



**UNIVERSIDADE FEDERAL DA PARAÍBA**  
**CENTRO DE TECNOLOGIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA**

**EFICIÊNCIA ENERGÉTICA EM SISTEMAS  
PRESSURIZADOS DE DISTRIBUIÇÃO DE ÁGUA COM O  
USO DE REDES NEURAS ARTIFICIAIS**

**Laís Régis Salvino**

**João Pessoa**  
**2018**

**LAÍS RÉGIS SALVINO**

**EFICIÊNCIA ENERGÉTICA EM SISTEMAS  
PRESSURIZADOS DE DISTRIBUIÇÃO DE ÁGUA COM O  
USO DE REDES NEURAS ARTIFICIAIS**

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

Orientador: Prof. Dr. Heber Pimentel  
Gomes

Coorientador: Prof. Dr. Saulo de Tarso  
Marques Bezerra

**João Pessoa  
2018**

**EFICIÊNCIA ENERGÉTICA EM SISTEMAS  
PRESSURIZADOS DE DISTRIBUIÇÃO DE ÁGUA COM O  
USO DE REDES NEURAIS ARTIFICIAIS**

*por*

**LAÍS RÉGIS SALVINO**

*Tese aprovada em 09 de fevereiro de 2018*

Prof. Dr. HEBER PIMENTEL GOMES  
Orientador - UFPB

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

Prof. Dr. CÍCERO DA ROCHA SOUTO  
Examinador Interno - UFPB

Prof. Dr. ARIEL ARES DO NASCIMENTO  
Examinadora Externa - IFPB

Prof. Dr. JOSÉ KLEBER COSTA DE OLIVEIRA  
Examinador Externo - IFRN

Pro. Dr. CRISTIANO DAS NEVES ALMEIDA  
Examinador Externo – UFPB

*Dedico este trabalho aos meus pais,  
meu irmão, meu marido Moisés Salvino e a todos os  
familiares, amigos e professores que com, muito carinho e apoio,  
não mediram esforços para que eu chegasse a essa etapa da minha vida.*

## AGRADECIMENTOS

Primeiramente, a Deus, por guiar meus passos durante toda a minha vida, incluindo esta jornada acadêmica.

Aos meus queridos pais Luís Régis Neto e Maricélia dos Santos Pereira, por toda dedicação, esforço e compreensão.

Ao meu estimado irmão Luiz Henrique Pereira Régis por todos os conselhos e incentivos.

Ao meu tão amado marido Moisés Menezes Salvino por toda dedicação, amor e motivação que contribuíram para o meu crescimento pessoal e profissional.

Ao meu orientador, professor doutor Heber Pimentel Gomes, pela orientação, dedicação e oportunidade para realizar este trabalho.

Ao meu coorientador, professor doutor Saulo de Tarso Marques Bezerra, pelas sugestões e orientações que contribuíram para o enriquecimento científico desta tese.

Aos professores do Departamento de Engenharia Mecânica da UFPB, em especial ao professor doutor Simplício Arnaud da Silva pelos comentários e sugestões no decorrer do curso.

Aos amigos do Laboratório de Eficiência Energética e Hidráulica em Saneamento (LENHS), José Kléber, Emânuel Guerra, Renato de Souza, Arthur Diniz e Geraldo Moura.

As minhas amigas tão estimadas, Anne Monteiro e Kamilla Henrique, por todos os auxílios e incentivos.

Ao meu amigo tão querido, João Vinícius por todo apoio e encorajamento.

As minhas primas que considero como irmãs, Amanda Santos Lima da Cunha e Alessandra Santos Lima da Cunha por todo apoio.

Aos meus sogros Antônio Salvino Pereira e Maria de Fátima Menezes Salvino por todos incentivos.

A todas as pessoas que de alguma forma contribuíram para a realização deste trabalho.

## RESUMO

Com o objetivo de desenvolver novas tecnologias para melhorar a operação de sistemas de abastecimento de água, visando a redução do desperdício de água e energia, foi realizado nesta tese um estudo experimental utilizando automação e controle via Redes Neurais Artificiais (RNA) com arquitetura recorrente. A técnica de controle escolhida foi aplicada para controlar as pressões de serviço em uma bancada experimental que simula um sistema de abastecimento capaz de fornecer água para duas regiões com topografia diferenciadas. Com o intuito de analisar o desempenho do sistema sob ação do controlador, foram realizados testes experimentais simulando uma curva de consumo para as duas regiões abastecidas, introduzindo perturbações externas e alterando o valor de referência. Além disso, tendo em vista a utilização do sistema de controle para reduzir o consumo energético dos sistemas de impulsão da bancada, foi realizada a otimização operacional, a partir da redução do Consumo Específico de Energia (CE), durante o controle das pressões de serviço. Dessa forma, foi garantida a redução do gasto energético do sistema ao mesmo tempo em que foi realizado o controle das pressões.

**Palavras-Chaves:** Eficiência energética. Redes neurais artificiais. Controle de pressão.

## **ABSTRACT**

In order to develop new technologies to improve the operation of water supply systems aiming to reduce water and energy waste, it was carried out in this thesis an experimental study using automation and control via Artificial Neural Networks (ANN) with recurrent architecture. The control technique chosen was applied to control the service pressures in an experimental bench that simulates a water supply system capable of supplying water to two regions with different topography. In order to analyze the performance of the system under the controller action, experimental tests were performed simulating a consumption curve for the two supplied regions, introducing external perturbations and changing the setpoint. In addition, considering the use of the control system to reduce the energy consumption of the pumping systems of the experimental bench, the operational optimization was carried out, by reducing the Specific Energy Consumption (SEC) during the control of the service pressures. In this way, it was guaranteed the reduction of the energy consumption of the system at the same time as the pressure control was performed.

