Inferior (<i>afogada</i>)	6
Figura 2.3 Comportamento das Curvas Características das Bombas	7
Figura 2.4 – Curvas Características de Conjunto Motor-Bomba	7
Figura 2. 5 – Catálogo para Seleção Prévia de Conjunto Motor-Bomba	8
Figura 2.6 – Curvas Características do CMB e do Sistema	8
Figura 2.7 – Ponto de Trabalho (PT) a Direita de Ponto de Máxima Eficiência (PME).....	9
Figura 2.8 – PT Coincidente com o Ponto de Máxima Eficiência (PME)	9
Figura 2. 9 – Curvas Características para Rotação Variável	11
Figura 2. 10 – Uso do Conversor de Frequência e Grandezas Características.....	11
Figura 2. 11 – Conjunto <i>Crisp</i>	15
Figura 2.12 – Conjunto <i>Fuzzy</i>	15
Figura 2.13 – Variável <i>Fuzzy Y</i>	17
Figura 2.14 – Mecanismo de Inferência Mandani.....	20
Figura 2.15 - Mecanismo de Inferência Larsen.....	21
Figura 2.16 – Mecanismo de Inferência Tsukamoto.....	22
Figura 2.17 – Mecanismo de Inferência Takagi-Sugeno-Kang.....	22
Figura 2.18 – Neurônio Biológico.....	24
Figura 2.19 – Neurônio Artificial.....	25

Figura 2.20 – Funções Parcialmente Diferenciáveis: (a) Degrau; (b) Degrau Bipolar e (c) Rampa.....	26
Figura 2.21 – Funções Totalmente Diferenciáveis: (a) Tangente Hiperbólica; (b) Gaussiana e (c) Logística.....	26
Figura 2.22 – Rede Perceptron de Única Camada.....	28
Figura 2.23 – Rede Andaline de Única Camada	30
Figura 2.24 – Rede Perceptron com Múltiplas Camadas	33
Figura 4.1 – Representação Esquemática de um Sistema de Distribuição de Água	52
Figura 4.2 – Bancada Experimental	52
Figura 4.3 – Estação de Bombeamento	53
Figura 4.4 – Planta Baixa do Bancada Experimental	54
Figura 4.5 – Conjunto motor-bomba	55
Figura 4.6 – Conversor de Frequência	55
Figura 4.7 – Transdutor de Pressão	56
Figura 4.8 – Transdutor de Vazão	56
Figura 4.9 – Válvula de Controle Proporcional.....	56
Figura 4.10 – Controlador Lógico Programável.....	57
Figura 4.11 – Painel de Controle do SCADA (código fonte).....	58
Figura 4.12 – Painel Frontal do SCADA.....	58
Figura 4.13 – Arquitetura da Rede Neural de Projeto	60
Figura 4.14 – Diagrama de Blocos do Controlador Neural em Malha Aberta.....	61
Figura 4.15 – Painel de Controle do SCN, (código fonte)	62
Figura 4.16 – Painel Frontal do SCN	62
Figura 4.17 – Variável <i>Fuzzy</i> da Pressão.....	63
Figura 4.18 – Variável <i>Fuzzy</i> da Derivada da Pressão	64
Figura 4.19 – Variável <i>Fuzzy</i> do Gradiente de Rotação do Conversor de Frequência.....	64

Figura 4.20 – Diagrama de Blocos do Controlador <i>Fuzzy</i> em Malha Fechada.....	65
Figura 4.21– Painel de Controle do SCF, (código fonte)	66
Figura 4.22 – Painel Frontal do SCF	66
Figura 4.23 – Pressão Calculada pela RNA frente a Demandas na Rede	68
Figura 4.24 – Variável <i>Fuzzy</i> Antecedente Erro da Pressão.....	70
Figura 4.25 – Variável <i>Fuzzy</i> Consequente Gradiente de Rotação	71
Figura 4.26 – Diagrama de Blocos Controlador <i>Fuzzy</i> Neural em Malha Fechada	73
Figura 4.27 – Painel de Controle do SCFN	74
Figura 4.28 – Painel de Frontal do SCFN	74
Figura 4.29 – Sistema de Controle Neural Adaptativo.....	76
Figura 4. 30 – Esquema de Ação do Controlador Neural Adaptativo.....	77
Figura 4.31 – Painel de Controle do SCNA	78
Figura 4.32 – Painel de Frontal do SCNA.....	78
Figura 5.1 – Validação da RNA Não Adaptativa.	79
Figura 5.2 – Curva de Resposta da Pressão sob a Atuação do Sistema de Controle Neural (SCN) – Caso 01.....	81
Figura 5.3 – Curva de Resposta do Inversor de Frequência para o Sistema de Controle Neural (SCN) – Caso 01	81
Figura 5.4 – Curva de Resposta da Pressão sob a Atuação do Sistema de Controle Neural (SCN) – Caso 02.....	82
Figura 5.5 – Curva de Resposta do Inversor de Frequência para o Sistema de Controle Neural (SCN) – Caso 02.....	82
Figura 5.6 – Curva de Resposta da Pressão sob a Atuação do Sistema de Controle <i>Fuzzy</i> (SCF)	83
Figura 5.7 – Curva de Resposta do Inversor de Frequência para o Sistema de Controle <i>Fuzzy</i> (SCF).....	83

Figura 5.8 – Curva de Resposta da Pressões dos Sistemas de Controle SCN, SCF e do SCFN	84
Figura 5.9 – Curva de Resposta do Inversor de Frequência para os Sistemas de Controle SCN, SCF e do SCFN	85
Figura 5.10 – Curva de Resposta da Pressão sob a Atuação do Sistema de Controle Fuzzy Neural (SCFN) submetido a várias pressões de referência	86
Figura 5.11 – Curva de Resposta do Inversor de Frequência para o Sistema de Controle Fuzzy Neural (SCFN) submetido a várias pressões de referência.....	86
Figura 5.12 – Curva de Resposta da Pressão sob a Atuação do Sistema de Controle <i>Fuzzy</i> Neural (SCFN) submetido a uma perturbação	87
Figura 5.13 – Curva de Resposta do Inversor de Frequência para o Sistema de Controle <i>Fuzzy</i> Neural (SCFN) submetido a uma perturbação	87
Figura 5.14 – Validação da RNA Adaptativa.....	88
Figura 5.15 – Curva de Resposta da Pressão sob a Atuação do Sistema de Controle Neural Adaptativo (SCNA)	89
Figura 5.16 – Curva de Resposta do Inversor de Frequência para o Sistema de Controle Neural Adaptativo (SCNA)	89
Figura 5.17 – Curva de Resposta da Pressão sob a Atuação do Sistema de Controle Neural Adaptativo (SCNA) submetido a várias pressões de referência.....	90
Figura 5.18 – Curva de Resposta do Inversor de Frequência para o Sistema de Controle Neural Adaptativo (SCNA) submetido a várias pressões de referência.....	91
Figura 5.19 – Curva de Resposta da Pressão sob a Atuação do Sistema de Controle Neural Adaptativo submetido a uma perturbação	91
Figura 5.20 – Curva de Resposta do Inversor de Frequência para o Sistema de Controle Neural Adaptativo submetido a uma perturbação	92
Figura 5.21 – Curva de Resposta das Pressões sob a Atuação dos Sistemas de Controle Neural Adaptativo (SCNA) <i>versus</i> Sistema de Controle <i>Fuzzy</i> Neural (SCFN) – Caso 01	92

Figura 5.22– Curva de Resposta do Inversor de Frequência para os Sistema de Controle Neural Adaptativo (SCNA) versus Frequência do Sistema de Controle <i>Fuzzy</i> Neural (SCFN) – Caso 01	93
Figura 5.23 – Curva de Resposta das Pressões sob a Atuação do Sistema de Controle Neural Adaptativo (SCNA) <i>versus</i> Sistema de Controle <i>Fuzzy</i> Neural (SCFN) – Caso 02	93
Figura 5.24 – Curva de Resposta do Inversor de Frequência para os Sistema de Controle Neural Adaptativo (SCNA) <i>versus</i> Sistema de Controle <i>Fuzzy</i> Neural (SCFN) – Caso 02.	93
Figura 5.25 – Curva de Resposta da Pressão sob a Atuação do SCNA com Controle Alternado do Ponto Pressão Mínima	95
Figura 5.26 – Curva de Resposta do Inversor de Frequência para o SCNA submetido ao Controle Alternado do Ponto Pressão Mínima	95

LISTA DE TABELAS

Tabela 2.1 – Propriedades mais Significativas da Teoria dos Conjuntos <i>Fuzzy</i>	16
Tabela 4.1 – Varável <i>Fuzzy</i> Antecedente do Erro da Pressão	70
Tabela 4.2 – Varável <i>Fuzzy</i> Consequente Gradiente de Rotação	71
Tabela 4.3 – Base de Regras.....	72
Tabela 5.1 – Parâmetros da RNA Não Adaptativa.....	80
Tabela 5.2 – Especificações do Sistema de Controle Neural (SCN).....	82
Tabela 5.3 – Especificações do Sistema de Controle Fuzzy (SCF).....	84
Tabela 5.4 – Especificações do Sistema de Controle <i>Fuzzy</i> Neural (SCFN)	85
Tabela 5.5 – Parâmetros da RNA Adaptativa.....	88
Tabela 5.6 – Especificações para os SCFN e SCNA.....	90
Tabela 5.7 Especificações para os SCFN e SCNA.....	94
Tabela 6.1 – Especificações para os SCFN e SCNA.....	98

LISTA DE ABREVIATURAS E SIGLAS

ANN – Artificial Neural Network
AWWA – American Water Works Association
BE – Bancada Experimental
CF – Conversor de Frequência
CLP – Controlador Lógico Programável
CMB – Conjunto Motor Bomba
Crisp – Conjunto Clássico
DMC – Distrito de Medição e Controle
GIS – Geographic Information System
IWA – International Water Association
LabVIEW® – Laboratory Virtual Instrument Engineering
LENHS – Laboratório de Eficiência Energética e Hidráulica em Saneamento;
MCP – Rede Lógica de Neurônios artificiais desenvolvida por McCulloch e Pitts
NI – National Instruments
NPSH – Net Positive Suction Head
NPSH_d – NPSH disponível
NPSH_r – NPSH requerido
PME – Ponto de Máxima Eficiência
PROCEL SANEAR – Programa Nacional de Conservação de Energia para o Setor de Saneamento
PT – Ponto de Trabalho
RDA – Rede de Distribuição de Água
RNA – Redes Neurais Artificiais
SAA – Sistema de Distribuição de Água
SAD – Sistema de Aquisição de Dados

SCF – Sistema de Controle *Fuzzy*
SCN – Sistema de Controle Neural
SCNA – Sistema de Controle Neural Adaptativo
SCFN – Sistema de Controle Fuzzy Neural
SDA – Sistema de Distribuição de Água
SNIS – Sistema Nacional de Informação sobre Saneamento
SS – Sistema Supervisório
ZMC – Zona de Medição e Controle
TSK – Takagi-Sugeno-Kang

LISTA DE SIMBOLOS

I_t – Índice de Desempenho no Instante t

e – entrada

i – camada intermediária

s – camada de saída

j – j -ésimo elemento de entrada e

k – k -ésimo neurônio da camada intermediária i

m – m -ésimo neurônio da camada de saída s

X_j^e - j -ésimo elemento de entrada e

Y_j^e - j -ésimo elemento de entrada e

t – tempo

I_t – índice de desempenho no instante t

Eq_t – erro quadrático no instante de tempo t

$E_{m,t}^s$ – erro no m -ésimo neurônio da camada s no instante de tempo t

$D_{m,t}^s$ – m -ésima saída desejada da camada s no instante de tempo t

μ – Coeficiente de Aprendizado

λ – Parâmetro de Levenberg-Marquardt

$W_{jk(t)}^{ei}$ – Peso entre o neurônio de entrada j e o neurônio da camada intermediária k , no instante de tempo t

$W_{km(t)}^{is}$ – Peso entre o neurônio da camada intermediária k e o neurônio da camada de saída m , no instante de tempo t

$\beta_{k(t)}^i$ – *Beta* da função de ativação tangente hiperbólica da camada intermediária i e neurônio k , no instante de tempo t

$T_{k(t)}^i$ – Limiar de ativação (*bias*) da camada intermediária i neurônio k

X_k^i – k -ésimo elemento de entrada da camada intermediária i

Y_k^i – k -ésimo elemento de saída da camada intermediária i

X_m^s – m -ésimo elemento de entrada da camada de saída s
 Y_m^s – m -ésimo elemento de saída da camada de saída s
 B – é uma propriedade qualquer do fluido (energia, massa e etc)
 β – é a derivada da propriedade B no tempo. $\frac{dB}{dt}$
 V – é o vetor de velocidades
 A – é a área
 Re – Número de Reynolds, adimensional.
 V – Velocidade
 D – Diâmetro
 ρ – Massa específica
 ν – Viscosidade cinemática
 p_1 – Pressão na seção 1
 p_2 – Pressão na seção 2
 v_1 – Velocidade na seção 1
 v_2 – Velocidade na seção 2
 z_1 – Cota da seção 1
 z_2 – Cota da seção 2
 γ – Peso específico do líquido
 g – Aceleração da gravidade
 H_f – diz respeito as perdas de carga
 H_c – Perda de carga contínua ou linear
 H_l – Perda de Carga localizada
 C – Coeficiente de rugosidade do tubo
 L – Comprimento da tubulação
 f – Coeficiente adimensional
 H – Altura manométrica
 Q – Vazão
 N – velocidade de rotação
 D_r – Diâmetro externo do rotor
 P_{hid} – Potência hidráulica ou útil
 $NPSH_d$ – NPSH disponível
 P_v – Pressão de vapor do líquido
 Hg_s – Desnível geométrico de sucção

Hf_s – Perda de carga na sucção

$\mu_A(x)$ – pertinência do valor x com relação ao conjunto A

v_{e1} – variável de entrada 1

v_{e2} – variável de entrada 2

f_{pve1} – Função de pertinência da variável de entrada 1

f_{pve2} – Função de pertinência da variável de entrada 2

CG_f – Centro de gravidade da função de pertinência inferida

A_f – Área da função de transferência inferida

Z^* – Valor defuzificado ou *crisp* da variável de saída

$\mu_c(Z_i)$ – Valor *fuzzy* da variável Z, relativa a i-ésima função de pertinência

CAPÍTULO I

INTRODUÇÃO

O abastecimento de água potável dos centros urbanos envolvem obras de engenharia que vão desde a captação, passando pelo tratamento, até distribuição e entrega ao usuário final. As Estações de Bombeamento são responsáveis pela pressurização da rede de distribuição de água de maneira direta ou indireta, com auxílio de reservatórios elevados. A complexidade enfrentada pelos sistemas de abastecimentos de água decorrem, dentre outros fatores, da heterogeneidade da topologia das zonas a serem abastecidas. Desta forma o sistema é exigido a atender concomitantemente, com vazões e pressões adequadas, a população localizada em zonas de topografia altas e baixas. Estas disparidades devem ser enfrentadas através do uso de estratégias que promovam a adequação entre os valores de pressão e vazão ao longo de toda a rede de distribuição.

Dados do Programa Nacional de Conservação de Energia para o setor de saneamento (PROCEL SANEAR) indicam que cerca de 10 bilhões de Kwh/ano são consumidos nos serviços de saneamento, o equivalente a 3% de consumo de energia total do país (GOMES, 2009). Este consumo refere-se aos vários setores envolvidos no abastecimento de água e esgoto dos centros urbanos. Entretanto, a grande monta destes custos, recai sobre os sistemas de bombeamento, em torno de 90%. No mundo, atualmente, estima-se que estes sistemas poderiam economizar cerca de 25% da energia consumida (GOMES, 2009). Diante do cenário mundial, em que pese o uso restritivo de combustíveis fósseis, era de se esperar o grande empenho das concessionárias de água e esgoto no sentido de reduzir os seus gastos de energia. Os dados são contundentes e corroboram neste sentido. As empresas prestadoras de serviço de saneamento estão buscando adotar medidas

para aumentar a sua eficiência energética. As questões relativas aos aspectos ambientais contribuem ainda mais neste sentido reforçando e incentivando a necessidade dessas ações.

Com relação as perdas de água, o Banco Mundial atesta que mais de 32 bilhões de metros cúbicos de água tratada são perdidos todos os anos por causa de vazamentos nos sistemas urbanos de abastecimento de água, enquanto 16 bilhões de metros cúbicos são entregues aos clientes gratuitamente (BEZERRA e CHEUNG, 2013). A ausência de gestão eficaz no saneamento, associada às estruturas físicas deterioradas são fatores que contribuem com a incidência das perdas de água nos sistemas de abastecimento de água. Além desses aspectos é importante destacar que as perdas não é um fenômeno isolado. A sua incidência promove o aumento das demandas de água dos mananciais e tratamento, além de contribuir com o aumento dos custos com energia elétrica, manutenção e controle operacional das redes. A divisão das redes hidráulicas de água em zonas de distribuição tem se tornado um procedimento importante no controle das perdas nessas redes.

Além de proporcionar a diminuição do consumo de energia elétrica, o controle de pressão é fundamental para a redução das perdas reais de água nos sistemas urbanos de distribuição de água, pois quanto maior a pressão maiores serão as perdas nos possíveis vazamentos das tubulações. Ademais, a pressão excessiva onera, desnecessariamente, os custos energéticos de bombeamento, provocando avarias nas tubulações e acessórios, além de contribuir com a redução da vida útil dos equipamentos.

O controle da pressão é o procedimento mais efetivo para aumentar a eficiência dos sistemas de distribuição de água (TSUTIYA, 2007). As implicações incidem positivamente sobre o aumento da vida útil dos sistemas, a redução de custos com a operação e manutenção, a diminuição nas interrupções do fornecimento de água, a redução sobre os vazamentos e conseqüentemente o aumento da credibilidade das companhias de saneamento junto ao consumidor final. Alguns equipamentos, como os conversores de frequência e as válvulas de controle de pressão, são fortes aliados na otimização dos níveis de pressão nos sistemas de abastecimento de água.

A ferramenta mais eficiente para o controle de pressão e eficiência energética nas redes de distribuição de água são os sistemas de automação e controle, que tem recebido grande atenção por parte dos pesquisadores e técnicos. Os benefícios obtidos não se restringem apenas a diminuição das despesas com energia elétrica. A redução das perdas reais de água também é significativa, além da redução, significativa, da mão de obra

empregada na operação e manutenção dos sistemas de abastecimento.

A automação de um sistema de abastecimento de água envolve a instrumentação da rede com uso dos transdutores de pressão e vazão, conversores de frequência, válvulas de controle, sensores de temperatura, controlador lógico programável, além de um eficiente sistema de comunicação. Um sistema supervisorio será de extrema importância no monitoramento, em tempo real, da planta, enquanto os algoritmos computacionais inteligentes cumprem o papel do controle automático dentro dos complexos sistemas de abastecimento de água.

A redação desta tese encontra-se dividida em sete capítulos. O primeiro é introdutório e define explicitamente os objetivos gerais e específicos. O capítulo segundo destina-se a uma revisão bibliográfica dos temas, sistemas de bombeamento, lógica fuzzy, redes neurais artificiais (RNA) e finaliza com a apresentação do otimizador de Levenberg-Marquardt. O capítulo terceiro é destinado ao estado da arte acerca de redes neurais artificiais, lógica fuzzy, automação e controle de pressão em sistemas de bombeamento pelo uso de conversores de frequência. O quarto capítulo apresenta a metodologia empregada na elaboração do sistema de controle fuzzy neural (SCFN) e do sistema de controle neural adaptativo (SCNA), incluindo uma análise comparativa entre as duas abordagens. O quinto capítulo está reservado a uma apresentação e discussão dos resultados apresentados pelos SCFN, SCNA e a adaptação do SCNA no controle alternado da pressão mínima da BE. O sétimo capítulo aborda aspectos relativos à conclusão e recomendação para trabalhos futuros. O sétimo e último capítulo é destinado à bibliografia utilizada, seguido pelos apêndices A, B e C.

1.1. OBJETIVOS GERAIS

O objetivo deste trabalho é o desenvolvimento de sistemas de controle inteligentes com a finalidade de otimizar as pressões em uma rede de distribuição de água visando reduzir as perdas de água e o consumo de energia nos sistemas de bombeamento. Para isso foram utilizadas técnicas baseadas em sistema de controle *fuzzy* neural (SCFN) com acionamento condicionado em sistema de controle neural adaptativo (SCNA) com otimizador de Levenberg-Marquardt (LM).

1.2. OBJETIVOS ESPECÍFICOS

- Desenvolver um algoritmo baseado em redes neural artificial, através do método de retropropagação (*backpropagation*) e do gradiente descendente, capaz de realizar as etapas do treinamento e de validação com a bancada experimental desativada (*off-line*).
- Desenvolver um sistema de controle por RNA, tomando por base as características obtidas nas fases de treinamento e validação da RNA, na plataforma LabVIEW®.
- Desenvolver um algoritmo *fuzzy* capaz de realizar todo o processo de *fuzzificação* da variável antecedente e a *defuzzificação* da variável consequente, baseado em regras do tipo *Mandani*.
- Desenvolver um sistema de controle *fuzzy Neural* que atue sobre o sistema garantindo a estabilização da pressão, na plataforma LabVIEW®.
- Desenvolver um algoritmo baseado em redes neural artificial, através do método de retropropagação (*backpropagation*), do gradiente descendente e otimizado por Levenberg-Marquardt, capaz de realizar as etapas do treinamento e de validação com a bancada experimental (*off-line*).
- Desenvolver um sistema de controle neural adaptativo com otimizador de Levenberg-Marquardt, tomando por base as características obtidas nas fases de treinamento e validação da RNA, na plataforma LabVIEW®.
- Ampliar a ação do SCNA para o controle alternado de pressão mínima sobre quatro pontos da rede de distribuição da bancada experimental.

CAPÍTULO II

REVISÃO BIBLIOGRÁFICA

2.1. SISTEMA DE DISTRIBUIÇÃO DE ÁGUA

Os Sistemas de Abastecimento de Água são formados por um conjunto de obras, que envolve a captação, o transporte, o tratamento e a distribuição de água nos centros de demanda. Logo, percebe-se que os sistemas de distribuição de água (SDA) é a última etapa deste processo (HELLER e PÁDUA, 2006).

Do ponto de vista hidráulico, os SDA são caracterizados por possuírem escoamento pressurizado ou a conduto forçado.

No setor de saneamento é comum a necessidade de mover água ou esgoto contra a ação da gravidade através de tubulações pressurizadas. Para isto, faz-se uso de bombas hidráulicas, que do ponto de vista energético são máquinas que convertem a energia mecânica, produzida por um motor, em energia hidráulica, na forma de pressão e energia cinética e/ou potencial. Em princípio qualquer motor pode ser utilizado. Na prática predominam os motores elétricos (ANDRADE FILHO, 2009)

Os sistemas de bombeamento são compostos em sua grande maioria por: tubulações e acessórios da sucção, conjunto motor bomba e tubulações e acessórios do recalque. A figura 2.1 mostra esquematicamente uma estação de bombeamento em que o conjunto motobomba encontra-se acima do nível da água do reservatório inferior. Este fato garante a presença de pressões negativa nas tubulações de sucção.

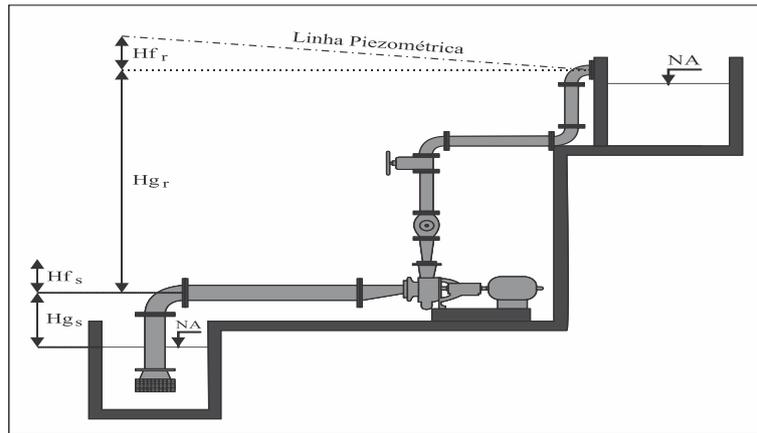


Figura 2.1 – Conjunto Motor-Bomba Acima do Nível do Reservatório Inferior

No entanto, a Figura 2.2 mostra uma situação em que o conjunto motobomba situa-se abaixo do nível da água do reservatório inferior. Neste esquema é comum considerar a bomba como *afogada*.

As vantagens do esquema mostrado na Figura 2.2 sobre o esquema da Figura 2.1, são:

- A bomba encontra-se sempre *escorvada*, ou seja, a tubulação de sucção sempre estará cheia com água. Fato este que praticamente elimina a formação de bolhas de ar e com isso elimina os efeitos de cavitação.
- As pressões na tubulação de sucção serão positivas. Fator este que dispensa qualquer cuidado quanto aos valores de NPSH (*net positive suction head*).

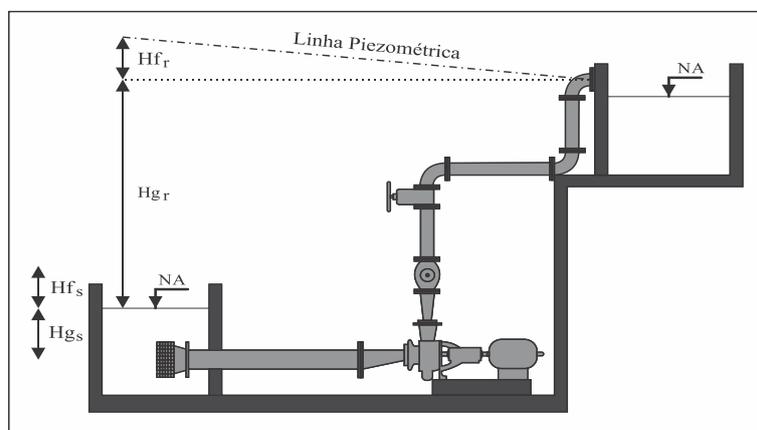


Figura 2.2 – Conjunto Motor-Bomba Abaixo do Nível do Reservatório Inferior (*afogada*)

Existe uma grande variedade de bombas disponíveis no mercado. Entretanto nos Sistemas de Abastecimento de Água, as bombas centrífugas radiais são as mais utilizadas.

O diâmetro dos rotores, o seu posicionamento e a quantidade das pás além da sua largura, produz uma correlação característica entre a altura manométrica e a vazão da bomba, Figura 2.3.

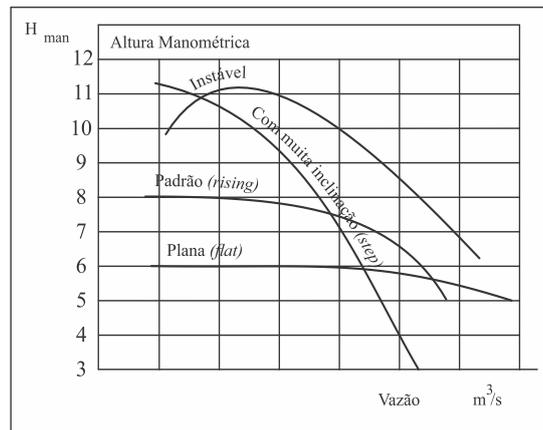


Figura 2.3 Comportamento das Curvas Características das Bombas

A forma plana (*flat*) está normalmente associada a rotores largos, muitas pás e ângulos acentuados. Enquanto que a curva com muita inclinação (*step*) possui característica oposta à forma plana.

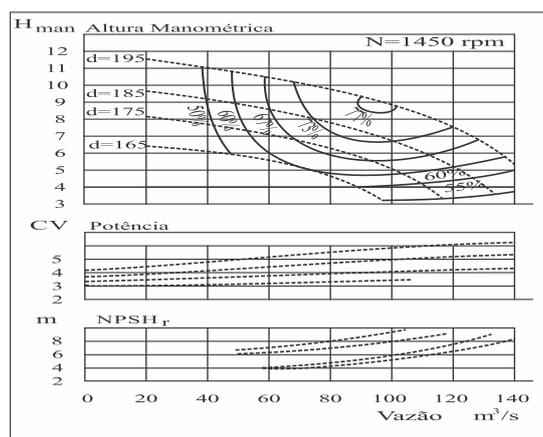


Figura 2.4 – Curvas Características de Conjunto Motor-Bomba

A forma padrão (*rising*) possui valores intermediários entre a forma plana e aquela com muita inclinação. Finalizando, temos a forma instável (*drooping*) que possui a

particularidade de ter altura manométrica máxima superior à altura com registro de recalque fechado (*shut off*).

Uma representação bastante comum utilizada pelos fabricantes de bomba é o de apresentar não apenas a curva altura manométrica versus vazão, mas associar a esta as curvas de rendimento, de potência motriz e de NPSH requerido, Figura 2.4. Conhecida como curvas características do conjunto motobomba.

Outra maneira bem útil de realizarmos uma seleção prévia do equipamento é através da Figura 2.5. Neste caso, necessitamos do par de valores: altura manométrica e vazão como valores de entrada e saímos com o modelo do conjunto motobomba.

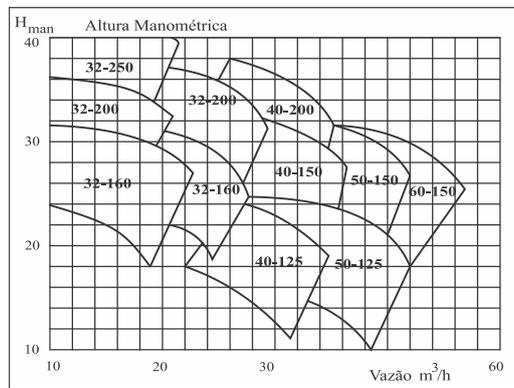


Figura 2. 5 – Catálogo para Seleção Prévia de Conjunto Motor-Bomba

Até aqui mencionamos apenas as características do conjunto motobomba. Agora é necessário apresentar a curva do sistema de bombeamento e confrontarmos essas curvas, como na Figura 2.6.

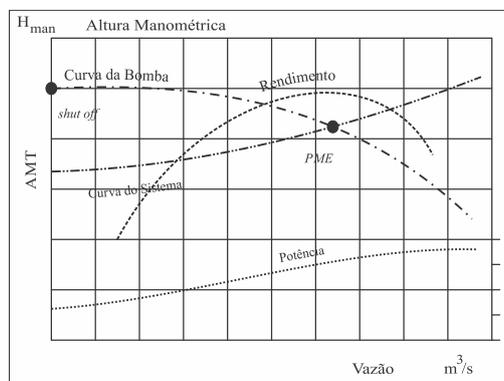


Figura 2.6 – Curvas Características do CMB e do Sistema

Percebamos que o ponto em que as curvas do sistema e do conjunto motobomba se cruzam é denominado de ponto de trabalho (PT). Entretanto é conveniente que conjunto motobomba trabalhe em seu melhor rendimento. Quando temos esta situação o PT passa ser, também o ponto de máxima eficiência (PME) Figura 2.6.

Entretanto, nem sempre é possível essa situação, Figura 2.7. O PT está à direita do PME, o que garante a possibilidade de alterarmos a curva do sistema de tal forma que o PT coincida com o PME. Isto pode ser realizado aumentando as perdas carga através da redução da vazão Figura 2.8.

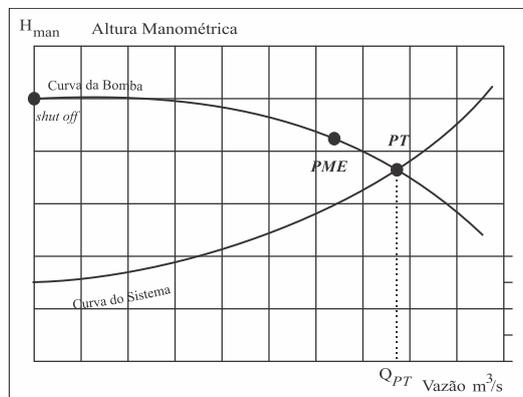


Figura 2.7 – Ponto de Trabalho (PT) a Direita de Ponto de Máxima Eficiência (PME)

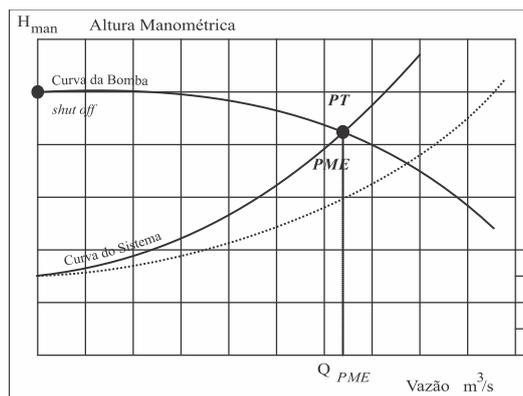


Figura 2.8 – PT Coincidente com o Ponto de Máxima Eficiência (PME)

Poderíamos imaginar esta manobra como o fechamento parcial de um registro localizado a jusante do conjunto motobomba. Entretanto isto só foi possível porque o PT estava à direita do PME. O inverso não seria possível.

As grandezas envolvidas nos sistemas de bombeamento são:

H – Altura manométrica.

Q – Vazão.

N – velocidade de rotação.

D_r – Diâmetro externo do rotor.

P_{hid} – Potência hidráulica ou útil.

De acordo com o teorema de Buckingham, um sistema que depende de n grandezas físicas pode ser reduzido a um sistema envolvendo $k < n$ parâmetros adimensionais. Baseado neste teorema, também conhecido como leis de afinidades, podemos escrever as seis grandezas físicas dos sistemas de bombeamento em três parâmetros adimensionais, equações 2.1, 2.2 e 2.3.

$$\frac{H_1}{N_1^2 D_{r1}^2} = \frac{H_2}{N_2^2 D_{r2}^2} \quad (2.1)$$

$$\frac{Q_1}{N_1 D_{r1}^3} = \frac{Q_2}{N_2 D_{r2}^3} \quad (2.2)$$

$$\frac{P_1}{N_1^3 D_{r1}^5} = \frac{P_2}{N_2^3 D_{r2}^5} \quad (2.3)$$

Com a disponibilidade dos conversores de frequência no mercado, poderíamos reescrever as equações 2.1, 2.2 e 2.3 para a condição em que temos uma mesma bomba. Isto seria a mesma coisa que escrevê-las para a condição em que $D_{r1} = D_{r2}$. A Figura 2.9 ilustra bem esta simulação.

$$\frac{H_1}{N_1^2} = \frac{H_2}{N_2^2} \quad (2.4)$$

$$\frac{Q_1}{N_1} = \frac{Q_2}{N_2} \quad (2.5)$$

$$\frac{P_1}{N_1^3} = \frac{P_2}{N_2^3} \quad (2.6)$$

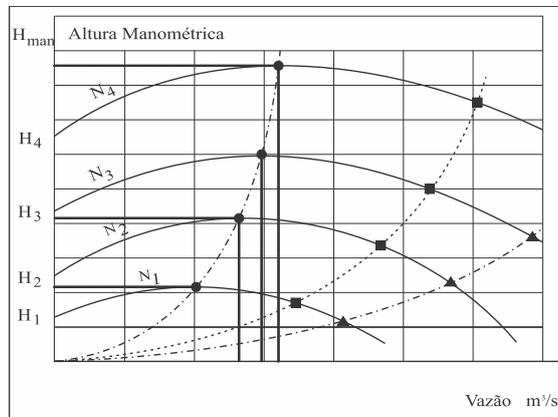


Figura 2. 9 – Curvas Características para Rotação Variável

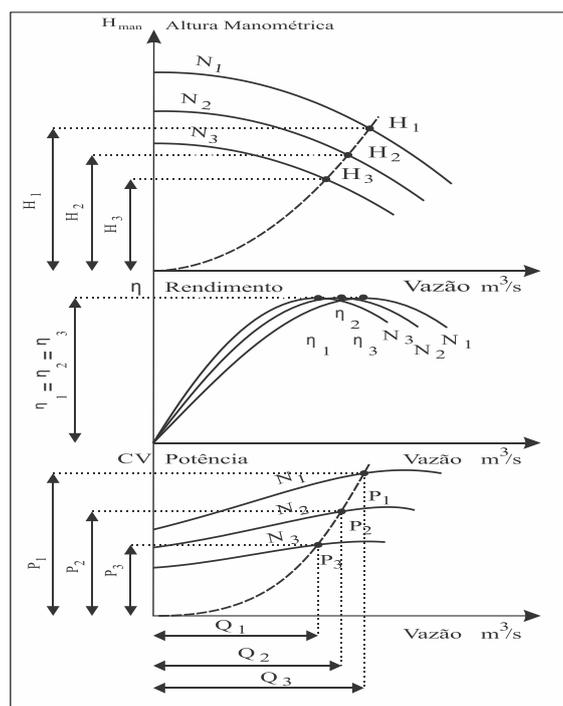


Figura 2. 10 – Uso do Conversor de Frequência e Grandezas Características

Apesar da variação da frequência do conjunto motobomba afetar substancialmente os valores da altura manométrica, da vazão e potência, o mesmo não ocorre com o rendimento. Note que isso implica em dizer que a variação na rotação do conjunto, não implica em variações significativas das perdas, Figura 2.10.

Durante o processo de sucção pode ocorrer a formação de bolhas de ar no interior da tubulação. Essas, por sua vez, são elevadas até a bomba. Quando ultrapassam o rotor provocam martelada que é extremamente prejudicial ao sistema como um todo. A eclosão das bolhas de ar chega a danificar fisicamente o rotor.

Este fenômeno é de extrema importância na captação dos sistemas de bombeamento. Pois deve ser evitado com todo o empenho.

Isto ocorre quando a pressão na entrada da bomba se aproxima da pressão de vapor do líquido a ser bombeado, provocando uma mudança de estado, do líquido para o vapor e conseqüentemente a formação de bolhas de ar.

A fim de evitarmos o efeito de cavitação, temos que garantir que a Inequação 2.7 seja satisfeita.

$$NPSH_d > NPSH_r \quad (2.7)$$

$$NPSH_d = \left(\frac{P_2}{\gamma} + \frac{V_2^2}{2g} \right) - \frac{P_v}{\gamma} \quad (2.8)$$

Onde:

$NPSH_d$ – NPSH disponível.

P_2 – Pressão na entrada da bomba.

γ – Peso específico do líquido.

V_2 – Velocidade do líquido na entrada da bomba.

P_v – Pressão de vapor do líquido, função da temperatura.

Considere dois pontos, 1 e 2, sobre a superfície do reservatório inferior e na entrada da bomba, respectivamente.

O $NPSH_d$ é uma característica do sistema, enquanto o $NPSH_r$ é uma característica da bomba. Portanto, para satisfazer a Inequação 2.7 temos a Equação 2.9.

$$Hg_s = \frac{P_1}{\gamma} - Hf_s - \frac{P_v}{\gamma} - NPSH_d \quad (2.9)$$

Onde:

Hg_s – Desnível geométrico de sucção.

P_1 – Pressão na superfície do reservatório inferior.

Hf – Perda de carga na sucção.

Em algumas situações faz-se necessário o aumento da vazão, mantendo-se a mesma altura manométrica. Neste caso poderíamos recorrer a uma associação de conjuntos motobomba em paralelo. Este procedimento permite funcionar os conjuntos motobomba tanto alternadamente como simultaneamente.

Outra situação pode ocorrer quando se necessita de elevação na altura manométrica, mantendo fixo o valor da vazão. Neste caso pode-se utilizar bombas com múltiplos estágios, ou mesmo, através da associação em série de conjuntos motobomba.

Os motores elétricos de corrente alternada assíncronos são os mais empregados nos SDA. No caso de potências acima de 300cv os motores de corrente alternada síncronos são os mais utilizados (ANDRADE FILHO, 2009).