**Keywords:** Energy efficiency. Artificial neural networks. Pressure control.

## LISTA DE FIGURAS

Figura 1.1 Representação de um sistema de impulsão único na origem. (SALVINO <i>et al.</i> , 2014).....	2
Figura 1.2 Representação de um SAA operado por um CMB e uma VRP. (SALVINO <i>et al.</i> , 2014). ...	3
Figura 1.3 Representação de um SAA operado por um CMB, um BST e uma VRP. (SALVINO <i>et al.</i> , 2014). .....	3
Figura 3.1 Representação de um neurônio biológico. (LOPES, 2004). .....	13
Figura 3.2 Exemplo de uma rede <i>feedforward</i> de múltiplas camadas. ....	18
Figura 3.3 Exemplo de uma rede com arquitetura recorrente. ....	19
Figura 3.4 Exemplo de uma rede do tipo PMC com arquitetura recorrente. ....	20
Figura 3.5 Exemplo de uma rede de Kohonem com arquitetura em estrutura reticulada. ....	20
Figura 4.1 Bancada experimental .....	24
Figura 4.2 Imagem ilustrativa da bancada experimental.....	25
Figura 4.3 Visão geral da bancada de testes. ....	28
Figura 4.4 Inversores de frequência utilizados para acionar os sistemas de impulsão. ....	29
Figura 4.5 <i>Interface</i> de aquisição de dados semelhante a utilizada na bancada experimental. ....	30
Figura 4.6 TC's instalados na bancada experimental.....	31
Figura 4.7 Esquema ilustrativo da bancada de testes. ....	32
Figura 4.8 Exemplo de uma rede neural com alimentação retroativa. ....	33
Figura 4.9 Tela principal ( <i>Front Painel</i> ) do LabVIEW®. ....	37
Figura 4.10 Tela do LabVIEW® aonde o controlador é acionado.....	38
Figura 4.11 Configuração da RNA utilizada como sistema de controle na bancada experimental. ....	38
Figura 4.12 Diagrama de blocos do sistema. ....	41
Figura 4.13 Configuração da RNA utilizada para controlar as pressões e minimizar o CE. ....	42
Figura 5.1 Desempenho da variável pressão sem ação do controlador no Ensaio Tipo 1.a. ....	45
Figura 5.2 Comportamento dos atuadores da bancada no Ensaio Tipo 1.a. ....	45
Figura 5.3 Desempenho da variável pressão sob ação do controlador no Ensaio Tipo 1.b. ....	46
Figura 5.4 Comportamento dos atuadores da bancada no Ensaio Tipo 1.b.....	47
Figura 5.5 Desempenho da variável pressão sob ação do controlador no Ensaio Tipo 1.c. ....	48
Figura 5.6 Comportamento dos atuadores da bancada no Ensaio Tipo 1.c.....	49
Figura 5.7 Desempenho da variável pressão sob ação do controlador no Ensaio Tipo 2.a. ....	51
Figura 5.8 Comportamento dos atuadores da bancada no Ensaio Tipo 2.a. ....	52
Figura 5.9 Desempenho da variável pressão sob ação do controlador no Ensaio Tipo 2.b. ....	53
Figura 5.10 Comportamento dos atuadores da bancada no Ensaio Tipo 2.b.....	54
Figura 5.11 Desempenho da variável pressão sob ação do controlador no Ensaio Tipo 2.c. ....	55
Figura 5.12 Comportamento dos atuadores da bancada no Ensaio Tipo 2.c.....	55
Figura 5.13 Desempenho da variável pressão sob ação do controlador no Ensaio Tipo 2.d. ....	56
Figura 5.14 Comportamento dos atuadores da bancada no Ensaio Tipo 2.d.....	57
Figura 5.15 Desempenho da variável pressão sob ação do controlador no Ensaio Tipo 3. ....	58
Figura 5.16 Comportamento dos atuadores da bancada no Ensaio Tipo 3.....	59
Figura 5.17 Monitoramento dos parâmetros Erro da Pressão (nas zonas Baixa e Alta) e Índice de Desempenho da RNA.....	60

## LISTA DE TABELAS

Tabela 3.1 Descrição dos elementos que compõem um neurônio artificial. ....	14
Tabela 3.2 Exemplos de funções de ativação parcialmente diferenciáveis. ....	15
Tabela 3.3 Exemplos de funções de ativação totalmente diferenciáveis. ....	16
Tabela 4.1 Especificações técnicas do motor. ....	26
Tabela 4.2 Especificações técnicas da bomba. ....	26
Tabela 4.3 Especificações técnicas do <i>booster</i> . ....	26
Tabela 4.4 Especificações técnicas dos transdutores de pressão. ....	27
Tabela 4.5 Especificações técnicas dos medidores de vazão. ....	27
Tabela 4.6 Especificações técnicas das válvulas proporcionais. ....	28
Tabela 4.7 Especificações técnicas dos inversores de frequência. ....	29
Tabela 4.8 Especificações técnicas das placas de aquisição de dados. ....	30
Tabela 4.9 Especificações técnicas dos transformadores de corrente. ....	31
Tabela 5.1 Principais características do sistema na demanda máxima do Ensaio Tipo 1. ....	49
Tabela 5.2 Principais características do sistema na demanda mínima do Ensaio Tipo 1. ....	50
Tabela 5.3 Parâmetros de controle calculados do ensaio Tipo 3. ....	58

## LISTA DE ABREVIATURAS E SIGLAS

<b>AC</b>	Abreviação do inglês <i>Alternating Current</i> [= Corrente Alternada]
<b>BST</b>	Abreviação do inglês <i>Booster</i> [= Impulsionador]
<b>CE</b>	Consumo Específico de Energia Elétrica
<b>CMB</b>	Conjunto Motor Bomba
<b>CV</b>	Abreviação do inglês <i>Control Valve</i> [= Válvula de controle]
<b>DC</b>	Abreviação do inglês <i>Direct Current</i> [= Corrente Direta]
<b>ed.</b>	Edição
<b>et al.</b>	Abreviação da locução latina <i>et alii</i> [= e outros]
<b>ETA</b>	Estação de Tratamento de Água
<b>FT</b>	Abreviação do inglês <i>Flux Transducer</i> [= Transdutor de vazão]
<b>IEEE</b>	Abreviação do inglês <i>Institute of Electrical and Electronics Engineers</i> [= Instituto de Engenheiros Eletricistas e Eletrônicos]
<b>IP</b>	Grau de proteção de motores elétricos
<b>ITAE</b>	Abreviação do inglês <i>Integral of Time-Weighted Absolute Error</i>
<b>K</b>	Elemento da Tabela Periódica [Diz-se Potássio.]
<b>LabVIEW®</b>	Abreviação do inglês <i>Laboratory Virtual Instrument Engineering Workbench</i>
<b>LENHS</b>	Laboratório de Eficiência Energética e Hidráulica em Saneamento
<b>LQG</b>	Linear Quadrático de Gauss
<b>MQR</b>	Mínimos Quadrados Recursivos
<b>NI</b>	Abreviação do inglês <i>National Instruments</i>
<b>N<sub>a</sub></b>	Elemento da Tabela Periódica [Diz-se Sódio.]
<b>PI</b>	Proporcional-Integral [Diz-se de controlador.]
<b>PID</b>	Proporcional-Integral-Derivativo [Diz-se de controlador.]
<b>PPGEM</b>	Programa de Pós-Graduação em Engenharia Mecânica
<b>PT</b>	Abreviação do inglês <i>Pressure Transducer</i> [= Transdutor de pressão]
<b>RAM</b>	Abreviação do inglês <i>Random Access Memory</i> [= Memória de acesso aleatório]
<b>RD</b>	Ramal de Descarga
<b>RNA</b>	Rede Neural Artificial
<b>SAA</b>	Sistema de Abastecimento de Água
<b>TC</b>	Transformador de Corrente
<b>UFPB</b>	Universidade Federal da Paraíba

<b>UFRN</b>	Universidade Federal do Rio Grande do Norte
<b>v.</b>	veja; volume.
<b>VMG</b>	Variância Mínima Generalizado [Diz-se de controlador.]
<b>VRP</b>	Válvula Redutora de Pressão
<b>USA</b>	Abreviação do inglês <i>United States of America</i> [v. EUA]
<b>ZA</b>	Zona Alta
<b>ZB</b>	Zona Baixa

## LISTA DE SÍMBOLOS

<b>A</b>	Ampére
<b>°C</b>	Celsius
<b><math>c_{final}</math></b>	Valor de referência
<b><math>c_{max}</math></b>	Valor máximo obtido no instante de pico
<b>cv</b>	Cavalo-vapor
<b>E</b>	Erro
<b><math>f(.)</math></b>	Função de ativação da rede neural artificial
<b>GB</b>	gigabyte
<b>GHz</b>	gigahertz
<b>h</b>	hora
<b><math>H_{\infty}</math></b>	Controlador H Infinito
<b>Hz</b>	Hertz
<b><math>I</math></b>	Corrente
<b><math>I_D</math></b>	Índice de desempenho
<b>kWh</b>	Quilowatt-hora
<b>l</b>	litro
<b>mA</b>	miliampére
<b>mca</b>	Metro de coluna de água
<b><math>\mu S</math></b>	Microsegundo
<b>mm</b>	milímetro
<b>ms</b>	milisegundo
<b><math>M_p</math></b>	Valor de sobressinal
<b><math>m^3</math></b>	Metro cúbico
<b><math>m^3/h</math></b>	Metro cúbico por hora
<b>ns</b>	nanosegundos
<b>rpm</b>	rotações por minuto
<b>tgh</b>	Tangente hiperbólica
<b><math>P_e</math></b>	Potência elétrica
<b>u</b>	Potencial de ativação de uma rede neural artificial, Sinal de controle
<b>V</b>	Tensão
<b><math>V_{ol}</math></b>	Volume bombeado

$W_I$	Matriz de pesos sinápticos entre a camada de entrada e a camada intermediária
$W_S$	Matriz de pesos sinápticos entre a camada de entrada e a camada de saída
$x$	Sinal de entrada
$y$	Sinal de saída
$y_R$	Valor (resposta) real
$y_{ref}$	Valor de referência
$\mu$	Taxa de aprendizagem de uma rede neural artificial
$\Sigma$	Combinador linear de uma rede neural artificial
$\beta$	Limiar de ativação (bias) de uma rede neural artificial
$\phi$	Parâmetro da função de ativação de uma rede neural artificial

## SUMÁRIO

CAPÍTULO 1 .....	1
1.1 Introdução .....	1
1.2 Objetivo Geral.....	5
1.3 Objetivos Específicos: .....	5
CAPÍTULO 2 .....	6
2.1 Revisão Bibliográfica.....	6
CAPÍTULO 3 .....	12
3.1 Conceitos Iniciais.....	12
3.2 Arquitetura das Redes Neurais Artificiais .....	17
3.3 Processos de Treinamento.....	21
CAPÍTULO 4 .....	24
4.1 Descrição da Bancada Experimental .....	24
4.2 Projeto do Controlador Neural Aplicado na Bancada Experimental .....	32
CAPÍTULO 5 .....	44
5.1 Ensaio Tipo 1 .....	44
5.2 Ensaio Tipo 2: .....	51
5.3 Ensaio Tipo 3:.....	57
6. CAPÍTULO 6 .....	61
7. REFERÊNCIAS .....	63
8. APÊNDICE .....	69

# CAPÍTULO 1

## INTRODUÇÃO E OBJETIVOS

### 1.1 Introdução

A água é um recurso natural de fundamental importância para a sobrevivência humana, por isso, os serviços de abastecimento de água fazem parte das necessidades básicas de uma população. Segundo Netto, Fernandez & Araújo (1998):

Define-se por sistema de abastecimento de água o conjunto de obras, equipamentos e serviços destinados ao abastecimento de água potável a uma comunidade para fins de consumo doméstico, serviços públicos, consumo industrial e outros usos. Essa água fornecida pelo sistema deverá ser, em quantidade suficiente e da melhor qualidade, do ponto de vista físico, químico e bacteriológico.

As principais partes que compõem um sistema de abastecimento de água (SAA) são: manancial, captação, estação elevatória, adutora, estação de tratamento de água (ETA), reservatório e rede de distribuição.

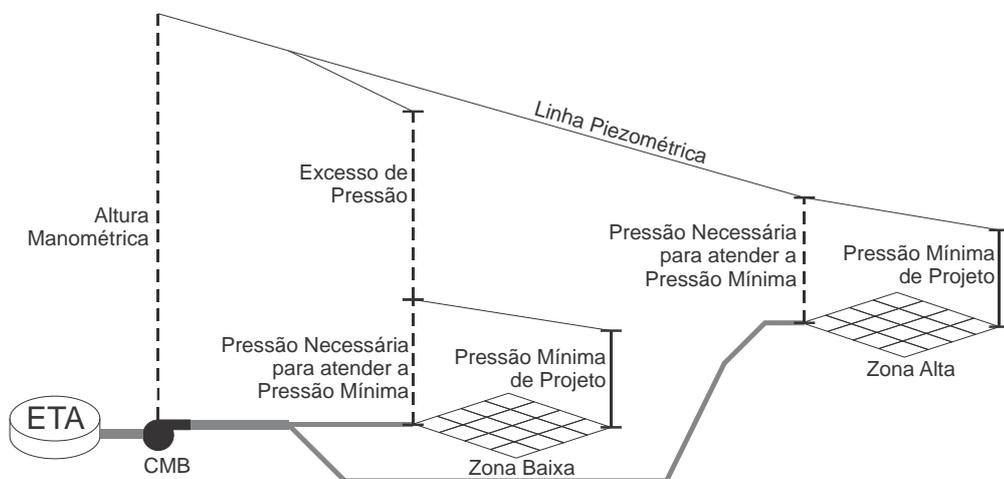
A água pressurizada pode ser conduzida na tubulação por gravidade e/ou impulsionada por uma estação elevatória. No primeiro caso, não se utiliza energia elétrica para impulsionar a água, entretanto, na segunda situação, se faz necessário dispor de sistema de impulsão composto por conjuntos motor bomba (CMB) e/ou *booster* (BST).

Geralmente, as bombas utilizadas são do tipo centrífuga, estas aceleram o fluido através da força centrífuga fornecida pelo giro do rotor, transformando a energia cinética internamente em energia de pressão, na saída do rotor, através da carcaça da bomba. O rotor é o elemento da bomba que tem a incumbência de transferir para o fluido o movimento de rotação, dessa forma, converte a energia mecânica em energia cinética. Estas bombas são acionadas por motores elétricos, cuja função é transformar energia elétrica em energia mecânica (TSUTIYA, 2006). Quando a bomba é instalada de modo intercalado na tubulação denomina-se *booster*, e tem como função aumentar a energia de pressão, contribuindo para o escoamento do fluido (MACINTYRE, 2013).

A operação de bombas e *boosters* gera um gasto energético elevado, fazendo com que os setores responsáveis pelo abastecimento de água contribuam, em média, com 2% a 3% da energia elétrica consumida em todo o mundo (JAMES & CAPELLA, 2002). No Brasil, esse consumo é de aproximadamente 12 milhões de MWh/ano, o que representa uma parcela de 2,26% do consumo total do país (SNIS, 2014). Desta parcela, cerca de 90% da energia é consumida por motores e conjuntos motor bombas (GONÇALVES, JORDÃO & JANUZZI, 2009).