Os conversores de frequência trabalhando em conjunto com os motores de indução assíncronos é atualmente uma das soluções mais viáveis quando se busca uma maior eficiência energética do sistema. Um dos fatores que ratifica o seu uso é o fato de o rendimento do conjunto motobomba pouco variar com a frequência de rotação, Figura 2.10.

2.2. SISTEMAS *FUZZY*

2.2.1. Aspectos Históricos

Usamos, no cotidiano, conceitos subjetivos para classificar ou considerar certas situações. Expressões como mais ou menos, quase, pouco e muito são igualmente comuns

nas descrições *fuzzy*.

A lógica clássica, *crisp*, ou mesmo a lógica Booleana só admite expressões rígidas, absolutas, como: verdadeiro ou falso; zero ou um. Por este fato é também conhecida como lógica binária ou digital. Enquanto a lógica *fuzzy* é puramente analógica.

As primeiras noções da lógica dos conceitos vagos foi desenvolvida pelo lógico polonês Jan Lukasiewicz (1878-1956) em 1920, que introduziu conjuntos com três graus de pertinência sendo 0, $\frac{1}{2}$ e 1. Onde percebe-se o surgimento do estado intermediário $\frac{1}{2}$ (Simões e Shaw, 2007).

Apenas em 1965 surge a lógica *fuzzy*, propriamente dita, desenvolvida pelo matemático Lofti Askeradeh, professor em Berkeley, Universidade da Califórnia (Simões e Shaw, 2007).

2.2.2. Lógica e Sistema de Controle

Zadeh criou a lógica *fuzzy*, combinando os conceitos da lógica clássica e os conjuntos vagos de Lukasiewicz, definindo assim os graus de pertinência. Desta maneira podemos ter infinitos números entre o 0 e 1 da lógica tradicional.

Resumidamente a lógica Clássica é bivalente, enquanto a lógica *fuzzy* é multivalente.

De acordo com a lógica clássica ou *crisp*, a pertinência é uma propriedade que indica se um elemento pertence ou não a um determinado conjunto. De acordo com a Figura 2.11, podemos escrever:

$$X1 \notin A \quad (2.10)$$

Enquanto.

$$X2 \in A \quad (2.11)$$

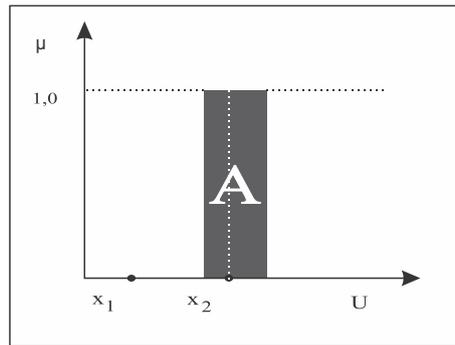


Figura 2. 11 – Conjunto *Crisp*

Referindo-se a pertinência, podemos escrever:

$$\mu_A(x) = \begin{cases} 1 & \text{se } x \in A \\ 0 & \text{se } x \notin A \end{cases} \quad (2.12)$$

$\mu_A(x)$ – pertinência do valor x com relação ao conjunto A

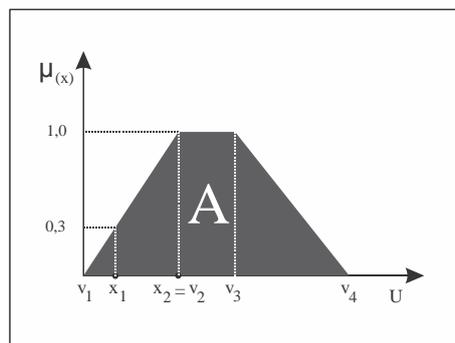


Figura 2.12 – Conjunto *Fuzzy*

A Figura 2.12 mostra a conjunto A *fuzzificado* por uma função de pertinência trapezoidal. O seu domínio é denominado de universo de discurso. A pertinência para este conjunto será da seguinte forma:

Com:

$$\mu_A(x_1) = 0,3 \quad (2.13)$$

$$\mu_A(x_2) = 1,0 \quad (2.14)$$

Alguns operadores sobre conjuntos *fuzzy* são de extrema importância. O operador denominado por norma triangular ou simplesmente *norma-t*, envolve os seguintes operadores: intersecção, produto algébrico, produto logarítmico e etc. Devido ao grande uso, mostramos abaixo o operador de intersecção.

$$\mu_{A \cap B}(x) = \min[\mu_A(x), \mu_B(x)] \quad (2.15)$$

Outro tipo de operador largamente utilizado é a *co-norma* triangular ou *norma-s*. São formados pelos operadores de: união, soma algébrica, soma limitada, soma logarítmica e etc. A união é o operador mais utilizado dentre os que compõem a *norma-s*.

$$\mu_{A \cup B}(x) = \max[\mu_A(x), \mu_B(x)] \quad (2.16)$$

A Tabela 2.1 possui as propriedades mais significativas da teoria dos conjuntos *fuzzy*. Essas propriedades, aplicáveis aos conjuntos *crisp*, são também aplicáveis aos conjuntos *fuzzy*, exceto aquelas destacadas em cinza, referentes ao complemento. Isto ocorre devido a uma particularidade dos conjuntos *fuzzy* e o seu complementar, Equação 2.17:

$$\mu_{A'}(x) = 1 - \mu_A(x) \quad (2.17)$$

Tabela 2.1 – Propriedades mais Significativas da Teoria dos Conjuntos *Fuzzy*

Comutativa	$A \cap B = B \cap A$
	$A \cup B = B \cup A$
Associativa	$(A \cap B) \cap C = A \cap (B \cap C)$
	$(A \cup B) \cup C = A \cup (B \cup C)$
Idempotência	$A \cap A = A$
	$A \cup A = A$
Distributividade em relação a intersecção	$A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$
Distributividade em relação a intersecção	$A \cap (B \cup C) = (A \cup B) \cap (A \cup C)$
Conjunto <i>fuzzy</i> e seu complemento	$A \cap A' \neq \emptyset$
	$A \cap A' \neq E$
Conjunto <i>fuzzy</i> e o conjunto nulo	$A \cap \emptyset \neq \emptyset$

Fonte: (Simões e Shaw, 2007)

Por uma questão de nomenclatura passaremos a chamar os conjuntos *fuzzy* por funções de pertinência. Onde, por definição, uma variável *fuzzy* passa a ser uma coleção de funções de pertinência. Na verdade uma variável *fuzzy* é um vetor composto pelas pertinências de suas respectivas funções.

Considere uma variável *fuzzy* Y composta por três funções de pertinência, como mostrado na Figura 2.13:

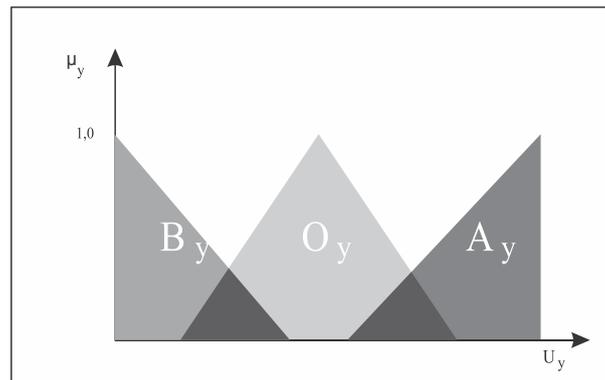


Figura 2.13 – Variável *Fuzzy* Y

Logo, a representação de um valor *fuzzy* pertencente a variável Y, será:

$$Y_i = \{\mu_B(Y^*_i), \mu_O(Y^*_i), \mu_A(Y^*_i)\} \quad (2.18)$$

Onde:

B – função de pertinência Baixa;

O – função de pertinência Ótima;

A – função de pertinência Alta;

Y_i – valor *i* - ésimo da variável *fuzzy* Y;

Y^*_i – valor *i* - ésimo da variável *crisp* Y.

O formato das funções de pertinência não está resumido às formas triangular e trapezoidal. Existem além desses, o triangular, sigmoide, spline cúbico e etc.

Além da forma, outro fator que afeta a precisão das funções de pertinência é a superposição entre elas. Um mínimo de 25% e um máximo de 75% foram determinados experimentalmente como adequados, sendo 50% um valor largamente empregado (Simões e Shaw, 2007).

Os sistemas de controle *fuzzy* utilizam um sistema de inferência que relaciona as variáveis de entrada do sistema com a variável de saída. Os operadores t-norma e co-norma são usados para correlacionar as entradas do sistema com a saída, do seguinte modo:

$$\begin{aligned}
 \text{se } v_{e1} = f_{pve1} \ll \text{operador} \gg v_{e2} = f_{pve2} \ll \text{operador} \\
 \gg \dots \text{então } v_{s1} = f_{pvs1} \ll \text{operador} \gg v_{s2} = f_{pvs2} \dots
 \end{aligned} \quad (2.19)$$

onde:

v_{e1} – variável de entrada 1

v_{e2} – variável de entrada 2

f_{pve1} – Função de pertinência da variável de entrada 1

f_{pve2} – Função de pertinência da variável de entrada 2

$\ll \text{operador} \gg$ – operador do tipo t-norma ou co-norma

Outra maneira de declarar as regras de inferência é através dos termos antecedentes e consequentes. Onde as variáveis de entrada e seus respectivos operadores são denominados de operação antecedente, enquanto a ação sobre as variáveis de saída são denominadas consequentes.

Convém salientar que, tanto as variáveis antecedentes como as consequentes são variáveis *fuzzy*. Entretanto, a ação do controlador *fuzzy* sobre o sistema, através do operador consequente, necessita de um valor *crisp* ou real. Esta tarefa denomina-se de *defuzzificação* (ALAVALA, 2005).

O procedimento de defuzzificação pode ser realizado por um dos seguintes métodos: centro-da-área (C-o-A), centro-do-máximo(C-o-M) e média-do-máximo (M-o-M).

O método do centro-da-área é frequentemente chamado método do centro-de-gravidade é escrito da seguinte forma:

$$Z^* = \frac{\sum_{i=1}^{N_f} CG_{af} \cdot A_f}{\sum_{i=1}^{N_f} A_f} \quad (2.20)$$

Onde:

CG_f – Centro de gravidade da função de pertinência inferida

A_f – Área da função de pertinência inferida

Z^* – Valor defuzzificado ou crisp da variável de saída

É através do valor de Z^* que o controlador *fuzzy* irá atuar sobre o sistema.

A partir deste ponto do trabalho iremos denominar “sistema” aquele representado pela bancada experimental (BE), reservando o termo “planta” para descrever os sistemas de distribuição de água (SDA) de uma cidade ou setor, propriamente dito.

O método de *defuzzificação* centro-do-máximo considera apenas os valores de máximo de cada função de pertinência ponderado pelos valores *fuzzy* inferidos. Assim, a *defuzzificação* será determinada por:

$$Z^* = \frac{\sum_{i=1}^N Z_i^{máx} \cdot \mu_c(Z_i)}{\sum_{i=1}^N \mu_c(Z_i)} \quad (2.21)$$

Onde:

$\mu_c(Z_i)$ – Valor *fuzzy* da variável Z, relativa a i-ésima função de pertinência

$Z_i^{máx}$ – Valor máximo *crisp* da variável Z, relativa a i-ésima função de pertinência

Z^* – Valor *defuzzificado* ou *crisp* da variável Z

Existem vários mecanismos de inferência *fuzzy* baseados em regras na literatura científica. Entretanto, alguns merecem destaque: Mandani, Larsen, Tsukamoto e Takagi-Sugeno-Kang ou Paramétrico (Simões e Shaw, 2007).

2.2.3. Método Mandani

Dentre os mecanismos existentes é realmente o mais empregado. É também conhecido como máx-mín, pois usa como operador antecedente a t-norma, interseção ou mínimo e para o operador consequente a co-norma, união ou máximo.

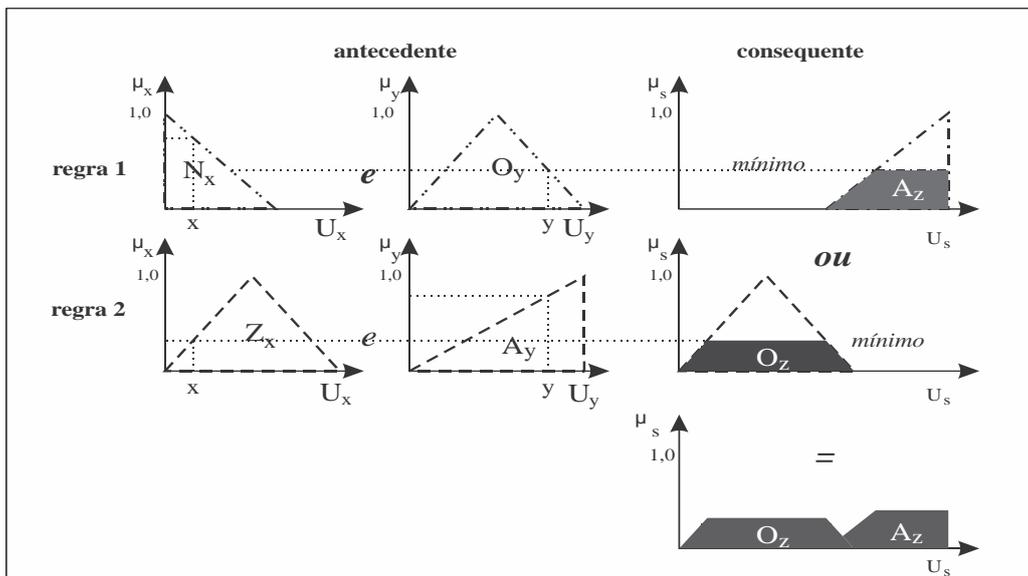


Figura 2.14 – Mecanismo de Inferência Mandani

A operação de *defuzzificação* pode ser realizada por um dos métodos descritos anteriormente, sendo o mais comum o C-o-M.

2.2.4. Método de Larsen

O método de inferência Larsen é bastante semelhante ao método Mandani descrito anteriormente. A diferença recai sobre a substituição do operador antecedente t-norma

intersecção pela multiplicação. Isto provoca um efeito de escalonamento, como pode ser visto na Figura 2.15.

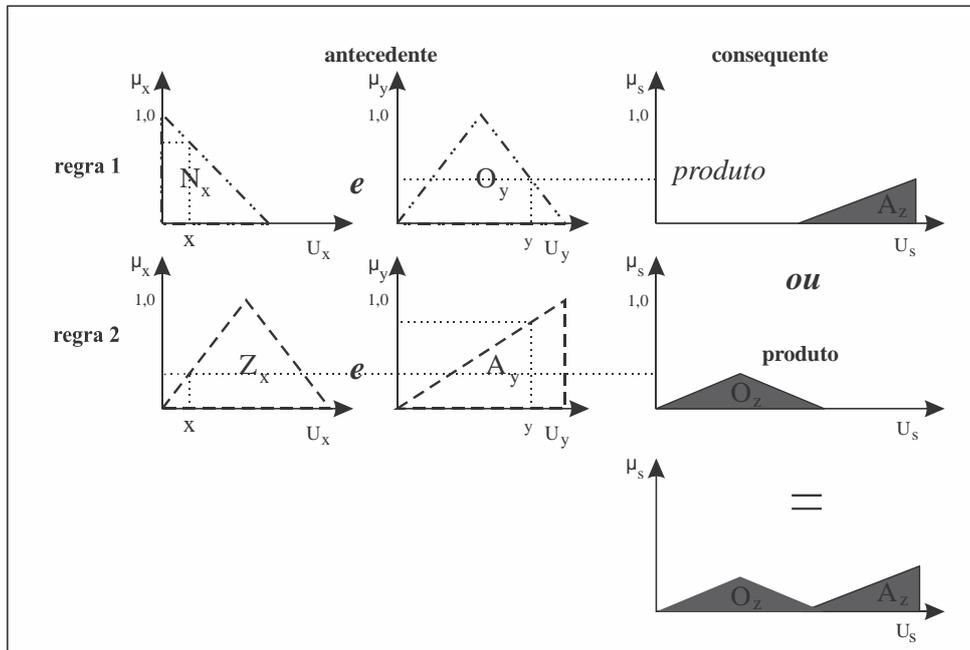


Figura 2.15 - Mecanismo de Inferência Larsen

Análogo à técnica Mandani, o Larsen pode utilizar alguns dos processos de *defuzzificação* citados anteriormente.

2.2.5. Método de Tsukamoto

O mecanismo de inferência Tsukamoto traz uma particularidade no tratamento das funções de pertinência. Ao invés das funções de pertinência gráficas como as triangulares e trapezoidais, faz uso de funções monótonas. Puramente crescente ou puramente decrescente, como logaritmos e exponenciais, Figura 2.16.

O operador antecedente é a intersecção com o valor mínimo e a *defuzzificação* dada pela Equação 2.22:

$$Z^* = \frac{\sum_{i=1}^N S_i \cdot \mu_{fp}(S_i)}{\sum_{i=1}^N \mu_{fp}(S_i)} \quad (2.22)$$

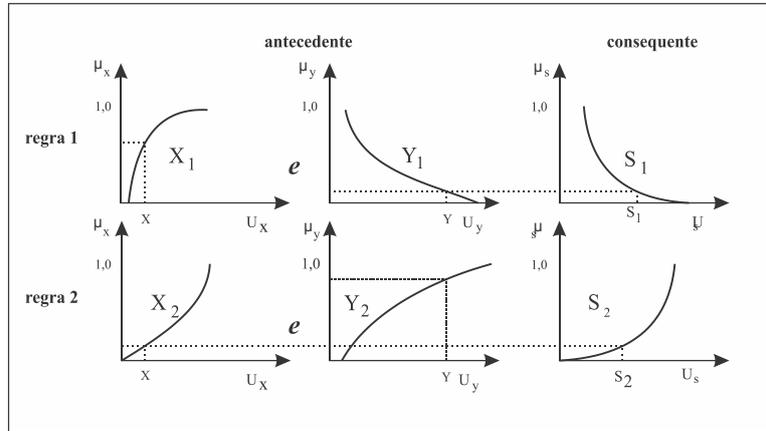


Figura 2.16 – Mecanismo de Inferência Tsukamoto

2.2.6. Método de Takagi-Sugeno-Kang

O Mecanismo inferência Takagi-Sugeno-Kang, Figura 2.17, faz uso do operador t-norma, intersecção para o operadores antecedente. Enquanto o operador consequente é uma função matemática linear. Este tipo de inferência necessita de treinamento para a determinação dos coeficientes destas funções. Isto assemelha-se às Redes Neurais Artificiais (RNA), como será visto no item 2.3.

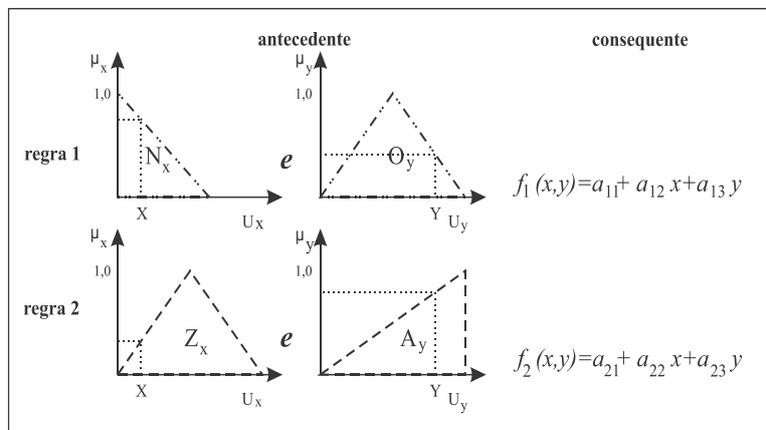


Figura 2.17 – Mecanismo de Inferência Takagi-Sugeno-Kang

A defuzzificação é dada pela Equação 2.23:

$$Z^* = \frac{\sum_{i=1}^N \alpha_i \cdot f_i}{\sum_{i=1}^N \alpha_i} \quad (2.23)$$

Onde:

$$\alpha_i = \text{mín}\{\mu_{fp}(X_i), \mu_{fp}(Y_i),\} \quad (2.24)$$

2.3. REDES NEURAIS ARTIFICIAIS

2.3.1. Aspectos Históricos

O pioneiro trabalho relacionado à neurocomputação data de 1943 quando os autores McCulloch, psicólogo e neurofisiologista, e Pitts, matemático, publicaram um extraordinário trabalho onde, de maneira sofisticada, é tratada uma rede lógica de neurônios artificiais, chamada de MCP. O trabalho tem uma forte inclinação em descrever um modelo artificial de neurônios, apesar de não preocupar-se com as técnicas de treinamento e aprendizado (MCCULLOCH e PITTS, 1943).

O treinamento das redes neurais artificiais (RNA), somente veio a ser abordado por Hebb, quando propõe uma teoria de aprendizado baseado na variação dos pesos de entrada dos neurônios (HEBB, 1949). A partir de então esta técnica passa a ser conhecida com *Regra de Hebb* que é utilizada na rede tipo *Perceptron* (ROSEMBLATT, 1958).

Outra técnica de treinamento bastante conhecida é *regra gradiente simplificada* utilizado pela RNA denominada *Andaline* (WIDROW e HOFF, 1960).

Durante este período houve um grande interesse do meio científico sobre as RNA. Isto proporcionou o surgimento de diversas arquiteturas e topologias para as redes, além de técnicas inovadoras sobre treinamento e aprendizado (SPATTI *et al.*, 2010).

Entretanto, em 1969, a área da neurocomputação sofreu um grande revés com a publicação do clássico livro *Perceptron: An Introduction to Computational Geometry* (MINSK; PAPER, 1969). Onde os autores foram enfáticos em afirmar que o modelo

Perceptron de uma única camada era incapaz de detectar paridade, conectividade e simetria. Problemas não linearmente separáveis (SPATTI *et al.*, 2010). Consequentemente o interesse pela neurocomputação sofre uma baixa.

Em 1982, Jonh Hopfield chamou a atenção da comunidade científica sobre a capacidade associativa das RNA (HOPFIELD, 1982). O grande feito deste trabalho está na demonstração da relação entre redes recorrentes *auto-associativas* e sistemas físicos (BRAGA *et al.*, 2007).

Em 1986 foi divulgado o algoritmo de treinamento backpropagation que permite o ajuste dos pesos de uma RNA com mais de uma camada (RUMELHART *et al.*, 1896). Certamente foi um marco para esta época e definitivamente alavancou o interesse pela neurocomputação. Este algoritmo de treinamento também é encontrado com a denominação de Regra Delta Generalizada, ou mesmo, Gradiente Descendente.

O neurônio artificial é uma analogia dos neurônios biológicos. Estes são compostos por um corpo, dentritos, axônios e sinapses Figura 2.18.

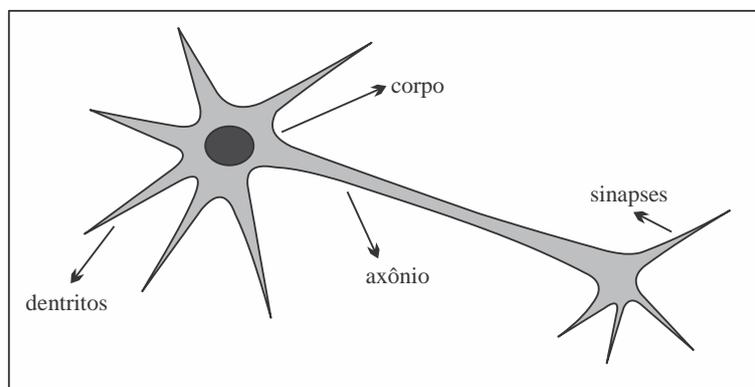


Figura 2.18 – Neurônio Biológico

Os dentritos são filamentos nervosos que consistem em captadores/receptores em captar dos impulsos elétricos dos outros neurônios. O corpo celular tem o objetivo de processar as informações captadas pelos dentritos e produzir um potencial de ativação que poderá disparar um impulso elétrico. O axônio tem o papel de conduzir este impulso direcionado pelas sinapses.

2.3.2. Considerações Gerais

Baseados neste processo é que foram desenvolvidos os neurônios artificiais e suas respectivas RNA.

Assim, considerando a Figura 2.19, verifica-se que o neurônio artificial é constituído de sete elementos básicos, ou seja: (SPATTI, SILVA, & FLAUZINO, 2010).

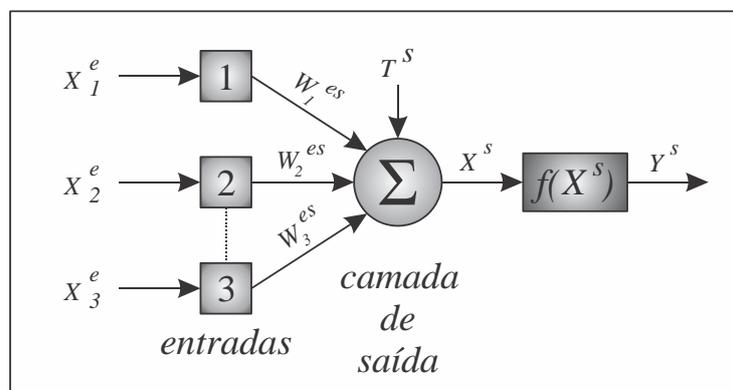


Figura 2.19 – Neurônio Artificial

Onde:

$X_{1..3}^e$ - referem-se aos sinais de entrada ou simplesmente entradas

$w_{1..3}^{es}$ - referem-se aos pesos sinápticos ou simplesmente pesos

Σ - é o combinador linear e tem a função de agregar as entradas pelos respectivos pesos

T^s - Limiar de ativação, (bias), responsável pelo patamar apropriado de disparo do combinador linear

X^s - é o resultado da soma entre o combinador linear e o limiar de ativação

$f(X^s)$ - função de ativação, que tem por objetivo limitar a saída do neurônio a intervalo apropriado

Y^s - é o valor de saída produzido pelo neurônio

As funções de ativação se subdividem em dois grupos: As que são parcialmente diferenciáveis e as totalmente.

As funções degrau, degrau bipolar e rampa simétrica são exemplos de funções parcialmente diferenciáveis, como pode ser visto na Figura 2.20.

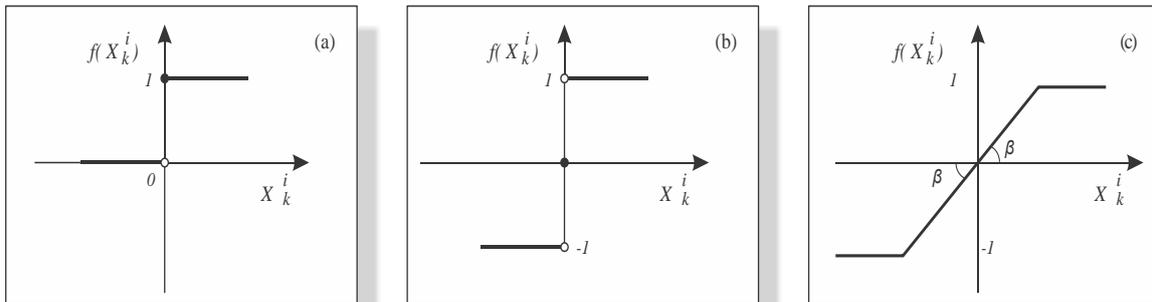


Figura 2.20 – Funções Parcialmente Diferenciáveis: (a) Degrâu; (b) Degrâu Bipolar e (c) Rampa

Enquanto as funções tangente hiperbólica, gaussiana e logística são exemplos de funções totalmente diferenciáveis, Figura 2.21.

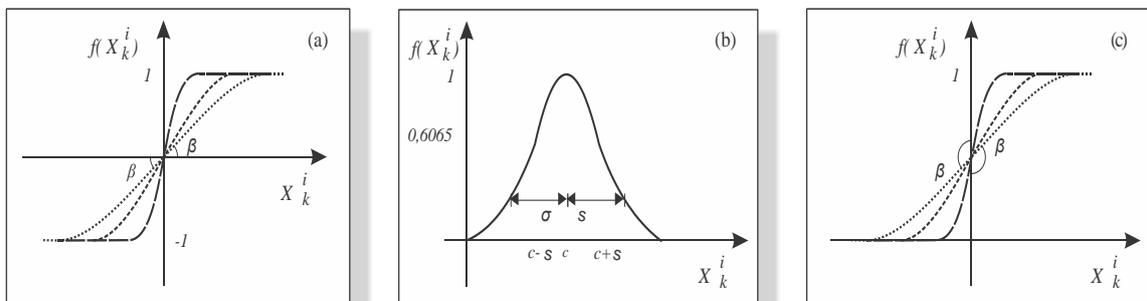


Figura 2.21 – Funções Totalmente Diferenciáveis: (a) Tangente Hiperbólica; (b) Gaussiana e (c) Logística

A arquitetura de uma rede neural pode ser compreendida como a forma em que seus neurônios estão dispostos. Outra característica importante diz respeito as interligações entre as camadas e os neurônios. Quanto a este fato podemos classificá-las em: *feedforward* com alimentação a frente de única camada, de múltiplas camadas, recorrentes e reticuladas.

Como exemplo das redes com alimentação à frente de única camada, podemos destacar as redes Perceptron e Adaline. Contudo podemos destacar as redes Perceptron com alimentação à frente de múltiplas camadas PMC. Este tipo de arquitetura é bastante versátil e possui inúmeras aplicações. Dentre elas, evidenciamos o uso deste tipo de arquitetura como *aproximador* universal de funções, incluindo as funções não lineares (HAYKIN, 1999).

O processo de treinamento das RNA pode ser classificado como supervisionado, não supervisionado. No treinamento supervisionado, para um dado sinal de entrada teremos um sinal de saída. Assim o valor de saída calculado pela rede, deve ser confrontado com o resultado desejado. Isto leva a um processo de correção dos pesos sinápticos.

No treinamento não supervisionado não existe sinal de saída desejado. Esta é diferença crucial entre os métodos. Este tipo de arquitetura tem sua aplicação na identificação de conjuntos e padrões.

Outra maneira de classificação das RNA, diz respeito ao tempo em que irá ocorrer o treinamento. Pode ser do tipo (*off-line*) ou (*on-line*). No primeiro caso, será realizada a coleta de amostras do sistema para em seguida ser feito o treinamento. Observe-se que durante o treinamento o sistema estará desligado. Enquanto que, no segundo caso, a rede será treinada durante o próprio processo de controle. Este é um caso típico das redes recorrentes, recursivas ou adaptativa. Onde os três termos são sinônimos neste contexto.

De acordo com SILVA *et al.* (2010) será detalhado adiante três tipos de arquitetura de RNA: A Perceptron e a Andaline de única camada e a Perceptron de múltiplas camadas. Não deixando de abordar os métodos de treinamento característico de cada tipo.

2.3.3. Rede Perceptron de Única Camada

A rede Perceptron de única camada é a forma mais simples de arquitetura de uma rede neural artificial (HAYKIN, 1999). A Figura 2.22 mostra uma rede Perceptron de única camada composta por três entradas, um único neurônio e uma única saída.

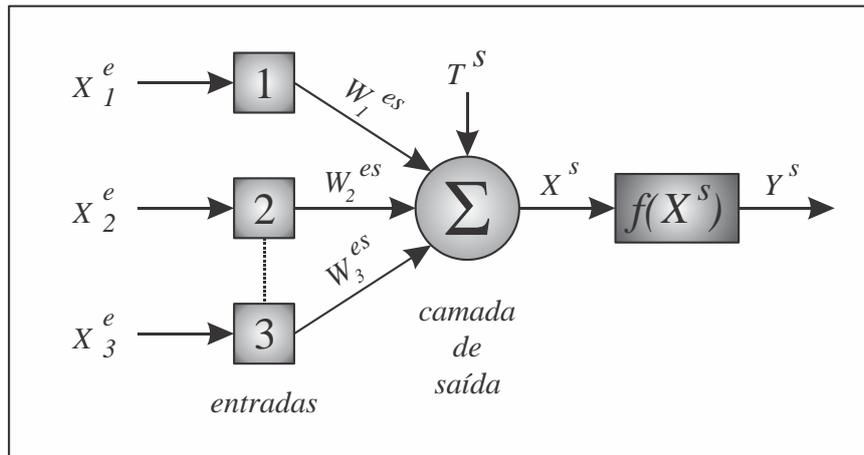


Figura 2.22 – Rede Perceptron de Única Camada

$$X^s = X_1^e \cdot w_1^{es} + X_2^e \cdot w_2^{es} + X_3^e \cdot w_3^{es} \quad (2.25)$$

Onde:

$X_{1..3}^e$ - entradas.

$w_{1..3}^{es}$ – pesos entre as camadas de entrada e saída.

Σ - é o combinador linear.

T^s - Limiar de ativação (*bias*).

X^s - é o resultado da soma entre o combinador linear e o limiar de ativação.

$f(X^s)$ - função de ativação.

Y^s - saída.

Devido ao fato de ser utilizada basicamente para a identificação de padrões. As redes Perceptron de única camada normalmente utilizam as funções degrau ou degrau bipolar, Figura 2.20 (a) e (b) respectivamente, como funções de ativação.

O processo de treinamento deste tipo de rede é realizado pela Regra de Hebb (HEBB, 1949). As equações 2.26 e 2.27 mostram como os pesos sinápticos e os limiares de ativação (*bias*) são corrigidos.

$$w_i^{es(t)} = w_i^{es(t-1)} + \mu \cdot (D^s - Y^s) \quad (2.26)$$

$$T^s(t) = T^s(t-1) + \mu \cdot (D^s - Y^s) \quad (2.27)$$

Onde:

$w_i^{es(t)}$ – peso no instante t .

$w_i^{es(t-1)}$ - peso no instante $t - 1$.

$T^s(t)$ – limiar de ativação no instante t .

$T^s(t-1)$ – limiar de ativação no instante $t - 1$.

μ – coeficiente de aprendizado.

D^s – saída desejada.

Y^s – saída calculada.

O coeficiente de aprendizado define o quão rápido o processo de treinamento está convergindo. O valor para μ deve ser escolhido cuidadosamente a fim de evitar instabilidade. Este fenômeno ocorre sempre que este coeficiente assume valores elevados. Por isso, deve-se adotar valores na faixa $0 < \mu < 1$ (RIUL, 2000).

Alguns aspectos relativos ao treinamento das redes Perceptron de única camada devem ser observados (BRAGA *et al.*, 2007):

- A rede não irá convergir no caso do problema ser composto por funções linearmente não separáveis. Caso das funções fortemente não lineares.
- A quantidade de amostras necessárias para o treinamento varia em função dos valores iniciais de w_i^{es} e μ .
- A normalização dos valores de entrada contribui para tornar o treinamento mais eficiente.
- Quando a faixa que separa uma classe de outra for bastante próxima, deve-se adotar valores de μ bem pequenos.

2.3.4. Rede Andaline

Passaremos a discutir a arquitetura de redes *Andaline* de única camada. Este tipo, apresenta algumas similaridades com as redes *Perceptron*, como pode ser vista na Figura 2.23.

Assim como a *Perceptron* a rede *Andaline* possui várias entradas, um único neurônio e uma única saída. Devido a simplicidade da sua arquitetura é vocacionada para a identificação de padrões. As funções de ativação do tipo degrau e degrau bipolar são muito utilizadas neste tipo de rede.

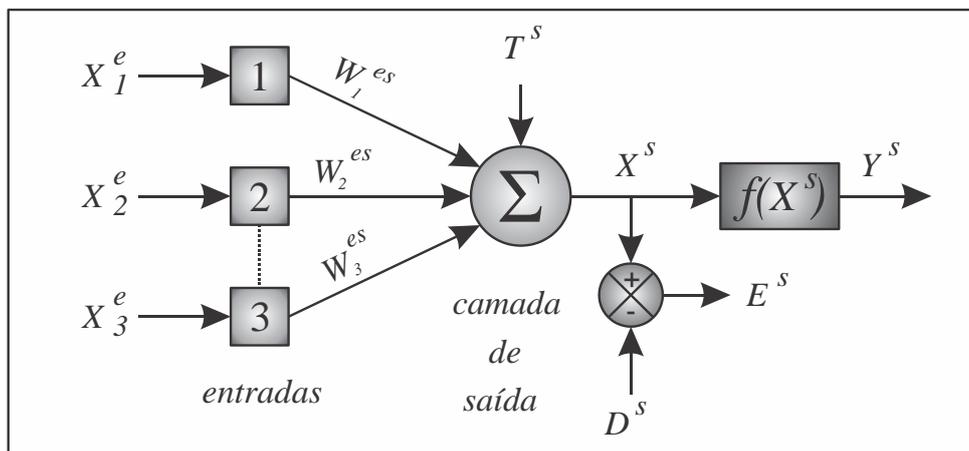


Figura 2.23 – Rede Andaline de Única Camada

A grande contribuição das redes Andaline encontra-se no algoritmo de treinamento, denominado Regra Delta ou Gradiente descendente simplificado (SILVA *et al.*, 2010).

Diferentemente das redes *Perceptron*, mesmo que o problema a ser mapeado seja composto por funções não linearmente separáveis, ainda assim, a Regra Delta é passível de convergência. Isto faz com que este tipo de rede seja mais imune a ruídos que porventura venham a afetar o mapeamento das respostas (CORNELIUS, 1998).

Mais especificamente, utiliza-se a minimização do índice de desempenho com a intenção de ajustar os pesos sinápticos e o valor do limiar de ativação.

$$I_d = \frac{1}{2} \sum_{i=1}^K (D_i - X_i^s)^2 \quad (2.28)$$

O próximo passo é aplicar a Gradiente Descendente sobre o índice de desempenho (RIUL, SILVA & CAVALCANTI, 2000).

$$\nabla I_d = \frac{\partial I_d(W)}{\partial(W)} \quad (2.29)$$

$$\nabla I_d = \sum_{i=1}^K (D_i - X_i^s) \cdot X_i^e \quad (2.30)$$

$$\Delta_w = \mu \cdot \nabla I_d \quad (2.31)$$

$$\Delta_w = \mu \cdot \sum_{i=1}^K (D_i - X_i^s) \cdot X_i^e \quad (2.32)$$

$$w_i^{es(t)} = w_i^{es(t-1)} + \mu \cdot \sum_{i=1}^K (D_i - X_i^s) \cdot X_i^e \quad (2.33)$$

$$T^s(t) = T^s(t-1) + \mu \cdot \sum_{i=1}^K (D_i - X_i^s) \cdot X_i^e \quad (2.34)$$

Onde:

E_q – Erro quadrático.

D_i – i-ésima saída desejada.

X_i^s – i-ésima saída calculada.

X_i^e – i-ésima entrada.

∇E_w – gradiente descendente do erro.

Δ_w – taxa de ajuste dos pesos.

μ – taxa de aprendizagem.

$w_i^{es(t)}$ – i-ésimo peso no instante t .

$w_i^{es(t-1)}$ – i-ésimo peso no instante $t-1$.

$T^s(t)$ – limiar de ativação no instante t .

$T^s(t-1)$ - limiar de ativação no instante $t-1$.

Da mesma forma, é aconselhável manter a taxa de aprendizagem com valores na faixa de $0 < \mu < 1$.

A normalização dos sinais de entrada é também indicado a este caso.

2.3.5. Rede Perceptron de Múltiplas Camadas

O grande salto qualitativo das RNA surge com as redes Perceptron de múltiplas camadas. Esta é uma das mais versáteis arquiteturas, podendo ser aplicada aos seguintes propósitos: Aproximação universal de funções, otimização de sistemas e previsão de séries temporais,

A grande popularidade deve-se a publicação do livro, *Learning Internal Representation by Error Propagation* (RUMELHART *et al.*, 1996), onde é tratado detalhadamente o método de treinamento, denominado de gradiente descendente generalizado.

A Figura 2.24 ilustra uma rede Perceptron de múltiplas camadas (PMC). É bem evidente a presença de uma camada além da camada de saída, denominada neste trabalho de intermediária. O número destas camadas é praticamente ilimitado. Entretanto, uma única camada oculta é capaz de responder com sucesso aos mais variados problemas (HAYKIN, 1999).

Diferentemente das redes mostradas anteriormente, a PMC pode possuir topologia com inúmeros neurônios de saída. O processo de treinamento através do gradiente descendente generalizado com o método da retropropagação (*backpropagation*) garante a PMC um aprendizado bastante satisfatório. Neste trabalho a correção não se limitou correção dos pesos, mas envolve também a correção dos limiares de ativação (*bias*) e do parâmetros (*beta*), presentes nas funções de ativação da tangente hiperbólica e logística.

A etapa de ajustes dos pesos tem origem na camada de saída para, em seguida, serem realizados os ajustes dos pesos e limiares de ativação da camada intermediária. Daí o nome do treinamento por retropropagação (*backpropagation*).

O erro quadrático é calculado pela Equação 2.35, abaixo.

$$E_q = \sum_{i=1}^K (D_i - X_i^s)^2 \quad (2.35)$$

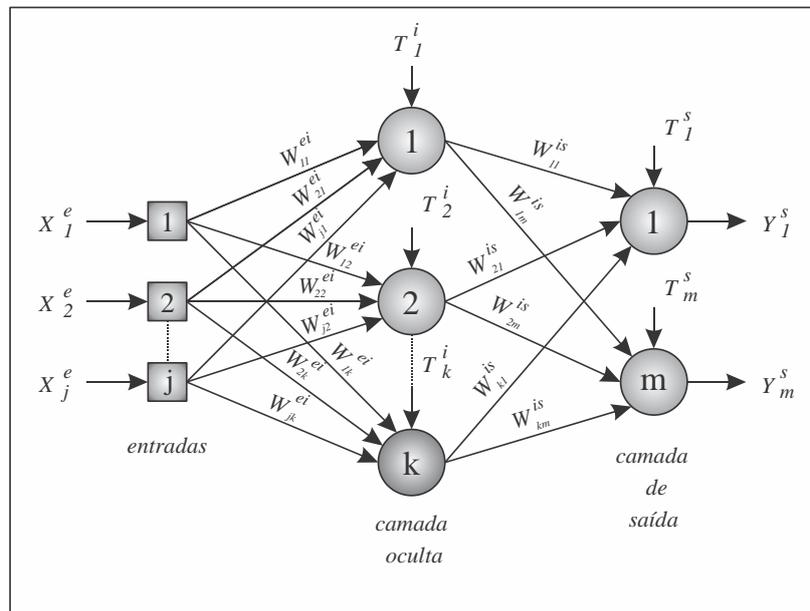


Figura 2.24 – Rede Perceptron com Múltiplas Camadas

Enquanto o erro quadrático médio pela Equação 2.36.

$$E_{qm} = \frac{1}{p} \cdot \sum_{i=1}^p E_q \quad (2.36)$$

A demonstração detalhada das equações pode ser vista no anexo B.

Para a correção dos pesos entre a camada de intermediária e a camada de saída, o ajuste dos pesos é dado pela Equação 2.37.

$$W_{km}^{is}(t+\Delta t) = W_{km}^{is}(t) + \mu \left(E_m^s \cdot Y_k^i \right)_{(t)} \quad (2.37)$$

Enquanto que a correção dos pesos entre a camada de entrada e a camada intermediária, será realizado pela Equação 2.38. Os limiares de ativação (*bias*) e os (*betas*) da função de ativação, determinado pelas equações 2.39 e 2.40, respectivamente.

Para o caso em particular, demonstrado no apêndice B, foi utilizado como função de ativação a tangente hiperbólica. Logo, além dos ajustes referentes aos pesos e limiares (*bias*) teremos também o ajuste do coeficiente (*beta*), como mostra as equações abaixo.

$$W_{jk}^{ei}(t+\Delta t) = W_{jk}^{ei}(t) + \mu \left(E_m^s W_{km}^{is} \frac{\beta_k^i}{2} [1 - (Y_k^i)^2] X_j^e \right)_{(t)} \quad (2.38)$$

$$\beta_k^i(t+\Delta t) = \beta_k^i(t) + \mu \left(E_m^s W_{km}^{is} \frac{X_k^i}{2} [1 - (Y_k^i)^2] \right)_{(t)} \quad (2.39)$$

$$T_k^i(t+\Delta t) = T_k^i(t) + \mu \left(E_m^s W_{km}^{is} \frac{\beta_k^i}{2} [1 - (Y_k^i)^2] \right)_{(t)} \quad (2.40)$$

Este método de treinamento, apesar de ser de grande valor no campo das RNA, requer inúmeras iterações para a sua convergência. Isto pode ser um empecilho, em se tratando de controles adaptativos (HAYKIN, 1999).

Mais recentemente, temos em especial, a proposição do algoritmo de otimização idealizado por Levenberg e Marquardt que tem como principal característica a de acelerar a convergência do treinamento Gradiente Descendente (CORNELIUS, 1998).

2.3.5. Otimizador de Levenberg-Marquardt Aplicado as Redes Neurais Artificiais

O método de otimização de Levenberg-Marquardt utilizado neste trabalho terá que minimizar o erro resultante da diferença entre a pressão de referência e a pressão na rede dada pela Equação 2.41.

$$E_{m,t}^s = D_{m(t)}^s - Y_{m(t)}^s \quad (2.41)$$

Onde:

$D_{m(t)}^s$ – Pressão desejada no instante t (mca)

$Y_{m(t)}^s$ – Pressão no ponto de controle no instante t (mca)

$E_{m,t}^s$ – Erro no instante t (mca.)

O método do gradiente descendente com retropropagação (*backpropagation*) irá distribuir esse erro ao longo dos pesos W_t^{ei} e W_t^{is} da RNA. O resultado obtido desta operação possibilita a determinação dos *gradientes* ΔW_t^{ei} e ΔW_t^{is} relativo aos pesos das camadas no instante de tempo t .

O passo seguinte cabe ao método de Levenberg-Marquardt ajustar os valores dos *gradientes* ΔW_t^{ei} e ΔW_t^{is} a serem utilizados na iteração seguinte, escrito genericamente pela Equação 4.6 (SILVA *et al.*, 2010).

$$\Delta W_t = [J^T(W) \cdot J(W) + \lambda \cdot I]^{-1} \cdot J(W) \cdot E^q \quad (2.42)$$

Onde:

I – Matriz Identidade de mesma ordem da aproximação da Matriz Hessiana.

λ – Parâmetro de Levenberg-Marquardt.

$J(W)$ – Matriz Jacobiana

ΔW_t – Gradiente relativo aos pesos sinápticos

O parâmetro de Levenberg-Marquardt usado neste trabalho foi proporcional ao erro quadrático, Equação 4.7

$$\lambda = \sum_t^n [D_{m(t)}^s - Y_{m(t)}^s]^2 \quad (2.43)$$

De posse desses valores, o método do gradiente descendente em sua fase a frente (*forward*) irá determinar os pesos W_{t+1}^{ei} e W_{t+1}^{is} do passo seguinte, de acordo com a Equação 4.8.

$$W_{t+1} = W_t + \Delta W_t \quad (2.44)$$

Maiores detalhes sobre o método de Levenberg-Marquardt pode ser visto no Apêndice C.

CAPÍTULO III

ESTADO DA ARTE

Este capítulo apresenta o estado da arte das seguintes áreas: operação e automação em sistemas de distribuição de água, conversores de frequência aplicados a sistemas de bombeamento, sistemas *fuzzy* e redes neurais artificiais. Este último foi dividido em: sistema de distribuição de água, níveis de reservatórios superficiais e subterrâneo, previsão de vazão e demanda, previsão de precipitação e preenchimento de falhas e qualidade da água. A seguir será descrito aspectos primordiais sobre diversos trabalhos científicos de relevo e originalidade dentro do escopo mencionado.

3.1. OPERAÇÃO E AUTOMAÇÃO EM SISTEMAS DE DISTRIBUIÇÃO DE ÁGUA.

FARMANI *et al.* (2006) desenvolveram um SCADA que realiza a supervisão e aquisição de dados como: pressão, vazão, níveis dos reservatórios, aberturas de válvulas e concentração de cloro. O sistema de otimização consiste em tornar eficiente a operação dos conjuntos motor-bomba e os níveis dos reservatórios da estação de tratamento de água localizada na Moravia, República Tcheca.

O risco de contaminação de um SDA, pode ocorrer devido a fenômenos naturais, ou mesmo, por ação humana. Um SCADA foi instalado com o objetivo de monitorar e

adquirir dados. Locais estratégicos como a saída da estação de tratamento de água – ETA, áreas degradadas e locais representativos foram monitorados. Um simulador hidráulico de qualidade da água baseado no método de Monte Carlo foi desenvolvido e aplicado ao SDA, localizado na cidade de Tiajin, China (WU *et al.*, 2007).

Um SCADA foi implantado em um SDA localizado na região sudoeste da Moravia, Republica Tcheca. Os dados oriundos deste supervisor alimenta um simulador hidráulico e de qualidade da água desenvolvido no EPANET 2.0. O sistema é composto por quatro módulos: *Virtual Sensor*, destinado a simular parâmetros hidráulicos e de qualidade em pontos da rede sem monitoramento físico; *Hindcasting*, Permite a modelagem de situações ocorridas num passado a partir de dados históricos sistematicamente gravados; *Event-Simulation*, Permite ao operador mudar parâmetros do sistema para realizar novas simulações; *Predictive*, Permite prever o comportamento futuro do sistema em horas, dias ou meses (INGEDULD, 2007).

Modelo de otimização desenvolvido para auxiliar a tomada de decisão para quando houver rompimento de adutora de SDA. O objetivo principal foi o de minimizar as flutuações das vazões e pressão e com isso garantir o funcionamento hidráulico da rede dentro das restrições impostas. Por outro lado a área a ser isolada deve ser aquela que contemple um número mínimo de usuários sem serviço, maximizando com isso a arrecadação. Estudo de caso realizado no norte da China registrou economia de energia de 11% e aumento na arrecadação de 5% (YI-MEI *et al.*, 2007).

O tempo de convergência dos modelos de otimização é muitas vezes a maior dificuldade na elaboração de modelos em tempo real. Algoritmos genéticos tem sido utilizado largamente nesta área. Entretanto, esta técnica apresenta algumas deficiências quanto a velocidade de aproximação da solução ótima. COSTA *et al.* (2010) apresentaram um algoritmo genético híbrido (AGH) de otimização, onde a cada solução original obtida por um algoritmo genético simples (AGS), será adicionada uma solução modificada. O AGH obteve uma redução de custos de 16% e tempo de convergência de 28,86 minutos contra, 13% e 157,7 minutos, comparado com o AGS em estudo caso realizado no SDA da cidade de Ourém, Portugal.

Ações voltadas para a melhoria dos sistemas de distribuição de água (SDA) terão que analisar os seguintes aspectos possíveis: uso de energia renovável, recuperação de energia através da instalação de micro hidroelétricas, gerenciamento e controle de pressão

e perdas de água, otimização da operação dos SDA, uso eficiente dos conjuntos motor-bomba das elevatórias, uso de variadores de velocidade *variable speed drive* (VSD) e a otimização dos níveis dos reservatórios de armazenamento. Quanto a redução no consumo de energia podemos citar algumas ações: o monitoramento em tempo real permite economia (entre 5% a 20%), o uso de conjuntos motor-bomba (CMB) mais eficientes (entre 5% a 10%), o uso de VSD (entre 10% e 50%), a otimização operacional dos sistemas de bombeamento (entre 15% e 30% podendo atingir valores em torno de 70%), a substituição das válvulas de controle por VSD (pode atingir valores acima de 50%) (VILANOVA & BALESTIERI, 2013).

ABIODUN & ISMAILI (2013) desenvolveram um modelo de otimização multi-objetivo (MO), *adaptive weighted sum genetic algorithm* (AWGA), aplicado a sistemas de abastecimento de água (SAA). Os resultados obtidos foram comparados com os modelos: *fix weight genetic algorithm* (FWGA) e o *random weight genetic algorithm* (SOGA). O modelo AWGA demonstrou ser mais eficiente em 16,2% quando comparado com o FWGA e o SOGA com índices de 7,74% e 7,23% respectivamente.

Além do custo de aquisição e instalação dos conjuntos motor-bomba (CMB), temos aqueles referentes ao consumo de energia que ocupa a maior despesa. MOREIRA & RAMOS (2013) apresentaram trabalho voltado para a redução do consumo de energia e manutenção dos conjuntos elevatórios do SDA da cidade de Fátima, Portugal. Uma análise detalhada foi realizada para a escolha do mais eficiente conjunto elevatório e um sistema de otimização envolvendo o simulador WaterGEMs, com módulos em algoritmo genético (AG), foi utilizado. Algumas restrições como o número de partidas dos motores durante um dia, assim como a adoção de níveis máximos e mínimos nos reservatórios foram seguidos. O resultado obtido pelo sistema de otimização quando confrontados com os dados operacionais manuais revelaram economia no consumo de energia de até 43,7%.

A não linearidade, além do grande número de equipamentos que compõem os SDA, não são os únicos elementos de dificuldade encontrados nos modelos de otimização de redes de distribuição de água. A incerteza sobre as demandas, em geral previstas por modelos, torna ainda mais complexo este trabalho. GORYASHKO & NEMIROVSKI (2014) demonstraram a alta sensibilidade dos modelos de otimização de custo de energia em SDA provocado pela ocorrência de pequenas perturbações sobre os valores de demanda. Estudo de caso envolvendo o modelo *linear robust optimal* na cidade de Hadera,

Israel comprovam os resultados obtidos.

Sistema de suporte a decisão, *smart water network decision support system* – SWNDSS foi desenvolvido e aplicado no SDA gerenciado pela *Las Vegas Valley Water District* – LVVWD, na cidade de Las Vegas, US. O principal objetivo deste modelo está na redução do índice da idade da água e conseqüentemente a melhoria da qualidade da água do sistema. A redução dos custos operacionais foram tratados com ações de implementação de regras e planos de operação dos sistemas de bombeamento. A LVVWD atende a uma população de 1,3 milhões de habitantes a um custo anual de 12,7 milhões de dólares. Composto por um sistemas de aquisição de dados, incluindo *geographic information system* – GIS e um supervisor SCADA. O SWNDSS demonstrou ser um componente essencial ao SDA, atuando em tempo real e garantindo redução de custos com melhorias na qualidade da água (BOULOS *et al.*, 2014).

ODAN *et al.* (2015) desenvolveram um modelo para operação em tempo real de um SDA. O primeiro módulo deste modelo utiliza o DAN2-H para a previsão das demandas horárias, seguido pelo simulador hidráulico EPANET2. A otimização foi realizada pelo *multialgorithm-genetically-adaptive-method* (AMALGAM) vocacionado para a minimização dos custos e a maximização da confiabilidade hidráulica. Estudo de caso realizado na cidade de Araraquara, SP demonstrou uma redução no consumo de energia de 13,2% quando comparado a simulações realizadas com os dados históricos.

Estudo de caso realizado na cidade de Tampere, municipalidade de Pikkarla, sudeste da Finlândia. SUNELA & PUUST (2015) implantaram um sistema supervisor do tipo SCADA que realiza a aquisição de dados do SDA e envia para um aplicativo desenvolvido no EPANET, onde são simulados as condições hidráulicas e de qualidade da água. idade da água, temperatura, PH, dureza e cloro livre. Os dados coletados e simulados são armazenados em dois bancos de dados. Um, em formato *geographic information system* (GIS) e o segundo do tipo relacional. Alguns desses dados são disponibilizados ao público pela *web*.

3.2. CONVERSOR DE FREQUÊNCIA APLICADO À CMB

Como principais desvantagens sobre o uso de conversores de frequência aplicados

a sistema de bombeamento a ABB (2011), EUROPUMP, HYDRAULIC & INSTITUTE (2004) e GAMBICA (2006) identificam: custo inicial relativamente alto, introdução de distorções harmônicas na tensão, elevação da temperatura dos motores para valores baixos de frequência, uso de cabos de baixa impedância e alta frequência, limitada distância entre o drive do inversor e o motor além da limitação de uso em locais com baixa ventilação com a presença de produtos inflamáveis.

ABB (2011), EUROPUMP, HYDRAULIC & INSTITUTE (2004) e GAMBICA (2006) consideram como as principais vantagens sobre o uso de conversores de frequência aplicados a sistema de bombeamento: economia significativa de energia elétrica, controle de pressão eficiente, maior eficiência do rendimento dos conjuntos motor-bomba, controle do fator de potência, não interrupção do CMB em eventual falha do conversor, eliminação das correntes de partida, aumento da vida útil dos motores, redução do nível de ruídos, vibração e cavitação quando associados a válvulas de controle e etc.

O bombeamento de água com uso do conversor de frequência para o abastecimento da zona alta da cidade de Lins-SP promoveu uma redução na demanda de energia de 18% (TSUTIYA, 2007).

BORTONI *et al.* (2008) desenvolveram um sistema de otimização, baseado em programação dinâmica, para a operação de uma estação de bombeamento composta por três conjuntos motor-bomba. Foram simulados quatro cenários de funcionamento. Dentre eles, o que fez uso do conversor de frequência com livre funcionamento dos conjuntos, apresentou os melhores resultados.

Foram utilizados previsão de demandas horárias, pressão na saída dos conjuntos motor bomba e as curvas características como dados de entrada de um modelo de otimização desenvolvido no EPANET. As regras e restrições foram idênticas em duas simulações. Na primeira o conversor sofre variação de 5% sobre a frequência, enquanto a segunda simulação considera alterações de 2%. Estudo de caso realizado na estação de bombeamento de Teiul Domanei, Bucharest, Romênia mostrou que o segundo modelo manteve as pressões dentro das faixas predefinidas e proporcionou um consumo de 800 Kwh/dia frente aos 1200 Kwh/dia consumidos segundo os critérios empregados na primeira simulação (PERJU e GEORGESCU, 2010).

Foi realizada a reestruturação do SDA do município de Santana, São Paulo com a substituição dos conjuntos-motor-bomba existentes por quatro conjuntos de 100 CV, sendo

um reserva. Um conversor de frequência foi instalado junto ao motor-bomba 03. Além dessas alterações foram instalados transdutores de pressão e medidores eletromagnéticos em locais estratégicos da rede. O resultado das alterações promoveu uma redução de 33% nas perdas de água e 54% no consumo de energia (BRAGHIROL *et al.*, 2011).

Em um programa de reestruturação do SDA do município de Limeira-SP, foi utilizado um conversor de frequência aliado a um plano de operação, que demonstrou uma economia de 18,3% frente ao sistema atuando sem controle da velocidade de rotação (MAKINO, 2012).

Os variadores de velocidade ou *variable speed drive* (VSD) são equipamentos que regulam a força rotacional e a velocidade do eixo girante de equipamentos mecânicos. Estão subdivididos em três grupos: *variable frequency drive* (VFD), que usa componentes eletrônicos para variar a frequência de alimentação dos motores; *variable speed drive*, que usa equipamentos elétricos ou mecânicos e *adjustable speed drive* (ASD), que usa equipamentos elétricos e mecânicos para este fim. O uso destes equipamentos tem a função de melhorar o rendimento, economizar energia, melhorar o fator de potência e aumentar a vida útil dos motores e compressores (SAIDUR *et al.*, 2012).

Uma estação de bombeamento equipada com dois conjuntos motor-bomba funcionando em paralelo e um conversor de frequência atuando sobre o segundo conjunto. Este trabalho analisou duas situações quanto a maneira mais eficiente de uso de conversores de frequência. Na primeira situação o acionamento do segundo conjunto acontecia quando o primeiro conjunto atingisse sua frequência nominal. A segunda situação foi definida pela delimitação de áreas de eficiência sobre as curvas características do sistema e do conjunto motor-bomba. Dessa forma o acionamento do segundo conjunto acontece sempre que rendimento do conjunto de número 1 sair dessa área. Os resultados entre as faixas de 80 m³/h a 160 m³/h produziu uma economia de 20% a 25% sobre o consumo de energia (VIHOLAINEM *et al.*, 2013).

Foi utilizado um controlador lógico programável (CLP) em conjunto com um conversor de frequência, sensores de umidade solo e transdutores de pressão em um sistema de irrigação por pivot central. O sistema de comunicação entre a CLP e os sensores foi tecnologia Modbus RTU, Zigbee e Compobus. O acionamento do sistema é comandado pelo sensor de umidade do solo. A topografia do terreno faz com que as alturas manométricas variem ao longo do ciclo. O conversor atua sobre o conjunto motor-bomba

para evitar pressões acima das necessárias. Os resultados promoveram uma redução de 19% sobre o consumo de energia (PEREIRA *et al.*, 2013).

Sistema de otimização utilizando técnica de diferenças finitas com integrador de 4ª ordem foi aplicado a um SDA. Uma primeira simulação considerou os conjuntos motor-bomba funcionando a plena carga com rotação fixa dos motores. A segunda simulação com a utilização do modelo de otimização e fazendo uso de conversor de frequência funcionando a quatro faixas de rotação, conseguiu uma economia de 33,3% (DINIZ *et al.*, 2014).

Na mesma estação de bombeamento de Teiul Domanei, foi aperfeiçoado o modelo de otimização e operação dos CMB. Dois conjuntos motor-bomba e um conversor de frequência atuando apenas sobre o segundo CMB foi analisado. Várias simulações foram realizadas e comparadas com os dados históricos de 2012. Os resultados foram bastante satisfatórios e registrou uma predominância dos valores medidos sobre os simulados. Possivelmente por alterações sofridas nas curvas características dos CMB, promovido pelo desgaste físico, quando comparado com as curvas características fornecidas pelo fabricante (GEORGESCU *et al.*, 2014).

Foram utilizadas duas RNA na elaboração de um sistema de otimização dinâmica baseado em regras e operação dos CMB. A estação de bombeamento equipada com conversores de frequência demonstrou ser mais eficiente do que o método tradicional até então empregado. A economia com energia chegou a 17,1% (DINIZ *et al.*, 2015).

Considerando uma RDA hipotética foram analisadas várias alternativas sobre controle de pressão. válvulas de controle, by-pass, booster e VSD . Alguns artifícios tiveram de ser utilizados no EPANET para que fosse possível a simulação dos efeitos desses equipamentos sobre o controle de pressão na rede. Dos vários equipamentos analisados o booster apresentou os melhores resultados (GEORGESCU *et al.*, 2015).

3.3. SISTEMAS FUZZY E REDES NEURAS ARTIFICIAIS - RNA

O uso simultâneo de técnicas de sistemas fuzzy, redes neurais artificiais e demais abordagens no campo da inteligência artificial, tornaram-se um fator impeditivo na separação do uso dessas técnicas em subitens. Portanto, para maior clareza foi realizada

uma subdivisão sobre as áreas de: sistemas de distribuição de água, níveis de reservatórios superficial e subterrâneo, previsões de vazão e demandas de água, previsões de precipitação e preenchimento de falhas hidrológicas e qualidade da água.

3.3.1. Sistemas de Distribuição de Água

Um sistema de controle *fuzzy* foi aplicado a um conversor de frequência e uma válvula de controle proporcional posicionada a montante do ponto de controle. O sistema controla a pressão na entrada de duas zonas topograficamente diferentes. Um CMB e um booster foram utilizados como sistema propulsor responsável pela elevação da água. Os resultados obtidos indicam uma considerável redução no consumo de energia (CARVALHO, 2012).

Foram analisados três abordagens sobre a estimativa de rugosidade e calibração de redes de abastecimento de água: RNA, AG e método iterativo de gradiente hidráulico alternativo MIGHA, modelo que melhor ajustou os valores de pressão, restando aos modelos AG e RNA os melhores ajustes quanto a rugosidade (ROCHA *et al.*, 2012).

Sistema de controle proporcional e um algoritmo de perda de carga induzida, por meio da abertura e fechamento de válvulas de controle, demonstrou ser bastante eficiente no controle de pressão piezométrica em um SDA. O estudo de caso foi realizado a nordeste da Itália e resultou em pequenas variações sobre vários cenários de pressão de referência, com concomitante redução de perdas de água por vazamento (CREACO e FRANCHINI, 2013).

CAMBOIM *et al.*, (2014) desenvolveram um sistema *fuzzy* de controle de pressão de redes de distribuição de água, por meio da utilização de conversores de frequência acoplados aos conjuntos motor-bomba. O controlador *fuzzy* determina a melhor opção, referente ao consumo energético do sistema, e toma decisão quanto ao estado dos motores (ligado, desligado ou com rotação parcial). Os experimentos foram realizados no laboratório de eficiência energética – LENHS da Universidade Federal da Paraíba UFPB. Quando comparado com sistema de injeção direta sem o controle de pressão a redução sobre o consumo energético foi de 15,5%.

DI NARDO *et al.* (2014) utilizaram algoritmo genético AG em estudo de previsão

de vazamentos em redes de distribuição de água. Estudo de caso realizado na província de Nápoles, Itália, possibilitou a validação do modelo. Os resultados demonstraram uma avaliação mais precisa entre os parâmetros envolvidos na relação demanda e vazamento. O aumento da confiabilidade das previsões foi comprovada com dados da rede de distribuição.

Modelo desenvolvido em algoritmo genético - AG acoplado ao EPANET foi utilizado no controle de rede de distribuição de água. Foi realizado dois esquemas de operação. Um esquema tradicional, baseado em regras, que aciona os sistemas de bombeamento sempre que os reservatórios atingem determinado nível. O segundo esquema é uma combinação de módulos de previsão e de simulação hidráulica. Este modelo demonstrou ser mais eficiente em reduzir o custo de energia de bombeamento em 20% (KANG, 2014).

O gerenciamento de pressões em redes de distribuição de água tem sido utilizado a mais de três décadas com o intuito de reduzir as perdas de água. Em estudo recente, foi realizado uma avaliação de sensibilidade de vários parâmetros que relacionou a pressão média nos sistemas de distribuição de água com os elevados valores do expoente de vazamento (SCHWALLER e ZIL, 2014).

Cumprir com eficiência a solicitação de ligações de água na China tem sido um dos maiores desafios enfrentados nos últimos anos. Effective decision support system – DSS são fundamentais para gerenciamento do consumo de energia dos sistemas de bombeamento e perdas por vazamento. Trabalho conjunto realizado entre a China e a Itália tem demonstrado este avanço (BERARDI *et al.*, 2014).

Um controlador de pressão do tipo proporcional integrativo e derivativo PID foi utilizado em uma rede de distribuição de água na cidade de Poznań, Polônia. Os resultados foram refletidos pela redução de 2,7% sobre o consumo de energia e uma redução estimada de perdas de água por vazamento de 20% (BAKKER *et al.*, 2014).

Outro sistema de controle *fuzzy* para conjuntos motor-bomba operando com rotação variável foi desenvolvido para demonstrar a economia de energia proporcionada pelo uso do conversor de frequência. Trabalho realizado em bancada experimental do LENHS-UFPB demonstrou uma redução de até 35% sobre o consumo de energia e erro médio em torno de 1,02% (BEZERRA *et al.*, 2015).

Ainda, no laboratório de eficiência energética – LENHS-UFPB foi desenvolvido um sistema de controle adaptativo para o modelamento e controle, em tempo real, de um sistema de distribuição de água SDA. Os controladores atuaram no controle da pressão por meio da variação da velocidade de rotação do sistema de bombeamento e do ângulo de abertura de uma válvula de controle. O sistema de controle do tipo variância mínima generalizada GMV produziu uma redução de energia de 19,2% com erro máximo de 2,12% (SILVA *et al.*, 2015).

3.3.2. Níveis de Reservatórios Superficial e Subterrâneo

Estudo realizado na bacia hidrográfica de Chateauguay, província de Quebec no Canadá utilizou de técnica de refinamento para a entrada de dados de uma RNA. A técnica utilizada é denominada de Wavelet Transform, que acoplada a uma RNA resulta em uma arquitetura híbrida conhecida por WA-ANN. Utilizando a precipitação total mensal, temperatura média mensal de dois meses antecedentes mais o nível do lençol freático de um mês de antecedência foi possível prever o nível do aquífero do mês seguinte. O coeficientes de correlação, nas estações de medição de Mercier e St-Remi, mostraram que o Modelo WA-ANN foi superior ao RNA e este por sua vez superior ao tradicional ARIMA – autoregressive moving average (ADAMOWSKI e CHAN, 2011).

Estudo realizado em Punta Sabbioni, localizado na fronteira da lagoa veneziana, Venetian Lagoon, na Itália, com o objetivo de prever inundações oriundas da elevação das marés através da previsão do nível do lençol freático (costeiro). Uma RNA foi utilizada com a precipitação média e a evaporação como variáveis de entrada, tangente hiperbólica como função de ativação e Levenberg-Marquardt – LM, como algoritmo de treinamento. O resultado foi bastante promissor quando comparado com o tradicional método ARX – Auto-Regressive with eXogenous inputs (TAORMINA *et al.*, 2012).

Estudo de previsão horária do nível do mar foi realizado em Darwin Harbor, Austrália. Foi utilizada uma RNA, ANFIS e o modelo ARMA. Preliminarmente foi realizados estudo de regressão linear múltipla MLR para determinar quais as combinações de entradas ótimas a serem utilizadas nos modelos. O resultado obtido demonstrou que a RNA e ANFIS foram superiores ao modelo ARMA (KARIMI *et al.*, 2012).

Em Semman, província do Iran, foi realizado estudo de previsão de nível do aquífero subterrâneo da região, utilizando as técnicas de RNA artificial neural network, ANFIS artificial neural network *fuzzy* inference system. Os resultados de previsão demonstraram mais precisos com o uso da ANFIS, do que da RNA, com coeficientes de correlação de 0,96 e 0,83 respectivamente (EMAMGHOLIZADEH *et al.*, 2014).

TAPOGLOU *et al.* (2014) utilizaram uma RNA combinada com o PSO *particle swarm optimization* com o objetivo de superar o processo de treinamento envolvendo a técnica da retropropagação, *backpropagation*. Com uma rede composta por quatro neurônios de entrada, duas camadas intermediárias e um único neurônio de saída: o nível do reservatório ou altura piezométrica. A variação do GLB-PSO, global best PSO obteve melhores resultados quando aplicado ao aquífero de Agia localizado na Grécia.

Estudo comparativo entre redes neurais artificiais Perceptron de múltiplas camadas - MPL, redes Bayesian e ANFIS foi realizado com o objetivo de prever o nível do lençol freático situado na região semi-árida da província de Dindgul. Preliminarmente foi realizado estudo de sensibilidade através da técnica ARD – automatic relevance determination com a intenção de determinar as variáveis de entrada mais relevantes no estudo. A precipitação média mensal e a temperatura máxima mensal foram os dados mais impactantes. A arquitetura ANFIS comportou-se de maneira superior as demais (MAITI e TIWARI, 2014).

3.3.3. Previsões de Vazão e Demandas de Água

Com o propósito de estimar a vazão do aquífero Rochefoucauld, situado no sudoeste da França. KURTULUS e RAZACK (2006) utilizaram uma RNA com algoritmo de LM. O estudo se assemelha aos conhecidos modelos chuva-vazão para a previsão da vazão de rios. Entretanto, sua particularidade está na previsão das descargas do aquífero, situada em dois pontos de medição: La Trouve e La Lèche Spring. Com os valores de precipitação e vazão referentes aos seis dias anteriores foi possível prever a vazão do dia seguinte com coeficiente de correlação de 0,99.

Três diferentes métodos de abordagem, artificial neural network RNA, adaptive neuro *fuzzy* inference system ANFIS e support vector machine SVM, foram utilizados para

a previsão da vazão de aporte a represa de Pailugou, localizada em uma região semiárida e montanhosa no nordeste da China. Foram analisadas vazões diárias durante o período de 2001 a 2003 e 2009 a 2011. As três metodologias obtiveram boa previsão para vazões baixa e média magnitude. Porém não responderam bem as vazões máximas (HE *et al.*, 2013).

TIWARI & ADAMOWSKI (2013) utilizaram o modelo híbrido wavelet-bootstrap-neural network WAB-RNA em previsão de demanda de água urbana de curto prazo (1, 3 e 5 dias; 1 e 2 semanas; e 1 e 2 meses). Esta metodologia foi comparada com os modelos, autoregressive integrated moving average - ARIMA, autoregressive integrated moving average model with exogenous input variables - ARIMAX, RNA tradicional, wavelet neural network - WA-ANN e bootstrap neural network - B-ANN. Este estudo foi testado com dados da cidade de Montreal, Canadá. As respostas mais precisas quanto as previsões diárias e semanais foram dos modelos WA-ANN e WAB-ANN. Quanto as previsões mensais o modelo WA-ANN obteve melhor comportamento.

Estudo de previsão de curto prazo de previsão de demanda de água tratada foi realizado nas cidades de Amsterdam, Rijnregio, Almere, Helden, Valkenberg e Hulsberg, Holanda. Foi utilizado um modelo determinístico para previsão da demanda nas próximas 48 horas com incremento de 15 minutos. Os resultados foram bastante satisfatórios, atingindo correlação de 0,803 (BAKKER *et al.*, 2013).

VAFAKHAH *et al.* (2014) realizaram estudo de previsão chuva/vazão. Foram utilizados dados de vazão diária da estação hidrométrica do rio Gorgan e dados de precipitação diária de cinco estações meteorológicas operada pelo Iраниan Water Research Institute, Iran. Foram analisados os modelos ARX, ARMAX, RNA, ANFIS e WA-ANN. A adaptive neuro *fuzzy* inference system ANFIS superou os demais modelos. Segundo os autores a combinação dos efeitos de fuzificação, das entradas, através das funções de pertinências, aliado as habilidades de aprendizado das RNA corroboram para o resultado.

Estudo de simulação hidrológica para a previsão de vazões mensais realizado na bacia do rio Ijuí, Rio Grande do Sul, demonstrou boa capacidade preditiva de uma RNA. Os dados de entrada utilizados foram: precipitação e evapotranspiração mensal defasados em tempos (t) e (t-1). A RNA desenvolvida foi comparada com o modelo hidrológico conceitual adaptado para simulações mensais – SMAP, resultando em desempenho superior da RNA frente ao SMAP com coeficiente de Nash-Sutcliffe (coeficiente de

correlações hidrológicas) de 0,898 e 0,672 respectivamente (OLIVEIRA *et al.*, 2014).

3.3.4. Previsões de Precipitação e Preenchimento de Falhas Hidrológicas

A previsão de precipitação diária máxima anual é tema de grande complexidade para os modelos estatísticos tradicionais. NASTOS *et al.* (2013) utilizaram dados de precipitação durante o período de 1891 a 2009 oriundos do NOA – National Observatory of Athens (Grécia). NASTOS *et al.* (2013) primeiramente aplicaram um Algoritmo Genético sobre os dados históricos, reduzindo os dados anuais a dois fatores, que serviram como entradas de uma RNA com uma camada intermediária e tendo como saída a precipitação máxima diária durante o ano. Os resultados foram promissores com coeficiente de correlação de 0,482 e índice de concordância IA de 0,817.

Com o objetivo de melhorar a confiança sobre a previsão de chuvas de curto prazo TIWARI *et al.* (2013) utilizaram várias técnicas em seus estudos. Self-organising maps (SOM), utilizada para a identificação de padrões, conduziu o processo de classificação dados de vazão diária com um, dois e três dias de antecedência nos grupos, baixas, médias e altas descargas. Esses grupos, separadamente, alimentaram uma variedade de redes neurais artificiais e combinações entre diversas técnicas, RNA, WA-ANN, bootstrap artificial neural network B-ANN, wavelet-bootstrap artificial neural network WAB-ANN. O estudo, realizado na bacia do rio Mahanadi, Índia, mostrou que o modelo WAB-ANN foi mais preciso.

Previsão de chuvas de curta duração na bacia hidrográfica do reservatório de Shihmen, Taiwan, utilizou ANFIS. Os dados de precipitação vieram de 13 pluviógrafos, de 4 estações de radar. A previsão para uma e duas horas revelaram coeficiente de correlação de 0,85 e 0,72, respectivamente (CHANG *et al.*, 2013).

Preenchimento de falhas em séries horárias de dados de precipitação na bacia hidrográfica do rio Taboão, Rio Grande do Sul utilizando RNA. O coeficiente de Nash-Sutcliffe mínimo, encontrado durante o treinamento e validação foi de 0,91 e 0,90, respectivamente. Enquanto o valor máximo atingiu 0,99 (DEPINÉ *et al.*, 2014).

3.3.5. Qualidade da Água

O rio Johr, localizado no estado de Johr, na Malásia, o qual é degradado significativamente pelas atividades humanas e industriais foi utilizado como estudo de caso de previsão de qualidade da água. Para isso foi utilizado uma RNA do tipo MLP e do tipo radial basis function RBF-ANN e linear regression models – LRM. Os modelos foram elaborados individualmente com dados de entrada de sólidos totais dissolvidos TD e condutividade e como resultado os valores de condutividade elétrica, TD e turbidez. A arquitetura do tipo RNA e RBF-ANN demonstraram maior precisão do que o LRM (NAJAH *et al.*, 2012).

Uma RNA foi utilizada para projetos de simulação e configuração de reator anaeróbico compartimentado - ABR. Para esta abordagem foi configurado uma RNA com seis neurônios de entrada, doze neurônios na primeira e dois na segunda camada intermediárias e dois neurônios na saída. Os resultados foram bastante satisfatórios com coeficientes de correlação de 0,915 e 0,974 entre as fases de treinamento e validação, confirmando o importante papel do uso de RNA na previsão e otimização de ABR (JAMSHIDI *et al.*, 2014).

Foi examinado a eficiência de multivariate linear regression – MLR e RNA na previsão dos dois principais parâmetros de qualidade da água: biochemical oxygen demand – BOD e chemical oxygen demand – COD. A RNA com dados de entrada de temperatura T, PH, sólidos totais suspensos TSS e sólidos totais resultaram em coeficientes de correlação de 0,83 e 0,81 para os parâmetros BOD e COD, respectivamente (ABYANEH, 2014).

CAPÍTULO IV

MATERIAIS E MÉTODOS

4.1. INTRODUÇÃO

Os sistemas de abastecimento de água possuem uma dinâmica própria relativa ao consumo de água ao longo do tempo, fazendo variar de valores baixos, nos horários de menor demanda, até atingir valores elevados, em períodos de grandes demandas. A vazão, grandeza física envolvida neste processo, através da sua variação temporal, provoca, como consequência a variação da pressão ao longo da rede de distribuição de água.

Na Figura 4.1 pode ser visto um sistema de distribuição de água por bombeamento direto sem o controle de pressão. A linha piezométrica 01 reflete o caso em que as demandas dos usuários encontram-se em níveis baixos. Isto implica em valores de pressão acima do necessário. Enquanto a linha piezométrica 02 representa a hora de maior consumo de água. Percebe-se que sobre essa hipótese (02) os valores de pressão estão bem abaixo da linha piezométrica para o caso 01. Ao longo do dia os valores referentes às demandas de água estão em constante mudança e provocando, com isso, variações sobre as linhas de pressão do sistema. Este fato explica a importância do controle de pressão nos sistemas de abastecimento de água, reduzindo custos com o consumo de energia e evitando os efeitos nocivos da pressão sobre as redes de distribuição. O uso dos conversores de frequência tem sido utilizado com o objetivo de controlar as pressões através da variação de rotação dos conjuntos motor-bomba CMB. Sempre que o sistema necessitar de aumento de pressão o inversor será solicitado a aumentar a valor da frequência e, por conseguinte, da rotação da bomba, elevando, assim, a linha piezométrica sobre a rede de tubulações. Do

contrário, quando a pressão for excessiva na rede, o inversor será impelido a reduzir a frequência e diminuindo com isso a rotação do CMB.