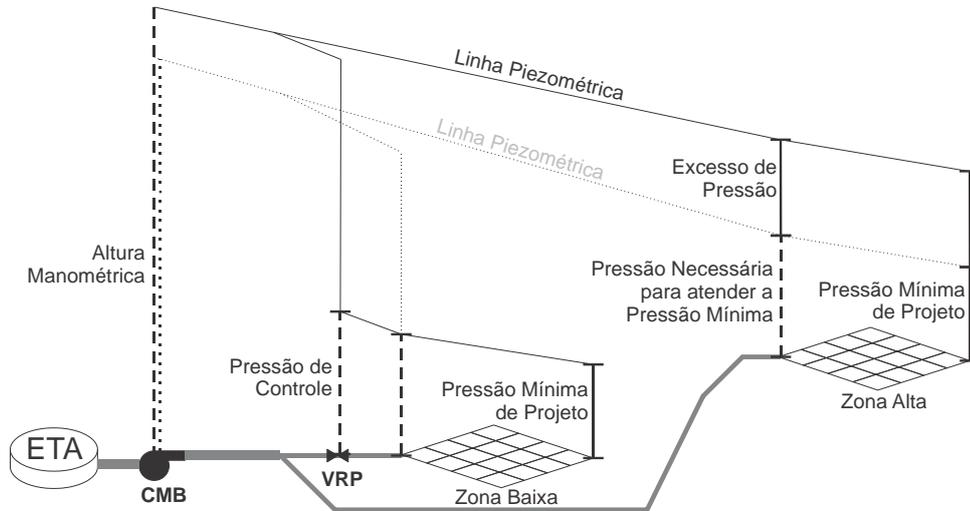
Os fatores que mais contribuem para o aumento do consumo energético dos sistemas de impulsão são: o uso de equipamentos superdimensionados e obsoletos; o dimensionamento inadequado das tubulações dos sistemas de distribuição de água; casos em que a região de consumo se encontra muito distante da estação elevatória; e, quando o setor de consumo está localizado em uma zona com topografia elevada. Nestas duas últimas situações, se faz necessário prever um acréscimo na altura manométrica do sistema de impulsão, a fim de garantir que toda rede atenda às pressões mínimas requeridas.

Na situação em que o abastecimento de água deve ser realizado para duas regiões com diferentes níveis topográficos é preciso aumentar a altura manométrica do sistema de bombeamento instalado a montante da região mais baixa, a fim de atender com a pressão requerida, a demanda na zona mais elevada. Considerando apenas a elevação da linha piezométrica, a zona com topografia mais baixa apresenta um excesso de pressão, ocasionando um aumento do volume de vazamentos (ver Figura 1.1).



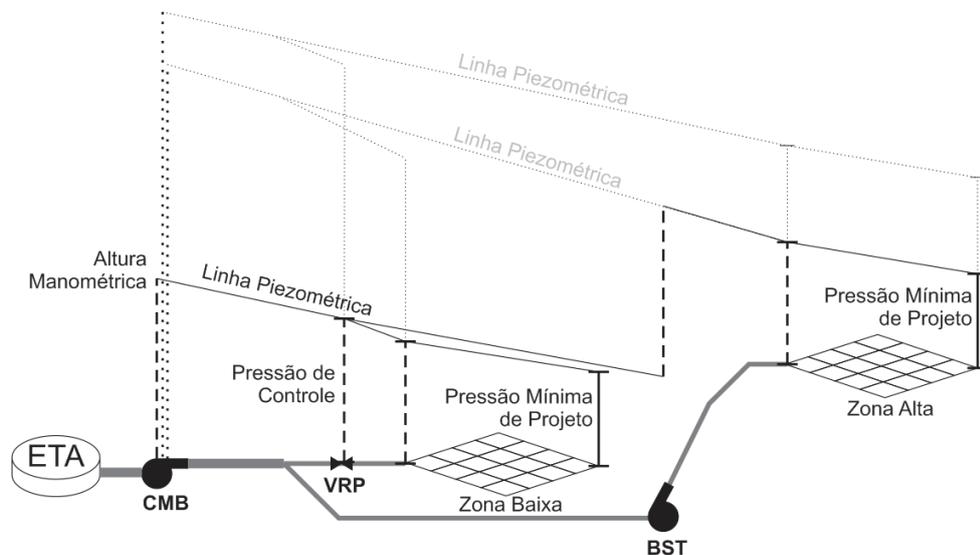
**Figura 2.1** Representação de um sistema de impulsão único na origem. (SALVINO *et al.*, 2014).

Portanto, torna-se comum a instalação de válvulas redutoras de pressão (VRPs) na entrada das zonas com pressões excessivas, no intuito de melhorar os serviços de abastecimento, conforme pode ser observado na Figura 1.2.



**Figura 2.2** Representação de um SAA operado por um CMB e uma VRP. (SALVINO *et al.*, 2014).

Além dessa alternativa, pode-se instalar um *booster* para aumentar a energia de pressão a montante da região mais alta, de modo a atender as zonas mais remotas ou com baixas pressões e, dessa forma, diminuir a altura manométrica de bombeamento na origem. Neste último caso, o sistema de impulsão fica caracterizado pela utilização de um conjunto motor bomba, um *booster* e uma válvula redutora de pressão (ver Figura 1.3).



**Figura 2.3** Representação de um SAA operado por um CMB, um BST e uma VRP. (SALVINO *et al.*, 2014).

Além do elevado gasto energético presente neste cenário de operação, também ocorre, em diversas situações de abastecimento, um significativo desperdício de energia elétrica quando o sistema de impulsão opera na sua máxima potência, nos horários em que a demanda exigida é mínima. Esta situação também ocasiona um excesso de pressão na rede de distribuição.

Uma solução que busca atingir a eficiência energética dos sistemas de abastecimento com esse tipo de configuração é o controle da pressão, a partir da automação. Um SAA pode ser automatizado para a simples supervisão dos parâmetros elétricos e hidráulicos do sistema; para a utilização de um controlador cuja tomada de decisão parta de uma intervenção do operador; ou ainda, para uma implementação mais robusta de um controle inteligente, no qual o sistema de abastecimento opera sem qualquer tipo de intervenção humana.

O controle da pressão tem como benefícios promover o aumento da vida útil das tubulações e acessórios, o aumento da confiabilidade do sistema, a redução dos transientes hidráulicos e a diminuição dos desperdícios de energia elétrica. Segundo Bezerra & Cheung (2013), para que um sistema de abastecimento possua um desempenho técnico e econômico satisfatório, se torna necessário realizar o controle de pressão. A uniformização da pressão na rede de distribuição, através deste controle, reduz a frequência de rupturas, o consumo de água excessivo induzido pela pressão e o volume perdido em vazamentos.

Diante do exposto, justifica-se o desenvolvimento de novas tecnologias aplicadas no gerenciamento e operação dos sistemas de impulsão. Este trabalho de tese visa à redução dos custos energéticos e do desperdício de água de sistemas de abastecimento, que atendem duas zonas de consumo com topografias distintas. Para isso, foi projetado e implementado um controlador inteligente, utilizando a técnica das Redes Neurais Artificiais (RNA), com o objetivo de controlar as pressões de uma bancada experimental, que simula um sistema de abastecimento com duas zonas de consumo com topografias diferenciadas. Este sistema se encontra no Laboratório de Eficiência Energética e Hidráulica em Saneamento (LENHS) da Universidade Federal da Paraíba (UFPB).