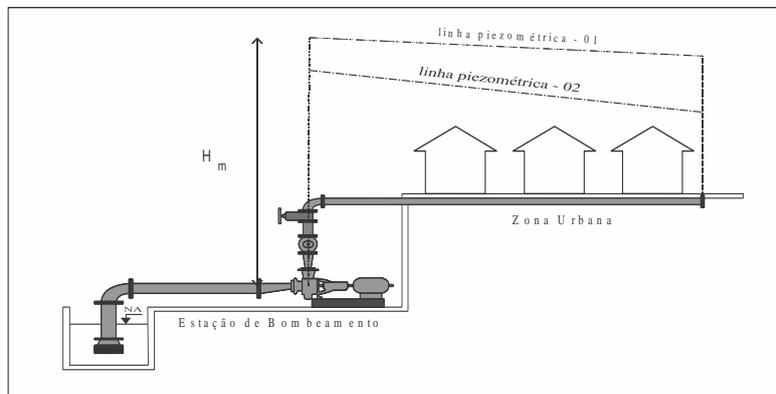


Figura 4.1 – Representação Esquemática de um Sistema de Distribuição de Água

4.2. BANCADA EXPERIMENTAL

No desenvolvimento dos sistemas de controle apresentados neste trabalho foi utilizada uma bancada experimental, localizada no laboratório de Eficiência Energética, Hidráulica e Saneamento da Universidade Federal da Paraíba – LENHS UFPB, ver Figura 4.2.

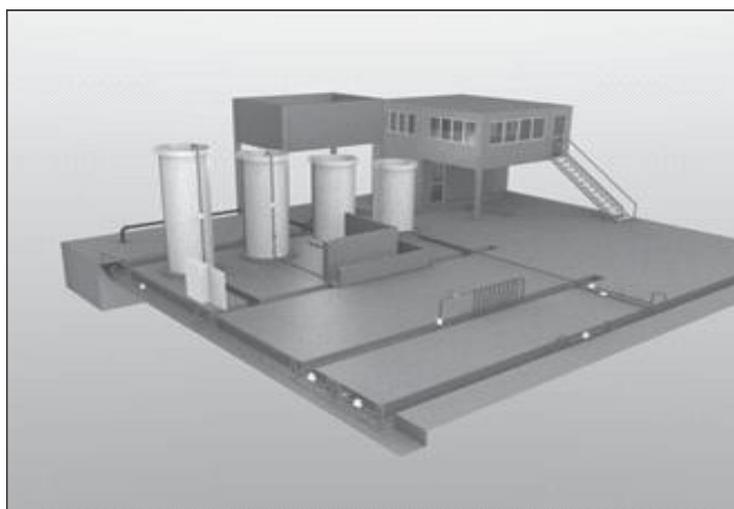


Figura 4.2 – Bancada Experimental

O sistema de distribuição de água do LENHS-UFPB, denominado doravante de bancada experimental (BE), possui 150 m de tubulações de PVC e ferro dúctil com diâmetros de 50 mm e 100 mm. Quatro saídas controladas por registros de gaveta que simulam a demanda de água na rede. A planta baixa da BE, Figura 4.2, está totalmente instrumentalizada por: 11 medidores de vazão eletromagnético, 02 medidores de nível ultra-sônico, 01 medidor de vazão ultrassônico, 14 transdutores de pressão, 16 válvulas solenoides, 02 válvulas proporcionais, 01 válvulas multifuncional, e 01 conversor de frequência. Além dos equipamentos de medição possui 01 reservatório inferior, 01 reservatório superior, ambos de concreto armado com capacidade de 15 m³.

O sistema de bombeamento, Figura 4.3, é composto por três conjuntos motor bomba em paralelo, sendo um de 5 CV, com motor de alto rendimento, e dois de 15 CV, sendo um com motor de alto rendimento e outro com motor convencional (standard). A bomba de 5 CV impulsiona a água diretamente para a rede de abastecimento, enquanto que as duas de 15 CV recalcam a água do reservatório inferior para o reservatório elevado de 15 m³. Através de manobras de registros, as três bombas podem funcionar, simultaneamente, alimentando a rede hidráulica do SPDA. As vazões e pressões nominais da bomba de 5 CV são, respectivamente, de 50 m³/h e 17 mca, enquanto que as bombas de 15 CV os valores nominais são de 162 m³/h e 17 mca, respectivamente. Neste trabalho foi utilizada o conjunto motor bomba de 5 CV com bombeamento direto na rede hidráulica da BE. Terceiro CMB, da esquerda para a direita na Figura 4.3.



Figura 4.3 – Estação de Bombeamento

A Figura 4.4 representa a planta baixa da bancada experimental. Para aumentar a clareza da representação foram omitidos os equipamentos e instrumentos que não fizeram parte deste estudo. Portanto temos representados os transdutores de pressão (PT_1, PT_3, PT_7, PT_8 e PT_15), conjunto motor-bomba (CMB), inversor de frequência (IF), controlador lógico programável (CLP), reservatório inferior, além das tubulações e conexões.

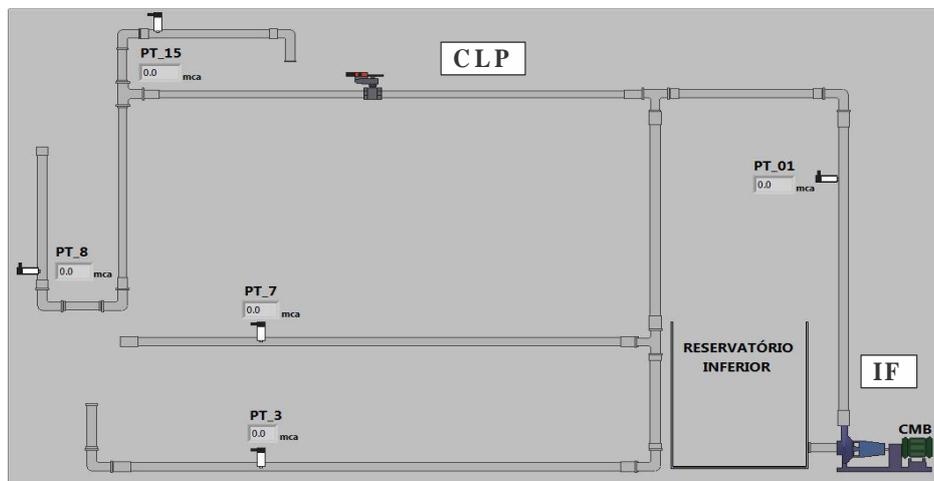


Figura 4.4 – Planta Baixa do Bancada Experimental

A rede foi projetada para que as águas bombeadas desde o reservatório inferior até a rede de distribuição fossem descarregadas em pontos específicos do sistema. Depois de percorrer os vários trechos da BE, as águas são captadas por canais retangulares que as conduzem ao reservatório de origem onde fora captada pelo CMB. Isto garante o reuso contínuo das águas.

O sistema de controle *fuzzy* neural (SCFN) e o sistema de controle neural adaptativo (SCNA) foram utilizados com o objetivo de controlar a pressão em um ponto da rede localizado após o conjunto motor bomba (CMB) e identificado pelo transdutor de pressão PT-04. A ação sobre o controle da pressão se fará pela atuação do inversor de frequência sobre o CMB.

Ao SCADA foi implementado um sistema de seleção sobre quatro pontos da rede identificado pelos transdutores de pressão PT-03, PT-07, PT-08 e PT-15. O objetivo é identificar o ponto de menor pressão à ser controlado pelo SCNA.

4.3. EQUIPAMENTOS

O motor elétrico, que compõe o conjunto motor bomba, é de indução, trifásico 220/380 V, potência de 5CV da marca WEG. A bomba é do tipo centrífuga radial da marca KSB. Ao conjunto motor-bomba (CMB) confere as características de vazão máxima de 50 m³/h e altura manométrica de 19 mca, Figura 4.5.



Figura 4.5 – Conjunto motor-bomba

O conversor de frequência (CF) é da marca WEG, modelo CFW-11, com alimentação trifásica 220/380 Vca e corrente nominal de 13 A.



Figura 4.6 – Conversor de Frequência

Os transdutores de pressão disposto ao longo da rede hidráulica é do tipo piezo-resistivo de silício, com sinal de saída variando entre 4 e 20 mA, faixa de medição variando entre 0 e 42,18 mca, tempo de resposta de 1 milissegundo e precisão de $\pm 0,2\%$.



Figura 4.7 – Transdutor de Pressão

Os transdutores de vazão são do tipo eletromagnético, da marca Incontrol, modelo VMS-038, com sinal de saída variando entre 4 e 20 mA, o que corresponde a uma faixa de medição de vazões de 1,24 até 40,8 m³/h.



Figura 4.8 – Transdutor de Vazão

A válvula de controle instalada na rede é do tipo proporcional em formato de esfera com tensão de alimentação de 24 V e ângulo de abertura variando de 0° e 90°.



Figura 4.9 – Válvula de Controle Proporcional

O controlador lógico programável (CLP) é da marca IMS e possui: fonte de alimentação, três módulos de entradas digitais, cinco módulos de entrada analógica, um módulo de saída analógica e um módulo de comunicação Modbus. Estas características possibilitam uma excelente comunicação e controle dos equipamentos instalados na rede.



Figura 4.10 – Controlador Lógico Programável

4.4. SISTEMAS SUPERVISÓRIO E DE AQUISIÇÃO DE DADOS

Um sistema supervisorio de aquisição e transmissão de dados do tipo SCADA (*supervisory control and data acquisition*), foi desenvolvido para o controle das condições de operação da rede. Por ser um sistema automatizado, admite o desenvolvimento de rotinas de simulação e monitoramento da rede em tempo real, possibilitando que os dados coletados sejam tratados e armazenados em um banco de dados que irá compor a base de dados históricos do sistema. Este sistema foi concebido em ambiente LabVIEW® com o protocolo de comunicação Modbus e pode ser visto nas Figuras 4.11 e 4.12.

O monitoramento e supervisão em tempo real dos transdutores de pressão, medidores de vazão, frequência do conversor, sinais elétricos de corrente e tensão e níveis dos reservatórios compreende a importância do SCDA para os técnicos, pesquisadores e operadores da BE.

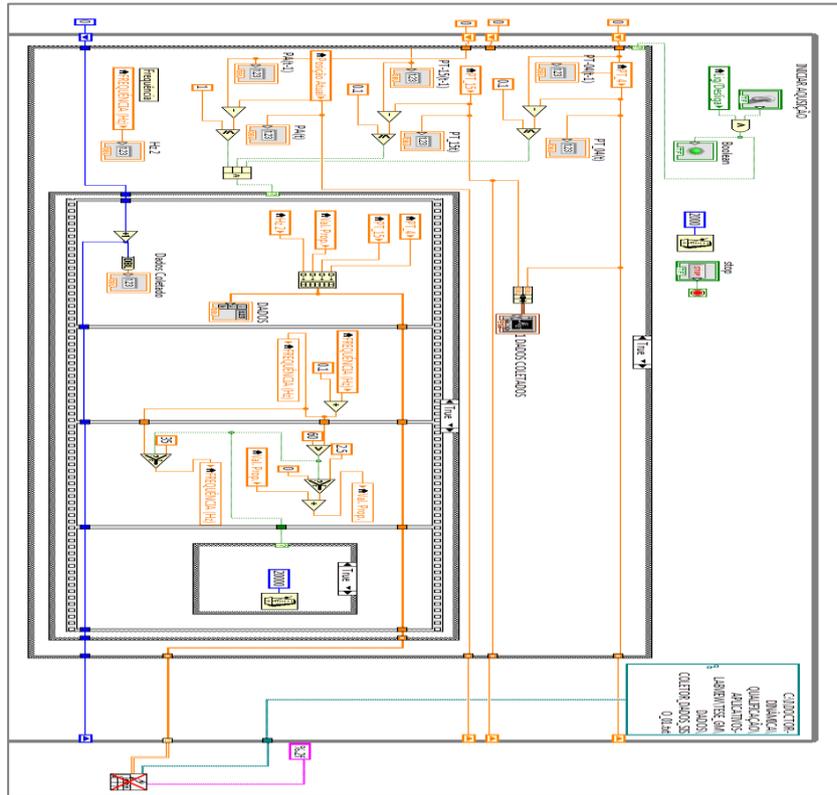


Figura 4.11 – Painel de Controle do SCADA (código fonte)

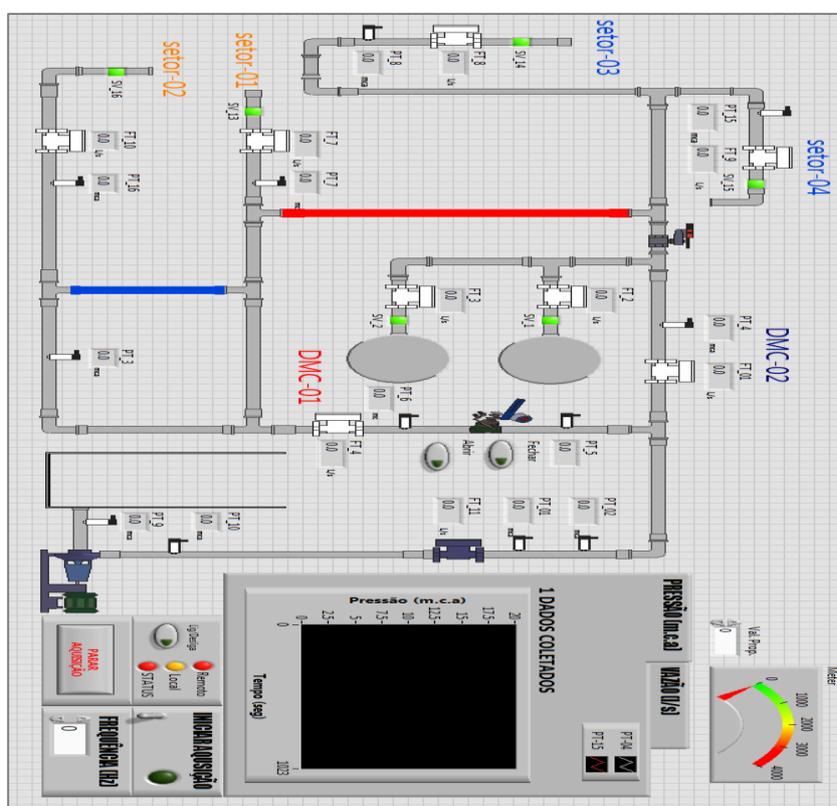


Figura 4.12 – Painel Frontal do SCADA

4.5. SISTEMA DE CONTROLE NEURAL NÃO ADAPTATIVO

A arquitetura considerada mais adequada para a RNA dispõe de uma camada oculta. Este fato não resulta em perda de qualidade ou mesmo capacidade de aprendizado por parte da rede, posto que uma RNA com uma camada oculta é capaz de identificar um sistema com a mesma precisão que teria uma RNA com múltiplas camadas ocultas. (HAYKIN, 1999).

Foi utilizado neste trabalho o treinamento (*off-line*) assistido, em que são apresentados os dados de entrada e saída desejados. Em nosso caso pressão desejada e frequência do conversor a ser estimada.

Foi seguida uma rotina de passos com o objetivo de garantir um bom treinamento da RNA. Desde a coleta de dados através do SCADA até a apresentação destes dados na fase de treinamento.

O primeiro cuidado diz respeito à quantidade de dados a ser apresentada a rede, assim como, à disposição em que esses dados serão apresentados.

O SCADA coleta dados de pressão e frequência do conversor em ordem crescente, fazendo variar o conversor desde a frequência de 35Hz até 60Hz. Este procedimento de aquisição produz valores sequenciados e crescentes de pressão e frequência. O fato de apresentarmos esses dados à fase de treinamento da RNA iria promover uma tendência sobre resultados. Ou seja, a rede guardaria o aprendizado dos últimos dados apresentados em detrimento do aprendizado inicial. Para contornar este inconveniente os dados foram embaralhados antes de serem levados à fase de treinamento.

Foi percebido ao longo das primeiras tentativas de treinamento que o número de dados era um limitante ao aprendizado. Portanto foi necessária a multiplicação dos dados até valores que garantisse um treinamento satisfatório.

Para garantir que os dados fossem apresentados em quantidade e misturados adequadamente foram seguidos os passos: multiplicar os dados e em seguida misturá-los.

Após o tratamento dos dados coletados partiu-se para o treinamento. Através de tentativas e erros chegamos ao número de neurônios da camada intermediária e do coeficiente de aprendizado μ . A função de ativação utilizada em nossa RNA foi a tangente

hiperbólica, com valores do coeficiente de aprendizado μ de 0,12 e um número de 11 neurônios na camada intermediária, Figura 4.13.

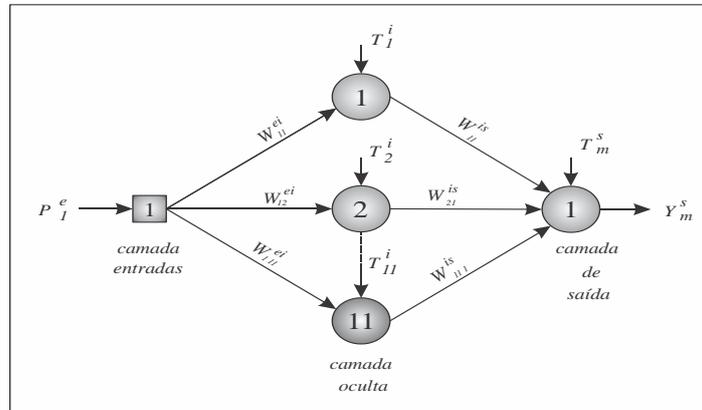


Figura 4.13 – Arquitetura da Rede Neural de Projeto

Para que essa tarefa fosse cumprida a contento, foi elaborado um conjunto de Aplicativos Computacionais. O MatLAB foi adotado como uma linguagem de programação convencional.

Em todos os códigos desenvolvidos não foi utilizada nenhuma função interna do MatLAB, o que garante a tradução para a linguagem C conferindo os mesmos resultados alcançados.

Em ordem de desenvolvimento foram elaborados os seguintes programas computacionais:

- Eliminador de Zeros – Durante a fase de coleta o SCADA cumpre uma restrição de gravar os dados coletados, desde que a diferença entre os valores em um instante t e $t-1$ não seja superior a 0,1. Apêndice A.1
- Eliminador de Dados Inconsistentes – Devido a flutuação provenientes da dinâmica do sistema poderia acontecer de termos valores de frequência bem maior e um equivalente de pressão menor. Este código elimina tais ocorrências. Apêndice A.2
- Multiplicador de Dados – A fim de garantir uma quantidade adequada de dados ao treinamento foram feitas multiplicações dos dados originais. Apêndice A.3
- Misturador de Dados – Este algoritmo tem o objetivo de embaralhar os dados

de forma aleatória para evitar a apresentação de dados sequenciados. Apêndice A.4

- Treinamento da RNA – Este programa utiliza a técnica do gradiente descendente com retropropagação para o treinamento da rede. Nesta fase são experimentados valores para o coeficiente de aprendizado e do número de neurônios da camada intermediária. É ao final desta fase que serão conhecidos os valores ajustados para os pesos, limiar de ativação e o (beta) da função de ativação tangente hiperbólica. Apêndice A.5
- Validação da RNA – Foi utilizado uma amostra de dados exclusiva para esta fase. O objetivo é a validação do treinamento. Apêndice A.6

Após concluída as fases de aquisição e tratamento dos dados, treinamento supervisionado e validação partiu-se para o desenvolvimento do controlador neural em malha aberta de acordo com a Figura 4.14.

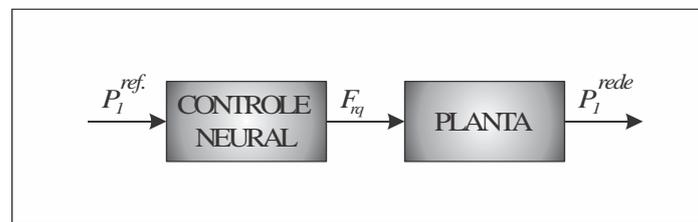


Figura 4.14 – Diagrama de Blocos do Controlador Neural em Malha Aberta

Onde:

P_1^{ref} – Pressão de Referência ou Desejada no ponto de controle 01.

P_1^{rede} – Pressão na Rede no ponto de controle 01.

F_{rq} – Frequência.

Os resultados e discussão sobre o comportamento do sistema de controle neural (SCN) no tempo pode ser visto no Capítulo 5, item 5.1.

O código fonte do SCN, desenvolvido em ambiente LabVIEW®, Figuras 4.15. Enquanto a Figuras 4.16 mostra o painel frontal.

4.6. SISTEMA DE CONTROLE *FUZZY*

O trabalho investigativo segue outro rumo. A lógica *fuzzy* passa a ser explorada a fim de avaliar o comportamento da planta no regime transitório e permanente. Para isso foi realizado uma longa pesquisa sobre trabalhos envolvendo lógica *fuzzy* nos últimos anos no LENHS-PB (Bezerra, 2009) e (CAMBOIM et al., 2014).

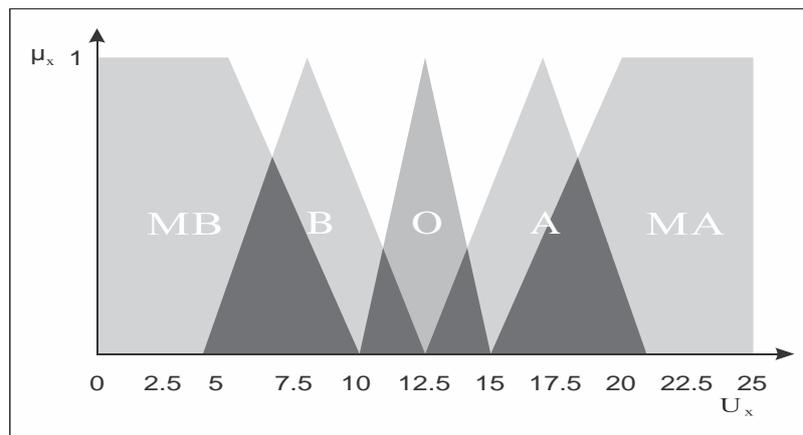


Figura 4.17 – Variável *Fuzzy* da Pressão.

Onde:

- MB – Pressão Muito Baixa
- B – Pressão Baixa
- O – Pressão Ótima
- A – Pressão Alta
- MA - Pressão Muito Alta

As variáveis *fuzzy* e as funções de pertinência foram adotadas com base nos trabalhos de (BEZERRA, 2009) e (BEZERRA *et al.*, 2015). Com isto foram consideradas duas variáveis *fuzzy* antecedentes. A variável *fuzzy* da pressão, Figura 4.17 e a variável *fuzzy* da derivada da pressão, Figura 4.18.

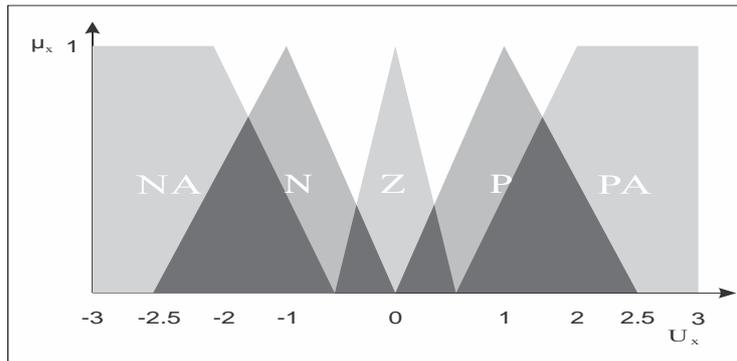


Figura 4.18 – Variável *Fuzzy* da Derivada da Pressão

Onde:

- NA – Derivada da Pressão Negativo Baixa
- N – Derivada da Pressão Negativa
- Z – Derivada da Pressão Zero
- P – Derivada da Pressão Positiva
- PA – Derivada da Pressão Positiva Alta

O incremento/decremento da rotação do conversor de frequência foi tomado sobre a variável consequente denominada de gradiente de rotação, como pode ser vista na Figura 4.19.

Gradiente de Rotação é a variável de inferência, acionada sempre que as variáveis antecedentes, pressão e derivada de pressão, são combinadas pela a regra Mandani. Figura 4.19.

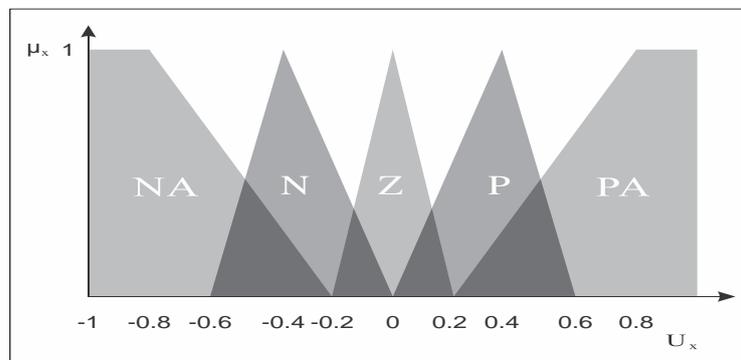


Figura 4.19 – Variável *Fuzzy* do Gradiente de Rotação do Conversor de Frequência

Onde:

- NA – Gradiente de Rotação Negativo Alto
- N – Gradiente de Rotação Negativo
- Z – Gradiente de Rotação Zero
- P – Gradiente de Rotação Positivo
- PA – Gradiente de Rotação Positiva Alto

Foi desenvolvido um Sistema de Controle *Fuzzy* (SCF) utilizando-se de ferramenta pertencente ao do LabVIEW®. Uma representação em diagrama de blocos como pode ser vista na Figura 4.20.

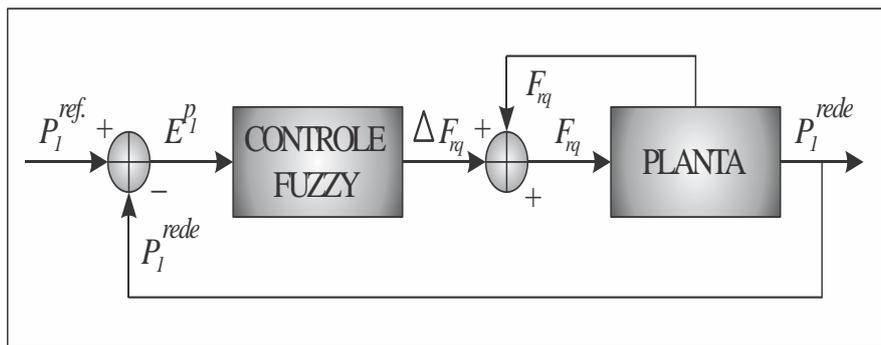


Figura 4.20 – Diagrama de Blocos do Controlador *Fuzzy* em Malha Fechada

Onde:

$P_1^{ref.}$ – Pressão de Referência ou Desejada no ponto de controle 01.

P_1^{rede} – Pressão na Rede no ponto de controle 01.

F_{rq} – Frequência.

ΔF_{rq} – Gradiente da Frequência.

E^{P_1} – Erro da Pressão no ponto de controle 01 ($P_1^{ref.} - P_1^{rede}$).

Os resultados e discussão sobre o comportamento do sistema de controle *fuzzy* (SCF) no tempo pode ser visto no capítulo 5, item 5.2.

O SCF desenvolvido em ambiente LabVIEW® constam das Figuras 4.21 e 4.22.

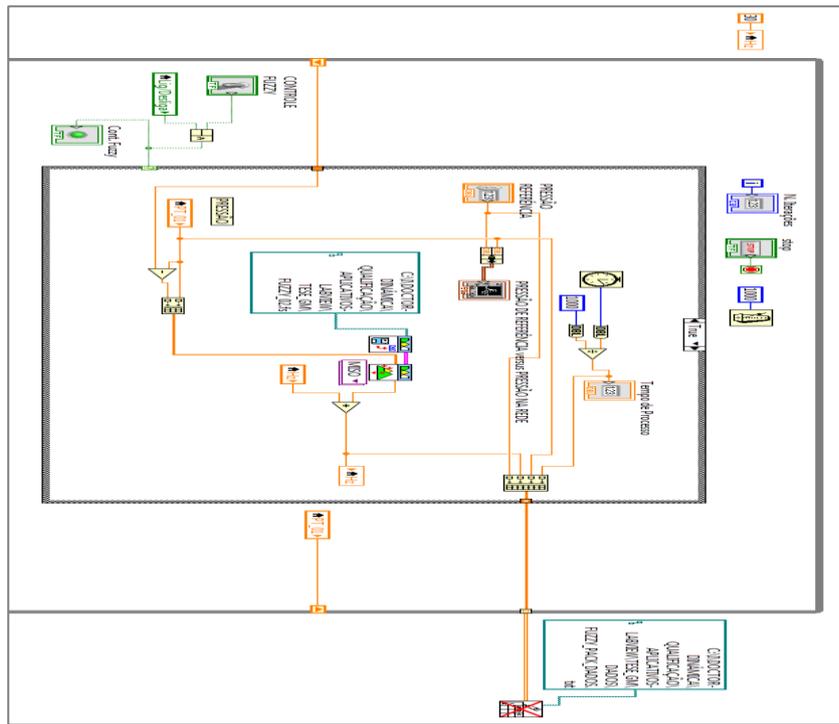


Figura 4.21– Painel de Controle do SCF, (código fonte)

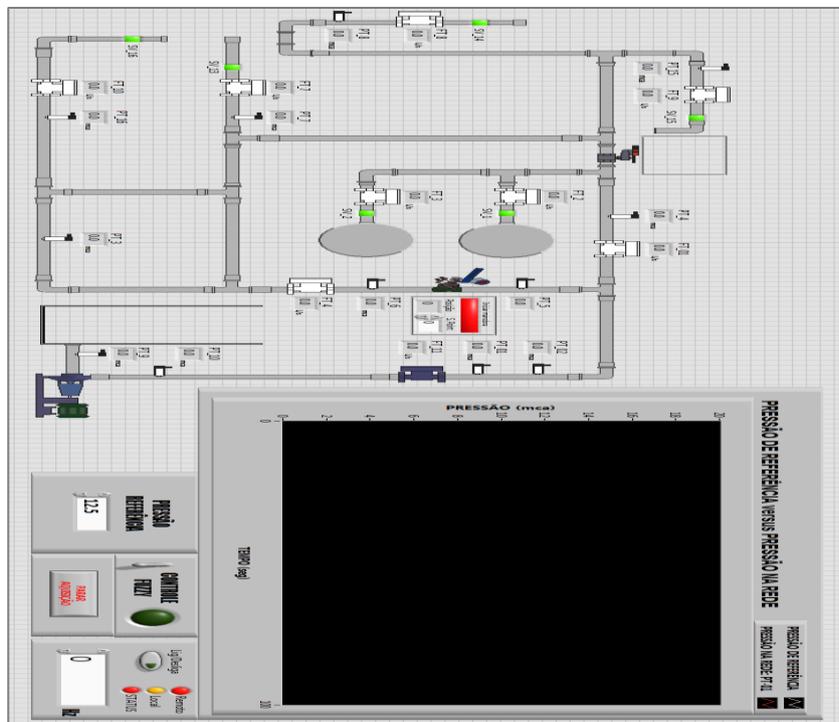


Figura 4.22 – Painel Frontal do SCF

4.7. SISTEMA DE CONTROLE *FUZZY* NEURAL

O sistema de controle *fuzzy* Neural, apresentado neste trabalho, é composto por uma rede neural de múltiplas camadas do tipo Perceptron que funcionará de forma colaborativa com um sistema de controle *fuzzy* baseado em regras do tipo Mandani. A ação do controlador sobre a planta fica condicionada a diferença entre a pressão de referência e a pressão na rede. Sempre que este valor, em módulo, encontra-se acima de 1,8 metros de coluna de água (mca) a atuação do sistema de controle será através de uma rede neural artificial. Do contrário, a atuação passa para o controlador *fuzzy*. Portanto, o objetivo desta estratégia com o sistema de controle *fuzzy* neural (SCFN) é o de acelerar o tempo de subida, através da ação da RNA e garantir o erro mínimo mediante a ação do controlador *fuzzy* baseado em regras do tipo Mandani.

Esta escolha foi realizada para contornar um problema de ordem operacional com relação à aplicação de RNA e o aprendizado genérico do comportamento da rede de distribuição da BE. O treinamento para esse fim deveria garantir a apresentação de dados de pressão e frequência nos mais variados posicionamentos possíveis. Para isto seria necessário fazer variar o conversor de frequência desde 35 Hz até 60 Hz, acompanhado de incrementos/decrementos sobre as manobras dos registros de gaveta localizados nas tomadas de água. O resultado deste procedimento torna-se impeditivo devido à grande quantidade de dados frente às inúmeras combinações que os registros e o conversor de frequência poderiam estar posicionados na BE.

A alternativa tomada neste trabalho foi posicionar os registros de gaveta a meia abertura e fazer o conversor de frequência variar entre as frequências de 35 Hz a 60 Hz com incremento de 0,1 Hz. A aquisição desses dados, depois do tratamento necessário, servirá para o treinamento da RNA (*off line*). É importante perceber que o sistema só irá responder com precisão adequada quando o posicionamento dos registros na BE coincidirem com a posição da fase de treinamento. Quando esta condição não for satisfeita, o sistema irá responder ao controlador com erro residual, acima ou abaixo da pressão de referência. Sob esta condição é que irá ocorrer o acionamento do controlador *fuzzy* e com isso garantir o erro nulo do sistema em regime permanente.

Com as operações de abertura e fechamento dos registros de gaveta, emulando a variação da demanda de água na rede, foi possível perceber o comportamento da pressão

calculada pela RNA frente à pressão de referência. Sempre que a demanda na rede era inferior àquela utilizada na fase de treinamento da RNA, os valores calculados para a pressão encontravam-se acima da pressão de referência, zona 01. Do contrário, para demandas superiores, as pressões calculadas resultavam em valores inferiores a pressão de referência e por conseguinte ocupavam valores dentro da zona 02. Além do mais percebeu-se empiricamente que o erro máximo entre a pressão calculada e a pressão de referência era de $\pm 1,8$ mca. Ver Figura 4.23.

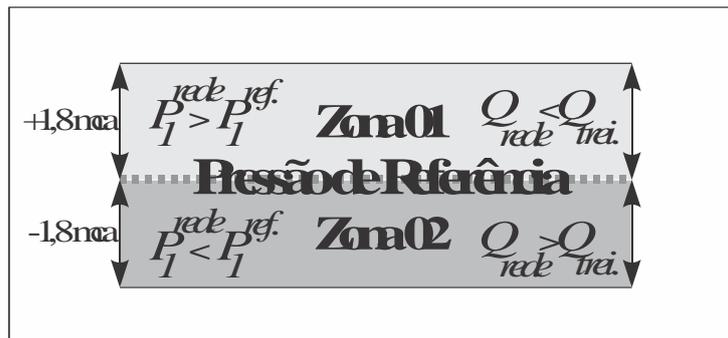


Figura 4.23 – Pressão Calculada pela RNA frente a Demandas na Rede

Onde:

$P_1^{ref.}$ – Pressão de Referência ou Desejada no ponto de controle 01.

P_1^{rede} – Pressão na Rede no ponto de controle 01.

Q_{rede} – Demanda de água na rede.

$Q_{trei.}$ – Demanda de água na fase de treinamento da RNA.

Porém, antes de abordarmos o controlador *fuzzy* neural, iniciaremos por elaborar todo o código do programa fonte que irá responder pelo controlador *fuzzy*. Este procedimento foi realizado na base de regra Mandani. Parte do código irá responder pela *fuzzificação* da variável antecedente, seguido pela *defuzzificação* da variável consequente, finalizando com o cálculo da área e do centro de massa da figura resultado deste último processo.

No processo de *fuzzificação* foi utilizada funções de pertinência do tipo triangular e trapezoidal, conforme as Equações 4.1 e 4.2, respectivamente.

$$\mu_A(x) = \begin{cases} 0 & \text{se } x \leq v_1 \\ \frac{x - v_1}{v_2 - v_1} & \text{se } v_1 < x \leq v_2 \\ 1 & \text{se } x = v_2 \\ -\frac{x - v_4}{v_4 - v_3} & \text{se } v_2 < x \leq v_3 \\ 0 & \text{se } x \geq v_3 \end{cases} \quad (4.1)$$

e

$$\mu_A(x) = \begin{cases} 0 & \text{se } x \leq v_1 \\ \frac{x - v_1}{v_2 - v_1} & \text{se } v_1 < x \leq v_2 \\ 1 & \text{se } v_2 \leq x \leq v_3 \\ -\frac{x - v_4}{v_4 - v_3} & \text{se } v_3 < x \leq v_4 \\ 0 & \text{se } x \geq v_4 \end{cases} \quad (4.2)$$

A *defuzzificação* da variável consequente é realizada a partir do cálculo da área e do centro de massa da figura geométrica gerada neste processo. A Equação 4.3 calcula a área, enquanto a Equação 4.4 determina o centro de massa. Que corresponde ao valor *defuzzificado* (*crisp*) dentro do universo de discurso da variável consequente.

Foram utilizadas duas variáveis *fuzzy*, uma antecedente denominada de erro da pressão e uma consequente denominada de gradiente de rotação. Ambas determinadas por análises heurísticas e experimentais, de acordo com as Figuras 4.24 e 4.25, respectivamente.

O método utilizado para o cálculo da área, faz uso das coordenadas dos vértices do polígono e pode ser visto pela Equação 4.3.

$$A = \frac{1}{2} \sum_{i=1}^n (x_i \cdot y_{i+1} - x_{i+1} \cdot y_i) \quad (4.3)$$

A Equação 4.4 demonstra a maneira como foi calculado o centro de gravidade de interesse C_x . Neste caso específico confunde-se com o valor *defuzzificado* resultante da inferência.

$$C_x = \frac{1}{6A} \sum_{i=1}^{n+1} (x_i + x_{i+1}) \cdot (x_i \cdot y_{i+1} - x_{i+1} \cdot y_i) \quad (4.4)$$

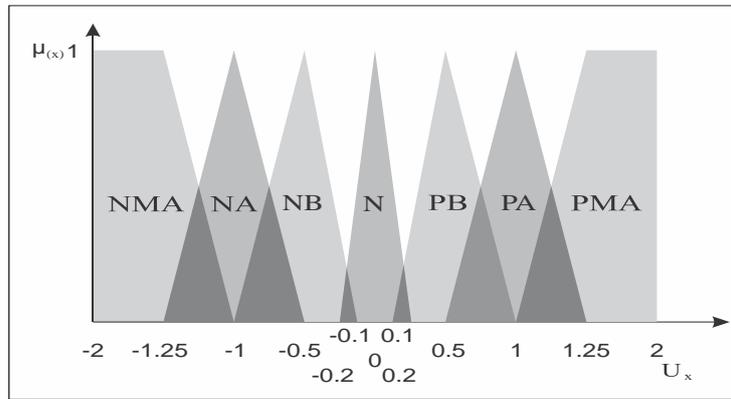


Figura 4.24 – Variável *Fuzzy* Antecedente Erro da Pressão

A variável *fuzzy* Antecedente erro da pressão foi alimentada no controlador *fuzzy* neural através de um arquivo no formato *.txt* como mostra a Tabela 4.1 abaixo.

Tabela 4.1 – Varável *Fuzzy* Antecedente do Erro da Pressão

NMA	0	-2,0	-2,0	-1,25	-1,0
NA	1	-1,25	-1,0	-0,5	0
NB	1	-1,0	-0,5	-0,1	0
N	1	-0,2	0	+0,2	0
PB	1	+0,1	+0,5	+1,0	
PA	1	+0,5	+1,0	+1,25	0
PMA	0	+1,0	+1,25	+2,0	+2,0

A cada linha da Tabela 4.1 corresponde uma função de pertinência *fuzzy*. Portanto a variável do erro da pressão representada acima possui sete funções de pertinência. A saber:

- NMA – Erro Negativo Muito Alto.
- NA – Erro Negativo Alto.
- NB – Erro Negativo Baixo
- N – Erro Nulo
- PB - Erro Positivo Baixo

- PA - Erro Positivo Alto
- PMA - Erro Positivo Muito Alto

A primeira coluna da Tabela 4.1 é reservada ao nome da função de pertinência. A segunda, representada pelos códigos zero (0) e (1), identificam se a função é do tipo trapezoidal ou triangular, respectivamente. É a partir da variável consequente denominada de gradiente de rotação que será extraído o valor incremento/decremento a ser atuado sobre o conversor de frequência, como mostra a Figura 4.25.

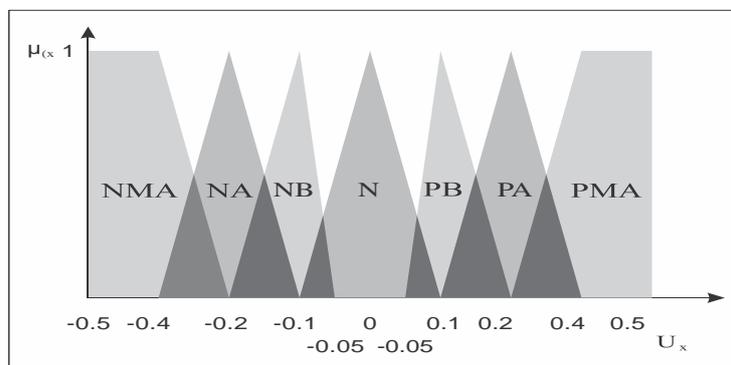


Figura 4.25 – Variável *Fuzzy* Consequente Gradiente de Rotação

A Tabela 4.2 servirá como entrada de dados, em formato *.txt*, na alimentação do controlador *fuzzy* neural.

Tabela 4.2 – Varável *Fuzzy* Consequente Gradiente de Rotação

NMA	0	-0,5	-0,5	-0,4	-0,2
NA	1	-0,35	-0,2	-0,1	0
NB	1	-0,2	-0,1	0,0	0
N	1	-0,025	0,0	+0,025	0
PB	1	0,0	+0,1	+0,2	
PA	1	+0,1	+0,2	+0,35	0
PMA	0	+0,2	+0,4	+0,5	+0,5

A base de regras utilizada nesta fase do trabalho pode ser vista em detalhes na Tabela 4.3. Onde parte-se do valor fuzzy da variável erro da pressão à inferência sobre a variável fuzzy gradiente de rotação. Ou seja, se o valor *fuzzificado* do erro for $\mu_{erro}(x) = (0,0,5,0,5,0,0,0,0)$, significa que a inferência será realizada sobre as funções de pertinência NA (negativa alta) e NB (negativa baixa) da variável fuzzy do gradiente de rotação. E o

processo será finalizado pela *defuzzificação* e conseqüentemente a determinação do valor *crisp* a ser adicionado ao inversor de frequência.

Tabela 4.3 – Base de Regras

ERRO						
NMA	NA	NB	N	PB	PA	PMA
1	2	3	4	5	6	7
GRADIENTE DE ROTAÇÃO						

A numeração presente na Tabela 4.3 corresponde a função de pertinência da variável conseqüente gradiente de rotação:

- 1 – NMA – Decremento Muito Alto.
- 2 – NA – Decremento Alto.
- 3 – NB – Decremento Baixo
- 4 – N – Incremento/ Decremento Nulo
- 5 – PB - Incremento Baixo
- 6 – PA - Incremento Alto
- 7 – PMA - Incremento Muito Alto

Entretanto, propõe-se uma maneira pouco usual para essa fusão. Associar as características positivas de um controlador sem ter que carregar consigo os aspectos negativos intrínsecos. Em outras palavras, minimizar o erro em regime permanente pelo controlador *fuzzy* e permitir um tempo de subida mais eficiente através da partida condicionada pelo controlador *fuzzy* ou mesmo pelo controlador neural.

O critério utilizado para escolha do tipo de acionamento está intimamente ligado à diferença entre a pressão de serviço e a pressão de referência. Quando o erro resultante da diferença entre a pressão de referência e a pressão de serviço na rede for superior a (1,8 mca) a partida será dada pela rede Neural, acelerando o tempo de subida e conseqüentemente melhorando a resposta no regime transitório. Para, em seguida, abandonar o controlador neural e partir para o controle do erro em regime permanente sob a tutela do controlador *fuzzy*.

O Sistema de controle *fuzzy* neural em malha fechada pode ser representado em diagramas de bloco, como mostra a Figura 4.26.

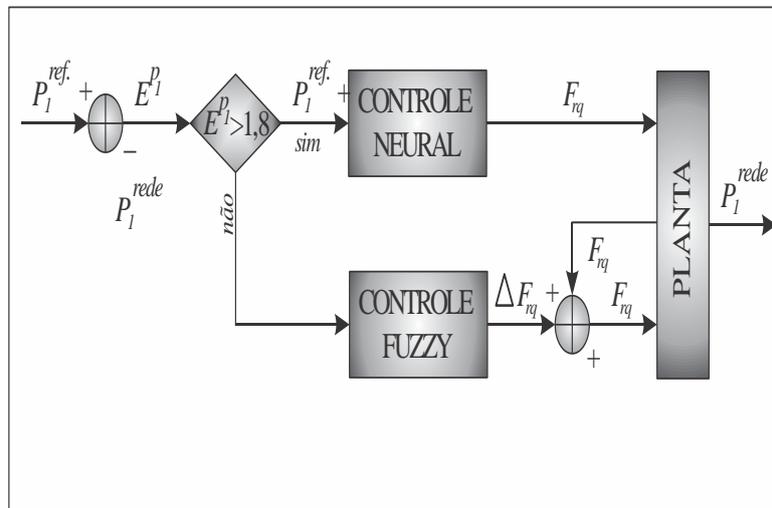


Figura 4.26 – Diagrama de Blocos Controlador *Fuzzy* Neural em Malha Fechada

Onde:

$P_1^{ref.}$ – Pressão de Referência ou Desejada no ponto de controle 01.

P_1^{rede} – Pressão na Rede no ponto de controle 01.

F_{rq} – Frequência.

ΔF_{rq} – Gradiente da Frequência.

E^{P1} – Erro da Pressão no ponto de controle 01 ($P_1^{ref.} - P_1^{rede}$).

O aplicativo desenvolvido para a operação de *fuzzificação* e *defuzzificação* do controlador *fuzzy* pode ser visto no Apêndice – A.7.

Os resultados e discussão sobre o comportamento do sistema de controle *fuzzy* neural (SCFN) no tempo pode ser visto no capítulo 5, item 5.3.

O SCFN desenvolvido em ambiente LabVIEW® constam das Figuras 4.27 e 4.28.

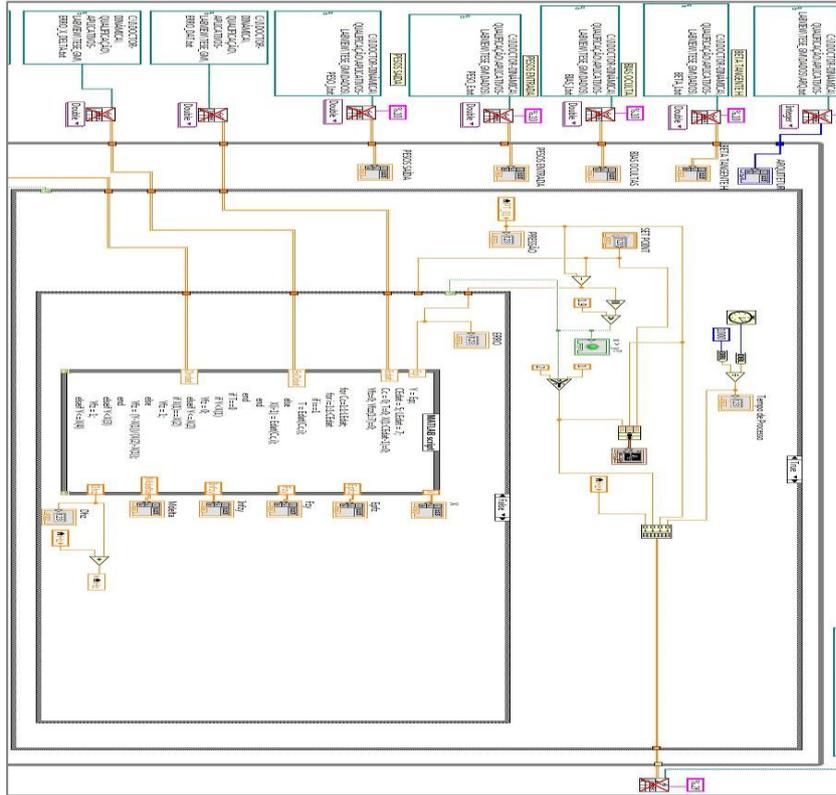


Figura 4.27 – Painel de Controle do SCFN

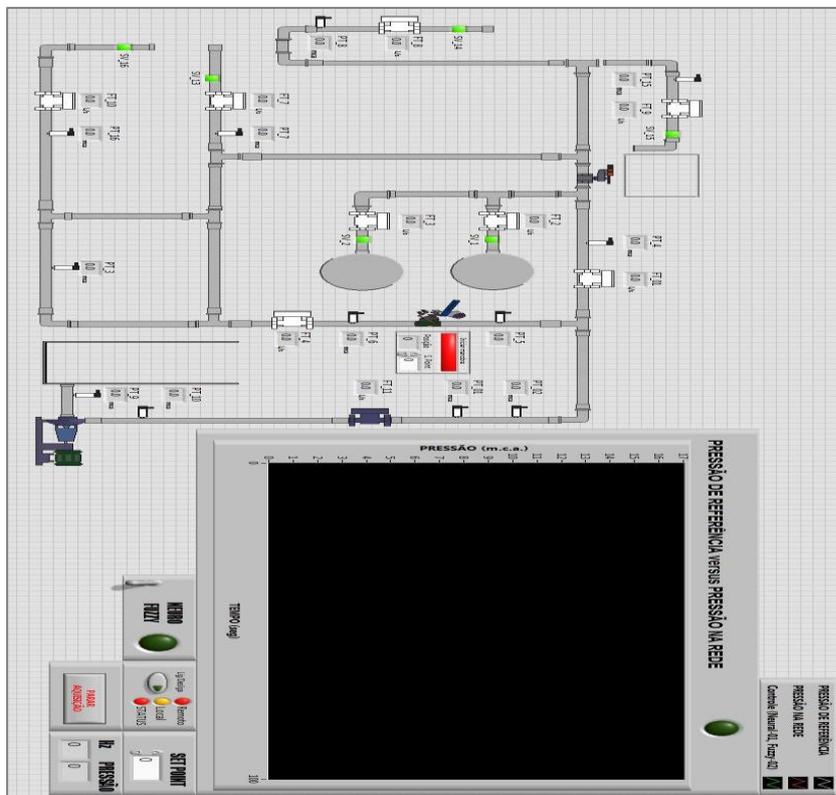


Figura 4.28 – Painel de Frontal do SCFN

4.8. SISTEMA DE CONTROLE NEURAL ADAPTATIVO COM OTIMIZADOR DE LEVENBERG-MARQUARDT.

O sistema de controle neural adaptativo (SCNA) com otimizador de Levenberg-Marquardt possui como característica principal a atualização dos pesos em tempo real (*on-line*) em resposta a dinâmica da bancada experimental (BE). Assim a atuação o conversor de frequência sofrerá flutuações sempre que a variações na demanda se façam presente.

O sistema de controle neural adaptativo (SCNA) com otimizador de Levenberg-Marquardt possui como característica principal a atualização dos pesos em tempo real (*on-line*) em resposta a dinâmica da bancada experimental (BE). Assim a atuação o conversor de frequência sofrerá flutuações sempre que a variações na demanda se façam presente.

A elaboração do sistema de controle adaptativo passa primeiramente por várias etapas realizadas (*off-line*) sobre a RNA. As relativas à aquisição de dados, tratamento dos dados e validação foram realizadas de maneira semelhante ao apresentado no item 4.4 e seus respectivos apêndices, a saber:

- Eliminador de Zeros – Apêndice A.1
- Eliminador de Dados Inconsistentes – Apêndice A.2
- Multiplicador de Dados – Apêndice A.3
- Embaralhador de Dados – Apêndice A.4

Foram utilizados pequenos ajustes as etapas citadas acima, relativos à formatação, gravação e leitura dos arquivos em formato *txt*. Este procedimento tem relevância apenas sobre o aspecto organizacional dos dados.

Entretanto, foi desenvolvido um aplicativo inteiramente novo para treinamento da RNA com otimizador de Levenberg-Marquardt, como descrito abaixo:

- Treinamento da RNA com otimizador de Levenberg-Marquardt – Este programa utiliza a técnica do gradiente descendente com retropropagação

(backpropagation), sendo otimizado pelo método de Levenberg-Marquardt. Nesta fase são experimentados valores para o número de neurônios da camada intermediária, valores do potencial de ativação (bias) e os valores de (beta) da função de ativação da tangente hiperbólica. Apêndice A.8.

Ao final desta fase serão conhecidos os valores ajustados para os pesos entre as camadas de entrada e intermediária W_t^{ei} e os pesos entre a camada intermediária e a camada de saída W_t^{is} . Os valores do limiar de ativação (bias) e o (beta) da função de ativação tangente hiperbólica.

O Sistema de controle neural adaptativo, em malha fechada com otimizador de Levenberg-Marquardt, pode ser representado em diagramas de bloco, como mostra a Figura 4.29.

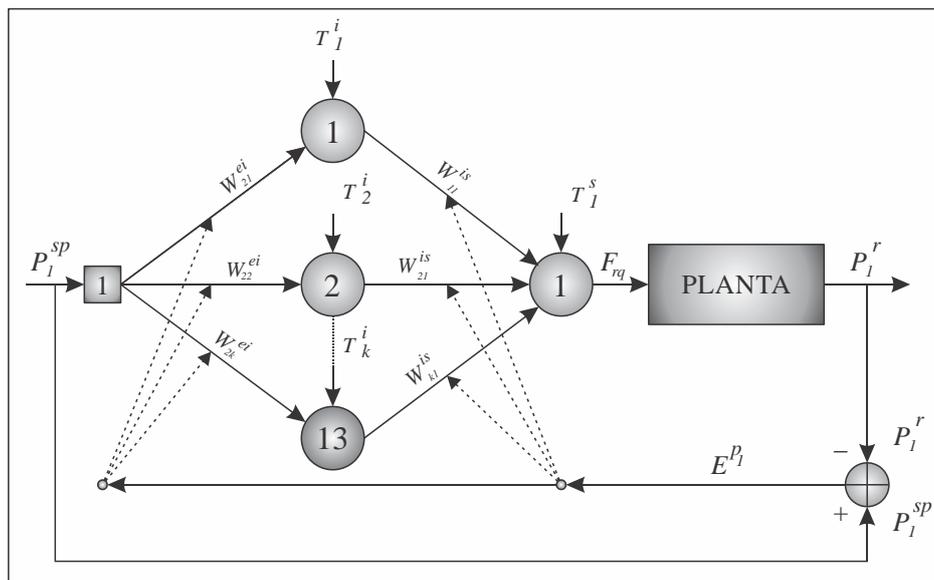


Figura 4.29 – Sistema de Controle Neural Adaptativo

A Figura 4.30 mostra o esquema de ação do sistema de controle neural adaptativo (SCNA). Os módulos 01 e 02 contém o código de programação elaborado previamente durante as fases de Treinamento e Validação. Ressalta-se, que o código fonte desenvolvido pode ser facilmente reescrito em qualquer linguagem de programação de alto nível.

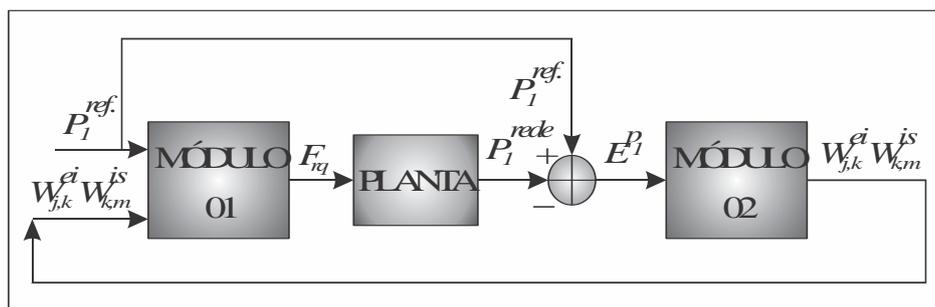


Figura 4. 30 – Esquema de Ação do Controlador Neural Adaptativo

Onde:

$P_1^{ref.}$ – Pressão de Referência ou Desejada no ponto de controle 01.

P_1^{rede} – Pressão na Rede no ponto de controle 01.

F_{rq} – Frequência.

E^{P1} – Erro da Pressão no ponto de controle 01 ($P_1^{ref.} - P_1^{rede}$).

$W_{j,k}^{ei}$ – Pesos Sinápticos entre as camadas de entrada e intermediária.

$W_{k,m}^{is}$ – Pesos Sinápticos entre as camadas de entrada e intermediária.

O Módulo 01 é iniciado pela Pressão de Referência P_1^{sp} (*set point*) e pelos pesos $W_{j,k}^{ei}$ e $W_{k,m}^{is}$ da RNA. A conclusão deste módulo acontece com o cálculo da frequência a ser alimentada ao conversor de frequência ligado ao conjunto motobomba. Esta etapa diz respeito a fase à frente (*forward*) da RNA. Em seguida a planta irá responder com o valor da pressão no ponto P_1^{sp} da bancada. O cálculo do Erro da Pressão, diferença entre a Pressão de Referência P_1^{sp} e a Pressão na Rede P_1^r , só será realizado quando as pressões na rede estiverem estabilizadas. Na sequência, o Módulo 02 será executado, dando início às fases referentes ao Gradiente Descendente com a Retropropagação (*backpropagation*) do erro (*off line*). O Método de Levenberg-Marquardt finaliza o Módulo 02 que responderá com os novos valores dos pesos $W_{j,k}^{ei}$ e $W_{k,m}^{is}$ à serem alimentados no Módulo 01. Este procedimento será repetido enquanto o Controlador estiver atuando sobre a planta.

Os resultados e discussão sobre o comportamento do sistema de controle neural adaptativo (SCNA) no tempo pode ser visto no capítulo 5, item 5.4.

O SCFN desenvolvido em ambiente LabVIEW® consta dos Figuras 4.31 e 4.32.

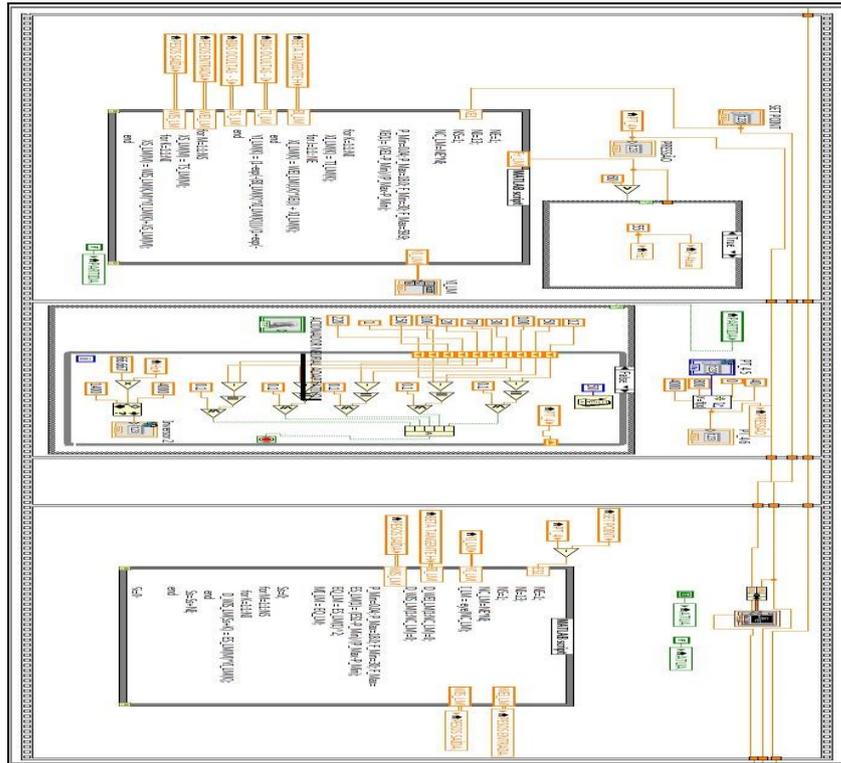


Figura 4.31 – Painel de Controle do SCNA

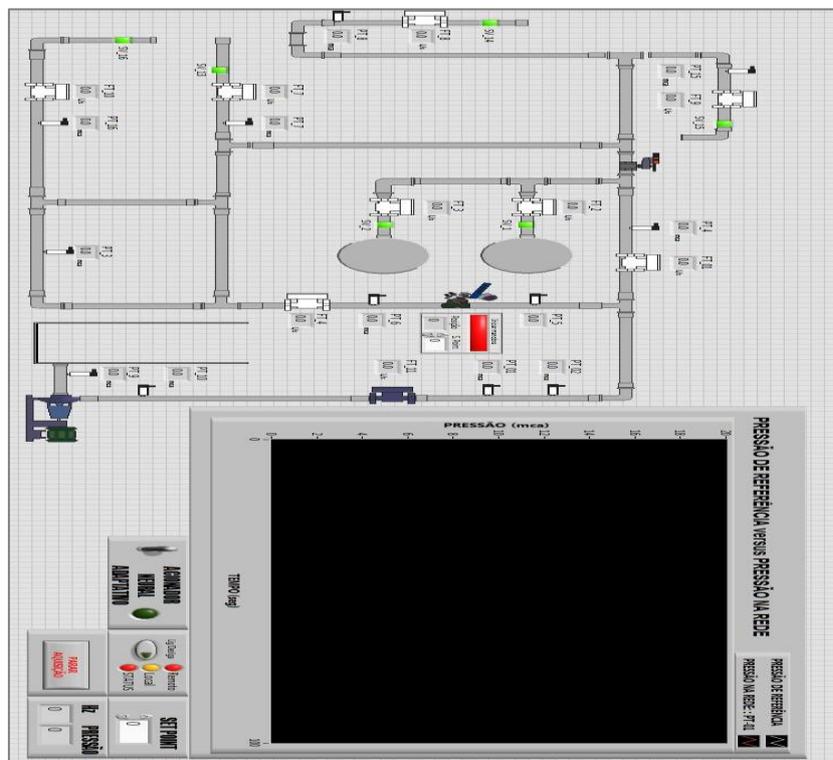


Figura 4.32 – Painel de Frontal do SCNA

CAPÍTULO V

RESULTADOS E DISCUSSÕES

5.1. SISTEMA DE CONTROLE NEURAL NÃO ADAPTATIVO (SCN)

O treinamento da RNA não adaptativa resultou em uma arquitetura composta por um neurônio na camada de entrada, 11 (onze) neurônios na camada intermediária e um neurônio na camada de saída. A função de ativação utilizada nos neurônios da camada intermediária foi a tangente hiperbólica, sendo desconsiderada tais funções para os neurônios das camadas de entrada e saída. Na Figura 5.1 está demonstrada a forte correlação entre os valores esperados e desejados durante a fase de validação.

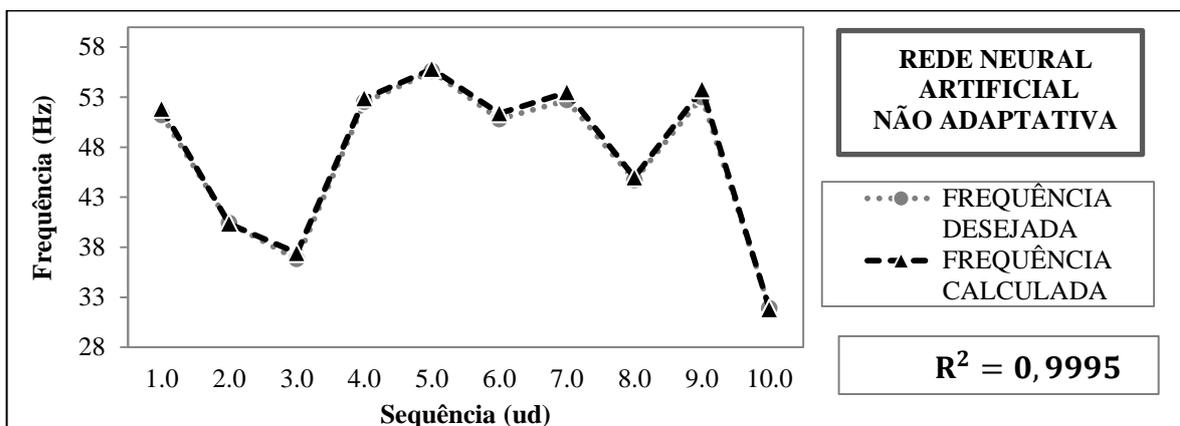


Figura 5.1 – Validação da RNA Não Adaptativa.

O critério utilizado para o fim do treinamento esteve condicionado ao valor do índice de desempenho ser inferior a 10^{-8} (RIUL et al., 2000). Com coeficiente de correlação $R^2 = 0,9995$ e demais parâmetros podem ser vistos na Tabela 5.1.

Tabela 5.1 – Parâmetros da RNA Não Adaptativa.

Pesos entre as Camadas de Entrada e Intermediária										
W_{11}^{ei}	W_{12}^{ei}	W_{13}^{ei}	W_{14}^{ei}	W_{15}^{ei}	W_{16}^{ei}	W_{17}^{ei}	W_{18}^{ei}	W_{19}^{ei}	W_{110}^{ei}	W_{111}^{ei}
2,55	2,34	1,93	1,91	1,96	1,16	1,32	1,48	1,37	1,26	1,68
Pesos entre as Camadas Intermediária e Saída										
W_{11}^{is}	W_{12}^{is}	W_{13}^{is}	W_{14}^{is}	W_{15}^{is}	W_{16}^{is}	W_{17}^{is}	W_{18}^{is}	W_{19}^{is}	W_{110}^{is}	W_{111}^{is}
4,98	5,54	6,69	3,56	6,72	7,20	7,09	5,37	6,57	1,64	6,65
Limiar de Ativação										
T_1^i	T_2^i	T_3^i	T_4^i	T_5^i	T_6^i	T_7^i	T_8^i	T_9^i	T_{10}^i	T_{11}^i
2,92	2,22	1,83	1,82	1,92	1,92	1,92	1,65	1,78	1,38	1,75
Beta da Função de Ativação – Tangente Hiperbólica										
β_1^i	β_2^i	β_3^i	β_4^i	β_5^i	β_6^i	β_7^i	β_8^i	β_9^i	β_{10}^i	β_{11}^i
-2,20	-0,91	0,23	0,02	0,06	1,58	1,19	1,21	1,28	0,55	0,78

Os parâmetros citados na Tabela 5.1 serviram como alimentação para controlador neural desenvolvido em LabVIEW®. Percebe-se que, a variação nas demandas de vazão provoca um erro residual em regime permanente, como pode ser visto na Figura 5.2.

No capítulo 4 foram ressaltadas as inúmeras possibilidades do posicionamento registros de gaveta e da variação do conversor de frequência atuando sobre o CMB da BE. Na Figura 5.2 está demonstrado que a resposta do SCN se deu acima do (*set-point*) fato este que revela que a demanda na BE está abaixo daquela que foi utilizada no treinamento da RNA. De outra forma, demonstra que a abertura dos registros encontram-se parcialmente mais fechado quando comparado com a situação em que foi realizado o referido treinamento.

Se por um lado o tempo de subida é bem rápido, conferindo ao sistema boa performance no regime transitório, o mesmo não ocorre em regime permanente, em que o erro não é eliminado.

A dinâmica dos sistemas de distribuição de água (SDA) ocorre devido às variações na demanda de água pelo usuário final. Na bancada, este fenômeno é emulado pelo procedimento de abertura/fechamento dos registros de gaveta instalados na rede.

A demanda no momento do teste, Figura 5.2, possui valor inferior ao que foi utilizada quando da aquisição dos dados para o treinamento da RNA (off line). Isto faz com que o aprendizado da rede encontre valores superiores. A Figura 5.3 mostra a frequência do inversor para o caso 01.

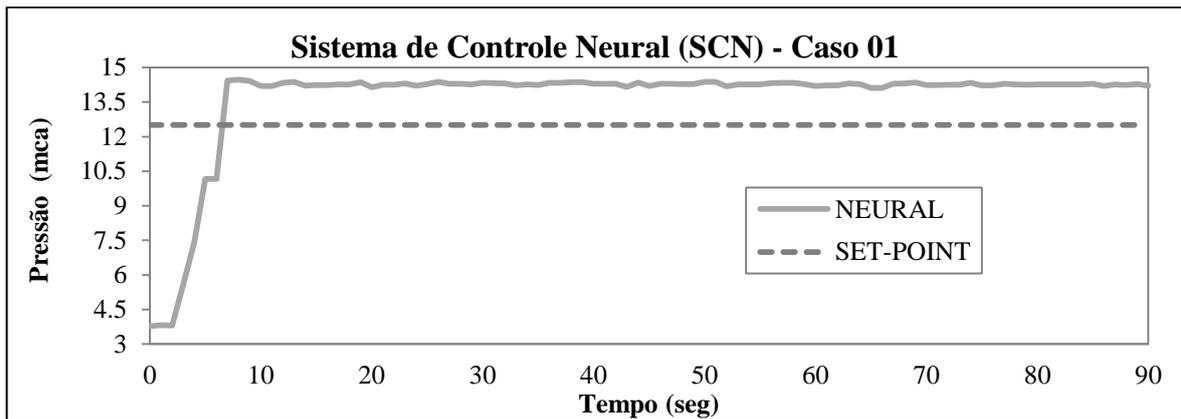


Figura 5.2 – Curva de Resposta da Pressão sob a Atuação do Sistema de Controle Neural (SCN) – Caso 01

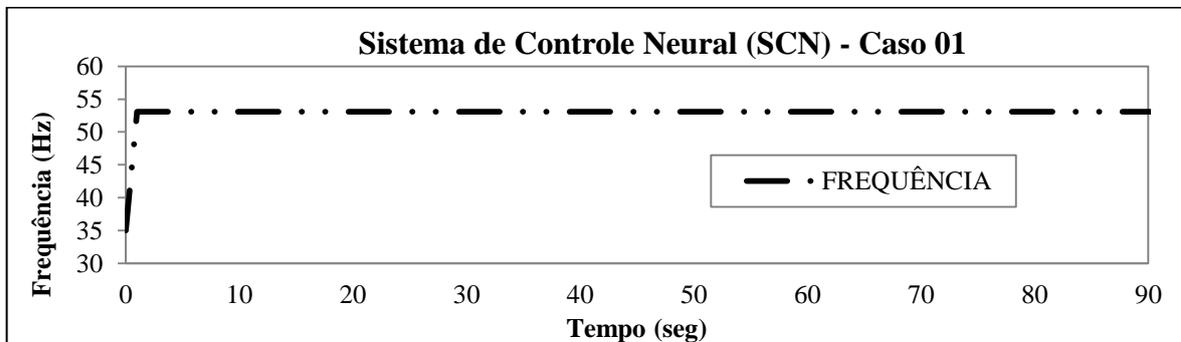


Figura 5.3 – Curva de Resposta do Inversor de Frequência para o Sistema de Controle Neural (SCN) – Caso 01

Outra simulação foi realizada com as aberturas dos registros de gaveta bem próximas daquelas que foram utilizadas durante o treinamento da RNA, caso 02. Na Figura 5.4 está demonstrado que o comportamento do sistema apresentou especificações melhores daqueles apresentados na Figura 5.2, caso 01. Quando comparado a este, percebe-se que embora o tempo de subida tenha se mantido idêntico, o mesmo não ocorreu com o sobre-sinal e o erro em regime permanente que foi bastante reduzido, Figura 5.4, caso 02.

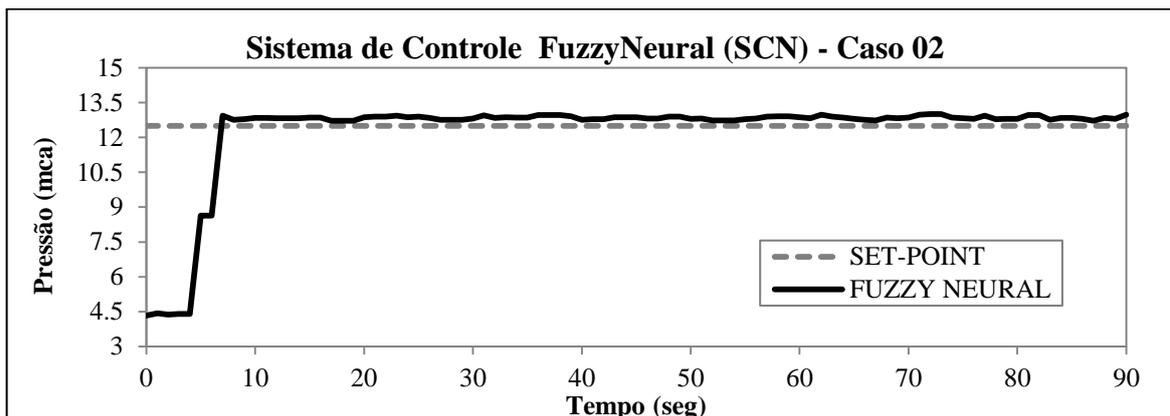


Figura 5.4 – Curva de Resposta da Pressão sob a Atuação do Sistema de Controle Neural (SCN) – Caso 02

A frequência do inversor ao longo do tempo pode ser visualizada na Figura 5.5, Caso 02.

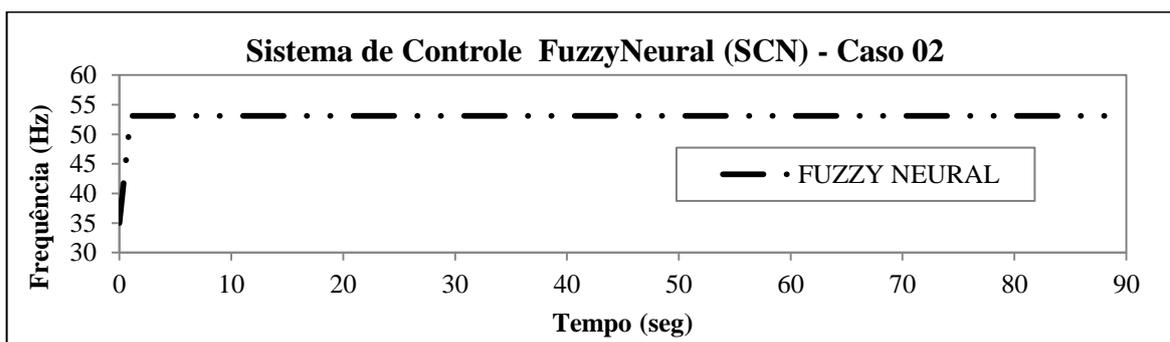


Figura 5.5 – Curva de Resposta do Inversor de Frequência para o Sistema de Controle Neural (SCN) – Caso 02

Na Tabela 5.2 constam as especificações para o SCN, casos 01 e 02, segundo os critérios usados por Nise (2012).

Tabela 5.2 – Especificações do Sistema de Controle Neural (SCN)

Especificações da Resposta do SCN	Caso 01	Caso 02
Ultrapassagem Percentual (UP)	15,76%	3,52 s
Tempo de Pico (Tp)	8,00 s	7,00 s
Tempo de Acomodação (Ts)	10,00 s	9,00 s
Tempo de Subida (Tr)	7,00 s	7,00 s
Erro Máximo em Regime Permanente (E máx)	1,88 mca	0,5 mca
Erro Mínimo em Regime Permanente (E mín)	1,61 mca	0,21 mca

5.2. SISTEMA DE CONTROLE *FUZZY* (SCF)

Como foi mencionado no item 4.6, foi elaborado o código de programação para a o sistema de controle *fuzzy* (SCF); composto pelo erro da pressão, como varável antecedente e o gradiente de rotação na condição de varável consequente. No processo de *fuzzificação* foram consideradas funções de pertinência triangular e trapezoidal e a *defuzzificação* pelo método Mandani. Nas Figuras 5.6 e 5.7 são mostrados o comportamento da pressão e da frequência do SCF no tempo, respectivamente.

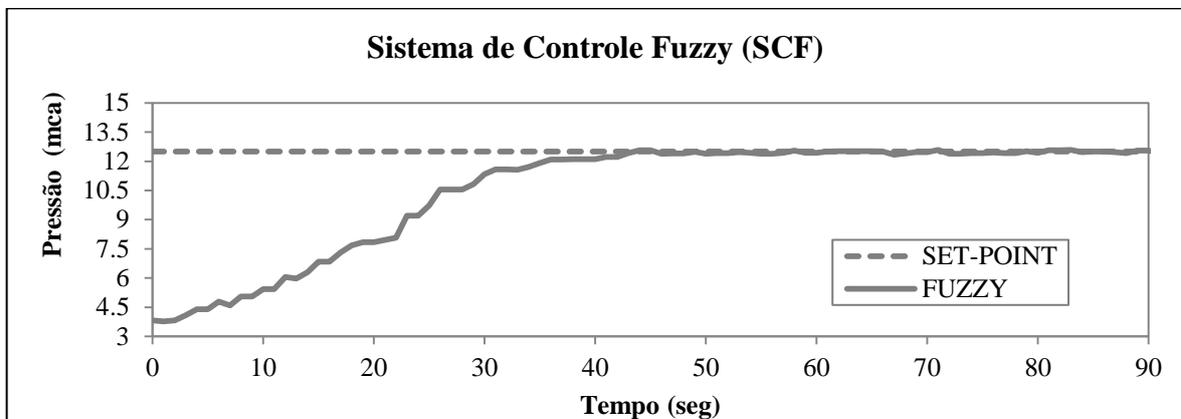


Figura 5.6 – Curva de Resposta da Pressão sob a Atuação do Sistema de Controle *Fuzzy* (SCF)

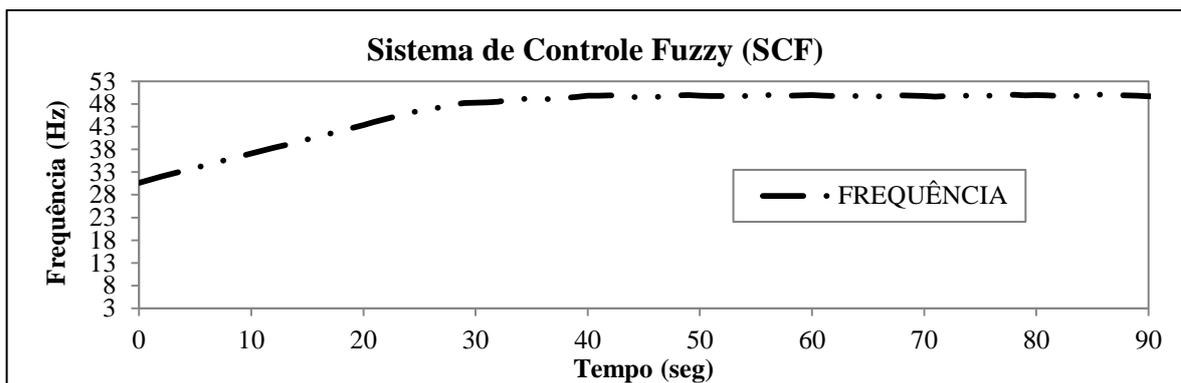


Figura 5.7 – Curva de Resposta do Inversor de Frequência para o Sistema de Controle *Fuzzy* (SCF)

O sistema de controle fuzzy tem seu ponto forte no erro em regime permanente, quando comparado com o erro apresentado no sistema de controle neural (SCN).

As especificações para o sistema de controle fuzzy (SCF) podem ser vistos na Tabela 5.3, seguindo os critérios de Nise (2012).

Tabela 5.3 – Especificações do Sistema de Controle Fuzzy (SCF)

Especificações da Resposta do SCF	Dados
Ultrapassagem Percentual (UP)	0,57%
Tempo de Pico (Tp)	44,00 s
Tempo de Acomodação (Ts)	45,00 s
Tempo de Subida (Tr)	30,00 s
Erro Máximo em Regime Permanente (E máx)	0,16 mca
Erro Mínimo em Regime Permanente (E mín)	0,0 mca

5.3. SISTEMA DE CONTROLE FUZZY NEURAL (SCFN)

O controlador *fuzzy* neural será responsável por garantir as características positivas do controlador neural no regime transitório com o erro nulo do controlador *fuzzy* em regime permanente. Estes aspectos podem ser evidenciados através da Figura 5.8 que reúne os gráficos do sistema de controle neural (SCN), *fuzzy* (SCF) e o híbrido (SCFN) com acionamento condicionado.