## 1.2 Objetivo Geral

Esta tese teve como principal objetivo desenvolver um sistema de controle inteligente, utilizando a técnica de Redes Neurais Artificiais, para operar uma rede pressurizada de distribuição de água com duas regiões de consumo com topografias distintas. Com a implementação do sistema de controle espera-se minimizar o custo de energia do bombeamento para diversos cenários operacionais.

## 1.3 Objetivos Específicos:

- Elaboração de um sistema supervisorio, utilizando a linguagem de programação *Laboratory Virtual Instrument Engineering Workbench* - LabVIEW<sup>®</sup>, para monitoramento em tempo real e análise dos parâmetros hidráulicos e elétricos da bancada experimental;
- Desenvolvimento de um sistema de controle inteligente, utilizando a técnica de Redes Neurais Artificiais, para obter o controle da pressão em duas regiões de consumo distintas, da forma mais eficiente energeticamente, tendo como parâmetro o Consumo Específico de Energia Elétrica (CE);
- Avaliação do desempenho do sistema de controle projetado diante de três cenários de operação distintos: simulação da alteração da demanda, perturbações na planta e alteração do valor de referência.

## CAPÍTULO 2

### 2.1 Revisão Bibliográfica

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

Para se automatizar um determinado sistema, torna-se necessário projetar um controlador que o fará funcionar da forma desejada, além de se adaptar as mudanças dos elementos sob controle. Nas últimas décadas, houve um grande avanço nas pesquisas relacionadas ao desenvolvimento de diferentes métodos de controle, com o objetivo de tornar o funcionamento dos sistemas eletromecânicos mais eficientes. Os tipos de técnicas de controle mais utilizadas são: os sistemas de controle baseado na lógica *Fuzzy*, o controlador Proporcional, Integrativo e Derivativo (PID), Controlador Preditivo e a Rede Neural Artificial (RNA).

Dentre as técnicas de controle citadas, a RNA recebe grande destaque devido ao seu grau de aplicabilidade, podendo ser empregada em sistemas dinâmicos complexos com múltiplas variáveis a serem controladas. Dependendo da configuração do tipo de algoritmo, as Redes Neurais Artificiais podem ser utilizadas para previsão, otimização e controle de processos. O aperfeiçoamento do algoritmo e dos seus parâmetros são objetos de pesquisas como as de Antsaklis & Passino (1989), que realizaram um estudo sobre a atuação da Rede Neural Artificial como uma técnica de controle inteligente, abordando a arquitetura dessas redes e a modelagem desse sistema.

A utilização da Rede Neural Artificial como uma técnica de controle também foi comprovada por Narendra & Parthasarathy (1990). Neste trabalho foi demonstrado que as RNAs podem ser utilizadas de forma eficaz para realizar a identificação e controle de sistemas dinâmicos não lineares. Os autores também apresentaram modelos de Redes Neurais Artificiais com múltiplas camadas e recorrentes, com propagação retroativa estática e dinâmica para o ajuste de parâmetros. Ainda no ano de 1990, Nguyen & Widrow realizaram a

identificação das características dinâmicas de um sistema físico não linear e, posteriormente, o controle desse sistema via Redes Neurais Artificiais. O objetivo desse estudo foi emular uma situação em que um caminhão deveria estacionar em determinado ponto de forma automática. O controlador utilizado se mostrou eficiente, visto que, na maioria das posições iniciais em que o caminhão se encontrava, o sistema de controle conseguia fazer com que o veículo estacionasse automaticamente no local desejado.

Automatizar um SAA é uma forma de promover a eficiência energética e hidráulica deste sistema. Uma vez que se adere um sistema de controle no processo de automação, além de monitorar os parâmetros elétricos e hidráulicos, se torna possível controlar o nível de água de reservatórios, o ângulo de uma válvula proporcional, como também, a frequência de rotação dos sistemas de impulsão, promovendo assim o controle da pressão.

Neste contexto, Cembrano *et al.* (2000) aplicaram uma técnica de controle ótimo em uma rede de distribuição de água da cidade de Sintra, em Portugal. Para isto, eles utilizaram um *software* como um otimizador denominado de *WATERNET* em conjunto com outras ferramentas que integraram valor quanto ao custo energético do sistema. Previamente, foi realizada uma modelagem matemática da rede e os elementos de controle considerados foram as válvulas proporcionais, transdutores de pressão e o conjunto motor bomba.

Elbelkacemi *et al.* (2001) aplicaram um controlador adaptativo no tempo discreto, em um sistema de bombeamento, com o objetivo de regular o consumo de uma rede de abastecimento de água. A primeira etapa deste trabalho consistiu em determinar o modelo matemático do sistema estimando seus parâmetros de forma on-line, através do método dos Mínimos Quadrados Recursivos (MQR). Em seguida, foi implementado um controlador adaptativo Linear Quadrático de Gauss (LQG), que tem como base a minimização de uma função de custo quadrática. Os resultados encontrados se mostraram satisfatórios em relação ao controle da demanda de consumo e do nível da água no reservatório, afetando assim a pressão distribuída na rede.

No ano de 2003, Elker & Kara realizaram a simulação de um sistema de abastecimento constituído por três sistemas de impulsão com elevatórias em série. Na modelagem hidráulica incluiu-se o acoplamento não linear entre a vazão e o nível dos reservatórios, bem como a calibração do coeficiente de rugosidade da tubulação de recalque. A partir da manipulação da velocidade de rotação do conjunto motor bomba, foi obtido um controlador de nível usando o método de otimização robusto  $H_\infty$  polinomial. A utilização do sistema de controle resultou em melhorias significativas na operação do sistema de abastecimento em estudo.

Com o intuito de reduzir os custos energéticos referentes ao bombeamento de um sistema adutor, para uma demanda de água específica, sem alterar as restrições operacionais do sistema, Machado *et al.* (2005) propuseram uma metodologia que utiliza algoritmos genéticos. Os resultados obtidos mostraram o comparativo entre o uso do algoritmo genético proposto e um conjunto de regras definidas para a operação do sistema. Com base nos dados apresentados foi possível atestar que o algoritmo genético ocasionou melhores soluções econômicas e operacionais, além de promover uma redução de 10,12% no custo de energia elétrica.

Segundo Tsutiya (2007), com o intuito de garantir pressões adequadas na rede, é comum no Brasil o uso de reservatório elevado servido por estação elevatória com bombas de rotação constante. Todo esse processo envolve um custo excessivo, tanto na construção como na manutenção. Esses cenários podem ser eliminados com a utilização de bombas de rotação variável, em conjunto com os inversores de frequência, que funcionam como um variador de rotação.

Neste contexto, o controle de pressão utilizando lógica *Fuzzy* em uma rede de abastecimento foi realizado no ano de 2009 pelos pesquisadores Xiaohong *et al.*. O sistema estudado simulava três bombas operando em paralelo. Aos conjuntos motor bomba estavam associados inversores de frequência, sobre os quais o controlador atuava alterando a velocidade de rotação e, conseqüentemente, mantendo a pressão da rede sempre no mesmo patamar, independente das perturbações sofridas pelo sistema. Ainda em 2009, Hongfeng *et al.* realizaram uma análise comparativa entre a performance dos controladores PID e *Fuzzy* – PID para manter a pressão constante em um sistema de abastecimento. Com os resultados obtidos ficou comprovado que o controlador *Fuzzy* – PID se mostrou mais eficiente no controle da pressão se comparado ao controlador PID.