A Figura 5.8 mostra o comportamento dos sistemas de controle *fuzzy* neural (SCFN) desenvolvido. Evidencia-se o comportamento previsto com tempo de subida herdado do controlador neural, enquanto em regime permanente o controlador *fuzzy* garante o erro nulo. A Figura 5.9 mostra os valores da frequência para os controladores.

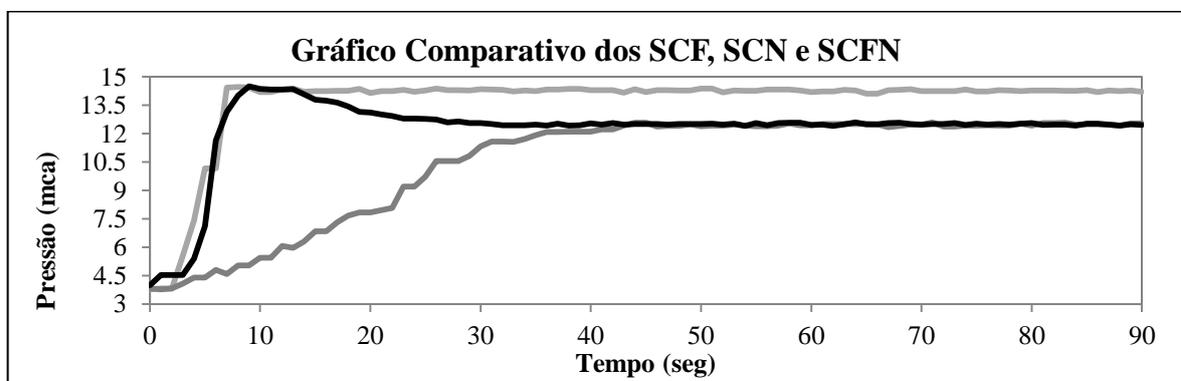


Figura 5.8 – Curva de Resposta da Pressões dos Sistemas de Controle SCN, SCF e do SCFN

A Figura 5.8 demonstra que o controlador *fuzzy* neural (SCFN) absorveu a potencialidade do sistema de controle neural (SCN) trazendo melhorias no regime transitório. Por outro lado, herda o regime permanente originário do SCF minimizando o erro em regime permanente.

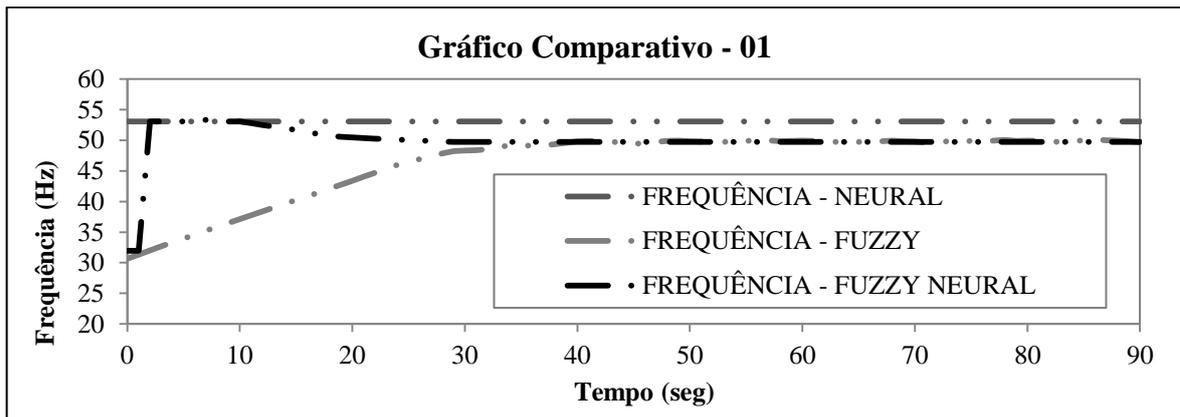


Figura 5.9 – Curva de Resposta do Inversor de Frequência para os Sistemas de Controle SCN, SCF e do SCFN

Torna-se bastante evidente, Figura 5.8, que o controlador *fuzzy* neural tem uma performance superior aos sistemas de controle SCF e SCN atuando isoladamente.

As especificações para o sistema de controle *fuzzy* neural (SCFN), casos 01 e 02, podem ser vistos na Tabela 5.4, seguindo os critérios de Nise (2012).

Tabela 5.4 – Especificações do Sistema de Controle *Fuzzy* Neural (SCFN)

Especificações da Resposta do SCFN	Caso 01	Caso 02
Ultrapassagem Percentual (UP)	15,92%	2,72 %
Tempo de Pico (Tp)	9,00 s	7,00 s
Tempo de Acomodação (Ts)	26,00 s	16,00 s
Tempo de Subida (Tr)	6,00 s	5,00 s
Erro Máximo em Regime Permanente (E máx)	0,25 mca	0,18 mca
Erro Mínimo em Regime Permanente (E mín)	0,00 mca	0,00 mca

Depois de demonstrado os aspectos positivos herdados pelo sistema de controle *fuzzy* neural (SCFN), será realizada uma simulação livre com variações sobre os valores da pressão de referência, denominado simulação 01.

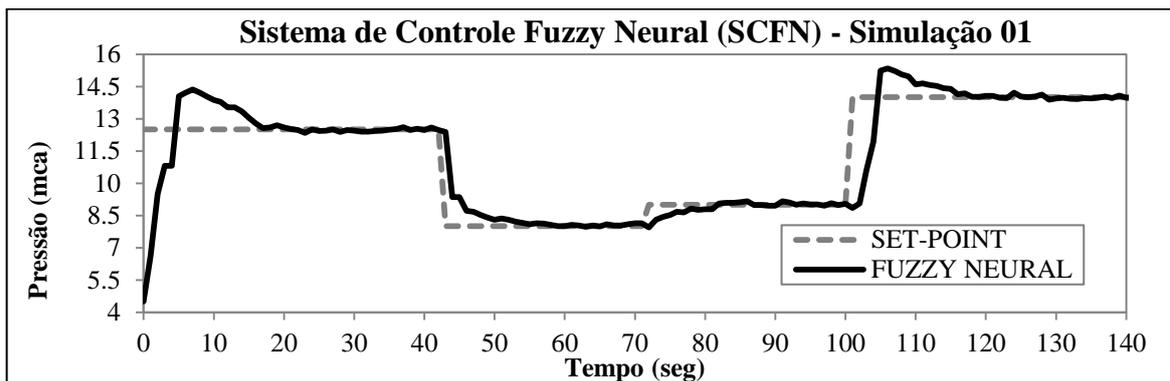


Figura 5.10 – Curva de Resposta da Pressão sob a Atuação do Sistema de Controle Fuzzy Neural (SCFN) submetido a várias pressões de referência

Nas Figuras 5.10 e 5.11 estão mostrados o comportamento do (SCFN) quando submetido a uma sequência de pressões de referência (*set-point*). Quando o sistema se aproxima da pressão de referência de 12,5 mca percebe-se uma sobre elevação (*over shoot*) do Controlador.

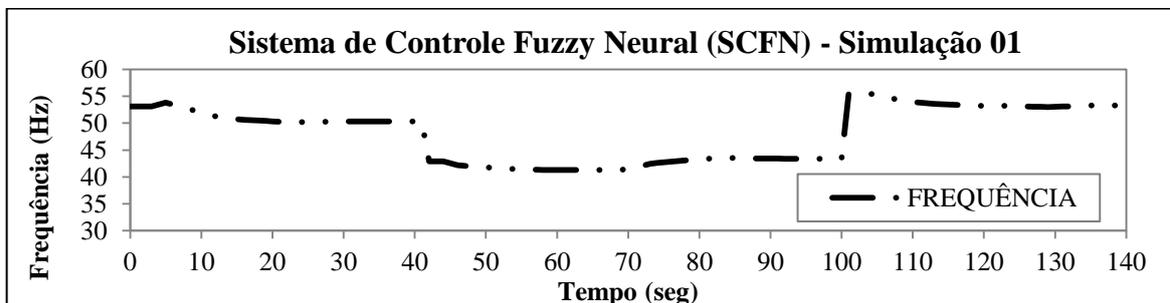


Figura 5.11 – Curva de Resposta do Inversor de Frequência para o Sistema de Controle Fuzzy Neural (SCFN) submetido a várias pressões de referência

É importante destacar que esta mudança possui gradiente entre a pressão desejada e a pressão de referência superior a 1,8 mca, o que solicita a ação SCN na partida. Após atingir e estabilizar a pressão em 12,5 mca o controlador é submetido a um set-point de 8,0 mca. Por outro lado, e igualmente importante, é a sub elevação quando solicitado à pressão de referência de 8,0 mca. Quando submetido a pressão de referência de 9,0 mca o controlador realiza essa transição sob a tutela do controlador fuzzy. Isto, porque o gradiente entre a pressão desejada e a pressão de referência ($9,0 - 8,0 = 1$ mca) ser inferior a 1,8 mca.

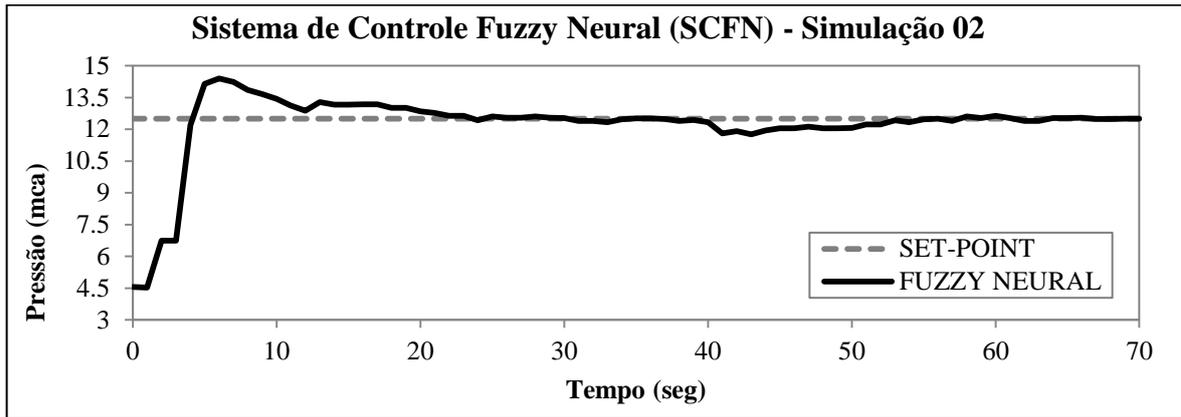


Figura 5.12 – Curva de Resposta da Pressão sob a Atuação do Sistema de Controle *Fuzzy* Neural (SCFN) submetido a uma perturbação

O sistema de controle fuzzy neural (SCFN) foi submetido a uma nova situação, denominada de simulação 02. As Figura 5.12 e 5.13 demonstram a reação do (SCFN) quando submetido a uma perturbação realizada sobre a bancada experimental. Procedimento promovido pela abertura simultânea de dois registros de gaveta localizado em extremidades distintas da rede.

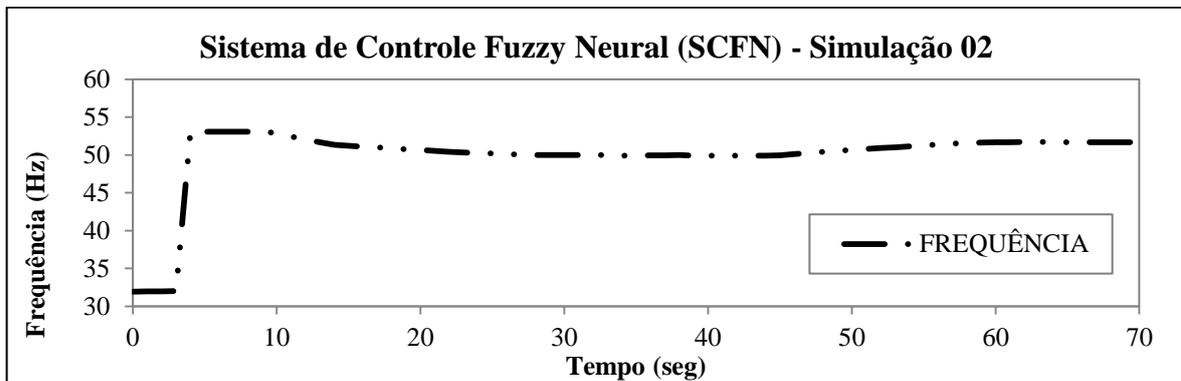


Figura 5.13 – Curva de Resposta do Inversor de Frequência para o Sistema de Controle *Fuzzy* Neural (SCFN) submetido a uma perturbação

Resumidamente pode-se avaliar que o SCFN apresentou bons resultado. Entretanto como dito anteriormente da dificuldade quase impeditiva de treinamento e identificação da uma RNA a ser aplicada sobre a BE deve ser visto como o ponto alto do SCFN.

5.4. SISTEMA DE CONTROLE NEURAL ADAPTATIVO (SCNA)

O treinamento e validação da RNA do SCNA resultou em uma arquitetura composta por um neurônio na camada de entrada, 13 (onze) neurônios na camada intermediária e um neurônio na camada de saída. A função de ativação utilizada nos neurônios da camada intermediária foi a tangente hiperbólica, com valores constantes de β_k^i e T_1^i , sendo desconsiderada tais funções para os neurônios das camadas de entrada e saída, Figura 5.14 e Tabela 5.5. O coeficiente de correlação encontrado durante a fase de validação foi de 0.9977.

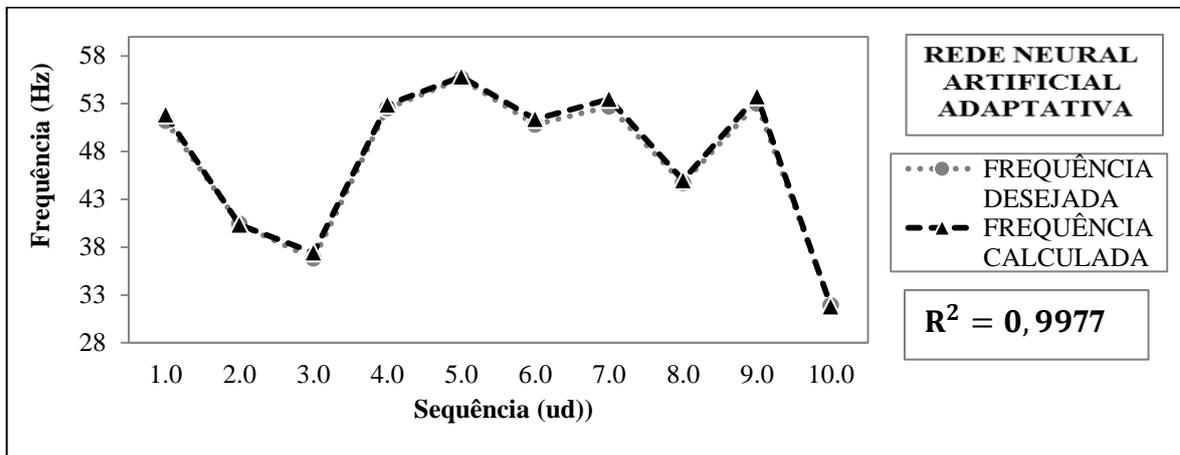


Figura 5.14 – Validação da RNA Adaptativa

Tabela 5.5 – Parâmetros da RNA Adaptativa

Pesos entre as Camadas de Entrada e Intermediária												
W_{11}^{es}	W_{12}^{es}	W_{13}^{es}	W_{14}^{es}	W_{15}^{es}	W_{16}^{es}	W_{17}^{es}	W_{18}^{es}	W_{19}^{es}	$W_{1\ 10}^{es}$	$W_{1\ 11}^{es}$	$W_{1\ 12}^{es}$	$W_{1\ 13}^{is}$
-0,32	1,77	0,58	1,23	0,71	-0,05	-0,02	0,64	1,23	1,33	0,19	-0,003	0,17
Pesos entre as Camadas Intermediária e Saída												
W_{11}^{is}	W_{21}^{is}	W_{31}^{is}	W_{41}^{is}	W_{51}^{is}	W_{61}^{is}	W_{71}^{is}	W_{81}^{is}	W_{91}^{is}	$W_{10\ 1}^{is}$	$W_{11\ 1}^{is}$	$W_{12\ 1}^{is}$	$W_{13\ 1}^{is}$
-0,94	0,24	-0,42	-0,15	-0,38	-0,80	-0,74	-0,48	-0,15	0,007	-0,66	-0,75	-0,71
Limiar de Ativação												
T_1^i	T_2^i	T_3^i	T_4^i	T_5^i	T_6^i	T_7^i	T_8^i	T_9^i	T_{10}^i	T_{11}^i	T_{12}^i	T_{13}^i
-1,0	-1,0	-1,0	-1,0	-1,0	-1,0	-1,0	-1,0	-1,0	-1,0	-1,0	-1,0	-1,0
Beta da Função de Ativação – Tangente Hiperbólica												
β_1^i	β_2^i	β_3^i	β_4^i	β_5^i	β_6^i	β_7^i	β_8^i	β_9^i	β_{10}^i	β_{11}^i	β_{12}^i	β_{13}^i
0,18	0,18	0,18	0,18	0,18	0,18	0,18	0,18	0,18	0,18	0,18	0,18	0,18

Finalizada as etapas de treinamento de validação da RNA deu-se prosseguimento na elaboração do sistema de controle neural adaptativo (SCNA) com otimizador de Levenberg-Maquardt. A Figura 5.15 demonstra o comportamento no tempo deste sistema.

Uma característica evidente do SCNA é a ausência da sobre elevação (*overshoot*). O tempo de subida é bem semelhante ao comportamento do sistema de controle *fuzzy* neural (SCFN). Enquanto preserva erro nulo em regime permanente, Figura 5.15. A Figura 5.16 mostra o comportamento da frequência do SCNA

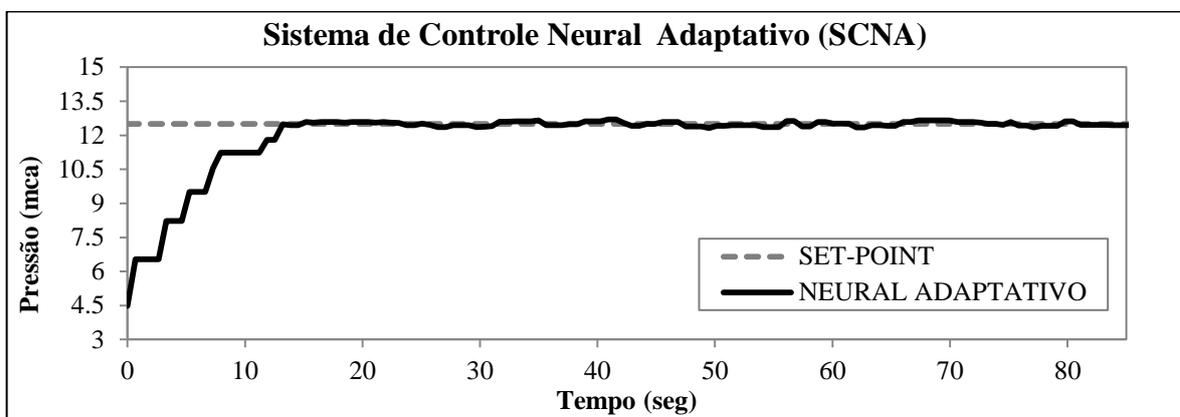


Figura 5.15 – Curva de Resposta da Pressão sob a Atuação do Sistema de Controle Neural Adaptativo (SCNA)

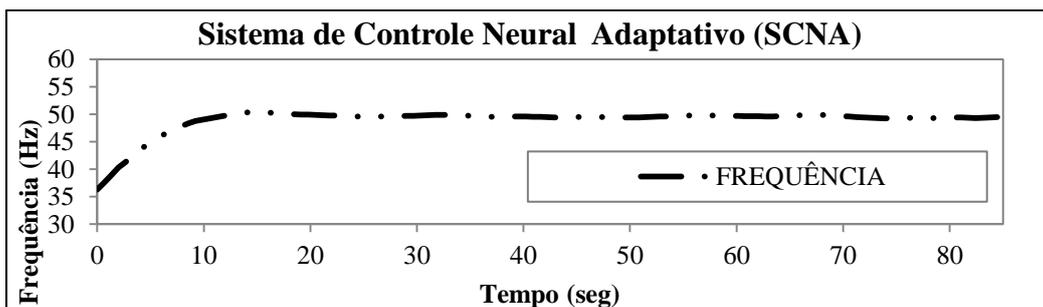


Figura 5.16 – Curva de Resposta do Inversor de Frequência para o Sistema de Controle Neural Adaptativo (SCNA)

O controlador neural adaptativo comportou-se de maneira eficiente, como pode ser visto pelo gráfico da Figura 5.15.

A Tabela 5.6 mostra as Especificações para o SCNA segundo os critérios usados por Nise (2012).

Tabela 5.6 – Especificações para os SCFN e SCNA

Especificações da Resposta do SCNA	Dados
Ultrapassagem Percentual (UP)	0,72%
Tempo de Pico (Tp)	16,50 s
Tempo de Acomodação (Ts)	19,14 s
Tempo de Subida (Tr)	7,92 s
Erro Máximo em Regime Permanente (E máx)	0,19 mca
Erro Mínimo em Regime Permanente (E mín)	0,0 mca

No item 5.3, o sistema de controle fuzzy neural SCFN foi submetido a duas simulações. Na primeira, o sistema passou por uma sequência de pressões de referência previamente estabelecida, simulação 01. Enquanto a segunda simulação o sistema é submetido a uma perturbação sobre a rede hidráulica da bancada experimental (BE), simulação 02. Este mesmo procedimento será realizado para avaliar o comportamento do sistema de controle neural adaptativo (SCNA)

As Figura 5.17 e 5.18 mostram o comportamento do sistema de controle neural adaptativo (SCNA) quando submetido a uma sequência de Pressões de Referência (*set-point*). Após atingir a pressão de 12,5 mca o Controlador é submetido a um *set-point* de 8,0 mca. Esta transição é realizada de maneira suave. A mudança para a Pressão Referência de 9,0 mca é realizada de maneira satisfatória. O tempo de subida à pressão de referência de 14,0 mca é realizada com bastante eficiência, com ausência de sobre elevação (*over-shoot*).

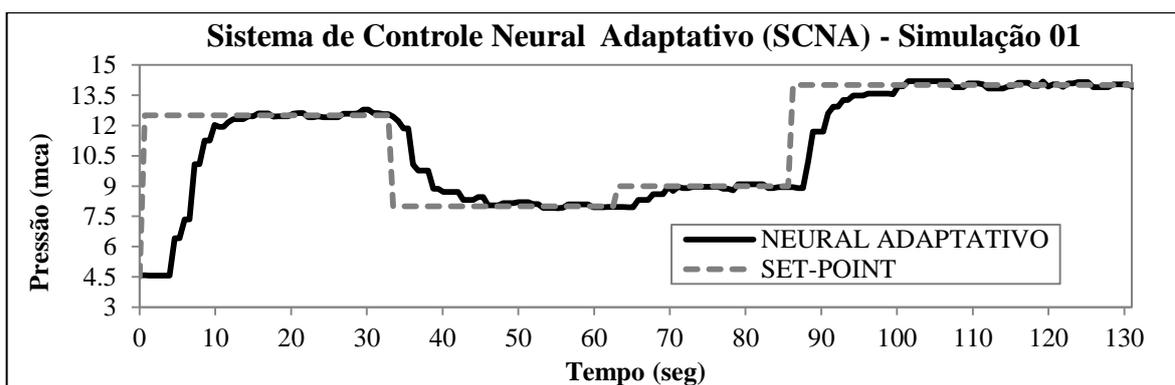


Figura 5.17 – Curva de Resposta da Pressão sob a Atuação do Sistema de Controle Neural Adaptativo (SCNA) submetido a várias pressões de referência

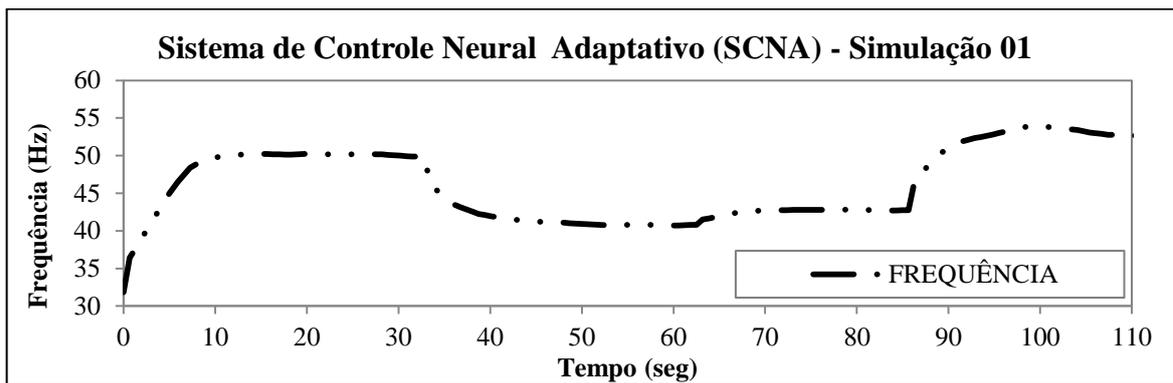


Figura 5.18 – Curva de Resposta do Inversor de Frequência para o Sistema de Controle Neural Adaptativo (SCNA) submetido a várias pressões de referência

As Figuras 5.19 e 5.20 demonstram a atuação do sistema de controle neural adaptativo (SCNA) submetido a uma perturbação sobre a rede hidráulica da bancada experimental (BE), oriunda da abertura simultânea de dois registros de gaveta. Este procedimento tem o propósito de aumentar drasticamente a demanda de água na rede. O que poderia ser comparado a uma ruptura em algum trecho da rede de distribuição.

Neste caso percebe-se a capacidade do SCNA em reestabeler-se de maneira rápida e eficiente a pressão de referência na rede hidráulica.

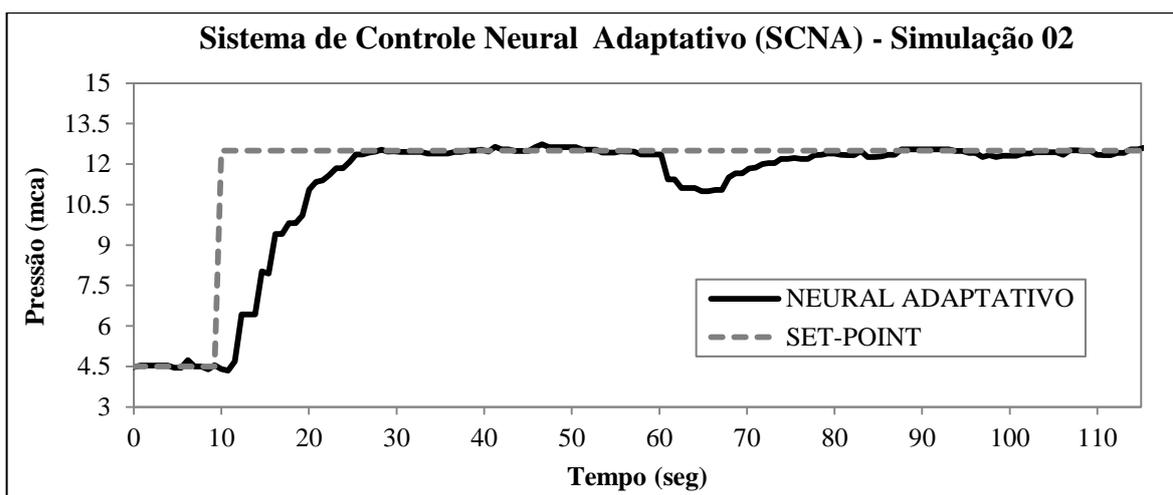


Figura 5.19 – Curva de Resposta da Pressão sob a Atuação do Sistema de Controle Neural Adaptativo submetido a uma perturbação

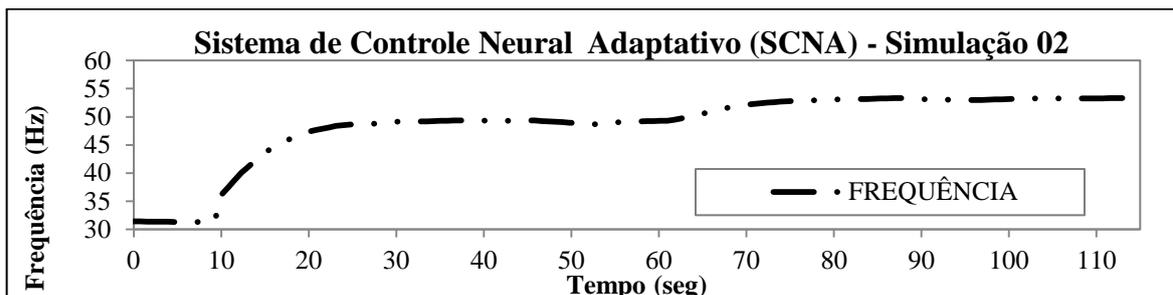


Figura 5.20 – Curva de Resposta do Inversor de Frequência para o Sistema de Controle Neural Adaptativo submetido a uma perturbação

5.5. COMPARATIVO ENTRE OS CONTROLADORES: NEURAL ADAPTATIVO (SCNA) E FUZZY NEURAL (SCFN)

As Figuras 5.21 e 5.22, caso 01, mostra o comportamento do sistema de controle *fuzzy* neural (SCFN) e o sistema de controle neural adaptativo (SCNA). A ultrapassagem percentual e o tempo de acomodação do SCNA é bem menor quando comparado com o SCFN, Tabela 5.7.

Nas Figuras 5.23 e 5.24, caso 02, situação em que a BE encontra-se com valores de demanda próximos dos utilizados no treinamento da RNA não adaptativa. O sistema de controle *fuzzy* neural (SCFN) melhora as especificações relativas a ultrapassagem percentual e tempo de acomodação. Esta situação coloca o SCFN em condições bem próximas do SCNA.

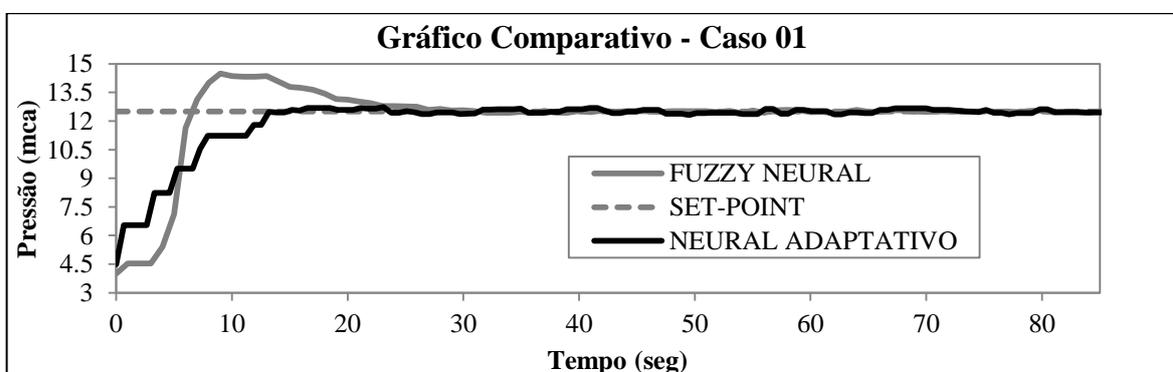


Figura 5.21 – Curva de Resposta das Pressões sob a Atuação dos Sistemas de Controle Neural Adaptativo (SCNA) versus Sistema de Controle *Fuzzy* Neural (SCFN) – Caso 01

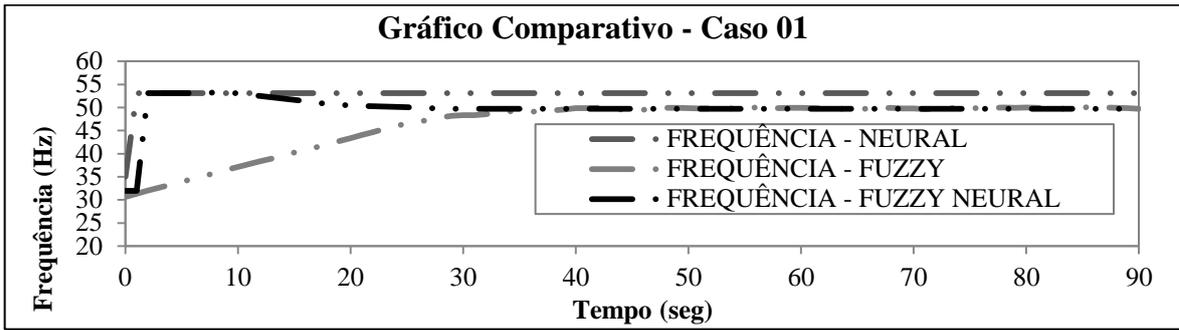


Figura 5.22– Curva de Resposta do Inversor de Frequência para os Sistema de Controle Neural Adaptativo (SCNA) versus Frequência do Sistema de Controle *Fuzzy* Neural (SCFN) – Caso 01

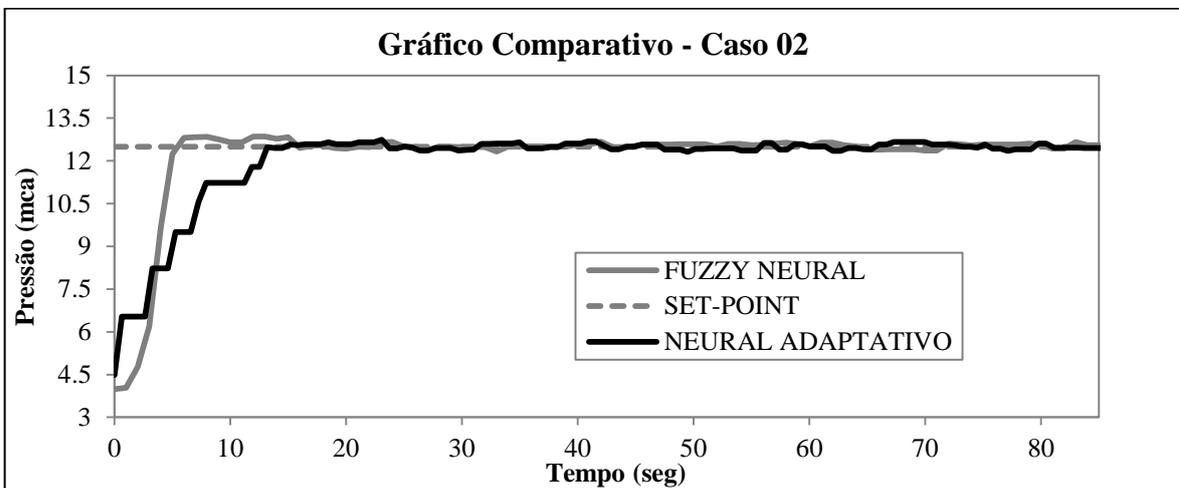


Figura 5.23 – Curva de Resposta das Pressões sob a Atuação do Sistema de Controle Neural Adaptativo (SCNA) versus Sistema de Controle *Fuzzy* Neural (SCFN) – Caso 02

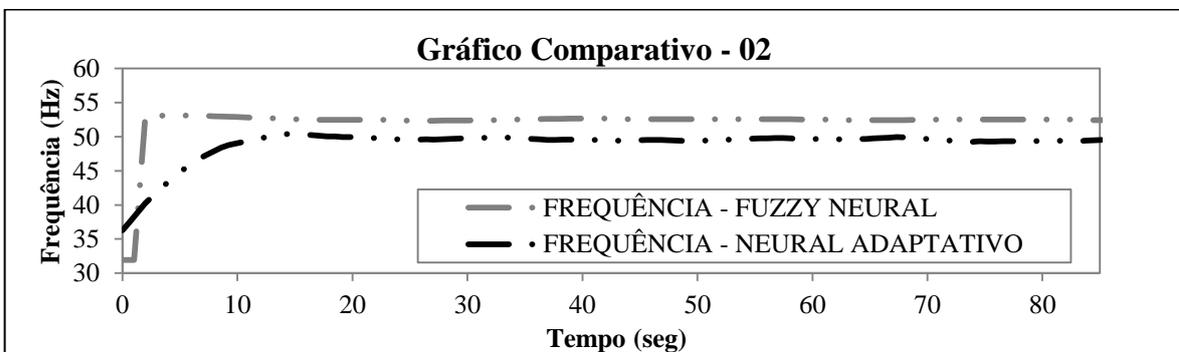


Figura 5.24 – Curva de Resposta do Inversor de Frequência para os Sistema de Controle Neural Adaptativo (SCNA) versus Sistema de Controle *Fuzzy* Neural (SCFN) – Caso 02.

Tabela 5.7 Especificações para os SCFN e SCNA

Especificações da Resposta do SCNA e SCFN	SCNA	SCFN	
		Caso 01	Caso 02
Ultrapassagem Percentual (UP)	0,72%	15,92%	2,72 %.
Tempo de Pico (Tp)	16,50 s	9,00 s	7,00 s
Tempo de Acomodação (Ts)	19,14 s	26,00 s	16,00 s
Tempo de Subida (Tr)	7,92 s	5,00 s	5,00 s
Erro Máximo em Regime Permanente (E máx)	0,19 mca	0,25 mca	0,18 mca
Erro Mínimo em Regime Permanente (E mín)	0,0 mca	0,00 mca	0,00 mca

Quando analisado a luz dos dados da Tabela 5.7, o SCNA apresentou-se mais robusto quando confrontado com o SCFN. A superioridade é quase absoluta quando analisadas as especificações dos respectivos controladores. Entretanto a versatilidade do sistema de controle *fuzzy* neural (SCFN) não deve ser totalmente ignorado. Primeiro porque apresenta resultados completamente satisfatórios e também por incorporar técnicas de concepções disparens neural e fuzzy em um mesmo controlador.

5.6. SCNA PARA O CONTROLE ALTERNADO DE PRESSÃO MÍNIMA SOBRE QUATRO PONTOS DA REDE DE DISTRIBUIÇÃO DA BANCADA EXPERIMENTAL (BE)

O SCADA passou por alterações com o propósito de habilitar o sistema de controle neural adaptativo (SCNA) à controlar a pressão mínima na rede de distribuição de água da BE. O sistema analisa dentre quatro pontos da BE (PT-03, PT-07, PT-08 e PT-15) e seleciona o de menor pressão. Sobre este, o SCNA irá atuar em manter a pressão de referência.

No início da simulação a pressão de referência é de 5 mca. Dentre os pontos analisados o PT-08 é o ponto de menor pressão na rede hidráulica da BE. Em seguida foi realizada alteração na pressão de referência (*set point*), que passou de 5 mca para 10 mca. Esta mudança promove uma elevação da pressão no PT-08, que continua sendo o ponto de menor pressão. Durante a fase intermediária foi realizada uma intervenção sobre a BE pelo fechamento parcial de uma válvula proporcional. A ação promoveu uma mudança sobre o ponto de pressão mínima, passando do PT-08 para o PT-03. O que promove uma inversão

completa sobre o comportamento do sistema. Para finalizar a simulação, foi alterada a pressão referência para 5 mca, Figuras 5.25 e 5.26.

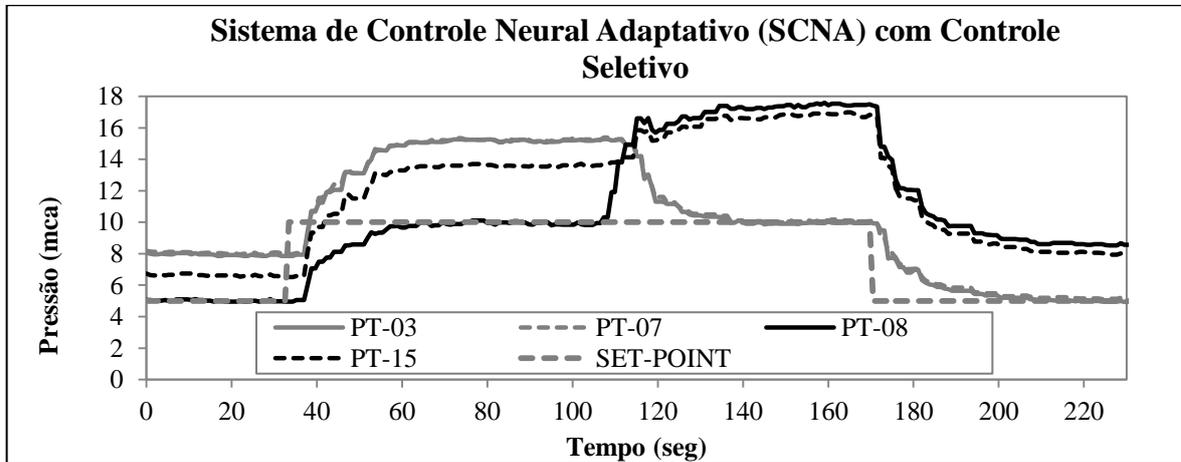


Figura 5.25 – Curva de Resposta da Pressão sob a Atuação do SCNA com Controle Alternado do Ponto Pressão Mínima

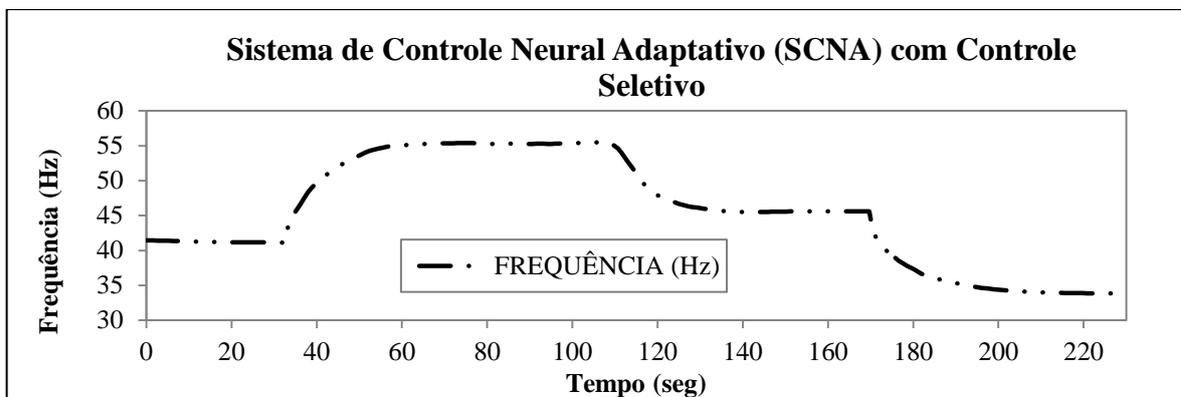


Figura 5.26 – Curva de Resposta do Inversor de Frequência para o SCNA submetido ao Controle Alternado do Ponto Pressão Mínima

CAPÍTULO VI

CONCLUSÕES E RECOMENDAÇÕES

6.1. CONCLUSÕES

Neste trabalho foram apresentados, um sistema de controle *fuzzy* (SCF), um sistema de controle neural (SCN), um sistema de controle *fuzzy* neural (SCFN) e um sistema de controle neural adaptativo (SCNA).

O motivo para o desenvolvimento do SCFN deve-se à dificuldade de treinamento de uma RNA que contemple os mais diversos valores de demandas associados a diferentes frequências do conversor. Desta forma, o treinamento da RNA, que irá compor o SCFN, foi realizado com os registros de gaveta posicionados a meia abertura e variando a frequência do conversor com incremento de 0,1 Hz. Durante a fase de treinamento (*off line*) foram ajustados, a cada passo do algoritmo, os valores dos pesos sinápticos, do limiar de ativação (*bias*), do valor *beta* que compõe a função de ativação da tangente hiperbólica e do coeficiente de aprendizado. A arquitetura desta RNA ficou definida por um neurônio na camada de entrada, onze neurônios na camada intermediária e um neurônio na camada de saída e coeficiente de aprendizado de 0,12.

O desenvolvimento do SCNA cumpriu a fase de treinamento de maneira similar a RNA que compõe o SCFN. Entretanto, a RNA envolvida neste controlador utiliza o otimizador de Levenberg-Marquardt, que dispensa o coeficiente de aprendizagem pelo uso do coeficiente de escalamento. A cada passo do algoritmo de treinamento foram ajustados os pesos sinápticos, enquanto os valores do limiar de ativação e do *beta* terem sido testados

manualmente no início de cada treinamento. A arquitetura desta RNA resultou em um neurônio na camada de entrada, treze neurônios na camada intermediária e um neurônio na camada de saída.

As dificuldades encontradas na fase de treinamento *off-line* das RNA que compõem o SCFN e o SCNA foram semelhantes. Dentre elas podemos citar:

- A Quantidade de Dados Disponíveis – Este fato pode criar impedimentos durante a fase de treinamento, fazendo com que a RNA não atinja a convergência devido o número limitado de iterações do algoritmo. Para contornar esta dificuldade foi criado um algoritmo com o objetivo de multiplicar os dados coletado, Apêndice A.3.
- A Maneira Como os Dados são Apresentados – Percebeu-se, nos primeiros treinamentos, que a apresentação sequenciada dos dados provocava falhas no processo de aprendizagem. Por isso foi desenvolvido um algoritmo com a função de embaralhar os dados a serem apresentados na fase de treinamento, Apêndice A.4.
- A Normalização dos Dados de Entrada – O treinamento com os dados de pressão e frequência sem estarem normalizados produziram resultados com precisão aquém da esperada para a RNA. A solução foi à normalização dos dados antes do início do treinamento. Este procedimento demonstrou-se muito eficiente.

O comportamento das redes de distribuição de água possuem características bem particulares. Por tratar-se de um fluido, provoca ondas de variação sobre os valores de vazão e pressão sempre que uma intervenção for promovida sobre a rede hidráulica. São conhecidos como transientes hidráulicos e se propagam com efeitos oscilatórios ao longo de toda a rede. Este fato não deve ser negligenciado sempre que for necessária uma intervenção de controle de pressão sobre os sistemas de distribuição de água.

O SCFN e o SCNA possuem em seu escopo a versatilidade do operador poder definir qual o valor a ser empregado para a pressão de referência (*set point*).

O SCFN apresentou comportamento bastante satisfatório no atendimento das especificações relativas ao controle de pressão da rede de distribuição de água da bancada

experimental (BE) do LENHS. O erro máximo em regime permanente foi inferior a 0,25 mca, com ultrapassagem percentual máxima de 15,92% na condição de maior adversidade.

As especificações, como a ultrapassagem percentual de 0,72% e erro máximo em regime permanente de 0,18 mca, demonstram que o SCNA é robusto e bastante eficiente no controle de pressão da rede hidráulica da bancada experimental do LENHS.

No estudo de caso 01, o SCNA demonstrou ser mais robusto quando confrontado com o SCFN. As especificações relativas à ultrapassagem percentual e o erro máximo em regime permanente demonstram esta afirmativa. A Tabela 5.1 reúne estes e outros parâmetros analisados neste trabalho.

Tabela 6.1 – Especificações para os SCFN e SCNA

Especificações da Resposta do SCNA e SCFN	SCNA	SCFN	
		Caso 01	Caso 02
Ultrapassagem Percentual (UP)	0,72%	15,92%	2,72 %
Tempo de Pico (Tp)	16,50 s	9,00 s	7,00 s
Tempo de Acomodação (Ts)	19,14 s	26,00 s	16,00 s
Tempo de Subida (Tr)	7,92 s	5,00 s	5,00 s
Erro Máximo em Regime Permanente (E máx)	0,19 mca	0,25 mca	0,18 mca
Erro Mínimo em Regime Permanente (E mín)	0,0 mca	0,00 mca	0,00 mca

No estudo de caso 02 os controladores apresentaram especificações bem semelhante. O SCNA obteve melhor performance no quesito ultrapassagem percentual (0,72%). Enquanto o SCFN obteve tempo de acomodação menor (16 segundos) alcançando o estado de regime permanente mais rapidamente. Quanto ao erro máximo em regime permanente, tanto o SCNA quanto o SCFN apresentaram comportamento similar com valores de 0,19 mca e 0,18 mca respectivamente.

6.2. RECOMENDAÇÕES

Para a elaboração do sistema de controle fuzzy neural (SCFN) foi necessário o desenvolvimento de código computacional relativo às redes neurais artificiais (RNA) e lógica *fuzzy*. A programação da RNA envolveu o método do gradiente descendente com a

retropropagação de erro. Enquanto que o código computacional *fuzzy* é baseado em regras do tipo Mandani. Estas ferramentas computacionais, *fuzzy* e neural, podem constituir a base para a elaboração do controle ANFIS (*adaptive neuro fuzzy inference system*) em trabalhos futuros.

O sistema de controle neural adaptativo (SCNA) com otimizador de Levenberg-Marquardt apresentou ótimo rendimento. Entretanto, reserva uma área de investimentos em novos trabalhos com a incorporação da correção dos limiares de ativação (*bias*) e o valor beta da função de ativação tangente hiperbólica. Os dados apresentados na fase de validação das RNA não adaptativa e adaptativa resultaram em coeficientes de correlação de 0,9995 e 0,9977 respectivamente. O que sinaliza ser a incorporação dos ajustes dos limiares de ativação (*bias*) e o (*beta*) da tangente hiperbólica ser o motivo da maior precisão e possivelmente maior aprendizado das não linearidades inerentes ao sistema.

Outra linha de trabalho que poderá ser explorada diz respeito à estimativa do coeficiente de escalamento utilizado no método de Levenberg-Maquardt. Neste trabalho foi considerado como sendo igual ao erro quadrático. Existe, um vasto material sobre este tema sugerindo novos critérios para este valor (MEDEIROS, NETO, & MARTÍNEZ, 2008).

A aplicação do sistema de controle neural adaptativo SCNA com otimizador de Levenberg-Maquardt tem seu código fonte disponível ao longo do apêndice A. A robustez e versatilidade deste método permitem a sua utilização em áreas diversas que não seja a aplicação a sistemas de distribuição de água (SDA). A sofisticação matemática envolvida, aliada a precisão e o rápido processamento, garante inúmeras aplicações nas mais variadas áreas do conhecimento.

CAPÍTULO VII

REFERÊNCIAS BIBLIOGRÁFICAS

- ABB, A. B. (2011). Technical Guide No. 4 - Guide to Variable Speed Drive.
- ABIODUN, F. & ISMAILI, F. (2013). Pump Scheduling Optimization Model for Water Supply System Using AWGA. *Symposium on Computers e Informatic*.
- ABYANEH, H. Z. (2014). Evaluation Of Multivariate Linear Regression And Artificial Neural Networks In Prediction Of Water Quality Parameters. *Journal Of Environmental Health Science & Engineering*, 1-8.
- ADAMOWSKI, J. & CHAN, H. F. (2011). A Wavelet Neural Network Conjunction Model for Groundwater Level Forecasting. *Journal of Hydrology*, 28-40.
- ANDRADE FILHO, L.S. (2009). Bombas e Estações Elevatórias. In: H. GOMES, *Sistemas de Bombeamento e Eficiência Energética* (pp. 45-112). João Pessoa: Editora Universitária - UFPB.
- ALAVALA, C. (2005). Fuzzy Logic and Neural Network - Basic Concepts & Applications. *New Age International Publishers*.
- BAKKER, A., VREEBURG, J. H., VAN SHAGEN, K. M. & RIETVELD, L. C. (2013). A fully adaptive Forecasting Model For Short-Term Drinking Water Demand. 141-151.

- BAKKER, M., RAJEWICZ, T., KIEN, H., VREEBURG, J. H. & RIETVELD, L. C. (2014). Advanced Control Of A Water Supply System: A case Study. *Water Practice & Technology*, 09 No. 2, 264-276.
- BARBOSA, J., GALVÃO, C. & GOMES, H. (2002). Operação Otimizada de parate do Sistema Adutor de Água de Campina Grande. *Anais do Seminaário, Planejamento, Projeto e Operação de Redes de Abastecimento de Água: O Estado da Arte e questões Avançadas*.
- BERARDI, L., LIU, S., LAUCELLI, D., XU, S., XU, P., ZENG, W., et al. (2014). Energy Saving and Leakage Control In Water Distribution Network: A Joint Research Project Between Italy And China. *ScienceDirect*, 152-161.
- BEZERRA, S. (2009). *Sistema Fuzzy para o Controle Piezométrico de Sistemas de Distribuição de Água Visando a Economia de Energia*. Tese de D.Sc - UFPB, João Pessoa.
- BEZERRA, S. T. & CHEUNG, P. B. (2013). *Perdas de Água - tecnologias e controle*. João Pessoa: Editora Universitária - UFPB.
- BEZERRA, S., SILVA, S., GOMES, H. & SALVINO, M. (2015). Energy Savings in Pumping Systems: Application of Fuzzy System. *Science & Engineering Journal*, pp. 71-84.
- BORTONI, E., ALMEIDA, R. & VIANA, A. (2008). Optimization of Parallel Variable-Speed-Driven Centrifugal Pumps Operation. *Energy Efficiency*.
- BOULOS, P., JACOBSEN, L., HEATH, J. & KAMOJJALA, S. (September de 2014). Real-Time Modeling of Water Distribution Systems: A case Study. *American Water Association*.
- BRAGA, A., CARVALHO, A. & LUDERMIR, T. (2007). *Redes Neurais Artificiais* (2ª ed.). Rio de Janeiro - RJ: LTC - Livros Técnicos e Científicos Ltda.
- BRAGHIROLI, M., SANTOS, M. & BRAGA, D. (2011). Estação Elevatória de Água de Santana: Um Caso de Sucesso na Redução de Perdas e Consumo de Energia no Stor de Saneamento. *International Workshop Advances in Cleaner Production*.

- CAMBOIM, W. L., SILVA, S. A. & GOMES, H. P. (2014). Aplicações de Técnicas Fuzzy no Controle de Pressão em Sistemas de Abastecimento de Água. *Eng Sanit Ambient*, 67-77.
- CARRIJO, I. & REIS, L. (Novembro de 2004). Extração de Regras Operacionais Ótimas de Sistemas de Distribuição de Água Atravé de Algoritmo Genético e Aprendizado de Máquina. *IV SEREA - Seminário Hispano-Brasileiro sobre Sistemas de Abastecimento Urbano de Água*.
- CARVALHO, P. (2012). *Controle para Bombeamento Distribuído com Vistas a Minimização dos Custos Energéticos Aplicado a Sistemas de Abastecimento de Água*. Tese de D.Sc. - UFPB, João Pessoa.
- CHANG, F. J., CHIANG, Y. M., TSAI, M. J., SHIEK, M. C. & HASU, K. L. (November de 2013). Watershed Rainfall Forecasting Using Neuro-Fuzzy Networks With The Assimilation Of Multi-Sensor Information. *Journal Of Hydrology*, 374-384.
- CORNELIUS, T. (1998). *Algorithms and Architectures* (Vol. 1). San Diego, Califórnia: Academic Press.
- CORNELIUS, T. (1998). *Implementation Techniques - Neural Network System Techniques and Applications* (Vol. 3). San Diego, California: Academic Press.
- CORNELIUS, T. (1998). *Optimization Techniques - Neural Networks Systems Techniques*. San Diego - California: Academic Press.
- COSTA, L., CASTRO, M. & RAMOS, H. (2010). Utilização de um Algoritmo Genético Híbrido para a Operação Ótima de Sistemas de Abastecimento de Água. *ABES - Associação Brasileira de Engenharia Sanitária*, pp. 187-196.
- CREACO, E. & FRANCHINI, M. (2013). A New Algorithm For Real-Time Pressure Control In Water Distribution Network. *Water Science & Technology: Water Supply*, 875-882.
- DAVIDSON, J., BOUCHART, F., CAVILL, S. & JOWITT, P. (2005). Real-Time Connectivity Modeling of Water Distribution Networks to Predict Contamination Spread. *Journal of Computing in Civil Engineering*, pp. 377-386.

- DEPINÉ, H., CASTRO, N. M., PINEIRO, A. & PEDROLLO, O. (2014). Preenchimento De Falhas De Dados Horários De Precipitação Utilizando Redes Neurais Artificiais. *Revista Brasileira De Recursos Hídricos - RBRH*, 19 No. 1, 51-63.
- DI NARDO, A., DI NATALE, M., GISONNI, C. & IERVOLINO, M. (2014). A Genetic Algorithm For Demand Pattern And Leakage Estimation In Water Distribution Network. *Journal Of Water Supply*, 1-16.
- DINIZ, A., FONTES, C., COSTA, C. & COSTA, G. (2014). Dynamic Modeling Simulation of a Water Supply System with Applications for Improving Energy Efficiency.
- DINIZ, A., FONTES, C., COSTA, C. FERREIRA, A., & SANTOS, P. (2015). Improvements in Water Supply Systems Based on Optimization and Recognition of Consumption Patterns. *Journal of Engineering Science and Technology*, pp. 571-590.
- EMAMGHOLIZADEH, S., MOSLEMI, K. & KARAMI, G. (2014). Prediction the Groundwater Level of Bastam Plain (Iran) by Artificial Neural Network (ANN) and Adaptive Neuro-Fuzzy Inference System (ANFIS). *Water Resource Manage.*
- EUROPUMP, HYDRAULIC & INSTITUTE. (2004). Variable Speed Drive - A Guide to Applications.
- FARMANI, R., INGEDULD, P., SAVIC, D., WALTERS, G., SVITAK, Z. & BERKA, J. (2006). Real-time Modelling of a Major Water Supply System. *Water Management*, pp. 1-6.
- GAMBICA, A. I.-L. (2006). Variable Speed Drive Pumps.
- GEORGESCU, A., GEORGESCU, C., PERJU, S. & ALBOIU, N. (2004). Energy Savings Quantification for The Refurbishment of a Pumping Station. *The 6th International Conference on Hydraulic Machinery and Hydrodynamics*.
- GEORGESCU, A., GEORGESCU, S. & ANTON, A. (2014). Numerical Model of a District Water Distribution System in Bucharest. *Procedia Engineering*, pp. 707-714.
- GEORGESCU, A., GEORGESCU, S., COSOIU, C., HASEGAN, L., ANTON, A. & BUCUR, D. (2015). EPANET Simulation of Control Methods for Centrifugal

- Pumps Operating under Variable System Demand. *Procedia Engineering*, pp. 1012-1019.
- GOMES, H. (2009). *Sistemas de Bombeamento - Eficiência Energética*. João Pessoa - PB: Editora Universitária - UFPB.
- GORYASHKO, A. & NEMIROVSKI, A. (2014). Robust Energy Cost Optimizacoin of Water Distribution System with Uncertyain Demand. *Automation and Remote Control*, pp. 1754-1769.
- HAYKIN, S. (1999). *Neural Networks - A Comprehensive Foundation*. (2^a ed.). New Jersey: Pretntice Hall International, Inc.
- HE, Z., WEN, X., LIU, H. & DU, J. (2013). A Comparative Study Of Artificial Neural Network, Adaptative Neuro Fuzzy Inference System And Support Vector Machine For Forecasting River Flow In The Semiarid Mountain Region. *Journal Of Hydrology*, 379-386.
- HELLER, L. & PÁDUA, V. L. (2006). Concepção de Instalações para Abastecimento de Água. In: L. Heller, & V. L. Pádua, *Abastecimento de Água para Consumo Humano*. Belo Horizonte, MG: UFMG.
- HOPFIELD, J. (1982). Neural Networks and Phisical Sistems with Emergent Collective Properties. *Proc. Nat. Acad. Sci*.
- INGEDULD, P. (2007). Real-Time Forecasting with EPANET. *World Environmental and Water Resource Congress*.
- JAMSHIDI, S., HAZRATI, H. & GHOLIKANDI, G. B. (2014). Optimization of Anaerobic Baffled Reactor (ABR) Using Artificial Neural Network In Municipal Wastewater Treatment. *Environmental Engineering and Management Journal*, 13, No.1, 95-104.
- KANG, D. (2014). Real-Time Optimal Control Of Water Distribution System. *ScienceDirect*, 917-923.
- KARIMI, S., KISI, O., SHIRI, J. & MAKARYNSKY, O. (2012). Neuro-Fuzzy and Neural Network Techniques For Forecasting Sea Level In Darwin Habor, Australia. *Computers & Geosciences*, 50-59.

- KURTULUS, B. & RAZACK, M. (2006). Evaluation of the Ability of an Artificial Neural Network Model to Simulate The Input-Output of a Large Karstic Aquifer. *Hidrogeology Journal*, pp. 241-254.
- MAITI, S. & TIWARI, R. (2014). A Comparative Study of Artificial Neural Networks, Bayesian Neural Network and Adaptative Neuro Fuzzy Inference System. *Environ Earth Sci*, pp. 3147-3160.
- MAKINO, D. (2012). *Eficiência Energética em Sistemas de Abastecimento de Água Usando Bombas de Rotação Variável*. M. Sc. Dissertação - UNICAMP - SP, Campinas - SP.
- MCCULLOCH, W. & PITTS, W. (1943). A Logical Calculus of the Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*, 5, 115-143.
- MEDEIROS, L., NETO, F. & MARTÍNEZ, J. (2008). *Acelerando o Método de Levenberg-Maquardt para a Minimização da Soma de Quadrados de Funções com Restrições em Caixa - Tese*. Campinas, SP.
- Moreira, D. & Ramos, H. (2013). Energy Cost Optimization in Water Supply System Case Study. *Journal of Energy*.
- MOREIRA, D. & RAMOS, H. (2013). Energy Cost Optimization in Water Supply System Case Study. *Journal of Energy*.
- NAJAH, A., EL-SHAFIE, A., KARIM, A. & EL-SHAFIE, A. H. (2012). Application of Artificial Neural Networks For Water Quality Prediction. *Neural Comput & Applic*, 187-201.
- NASTOS, P. T., PALIATSOS, A. G., KOULOULETSOS, K. V., LARISSI, I. K. & MOUSTRIS, K. P. (2013). Artificial Neural Network Modeling For Forecasting The Maximum Daily Total Precipitation At Athens, Greece. *Atmospheric Research*, 141-150.
- Nise, N. S. (2012). *Engenharia de Sistemas de Controle*. Rio de Janeiro: LTC - Livros Técnicos e científicos Editora Ltda.
- ODAN, F., REIS, L. & KAPELAN, Z. (2015). Real Time Multiobjective Optimization of Operation of Water Supply Systems. *American Society of Civil Engineers*.

- OLIVEIRA, G. G., PEDROLLO, O. C. & CASTRO, N. M. (2014). O Desempenho Das Redes Neurais Artificiais (RNAs) Para Simulação Hidrológica Mensal. *Revista Brasileira de Recursos Hídricos*, 19 No.2, Abr/Jun 251-265.
- PEREIRA, P., COLOMBO, A. & RABELO, G. (2013). O Uso da Engenharia de Automação na Redução do Consumo de Energia Elétrica em um Sistema de Irrigação por Pivot Central. *XI Simpósio Brasileiro de Automação Inteligente*.
- PERJU, S. & GEORGESCU, A. (2010). Numerical Quantification of Energy Consumption for The "Teiul Domanei" Pumping Station. *U.P.B. Sci. Bull.*
- RIUL, J., SILVA, J. & CAVALCANTI, J. (2000). *Controladores Neurais e Híbrido Aplicados em uma Carga Acionada por um Atuador Hidráulico - Tese*. João Pessoa.
- ROCHA, V. A., ARAÚJO, J. K., CASTRO, M. A., COSTA, M. G. & COSTA, L. H. (2012). Análise Comparativa Entre RNA, AG e Migha Na Determinação De Rugosidade Através De Calibração De Redes Hidráulicas. *Revista Brasileira de Recursos Hídricos - RBRH*, 18 No.1 Jan/Mar 2013, 125-134.
- RODRIGUES, W. (2007). Critérios para Uso Eficiente de Inversores de Frequência em Sistemas de Bombeamento. Campinas - SP: Editora Universitária - UNICAMP.
- ROSEMBLATT, F. (1958). The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. *Psychol. Rev.*
- RUMELHART, D., HINTON, G. & WILLIAMS, R. (1996). Learning Internal Representation by Error Propagation. *Parallel Distributed Processing. 1*. Massachusetts: MIT Press.
- SAIDUR, R., MEKHILEF, S. ALI, M., SAFARI, A., & MOHAMMED, H. (2012). Applications of Variable Speed Drive (VSD) in Electrical Motors Energy Savings. *Renewable and Sustainable Energy Reviews*.
- SAIDUR, R., Mekhilef, S., Ali, M., Safari, A. & Mohammed, H. (2012). Applications of Variable Speed Drive (VSD) in Electrical Motors Energy Savings . *Renewable and Sustainable Energy Reviews*.
- SALVINO, M. & GOMES, H. (2012). Modelagem Computacional Visando a Reabilitação de Redes Hidráulicas. *Tese - UFPB*.

- SCHWALLER, J. & ZIL, J. E. (2014). Modeling The Pressure-Leakage Response Of Water Distribution Systems Based On Individual Leak Behavior. *American Society Of Civil Engineers - (ASCE)*.
- SILVA, I., SPATTI, D. & FLAUZINO, R. (2010). *Redes Neurais Artificiais*. São Paulo, SP: Artliber Editora Ltda.
- SILVA, M., ARAUJO, C., BEZERRA, S., ARNAUD, S., SOUTO, C. & GOMES, H. (2015). Adaptive Control System Applies in Water Distribution System with Emphasis on Energy Efficiency. *Eng Sanit Ambient*, pp. 405-413.
- SIMÕES, M. G. & SHAW, I. S. (2007). *Controle e Modelagem Fuzzy*. São Paulo: Editora Edgard Blücher Ltda.
- SOUZA, J. C. (2014). *Distritos de Medição e Controle com Ferramentas de Gestão de Perdas em Redes de Distribuição de Água*. Campinas - SP: Editora Universitária - UNICAMP.
- SPATTI, D., SILVA, I. & FLAUZINO, R. (2010). *Redes Neurais Artificiais*. São Paulo - SP: Artliber Editora Ltda.
- SUNELA, M. & PUUST, R. (2015). Real Time Water Supply System Hydraulic and Quality Modeling - A Case Study. *ScienceDirect*, pp. 744-752.
- TAORMINA, R., CHAU, K. & SETHI, R. (2012). Artificial Neural Network Simulation of Hourly Groundwater Levels in a Coastal Aquifer System of the Venice Lagoon. *Engineering Applications of Artificial Intelligence*, pp. 1670-1676.
- TAPOGLOU, E., TRICHAKIS, I., DOKOU, Z., NIKOLOS, I. & G.P., K. (2014). Groundwater-Level Forecasting Under Climate Change Scenarios Using an Artificial Neural Network Trained with Particle Swarm Optimization. *Hydrological Sciences Journal*, pp. 1225-1239.
- TIWARI, M. K. & ADAMOWSKI, J. (2013). Urban Water Demand Forecasting and Uncertainty Assessment Using Ensemble Wavelet-Bootstrap-Neural Network Models. *Water Resources Research*, 49, 6486-6507.
- TIWARI, M. K., SONG, K. Y., CHATTERJEE, C. & GUPTA, M. M. (2013). Improving Reliability Of River Flow Forecasting Using Neural Networks, Wavelets and Self-Organizing Maps. *Journal Of HydroInformatics*.

- TSUTIYA, M. T. (2007). Uso de Inversores de Frequência para a Diminuição do Consumo de Energia em Bombeamentos. In: H. P. Gomes, R. P. Garcia, & P. L. Rey, *Abastecimento de Água - Estado da Arte e Técnicas Avançadas*. João Pessoa: Editora Universitária - UFPB.
- VAFAKHAH, M., JANIZADEH, S. & BOZCHALOEI, S. K. (2014). Application Of Several Data-Driven Techniques For Rainfal-Runoff Modeling. *Ecopersia*, 455-469.
- VAN ZYL, J., SAVIC, D. & WALTERS, G. (2004). Operational Optimization of Water Distribution System Using a Hibrid Genetic Algorithm. *Journal of Water Resources Planning and Management*.
- VIHOLAINEM, J., TAMMINEN, J., AHONEN, T., AHOLA, J., VAKKILAINEN, E. & SOUKKA, R. (2013). Energy-Efficient Control Strategy for Variable Speed-Driven Parallel Pumping System. *Energy Efficiency*, pp. 495-509.
- VILANOVA, M. & BALESTIERI, J. (2013). Energy and Hidraulic Efficiency in Conventional Water Supply System. *Renewable and Sustainable Energy Review*, pp. 701-714.
- WIDROW, B. & HOFF, M. (1960). Adaptative Switching Circuits. *Institute of Radio Engineers, Western Eletronic Show and Convention*.
- WU, W., GAO, J., ZHAO, M., QIAN, Z., HOU, X. & HAN, Y. (2007). Assessing Optimizing Online Monitoring for Securing the Water Distribution System. *IEEE*, pp. 350-355.
- YI-MEI, T. F., HAI-YAN, C. & YE, L. (2007). Optimal Operation of Water Distribution Networks under Local Pipe Failures.

APÊNDICES A – APLICATIVOS

APÊNDICE - A.1 LIMPADOR DE ZERO

```
% PPGEM - PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA MECÂNICA
% ÁREA - DINÂMICA E CONTROLE
% ALUNO - GERALDO DE ARAÚJO MOURA
% MATRÍCULA - 2014106604
% APLICATIVO - LIMPADOR DE ZEROS
clc; clear all;
fprintf('-----Operação Iniciada----- \n')
Fid_ENT_SAI = fopen('DADOS_BRUTO_ORDEM.txt', 'r');
NE = 1;
NS = 1;
Cc=0; Mdad = [ ]; Mcad = [ ];
% Montar a matriz de dados 'Mdad'
while ~feof(Fid_ENT_SAI);
    Cc = Cc+1;
    Ldad = fscanf(Fid_ENT_SAI,'%f', 3);
    Ldad =Ldad';
    Mdad = [Mdad; Ldad];
end
fclose(Fid_ENT_SAI);
[Li, Ci] = size(Mdad);
Cont=0;
% Extrair dados nulos
for i=1:1:Li
    Num_1 = Mdad(i,1);
    if (Num_1 ~= 0);
        Mcad = [Mcad; Mdad(i,:)];
    end
end
```

```
end
[Li, Ci] = size(Mcad);
Fid_ENT_SAI = fopen('DADOS_BRUTO_ORDEM_SEM_ZERO.txt', 'w');
for i=1:1:Li
    fprintf(Fid_ENT_SAI,'%3.2f\t%3.2f\t%3.2f\r\n', Mcad(i,:));
end
fclose(Fid_ENT_SAI);
```

APÊNDICE - A.2. ELIMINADOR DE DADOS INCONSISTENTES

```
% PPGEM - PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA MECÂNICA
% ÁREA - DINÂMICA E CONTROLE
% ALUNO - GERALDO DE ARAÚJO MOURA
% MATRÍCULA - 2014106604
% APLICATIVO - ELIMINADOR DE DADOS INCONSISTENTES
clc; clear all;
fprintf('-----VALORES CONSISTENTES Iniciado----- \n')
Fid_ENT_SAI = fopen('DADOS_BRUTO_ORDEM_SEM_ZERO.txt', 'r');
NE = 1;
NS = 1;
Cc=0; Mdad = [ ]; Mcad = [ ];
% Montar a matriz de dados 'Mdad'
while ~feof(Fid_ENT_SAI);
    Cc = Cc+1;
    Ldad = fscanf(Fid_ENT_SAI,'%f', 3);
    Ldad =Ldad';
    Mdad = [Mdad; Ldad];
end
fclose(Fid_ENT_SAI);
[Li, Ci] = size(Mdad);
Cont=0;
% Extrair dados inconsistentes
Ficar = true; i = 0;
while i<Li-1 | Ficar
    i = i+1;
    Ficar = false;
    Cc = 0;
    for j=i+1:1:Li
        Num_1 = Mdad(i,1);
        Num_2 = Mdad(j,1);
        if (Num_1 >= Num_2);
            Cc = Cc+1;
```

```

        Nreg(Cc) = j;
        Ficar = true;
    end
end
for Nn=1:1:Cc
    if Nn>1
        Ind = Nreg(Nn)-(Nn-1);
        Mdad(Ind,:) = [ ];
    else
        Mdad(Nreg(Nn),:) = [ ];
    end
end
Nreg = []; Cc = 0;
[Li, Ci] = size(Mdad);
end

[Li, Ci] = size(Mdad);
Fid_ENT_SAI = fopen('DADOS_ORDEM_CONSISTENTE.txt', 'w');
for i=1:1:Li
    fprintf(Fid_ENT_SAI,'%3.2f\t%3.2f\t%3.2f\r\n', Mdad(i,:));
end
fclose(Fid_ENT_SAI);
fprintf('-----VALORES CONSISTENTES Encerrado----- \n')

```

APÊNDICE - A.3. MULTIPLICADOR DE DADOS

```
% PPGEM - PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA MECÂNICA
% ÁREA - DINÂMICA E CONTROLE
% ALUNO - GERALDO DE ARAÚJO MOURA
% MATRÍCULA - 2014106604
% APLICATIVO - MULTIPLICADOR DE DADOS
clc; clear all;
fprintf('-----MULTIPLICADOR Iniciado----- \n')
Fid_ENT_SAI = fopen('DADOS_ORDEM_CONSISTENTE.txt', 'r');
NE = 1;
NS = 1;
Cc=0; Mdad = [ ]; Mcad = [ ];
Nmult = input('Número de Multiplicações = ');
% Montar a matriz de dados 'Mdad'
while ~feof(Fid_ENT_SAI);
    Cc = Cc+1;
    Ldad = fscanf(Fid_ENT_SAI,'%f', 3);
    Ldad =Ldad';
    Mdad = [Mdad; Ldad];
end
fclose(Fid_ENT_SAI);
[Li, Ci] = size(Mdad);
Fid_ENT_SAI = fopen('DADOS_ORDEM_CONSISTENTE_MULTIPLICADO.txt', 'w');
for Ni=1:1:Nmult
    for i=1:1:Li
        fprintf(Fid_ENT_SAI,'%3.2f\t%3.2f\t%3.2f\r\n', Mdad(i,:));
    end
end
fclose(Fid_ENT_SAI);
fprintf('-----MULTIPLICADOR Concluido----- \n')
```

APÊNDICE - A.4 MISTURADOR DE DADOS

```
% PPGEM - PROGRAMA DE PÓS GRADUAÇÃO EM
% ENGENHARIA MECÂNICA
% ÁREA - DINÂMICA E CONTROLE
% ALUNO - GERALDO DE ARAÚJO MOURA
% MATRÍCULA - 2014106604
% APLICATIVO - MISTURADOR DE DADOS
fprintf('-----MISTURADOR Iniciado----- \n')
Fid_ENT_SAI = fopen('DADOS_ORDEM_CONSISTENTE_MULTIPLICADO.txt', 'r');
while ~feof(Fid_ENT_SAI);
    Cc = Cc+1;
    Ldad = fscanf(Fid_ENT_SAI,'%f', 3);
    Ldad =Ldad';
    Mdad = [Mdad; Ldad];
end
fclose(Fid_ENT_SAI);
[Li, Ci] = size(Mdad);
Fid_ENT_SAI = fopen('DADOS_MISTURADOS.txt', 'w');
% Embaralhar os dados
while (Li~=0)
    Ql=unidrnd(Li,1,1);
    fprintf(Fid_ENT_SAI,'%3.2f\t%3.2f\t%3.2f\r\n', Mdad(Ql,:));
    Mdad(Ql,:)=[ ];
    [Li, Ci] = size(Mdad);
end
fclose(Fid_ENT_SAI);

fprintf('-----MISTURADOR Concluido----- \n')
```

APÊNDICE - A.5. TREINAMENTO DA RNA

```
% PPGEM - PROGRAMA DE PÓS GRADUAÇÃO EM
% ENGENHARIA MECÂNICA
% ÁREA - DINÂMICA E CONTROLE
% ALUNO - GERALDO DE ARAÚJO MOURA
% MATRÍCULA - 2014106604
% APLICATIVO - TREINAMENTO DA RNA
fprintf('-----TREINAMENTO Iniciado----- \n')
clc; clear all; format long e;
%EP =441; % N° de Épocas
NE = 1; % Número de Entradas
NI = 7; % Número de Neurônios da camada
    % Intermediária
NS = 1; % Número de Neurônios da camada
    % de Saída
XE(1:NE) = 0; % XE de Entrada
YE(1:NE) = 0; % YE = XE
DE(1:NE) = 0; %
TE(1:NE) = 0; % Bias de Entrada
WEI=random('Uniform',0,1,NE,NI); % Pesos Int.
%
XI(1:NI) = 0; % Soma dos Pesos * YE
YI(1:NI) = 0; % F(XI) + TI
DI(1:NI) = 0; %
TI(1:NI) = 0; % Bias Intermediárias
WIS=random('Uniform',0,1,NI,NS); % Pesos Saída
BI=random('Uniform',0,1,NI,1); % Beta Int.
TI =random('Uniform',0,1,NI,1); % Bias Int.
%
XS(1:NS) = 0; % XS de Saída
YS(1:NS) = 0; % YS = XS
DS(1:NS) = 0; % Saída desejada
TS(1:NS) = 0; % Bias de Saída
```

```

ES(1:NS) = 0;
MI = 0.02; % Coeficiente de Aprendizado
Fid_ENT_SAI=fopen('DADOS_MISTURADOS.txt','r')
T=0;
while ~feof(Fid_ENT_SAI)
    T=T+1;
    for li=1:1:NE
        XE(li)=fscanf(Fid_ENT_SAI,'%f',1)/10;
    end
    Tp=fscanf(Fid_ENT_SAI,'%f',1);
    for Ji=1:1:NS
        DS(Ji) = fscanf(Fid_ENT_SAI,'%f',1);
    end
    XE
    DS
    for K=1:1:NI
        XI(K) = TI(K);
        for J=1:1: NE
            XI(K) = WEI(J,K)*XE(J) + XI(K);
        end
        YI(K) = (1-exp(-(BI(K)*XI(K))))/(1+exp(-(BI(K)*XI(K))));
    end
% Cálculo das Saídas da Camada Entrada YI()
    for M=1:1:NS
        XS(M) = TS(M);
        for K=1:1:NI
            XS(M) = WIS(K,M)*YI(K)+XS(M);
        end
        YS(M) = XS(M);
    end
    EQ = 0;
    for M=1:1:NS
        ES(M) = (DS(M)-YS(M)); % Erro absoluto
        EQ = EQ+(ES(M))^2;
    end
end

```

```

end
%EQ = EQ^2; % Erro Quadrático
ID = EQ/2; % Índice de Desempenho
% Propagação Retroativa do Erro
% Gradiente Descendente do Erro
% Correção dos Pesos WIS() da
% Camada de Saída
for M=1:1:NS
    for K=1:1:NI
        WIS(K,M) = WIS(K,M)+MI*ES(M)*YI(K);
    end
end
% Correção dos Pesos WEI() da
% Camada Intermediária
for J=1:1:NE
    for K=1:1:NI
        for M=1:1:NS
            PIS2 = ES(M)*WIS(K,M)*(BI(K)/2)*(1-(YI(K)^2));
            WEI(J,K) = WEI(J,K)+MI*(PIS2*XE(J));
            TI(K) = TI(K)+MI*(PIS2);
            BIS2 = ES(M)*WIS(K,M)*(XI(K)/2)*(1-(YI(K)^2));
            BI(K) = BI(K)+MI*(BIS2);
        end
    end
end
fprintf('EPOCA = %d\n', T)
fprintf('Es = %3.4f --- Ys = %3.4f --- Ds = %3.4f\n',ES(1), YS(1),DS(1))
Eperc = DS(1)/YS(1);
fprintf('ID = %3.4f --- DS(1)/YS(1) = %3.6f \n ', ID, Eperc)
if abs(ES(1)<0.0000001) && abs(ID)<0.0000001
    break;
end
end
end