Gonçalves, Ramos & Reis (2010) elaboraram um algoritmo utilizando Redes Neurais Artificiais, para determinar estratégias operacionais em sistemas de abastecimento de água, visando à redução do consumo de energia elétrica. No mesmo ano, Chengsong & Lijun simularam computacionalmente um sistema de abastecimento de água com o propósito de controlar a pressão dessa rede utilizando um controlador adaptativo *Fuzzy* – PID.

A garantia da eficiência energética de um sistema de bombeamento foi dada com a utilização de um sistema de controle em cinco bombas com rotação variável por Pilscikovs & Dzelzitis (2012). Neste caso, os pesquisadores obtiveram uma redução de 1011 MWh de energia elétrica consumida anualmente.

Em 2012, Carvalho aplicou uma técnica de controle *Fuzzy* em uma bancada experimental que simula um sistema de abastecimento de água com duas zonas topográficas diferenciadas. O intuito deste trabalho foi controlar a pressão desses ramais e promover a redução do custo energético do sistema. O controlador atuou nos sistemas de impulsão e em uma válvula redutora de pressão. Os resultados obtidos foram satisfatórios, apresentando uma diminuição de aproximadamente 12,17% no consumo de energia elétrica.

Ainda com o objetivo de promover o controle de pressão em sistemas de distribuição de água, pode-se utilizar para esta finalidade uma válvula redutora de pressão. Segundo Bezerra & Cheung (2013), quando se associa a atuação deste tipo de válvula a um controle eletrônico, esse dispositivo garante o monitoramento e controle de pressão a montante da sua instalação.

Com o objetivo de obter o controle de pressão, Quadros & Pinto (2013) aplicaram um controlador do tipo PID com sintonia automática e adaptativa utilizando os métodos de Astrom – Hagglund e algoritmos genéticos numa VRP. Para esta pesquisa, foram utilizados modelos matemáticos validados experimentalmente. Os resultados obtidos demonstraram a eficiência do uso do controlador PID utilizando-se os dois métodos, com a VRP sendo controlada pela válvula piloto. Os parâmetros de comparação utilizados foram o tempo de simulação, o custo (ITAE), média, variância, máximo e mínimo.

Um controlador Proporcional Integrativo (PI) foi projetado e implementado por Gobis *et al.* (2013), com o objetivo de otimizar o abastecimento doméstico, visando reduzir o consumo energético do sistema de bombeamento, além de promover uma melhoria na qualidade da água fornecida. Os resultados obtidos se mostraram satisfatórios, apresentando uma redução no consumo de energia do sistema.

Camboim, S. Silva & Gomes (2014) otimizaram a operação de uma bancada experimental que simula um sistema de distribuição de água operando com bombas em paralelo. Um controlador com base na lógica *Fuzzy* foi desenvolvido e aplicado nos inversores de frequência, que acionam os sistemas motor bomba para alterar a velocidade de rotação dos mesmos, com o objetivo de controlar a pressão da rede da forma mais eficiente energeticamente, atendendo a demanda desejada. Com os resultados obtidos ficou constatado que a metodologia implementada gerou uma economia de energia significativa ao sistema, além de manter a pressão de serviço desejada.

Para minimizar o desperdício de energia sem prejudicar o abastecimento de água de uma indústria cimenteira, Cassandra, Fabiana & Danielle (2014) automatizaram esse sistema

através do uso do controlador PID. O SAA possui um poço onde se encontra instalada uma bomba submersa, que abastece uma cisterna e a caixa d'água dos escritórios; através de uma bomba centrífuga a cisterna alimenta uma bacia de refrigeração. Por outra bomba centrífuga, a água é bombeada da bacia de refrigeração até a caixa geral que possui 25,5 m de altura (ponto crítico do sistema), e por gravidade a água é transportada para a parte de refrigeração dos equipamentos de grande porte dos processos produtivos da indústria. Como parte do processo de automação, foram instaladas válvulas eletropneumáticas para medir o nível dos reservatórios, inversores de frequência para a partida das bombas e o controlador PID para obter o controle de nível dos reservatórios. Como conclusão deste trabalho, ficou comprovada a eficiência energética do SAA pelo uso dos inversores de frequência, que diminuíram o fator de potência do sistema, além da obtenção de um controle de nível efetivo com a utilização do controlador PID.

Bezerra *et al* (2015) realizaram um estudo sobre a relação entre o uso de inversores de frequência na redução do consumo de energia elétrica em sistemas de bombeamento de água. No intuito de controlar a altura manométrica de uma bancada experimental que simula um sistema de abastecimento, foi utilizado um controlador a partir da lógica *Fuzzy* para alterar a velocidade de rotação dos conjuntos motor bomba do sistema. Os testes foram realizados em duas etapas: na primeira foi acionado o sistema com o intuito de atender a variação da demanda solicitada sem a utilização do controlador PID; posteriormente, repetiu-se a mesma simulação com o controlador atuando no sistema. Os resultados obtidos constatarem uma redução de 35% do consumo energético do sistema com a utilização do controlador *Fuzzy*.

Silva *et al* (2015) promoveram o controle da pressão de uma bancada experimental que simula um sistema de distribuição de água, a partir da utilização de um controlador adaptativo do tipo Variância Mínima Generalizado (VMG). Como primeira etapa deste trabalho, foi realizada a identificação do sistema através do método dos Mínimos Quadrados Recursivos (MQR). A atuação do controlador ocorreu na alteração da velocidade de rotação do conjunto motor bomba e do ângulo de abertura da válvula proporcional. Os resultados obtidos demonstraram a eficiência da utilização deste tipo de controlador, obtendo uma redução de 19,2% no consumo de energia elétrica, com o sistema atuando nas condições mais desfavoráveis, e erro máximo de 2,12%, que equivale a 0,42 mca no controle de pressão.

No ano de 2015, os pesquisadores Cunha & Dórea realizaram a modelagem matemática, simulação e controle do sistema de abastecimento de água da Universidade Federal do Rio Grande do Norte (UFRN), com o propósito de reduzir as perdas de água e

tornar o sistema mais eficiente energeticamente. Foi realizado o comparativo entre a técnica de controle servo aplicada em uma planta com multivariáveis e um controlador preditivo linear.

Mendonça (2016) utilizou a lógica *Fuzzy* como controlador para um sistema centralizado e outro descentralizado, com o objetivo de controlar a pressão em duas regiões com topografias diferenciadas de uma bancada experimental. Para garantir as pressões, o sistema de controle atuou no inversor que varia a frequência de rotação do conjunto motor bomba e na válvula redutora de pressão instalada a montante da região com topografia mais baixa. Ainda no mesmo ano, Moura também realizou o controle da pressão de uma bancada experimental que simula um SAA. Em seu trabalho, o autor realizou o comparativo entre duas técnicas de controle distintas: um sistema de controle neural adaptativo e um controlador utilizando a lógica *Fuzzy*.

Ainda no ano de 2016, o pesquisador Sarbu realizou um estudo de caso real no sistema de distribuição de água da Romênia, utilizando um controlador para alterar a velocidade de rotação dos sistemas de impulsão e ângulo de posição da válvula. Nos seus estudos, o autor comparou o consumo de energia do sistema com e sem a atuação do controlador. Com o controle da velocidade de rotação do conjunto motor bomba houve uma economia de 2280 MWh/ano. Quando o controle foi utilizado na válvula a redução observada foi de 1345 MWh/ano.