```

```
Fid_ARQ = fopen('ARQ.txt', 'w');
Fid_PE = fopen('PESO_E.txt', 'w');
Fid_PI = fopen('PESO_I.txt', 'w');
Fid_TI = fopen('BIAS_I.txt', 'w');
Fid_TS = fopen('BIAS_S.txt', 'w');
Fid_BI = fopen('BETA_I.txt', 'w');

fprintf(Fid_ARQ, '%d \t %d \t %d \r\n', NE, NI, NS);
fprintf(Fid_PE, '%5.10f \r\n', WED);
fprintf(Fid_PI, '%5.10f \r\n', WIS);
fprintf(Fid_TI, '%5.10f \r\n', TI);
fprintf(Fid_TS, '%5.10f \r\n', TS);
fprintf(Fid_BI, '%5.10f \r\n', BI);

fclose(Fid_ARQ);
fclose(Fid_PE);
fclose(Fid_PI);
fclose(Fid_TI);
fclose(Fid_TS);
fclose(Fid_BI);
fclose(Fid_ENT_SAI);
fprintf('-----TREINAMENTO Concluido----- \n')
```

APÊNDICE - A.6. VALIDAÇÃO DA RNA

```
% PPGEM - PROGRAMA DE PÓS GRADUAÇÃO EM
% ENGENHARIA MECÂNICA
% ÁREA - DINÂMICA E CONTROLE
% ALUNO - GERALDO DE ARAÚJO MOURA
% MATRÍCULA - 2014106604
% APLICATIVO - VALIDAÇÃO DA RNA
fprintf('-----ATUADOR Iniciado----- \n')
clc; clear all; format long e;
Fid_ARQ = fopen('ARQ.txt', 'r');
Fid_PE = fopen('PESO_E.txt', 'r');
Fid_PI = fopen('PESO_I.txt', 'r');
Fid_TI = fopen('BIAS_I.txt', 'r');
Fid_TS = fopen('BIAS_S.txt', 'r');
Fid_BI = fopen('BETA_I.txt', 'r');
Fid_DAD = fopen('DADOS_ORDEM_CONSISTENTE.txt', 'r');
NE = fscanf(Fid_ARQ, '%f', 1);
NI = fscanf(Fid_ARQ, '%f', 1);
NS = fscanf(Fid_ARQ, '%f', 1);
for K=1:1:NI
    TI(K) = fscanf(Fid_TI, '%f', 1);
    BI(K) = fscanf(Fid_BI, '%f', 1);
    for J=1:1: NE
        WEI(J,K) = fscanf(Fid_PE, '%f', 1);
    end
end
for M=1:1:NS
    for K=1:1:NI
        WIS(K,M) = fscanf(Fid_PI, '%f', 1);
    end
end

fclose(Fid_PI);
```

```

fclose(Fid_TI);
fclose(Fid_PE);
fclose(Fid_BI);
fclose(Fid_ARQ);
fclose(Fid_TS);
Cc =0;
while ~feof(Fid_DAD)
    Cc=Cc+1;
    ENT = fscanf(Fid_DAD,'%f',1);
    PRES(Cc) = ENT;
    ENT = fscanf(Fid_DAD,'%f',1);
    ENT = fscanf(Fid_DAD,'%f',1);
    FREQ(Cc) = ENT;
    for K=1:1:NI
        XI(K) = TI(K);
        for J=1:1: NE
            XE(J) = PRES(Cc)/10;
            XI(K) = WEI(J,K)*XE(J) + XI(K);
        end
        YI(K) = (1-exp(-(BI(K)*XI(K))))/(1+exp(-(BI(K)*XI(K))));
    end
    % Cálculo das Saídas da Camada Entrada YI()
    for M=1:1:NS
        XS(M) = 0;
        for K=1:1:NI
            XS(M) = WIS(K,M)*YI(K)+XS(M);
        end
        YS(M) = XS(M);
    end
    FREQ(Cc);
    SAIDA(Cc) = YS(M);
end
figure(1);
clf(1);

```

```
xlabel('FREQUÊNCIA - Hz');
ylabel('PRESSÃO - m.c.a.');
```

```
title('TREINAMENTO DA REDE NEURAL');
hold on;
plot(FREQ, PRES, '-o', 'color', 'r');
hold on;
plot(SAIDA, PRES, ':+', 'color', 'b');
legend('DADOS AMOSTRADOS','DADOS CALCULADOS');
```

fprintf('Ys = %2.2f \n', YS(1));

fprintf('-----ATUADOR Concluido----- \n')

APÊNDICE - A.7. SISTEMA *FUZZY* MANDANI

```
% PPGEM - PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA MECÂNICA
% ÁREA - DINÂMICA E CONTROLE
% ALUNO - GERALDO DE ARAÚJO MOURA
% MATRÍCULA - 2014106604
% APLICATIVO - FUZZY MANDANI
clc; clear all; format long e;
% Função de Pertinência Pessão
% P - Valor Crisp da Pressão

%----- FUZIFICAÇÃO PRESSÃO -----
Arq = 'ERRO_DAT.txt';
% Pfz - Vetor FUZZY da PRESSÃO
Fid_ENT_SAI = fopen(Arq, 'r');

Ep = 0.5; Y = Ep;
CEdat = 5; LEdat = 7;
Edat([1:LEdat 1:CEdat])=0;
Edat = fscanf(Fid_ENT_SAI,'%f', [CEdat LEdat]);
Edat = Edat';
Cc = 0; T=0; X(1:CEdat-1)=0;
Yfz=0;

for Cc=1:1:LEdat;
    for i=1:1:CEdat
        if i==1
            T = Edat(Cc,i);
        else
            X(i-1) = Edat(Cc,i);
        end
    end
    % Se T==0 se Trata de um Trapézio
    if T==0
        if Y<X(1)
            Yfz = 0;
        elseif Y<=X(2)
            if X(1)==X(2)
                Yfz = 1;
            else
                Yfz = (Y-X(1))/(X(2)-X(1));
            end
        elseif Y<X(3)
            Yfz = 1;
        elseif Y<=X(4)
            if X(3)==X(4)
                Yfz = 1;
            end
        end
    end
end
```

```

else
    Yfz = -((Y-X(4))/(X(4)-X(3)));
end
elseif Y>X(4)
    Yfz = 0;
end
Yfzz(Cc) = Yfz;
else
if Y<=X(1)
    Yfz = 0;
elseif Y<=X(2)
    Yfz = (Y-X(1))/(X(2)-X(1));
elseif Y<=X(3)
    Yfz = -((Y-X(3))/(X(3)-X(2)));
elseif Y>X(3)
    Yfz = 0;
end
Yfzz(Cc) = Yfz;
end
end
fclose(Fid_ENT_SAI);
Epfz=Yfzz;
fprintf('%1.3f\t', Epfz)
fprintf('\n')
%Pfz = Pfz';
% Função de Pertinência Erro da Pressão
% E - Valor Crisp do Erro
% Agregação pela T-Norma mín PRESSÃO e ERRO
% Arq - Tabela de Inferências sobre a Variável
% FUZZY - Delta de Rotação

%----- INFERENCIA -----
Arq = 'ERRO_X_DELTA.txt';
Fid_ENT_SAI = fopen(Arq, 'r');
CExDdat = 7; LExDdat = 1;
ExDdat([1:LExDdat 1:CExDdat])=0;
ExDdat = fscanf(Fid_ENT_SAI,'%f', [CExDdat LExDdat]);
ExDdat = ExDdat';
% Fzy Valor agregado de acordo com a tab
% PRESSAO_ERRO_DAT.txt
% Infzy Valor das Inferências sobre
% a Variável FUZZY DELTA_ROTACAO_DAT.txt
% Regras do Sistema T-Norma e S-Norma
Fid_ENT_SAI = fopen(Arq, 'r');
Cc = 0;
Fc = 0;
for i=1:1:CExDdat
    if Epfz(i)~=0 && ExDdat(i)~=0
        Fc = Fc+1;
    end
end

```

```

        Fzy(Fc) = Epfz(i);
        Infzy (Fc) = ExDdat(i);
    end
end
fclose(Fid_ENT_SAI);

%----- DEFUZUFICAÇÃO -----
Arq = 'DELTA_ROTACAO_DAT.txt';
Fid_ENT_SAI = fopen(Arq, 'r');
CDrdat= 5; LDrdat = 7;
Mdelta(LDrdat, LDrdat+1)=0
Drdat([1:LDrdat 1:CDrdat])=0;
Drdat = fscanf(Fid_ENT_SAI,'%f', [CDrdat LDrdat]);
Drdat = Drdat';
% Area Valor da Área resultante da DEFUZUFICAÇÃO
% Valores dos Centros de Gravidade
% Cx é o valor CRISP para o Delta de Rotação

Cc = 0;
for Cc=1:1:LDrdat;
    Mdelta(Cc,1)=Cc;
    for i=1:1:5
        Mdelta(Cc,i+1) = Drdat(Cc, i)
    end
end
Mdelta;
Nfc = length(Mdelta);
Area=0; Cx=0; Cy=0; Fp=0; Np=0;
for i=1:1:length(Infzy)
    X = []; Y = [];
    Fp = Infzy(i);
    if Mdelta(Fp,2)==0 % Trapézio
        Np = 4;
        Y = [0 Fzy(i) Fzy(i) 0];
        Lf = 4;
        for j=1:1:Lf
            X(j) = Mdelta(Fp,j+2);
        end
    else % Triângulo ou Trapézio
        Lf =3;
        for j=1:1:Lf
            X(j) = Mdelta(Fp,j+2);
        end
        if Fzy(i)==1.0 % Se Fzy(i)==1.0 é Triângulo
            Np = 3;
            Y = [0 Fzy(i) 0];
        else % Trapézio
            Np = 4;
            Y = [0 Fzy(i) Fzy(i) 0];
        end
    end
end

```

```

X12 = X(1)+(Fzy(i)*(X(2)-X(1)));
X13 = X(3)-(Fzy(i)*(X(3)-X(2)));
X(4) = X(3);
X(3) = X13;
X(2) = X12;
end
end
X(Np+1) = X(1); Y(Np+1) = Y(1);
A=0;
for ii=1:1:Np
    A = (X(ii)*Y(ii+1)) - (X(ii+1)*Y(ii))+A;
    Area = (X(ii)*Y(ii+1)) - (X(ii+1)*Y(ii)) + Area;
end
A=A/2;
% Cálculo do Centro de Gravidade Cx
for ii=1:1:Np
    Cx = (X(ii)+X(ii+1))*(X(ii)*Y(ii+1)-X(ii+1)*Y(ii)) + Cx;
end

% Cálculo do Centro de Gravidade Cy
for ii=1:1:Np
    Cy = (Y(ii)+Y(ii+1))*(X(ii)*Y(ii+1)-X(ii+1)*Y(ii)) + Cy;
end
end
A=A/2;
Area = Area/2;
Cx = Cx/(6*Area);
Cy = Cy/(6*Area);
Dhz = Cx;

```

APÊNDICE - A.8. TREINAMENTO DA RNA ADAPTATIVA

```
% PPGEM - PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA MECÂNICA
% ÁREA - DINÂMICA E CONTROLE
% ALUNO - GERALDO DE ARAÚJO MOURA
% MATRÍCULA - 2014106604
% APLICATIVO - VALIDAÇÃO DA RNA ADAPTATIVA
clc; clear all; format long e;
fprintf('-----ATUADOR Iniciado----- \n')
% Abertura do Arquivo de Leitura ARQ.txt
% Número de Entradas. Número de Neurônios
% das Camadas Intermediária e Saída
Arq1w = 'C:\I\DOCTOR-
DINÂMICA\QUALIFICAÇÃO\APLICATIVOS_MATLAB\TESE_GM\ARQ_LM_SISO
_03_2016.txt';
Fid_ARQ = fopen(Arq1w, 'r');
% Abertura do Arquivo de Leitura PESO_E.txt
% Pesos entre as Camadas de Entrada e
% Intermediária - WEI(j,k)
Arq2w = 'C:\I\DOCTOR-
DINÂMICA\QUALIFICAÇÃO\APLICATIVOS_MATLAB\TESE_GM\PESO_E_LM_SI
SO_03_2016.txt';
Fid_PE = fopen(Arq2w, 'r');
% Abertura do Arquivo de Leitura PESO_I.txt
% Pesos entre as Camadas Intermediária e
% Saída - WIS(k,m)
Arq3w = 'C:\I\DOCTOR-
DINÂMICA\QUALIFICAÇÃO\APLICATIVOS_MATLAB\TESE_GM\PESO_I_LM_SI
SO_03_2016.txt';
Fid_PI = fopen(Arq3w, 'r');
% Abertura do Arquivo de Leitura BIAS_I.txt
% Valores dos Limiares de Ativação da Camada
% Intermediária TI(k)
Arq4w = 'C:\I\DOCTOR-
DINÂMICA\QUALIFICAÇÃO\APLICATIVOS_MATLAB\TESE_GM\BIAS_I_LM_SIS
O_03_2016.txt';
Fid_TI = fopen(Arq4w, 'r');
% Abertura do Arquivo de Leitura BIAS_S.txt
% Valores dos Limiares de Ativação da Camada
% de Saída TS(m)
Arq5w = 'C:\I\DOCTOR-
DINÂMICA\QUALIFICAÇÃO\APLICATIVOS_MATLAB\TESE_GM\BIAS_S_LM_SI
SO_03_2016.txt';
Fid_TS = fopen(Arq5w, 'r');
% Abertura do Arquivo de Leitura BETA_I.txt
% Valores de Beta da Função de
% Ativação da Tangente Hiperbólica BI(k)
```

```

Arq6w = 'C:\I\DOCTOR-
DINÂMICA\QUALIFICAÇÃO\APLICATIVOS_MATLAB\TESE_GM\BETA_I_LM_SISO_03_2016.txt';
Fid_BI = fopen(Arq6w, 'r');
% Abertura do Arquivo de Leitura DADOS_MISTURADOS.txt
Arq7w = 'C:\I\DOCTOR-
DINÂMICA\QUALIFICAÇÃO\APLICATIVOS_MATLAB\TESE_GM\DADOS_VALID
ACAO_SISO_01_2016.txt';
Fid_DAD = fopen(Arq7w, 'r');
Arq8w = 'C:\I\DOCTOR-
DINÂMICA\QUALIFICAÇÃO\APLICATIVOS_MATLAB\TESE_GM\DSxYS_SISO_0
3_2016.txt';
Fid_DSxYS = fopen(Arq8w, 'w');

NE = fscanf(Fid_ARQ,'%f',1);
NI = fscanf(Fid_ARQ,'%f',1);
NS = fscanf(Fid_ARQ,'%f',1);
% Leitura dos Pesos entre as Camadas de Entrada e
% Intermediária - WEI(j,k)
for I=1:1: NE
    for J=1:NI
        WEI(I,J) = fscanf(Fid_PE,'%f',1);
    end
end
% Leitura dos Valores dos Limiares de Ativação da
% Camada Intermediária TI(k) e Valores de Beta
% da Função de % Ativação da Tangente Hiperbólica BI(k)
for K=1:1:NI
    TI(K) = fscanf(Fid_TI,'%f',1);
    BI(K) = fscanf(Fid_BI,'%f',1);
end
% Leitura dos Pesos entre as Camadas
% Intermediária e Saída - WIS(k,m)
for M=1:1:NI
    for K=1:1:NS
        WIS(M,K) = fscanf(Fid_PI,'%f',1);
    end
end
% Fechamento dos Arquivos de Leitura ARQ.txt,
% PESO_E.txt, PESO_I.txt, BIAS_I.txt,
% BIAS_S.txt, BETA_I.txt
fclose(Fid_ARQ);
fclose(Fid_PE);
fclose(Fid_PI);
fclose(Fid_TI);
fclose(Fid_TS);
fclose(Fid_BI);

Cc =0; Corr = 0;

```

```

% Número de Colunas do Arquivo
% DADOS_MISTURADOS.txt
Ncol=2;
% Colunas a serem Lidas como Entradas
% Parâmetros para Normalização do Dados
P_Min=4.04; P_Max=16.8; F_Min=30; F_Max=59.9;
%Enti=[1];
% Colunas a serem Lidas como Saída
% Saii=[7];

NumR2(1:8)=0; YSmed(1:8)=0; DenR2(1:8)=0;
while ~feof(Fid_DAD)
    Cc=Cc+1;
    Ldad = fscanf(Fid_DAD,'%f\r',Ncol);
    % Leitura das Entradas
    % Leitura da Saída Desejada
    for Ii=1:1:NE
        XE(Ii)= (Ldad(Ii)-P_Min)/(P_Max-P_Min);
        DS(Ii) = (Ldad(Ii+1)-F_Min)/(F_Max-F_Min);
    end
    XE_LM(Cc)=XE(Ii);
    DS_LM(Cc)=DS(Ii);
    % Início do passo a frente - Forward
    % Entre as Camadas de Entrada e Intermediária
    for K=1:1:NI
        XI(K) = TI(K);
        for J=1:1: NE
            XE(J) = XE(J);
            XI(K) = WEI(J,K)*XE(J) + XI(K);
        end
        YI(K) = (1-exp(-(BI(K)*XI(K))))/(1+exp(-(BI(K)*XI(K))));
    end
    % Entre as Camadas Intermediária e Saída
    for M=1:1:NS
        XS(M) = 0;
        for K=1:1:NI
            XS(M) = WIS(K,M)*YI(K)+XS(M);
        end
        YS(M) = XS(M);
        %FreqCalc(Cc,M) = YS(M);
    end
    YS_LM(Cc)=YS(M);
    for M=1:1:NS
        % Erro Absoluto
        ES(M) = (DS(M)-YS(M));
        % Erro Quadrático
        NumR2(M) = NumR2(M)+ES(M)^2;
        YSmed(M) = YSmed(M)+YS(M);
        DenR2(M) = DenR2(M)+(DS(M)+(DS(M)/Cc))^2;
    end
end

```

```

        fprintf('DS(%1d) = %5.4f --- YS(%1d) = %5.4f\r', M, (DS(M)*(F_Max-
F_Min)+F_Min), M, (YS(M)*(F_Max-F_Min)+F_Min));
    end
    %Corr = Corr+FreqCalc(Cc)-FreqDes(Cc);
end

% Impressão dos Parâmetros de Cálculo

for M=1:1:NS
    R2(M) = 1 - (NumR2(M)/DenR2(M));
    fprintf('Correlação Múltipla R2(%1d) = %2.6f \n', M, R2(M));
    fprintf('Somatório do Erro Quadrático SEQ(%1d) = %2.6f \n', M, NumR2(M));
    fprintf('Variância Sigma2(%1d) = %2.6f \n', M, DenR2(M)/Cc);
end
Corr = Corr/Cc;
% Impressão Gráfico - Dados Amostrados
% Versus Dados Calculados
figure(1);
clf(1);
xlabel('FREQUÊNCIA - Hz');
ylabel('PRESSÃO - m.c.a.');
```

TREINAMENTO DA REDE NEURAL

```

hold on;
ArqPGw = 'C:\I\DOCTOR-
DINÂMICA\QUALIFICAÇÃO\APLICATIVOS_MATLAB\TESE_GM\GRAFICO_RNA
.txt';
Fid_PGw = fopen(ArqPGw, 'w');

for ii=1:1:Cc
    %fprintf(Fid_PGw, '%5.10f\t%5.10f\t%5.10f\r\n', PRES(ii)*14.9, FreqDes(ii), FreqCalc(ii));
    plot(DS_LM(ii), XE_LM(ii), '-o', 'color', 'r');
    hold on;
    plot(YS_LM(ii), XE_LM(ii), '-+', 'color', 'b');
end
fclose(Fid_PGw);
legend('DADOS AMOSTRADOS', 'DADOS CALCULADOS', 'Location', 'NorthWest');
fprintf('-----ATUADOR Concluido----- \n')
fclose(Fid_DSxYS);

```

ANEXO A – MÉTODO DO GRADIENTE DESCENDENTE COM RETROPROPAGAÇÃO (*backpropagation*) APLICADO AS REDES NEURAS ARTIFICIAIS - RNA

Este apêndice apresenta o desenvolvimento matemático para as redes neurais com duas camadas. Uma camada intermediária com função de ativação do tipo tangente hiperbólica e limiar de ativação diferente de zero. A camada de saída está sendo tratada com função de ativação linear e limiar de ativação nulas, conforme Figura B.1:

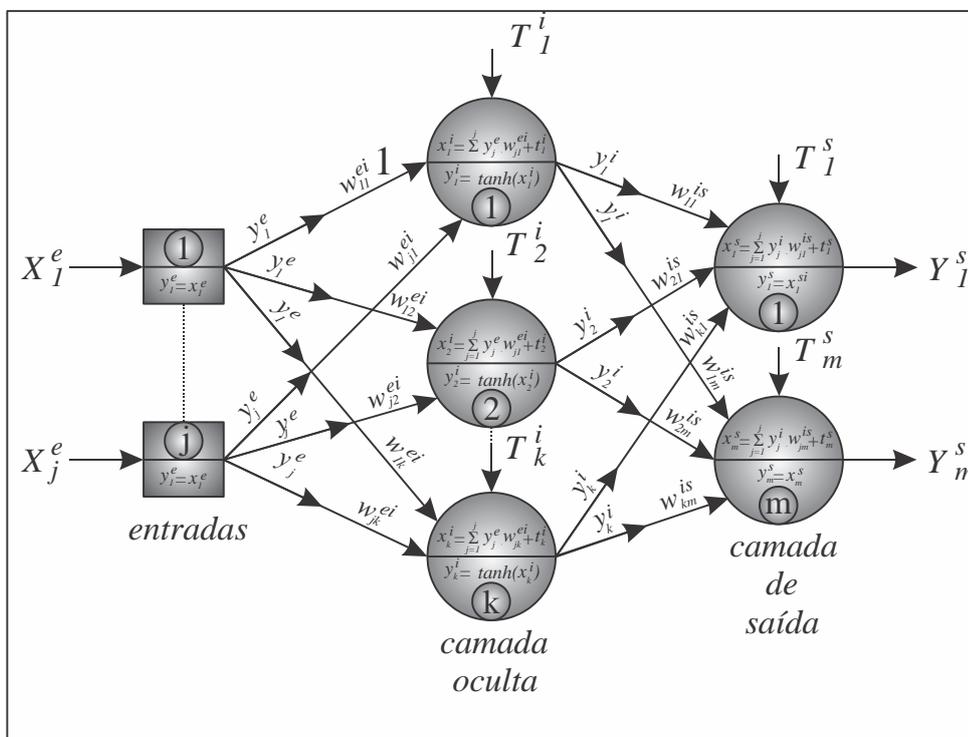


Figura B.1 – Rede Neural Artificial de Múltiplas Camadas

A nomenclatura utilizada neste apêndice encontra-se descrita abaixo:

e – entrada

i – camada intermediária

s – camada de saída

j – j -ésimo elemento de entrada e

k – k -ésimo neurônio da camada intermediária i

m – m -ésimo neurônio da camada de saída s

X_j^e - j -ésimo elemento de entrada e

Y_j^e - j -ésimo elemento de entrada e

$$Y_j^e = X_j^e \quad (\text{B.1})$$

$$X_k^i = \sum_j W_{jk}^{ei} Y_j^e + T_k^i \quad (\text{B.2})$$

$$Y_k^i = \frac{1 - e^{-\beta_k^i X_k^i}}{1 + e^{-\beta_k^i X_k^i}} \quad (\text{B.3})$$

$$X_m^s = \sum_k W_{km}^{is} Y_k^i \quad (\text{B.4})$$

$$Y_m^s = X_m^s = \sum_k W_{km}^{is} Y_k^i \quad (\text{B.5})$$

$$Eq_{(t)} = \sum_m (E_m^s)^2 \quad (\text{B.6})$$

$$Id_{(t)} = \frac{1}{2} Eq_t \quad (\text{B.7})$$

$$E_{m,t}^s = D_{m(t)}^s - Y_{m(t)}^s \quad (\text{B.8})$$

t – tempo

$Id_{(t)}$ – índice de desempenho no instante t

$Eq_{(t)}$ – erro quadrático no instante de tempo t

$E_{m,t}^s$ – erro no m-ésimo neurônio da camada s no instante de tempo t

$D_{m,t}^s$ – m-ésima saída desejada da camada s no instante de tempo t

$Y_{m(t)}^s$ – m-ésima saída calculada da camada s no instante de tempo t

Considerando o gradiente do índice de desempenho com o método do gradiente descendente, o algoritmo de propagação retroativa para o ajuste dos pesos das camadas de saída é dado por:

$$W_{km}^{is}(t+\Delta t) = W_{km}^{is}(t) + \mu(-\nabla I_d(W_{km}^{is}))_{(t)} \quad (\text{B.9})$$

$$\nabla I_d(W_{km}^{is}) = \frac{\partial I_d(W_{km}^{is})}{\partial W_{km}^{is}} = -E_m^s \frac{\partial Y_{km}^s}{\partial W_{km}^{is}} \quad (\text{B.10})$$

$$\frac{\partial I_d(W_{km}^{is})}{\partial W_{km}^{is}}_{(t)} = \frac{\Delta W_{km}^{is}(t)}{\mu} \quad (\text{B.11})$$

Onde:

μ – coeficiente de aprendizado

$$\frac{\partial Y_m^s}{\partial W_{km}^{is}} = Y_k^i \quad (\text{B.12})$$

$$\frac{\partial Y_m^s}{\partial Y_k^i} = W_{km}^{is} \quad (\text{B.13})$$

$$W_{km}^{is}(t+\Delta t) = W_{km}^{is}(t) + \mu(E_m^s \cdot Y_k^i)_{(t)} \quad (\text{B.14})$$

$$\Delta W_{km}^{is}(t) = \mu(E_m^s \cdot Y_k^i)_{(t)} \quad (\text{B.15})$$

Substituindo B.15 em B.11 encontramos a Equação B.16 que será usada na montagem da matriz Jacobiana, Apêndice C.

$$\frac{\partial I_d(W_{km}^{is})}{\partial W_{km}^{is}} = (E_m^s \cdot Y_k^i)_{(t)} \quad (\text{B.16})$$

De maneira análoga ao que foi feito para a camada de saída, podemos utilizar o gradiente do índice de desempenho com o método do gradiente descendente, para a camada intermediária e determinar os seguintes termos:

$$W_{jk(t+\Delta t)}^{ei} = W_{jk(t)}^{ei} + \mu(-\nabla I_d(W_{jk}^{ei}))_{(t)} \quad (\text{B.17})$$

$$\nabla I_d(W_{jk}^{ei}) = \frac{\partial I_d(W_{jk}^{ei})}{\partial W_{jk}^{ei}} = -E_m^s \frac{\partial Y_m^s}{\partial W_{jk}^{ei}} \quad (\text{B.18})$$

$$\frac{\partial I_d(W_{jk}^{ei})}{\partial (W_{jk}^{ei})_{(t)}} = \frac{\Delta(W_{jk}^{ei})}{\mu} \quad (\text{B.19})$$

$$\beta_{k(t+\Delta t)}^i = \beta_{k(t)}^i + \mu(-\nabla I_d(\beta_k^i))_{(t)} \quad (\text{B.20})$$

$$\nabla I(\beta_k^i) = \frac{\partial I(\beta_k^i)}{\partial \beta_k^i} = -E_m^s \frac{\partial Y_m^s}{\partial \beta_k^i} \quad (\text{B.21})$$

$$\frac{\partial I(\beta_k^i)}{\partial \beta_k^i}_{(t)} = \frac{\Delta \beta_{k(t)}^i}{\mu} \quad (\text{B.22})$$

$$T_{k(t+\Delta t)}^i = T_{k(t)}^i + \mu(-\nabla I_d(T_k^i))_{(t)} \quad (\text{B.23})$$

$$\nabla(T_k^i) = \frac{\partial I(T_k^i)}{\partial T_k^i} = -E_m^s \frac{\partial Y_m^s}{\partial T_k^i} \quad (\text{B.24})$$

$$\frac{\partial I_d(T_k^i)}{\partial T_k^i}_{(t)} = \frac{\Delta T_{k(t)}^i}{\mu} \quad (\text{B.25})$$

Usando a regra da cadeia para a Equação B.18 encontramos a Equação B.25:

$$\nabla I_d(W_{jk}^{ei}) = -E_m^s \frac{\partial Y_m^s}{\partial Y_k^i} \frac{\partial Y_k^i}{\partial X_k^i} \frac{\partial X_k^i}{\partial W_{jk}^{ei}} \quad (\text{B.26})$$

$$\frac{\partial X_k^i}{\partial W_{jk}^{ei}} = X_j^e \quad (\text{B.27})$$

$$\frac{\partial Y_k^i}{\partial X_k^i} = \frac{\beta_k^i}{2} [1 - (Y_k^i)^2] \quad (\text{B.28})$$

Substituindo as equações B.13, B.27 e B.28 em B.26 temos a Equação B.29.

$$\nabla I(W_{jk}^{ei}) = -E_m^s W_{km}^{is} \frac{\beta_k^i}{2} [1 - (Y_k^i)^2] X_j^e \quad (\text{B.29})$$

Usando a regra da cadeia para a Equação B.21 encontramos a Equação B.30:

$$\nabla I_d(\beta_k^i) = -E_m^s \frac{\partial Y_m^s}{\partial Y_k^i} \frac{\partial Y_k^i}{\partial \beta_k^i} \quad (\text{B.30})$$

$$\frac{\partial Y_k^i}{\partial \beta_k^i} = \frac{X_k^i}{2} [1 - (Y_k^i)^2] \quad (\text{B.31})$$

Substituindo as equações B.13 e B.31 em B.30 temos a Equação B.32.

$$\nabla I_d(\beta_k^i) = -E_m^s W_{km}^{is} \frac{X_k^i}{2} [1 - (Y_k^i)^2] \quad (\text{B.32})$$

Usando a regra da cadeia para a Equação B.24 temos a Equação B.33.

$$\nabla I_d(T_k^i) = -E_m^s \frac{\partial Y_m^s}{\partial Y_k^i} \frac{\partial Y_k^i}{\partial X_k^i} \frac{\partial X_k^i}{\partial T_k^i} \quad (\text{B.33})$$

$$\frac{\partial X_k^i}{\partial T_k^i} = 1 \quad (\text{B.34})$$

Substituindo as equações B.13, B.28 e B.34 em B.33 temos a Equação B.35.

$$\nabla I_d(T_k^i) = -E_m^s W_{km}^{is} \frac{\beta_k^i}{2} [1 - (Y_k^i)^2] \quad (\text{B.35})$$

E substituindo a Equação B.29 em B.17 encontramos a Equação B.36.

$$W_{jk(t+\Delta t)}^{ei} = W_{jk(t)}^{ei} + \mu \left(E_m^s W_{km}^{is} \frac{\beta_k^i}{2} [1 - (Y_k^i)^2] X_j^e \right)_{(t)} \quad (\text{B.36})$$

$$\Delta W_{jk(t)}^{ei} = \mu \left(E_m^s W_{km}^{is} \frac{\beta_k^i}{2} [1 - (Y_k^i)^2] X_j^e \right)_{(t)} \quad (\text{B.37})$$

Substituindo B.37 em B.19 temos a Equação B.38.

$$\frac{\partial I_d(W_{jk}^{ei})}{\partial W_{jk}^{ei}}_{(t)} = \left(E_m^s W_{km}^{is} \frac{\beta_k^i}{2} [1 - (Y_k^i)^2] X_j^e \right)_{(t)} \quad (\text{B.38})$$

E substituindo a Equação B.32 em B.20 encontramos a Equação B.39.

$$\beta_{k(t+\Delta t)}^i = \beta_{k(t)}^i + \mu \left(E_m^s W_{km}^{is} \frac{X_k^i}{2} [1 - (Y_k^i)^2] \right)_{(t)} \quad (\text{B.39})$$

$$\Delta \beta_{k(t)}^i = \mu \left(E_m^s W_{km}^{is} \frac{X_k^i}{2} [1 - (Y_k^i)^2] \right)_{(t)} \quad (\text{B.40})$$

Substituindo B.40 em B.22 temos a Equação B.41.

$$\frac{\partial I_d(\beta_k^i)}{\partial \beta_k^i}_{(t)} = \left(E_m^s W_{km}^{is} \frac{X_k^i}{2} [1 - (Y_k^i)^2] \right)_{(t)} \quad (\text{B.41})$$

E substituindo a Equação B.35 em B.23 encontramos a Equação B.38.

$$T_{k(t+\Delta t)}^i = T_{k(t)}^i + \mu \left(E_m^s W_{km}^{is} \frac{\beta_k^i}{2} [1 - (Y_k^i)^2] \right)_{(t)} \quad (\text{B.42})$$

$$\Delta T_{k(t)}^i = \mu \left(E_m^s W_{km}^{is} \frac{\beta_k^i}{2} [1 - (Y_k^i)^2] \right)_{(t)} \quad (\text{B.43})$$

Substituindo B.43 em B.25 temos a Equação B.40.

$$\frac{\partial I_d(T_k^i)}{\partial T_k^i}_{(t)} = \left(E_m^s W_{km}^{is} \frac{\beta_k^i}{2} [1 - (Y_k^i)^2] \right)_{(t)} \quad (\text{B.44})$$

ANEXO B – MÉTODO DE LEVENBERG-MARQUARDT APLICADO AS REDES NEURAIS ARTIFICIAIS - RNA

O objetivo de criar este apêndice foi motivado pela carência de publicações sobre o Método de LM voltado diretamente as RNA. Neste sentido será apresentado um breve desenvolvimento desta técnica e o tratamento matemático pertinente.

Considere o problema de minimizar o erro de uma função E , consistindo da soma quadrática destas funções (MEDEIROS, NETO, & MARTÍNEZ, 2008). Este problema pode ser escrito como:

Onde:

$$\min(E_t^q) = \frac{1}{2} \sum_t^n [E_{m,t}^s]^2 \quad (C.1)$$

$$E_{m,t}^s = D_{m(t)}^s - Y_{m(t)}^s \quad (C.2)$$

Onde:

$E_{m,t}^s$ – erro no m-ésimo neurônio da camada s no instante de tempo t

$D_{m,t}^s$ – m-ésima saída desejada da camada s no instante de tempo t

$Y_{m(t)}^s$ – m-ésima saída calculada da camada s no instante de tempo t

De posse do valor do erro $E_{m,t}^s$ será aplicado o método do gradiente descendente e com retropropagação do erro o que irá permitir a determinação dos *gradientes* relativo aos seus respectivos pesos. Sem distinção entre os pesos entre as camadas de entrada e intermediária e entre as camadas intermediária e a camada de saída, temos:

$$\Delta W_t = W_{t+1} - W_t \quad (C.3)$$

O Método de LM é uma variação do Método de Newton descrito abaixo:

$$\Delta W_t = [H(W)]^{-1} \cdot J(W) \cdot E^q \quad (C.4)$$

Onde:

ΔW_t – gradientes (*incremento/decremento*) relativos aos seus respectivos pesos.

$J(W)$ – Matriz Jacobiana.

$H(W)$ – Matriz Hessiana.

E^q – Erro Quadrático.

Onde:

$$J(W) = \nabla Id(W) = \begin{bmatrix} \frac{\partial I_d(W_{1,1}^{ei})}{\partial W_{1,1}^{ei}} & \frac{\partial I_d(W_{1,2}^{ei})}{\partial W_{1,2}^{ei}} & \dots & \frac{\partial I_d(W_{1,j}^{ei})}{\partial W_{1,j}^{ei}} \\ \frac{\partial I_d(W_{1,1}^{is})}{\partial W_{1,1}^{is}} & \frac{\partial I_d(W_{1,2}^{is})}{\partial W_{1,2}^{is}} & \dots & \frac{\partial I_d(W_{1,j}^{is})}{\partial W_{1,j}^{is}} \end{bmatrix} \quad (C.5)$$

Os parâmetros que compõe a matriz Jacobiana podem ser visto no Apêndice B, equações B.16 e B.38.

A matriz Hessiana envolve derivadas de segunda ordem, o que implica em um

custo computacional elevado. Algumas técnicas alternativas foram desenvolvidas com o objetivo de sanar essas dificuldades. É o caso do método de Gauss-Newton, que propõe uma aproximação para a matriz Hessiana como o produto da transposta da matriz Jacobiana por ela própria, Equação C.7 (MEDEIROS, NETO, & MARTÍNEZ, 2008).

$$H(W) = \nabla^2 Id(W) = \begin{bmatrix} \frac{\partial^2 I_d(W_{1,1}^{ei})}{\partial W_{1,1}^{ei^2}} & \frac{\partial^2 I_d(W_{1,2}^{ei})}{\partial W_{1,2}^{ei^2}} \dots & \frac{\partial^2 I_d(W_{1,j}^{ei})}{\partial W_{1,j}^{ei^2}} \\ \frac{\partial^2 I_d(W_{1,1}^{is})}{W_{1,1}^{is^2}} & \frac{\partial^2 I_d(W_{1,2}^{is})}{\partial W_{1,2}^{is^2}} \dots & \frac{\partial^2 I_d(W_{1,j}^{is})}{\partial W_{1,j}^{is^2}} \end{bmatrix} \quad (C.6)$$

Onde:

$$H(W) \cong J^T(W).J(W) \quad (C.7)$$

Entretanto, persiste ainda algumas dificuldades para a aplicação do Método Gauss-Newton como mostrado acima. Dentre elas tem-se como imperativa as seguintes situações (MEDEIROS, NETO, & MARTÍNEZ, 2008):

- Quando os valores de W encontram-se distante do valor ótimo esperado, o processo iterativo resultará dispendioso devido ao comprimento do passo ser pequeno, provocando uma lenta convergência do método.
- Para alguma aproximação de W, durante o processo iterativo, a aproximação da Matriz Hessiana pode tornar-se negativa o que invalida o método por não admitir a respectiva matriz inversa.

Para contornar esses impedimentos, Levenberg e em seguida Marquardt propuseram a seguinte alternativa:

$$\Delta W_t = [J^T(W).J(W) + \lambda.I]^{-1}.J(W).E^q \quad (C.8)$$

Onde:

I – Matriz Identidade de mesma ordem da aproximação da Matriz Hessiana.

λ – Parâmetro de Levenberg-Marquardt.

O parâmetro de Levenberg-Marquardt usado neste foi proporcional ao erro quadrático, Equação C.9

$$\lambda = \sum_t^n [D_{m(t)}^s - Y_{m(t)}^s]^2 \quad (\text{C.9})$$

O parâmetro de LM será um valor sempre positivo e de alguma maneira proporcional ao erro quadrático. Isto, promoverá um aumento do passo em direção a convergência e conseqüentemente a aceleração do processo de convergência.

Por outro lado, este parâmetro multiplicado pela matriz identidade $\lambda.I$, somado a aproximação da matriz Hessiana $J^T(W).J(W)$ cumprirá o papel de garantir que o resultado desta soma $[J^T(W).J(W) + \lambda.I]$, será sempre positiva e conseqüentemente admitirá o cálculo da sua inversa.

Os valores de ΔW_{t-1} calculado a cada iteração será propagado à frente *forward* a fim de determinar os novos valores dos pesos W_t . Ao término deste processo o algoritmo de retropropagação (backpropagation) realizará o cálculo dos novos valores de ΔW_t que serão usados na montagem da nova matriz Jacobiana. Essas etapas repetidas até que o erro quadrático atenda as exigências de projeto.

A eficiência do Método de LM despertou na comunidade científica um grande interesse sobre a determinação de parâmetro λ . Atualmente existe uma linha de pesquisa em que inúmeros estudos são realizados com o objetivo de propor melhores técnicas de ajuste deste parâmetro.