Trabalhos mais recentes, como o do autor Oliveira (2017), mostram a eficiência na utilização de um sistema de controle para manter a pressão constante em diversos pontos de um SAA, além de promover a eficiência energética deste sistema. O mesmo ocorre na pesquisa realizada pelos autores Barros Filho *et al* (2017), neste caso o controlador utilizado foi baseado nas redes neurais artificiais com arquitetura recorrente, com o intuito de promover o controle da pressão em um SAA que opera com bombas em paralelo.

Com o intuito de contribuir cientificamente com os trabalhos que já foram realizados na área de automação e controle, com foco em sistemas de abastecimento de água, e promover a eficiência energética desses sistemas, esta tese foi desenvolvida utilizando um sistema de controle neural para controlar a pressão em uma bancada experimental com duas regiões com topografias distintas. Neste trabalho, o controlador atuou nos sistemas de impulsão (conjunto motor bomba e *booster*) e em uma válvula redutora de pressão visando controlar as pressões com um menor custo energético. Para isso, o sistema de controle toma como base na sua decisão a minimização do consumo específico de energia (CE).

## CAPÍTULO 3

### REDES NEURAIS ARTIFICIAIS

#### 3.1 Conceitos Iniciais

As Redes Neurais Artificiais podem ser definidas como técnicas computacionais que representam um modelo matemático, cuja inspiração vem da estrutura neural dos seres vivos. De acordo com Gurney (1997):

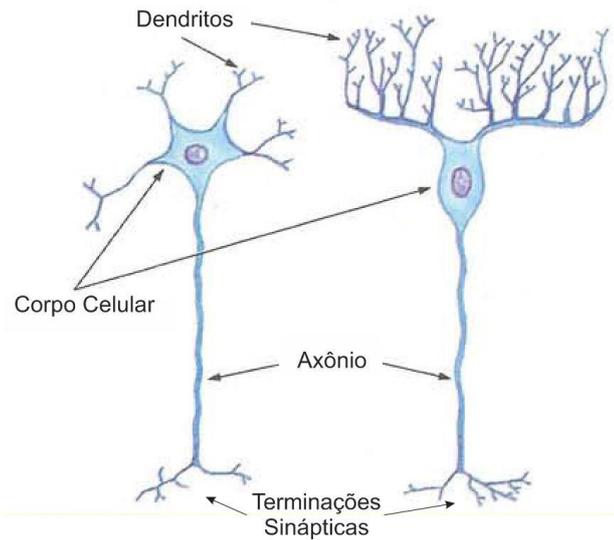
Uma rede neural é um conjunto interligado de elementos, *unidades* ou *nós* de processamento simples, cuja funcionalidade é parcialmente baseada no neurônio biológico. A capacidade de processamento da rede é armazenada nas suas conexões, ou *pesos*, obtidos por um processo de adaptação ou *aprendizagem* de um conjunto de treinamento padrões.

O primeiro trabalho envolvendo o estudo das Redes Neurais ocorreu no ano de 1943 e foi desenvolvido por McCulloch & Pitts. Nessa pesquisa, os autores descreveram matematicamente o neurônio artificial com base no comportamento do neurônio biológico.

Biologicamente, as células nervosas denominadas neurônios são responsáveis por coordenar as funções entre os diferentes órgãos dos seres vivos, sendo capazes de transmitir (por meio dos axônios) e receber (através dos dendritos) estímulos nervosos, fazendo com que o organismo responda às alterações ocorridas no meio.

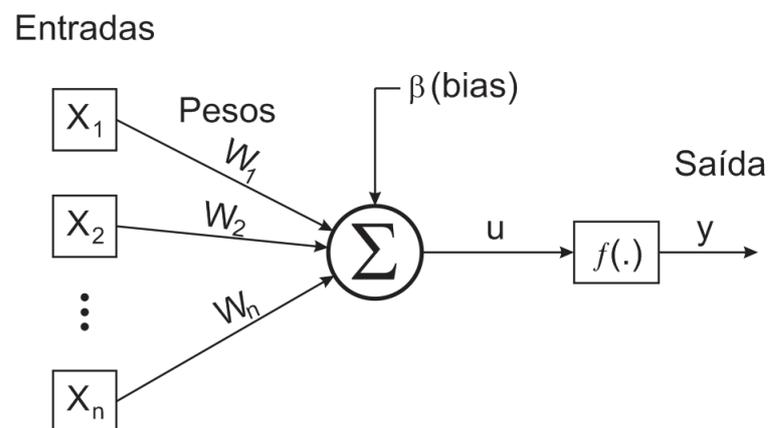
Quando a membrana de uma célula neural encontra-se em repouso, ou seja, está polarizada, há carga elétrica positiva do lado externo e carga elétrica negativa do lado interno. Essa diferença entre as cargas é mantida pela bomba de Sódio (Na) e Potássio (K) e denomina-se potencial de repouso. No momento em que o neurônio recebe um estímulo, ocorre uma alteração na permeabilidade da membrana, invertendo as cargas (despolarização) e gerando um potencial de ação. A propagação dessa despolarização caracteriza-se como um impulso nervoso. Em seguida a membrana volta a ficar polarizada e o impulso é cessado. Para que o neurônio gere o potencial de ação deve receber um estímulo forte o suficiente, denominado estímulo limiar. Se isso não ocorrer, não será transmitido o impulso nervoso. As transmissões desses impulsos ocorrem por uma região de ligação chamada de sinapse (LOPES, 2004).

O esquema ilustrativo de um neurônio biológico está representado pela Figura 3.1.



**Figura 4.1** Representação de um neurônio biológico. (LOPES, 2004).

O neurônio artificial advém de um modelo simplificado do neurônio biológico, sendo tipicamente não linear com saída contínua. Seu funcionamento se resume em coletar os sinais de entrada e agrupá-los de acordo com sua função operacional para fornecer uma saída. Para gerar a resposta é levada em consideração a função de ativação presente no processo. A Figura 3.2 retrata um esquema ilustrativo de um neurônio artificial.



**Figura 4.2** Esquema ilustrativo de um neurônio artificial.

A Tabela 3.1 reúne as informações dos elementos que compõem a estrutura de um neurônio artificial.

**Tabela 4.1** Descrição dos elementos que compõem um neurônio artificial.

<b>Tipo de elemento</b>	<b>Símbolo</b>	<b>Descrição</b>
Sinais de entrada	$x_1, x_2, \dots, x_n$	Sinais que recebem valores de acordo com a aplicação específica.
Pesos sinápticos	$w_1, w_2, \dots, w_n$	Variáveis utilizadas para quantificar a relevância dos sinais de entrada da rede neural.
Combinador linear	$\Sigma$	Produz um valor de potencial de ativação agregando todos os sinais de entrada que foram ponderados pelos pesos sinápticos.
Limiar de ativação (bias)	$\beta$	Variável responsável pela especificação do patamar apropriado para que a resultante do combinador linear gere um valor de disparo em direção à saída do neurônio.
Potencial de ativação	$u$	Resultante da diferença dos valores produzidos entre o combinador linear e o limiar de ativação. O neurônio produz um potencial excitatório quando $u \geq \theta$ , caso contrário, será inibitório.
Função de ativação	$f(.)$	Limita a saída do neurônio para um intervalo de valores que serão assumidos pela sua própria imagem funcional.
Sinal de saída	$y$	É o valor final resultante produzido pelo neurônio de acordo com o conjunto de sinais de entrada.

Fonte: Silva, Spatti & Flauzino (2010).

As Equações 3.1 e 3.2 representam o resultado produzido pelo neurônio artificial (MCCULLOCH & PITTS, 1943):

$$u = \sum_{i=1}^n w_i \cdot x_i - \beta \quad (3.1)$$

$$y = f(u) \quad (3.2)$$

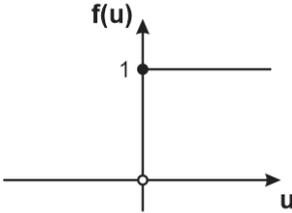
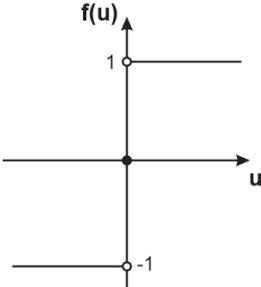
Segundo Silva, Spatti & Flauzino (2010), o funcionamento de um neurônio artificial resume-se em:

- Apresentar as variáveis de entrada do neurônio;
- Em seguida realizar a multiplicação entre os sinais de entrada e os seus respectivos pesos sinápticos;
- Obter o potencial de ativação através da soma ponderada dos valores de entrada e depois subtraindo-se o limiar de ativação;
- Aplicar a função de ativação escolhida para limitar o valor de saída do neurônio;
- Por fim, produzir o sinal de saída de acordo com a aplicação da função de ativação em relação ao seu potencial de ativação.

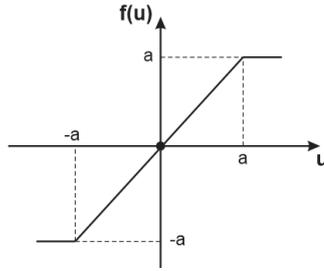
As funções de ativação podem ser divididas em duas categorias: funções parcialmente diferenciáveis e funções totalmente diferenciáveis. Os principais tipos de funções que podem ser utilizadas nas Redes Neurais Artificiais estão descritas abaixo.

- **Funções de ativação parcialmente diferenciáveis:** este grupo é composto pelas funções que possuem pontos onde suas derivadas de primeira ordem não existem. A Tabela 3.2 apresenta as principais funções dessa categoria;

**Tabela 4.2** Exemplos de funções de ativação parcialmente diferenciáveis.

Tipo	Representação Gráfica	Notação Matemática
Função Degrau		$f(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ 0, & \text{se } u < 0 \end{cases}$
Função Degrau Bipolar		$f(u) = \begin{cases} 1, & \text{se } u > 0 \\ 0, & \text{se } u = 0 \\ -1, & \text{se } u < 0 \end{cases}$

Função Rampa Simétrica



$$f(u) = \begin{cases} a, & \text{se } u > a \\ u, & \text{se } -a \leq u \leq a \\ -a, & \text{se } u < -a \end{cases}$$

- **Funções de ativação totalmente diferenciáveis:** as funções que compõem esse grupo se caracterizam por terem suas derivadas de primeira ordem existentes e conhecidas em todos os pontos de seu domínio de definição. A Tabela 3.3 apresenta as principais funções pertencentes a essa categoria.

Tabela 4.3 Exemplos de funções de ativação totalmente diferenciáveis.

Tipo	Representação Gráfica	Notação Matemática
Função Logística		$f(u) = \frac{1}{1 + e^{-\beta u}}$
Função Tangente Hiperbólica		$f(u) = \frac{1 - e^{-\beta u}}{1 + e^{-\beta u}}$
Função Gaussiana		$f(u) = e^{-\frac{(u-c)^2}{2\sigma^2}}$
Função Linear		$f(u) = u$

Para escolher uma função de ativação deve ser levado em conta a satisfação do critério de aproximação universal e o esforço computacional, além disso, a sua escolha tem forte influência na complexidade e no desempenho da RNA, e uma forte relevância quanto a convergência dos algoritmos de aprendizagem (CHANDRA & SINGH, 2004).

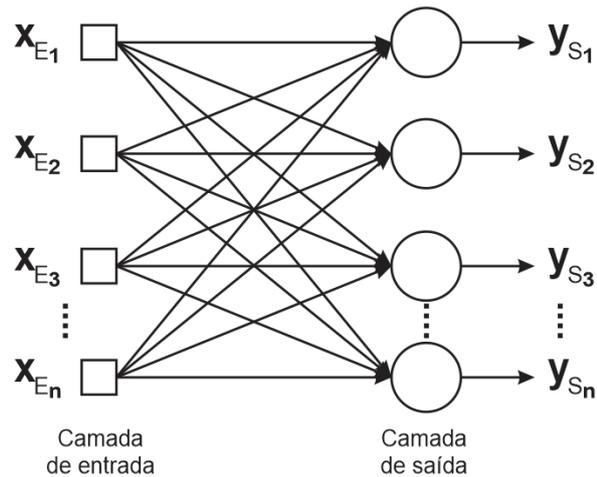
Segundo S. Haykin (2001) a função de ativação do tipo tangente hiperbólica é a mais comumente usada nas camadas ocultas de uma RNA em diversas aplicações, diferindo das demais por apresentar valores de ativação em um intervalo de valores positivos e negativos.

### 3.2 Arquitetura das Redes Neurais Artificiais

Uma RNA é dividida basicamente em três partes (ou camadas): camada de entrada, onde são recebidos e normalizados os sinais de entrada (informações) de acordo com a função de ativação utilizada; camada intermediária (ou oculta), nela ocorre todo o processamento que envolve o neurônio artificial; e por último a camada de saída que é responsável pelo resultado final da rede de acordo com os processos que foram realizados nas camadas anteriores.

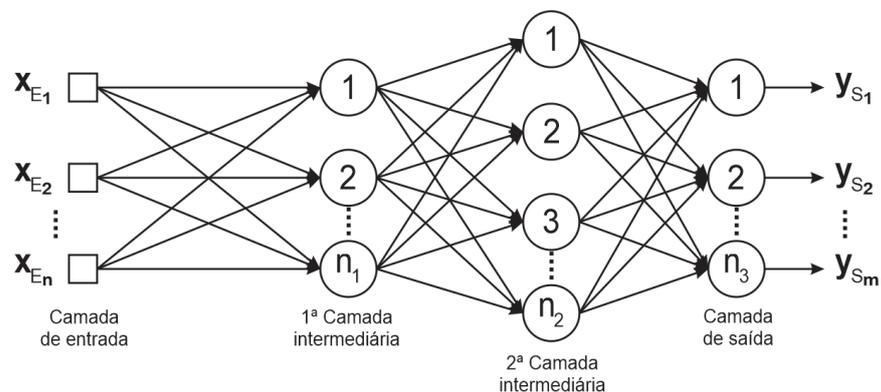
Os tipos de RNA diferem em relação a sua arquitetura, ou seja, a forma como os seus neurônios estão interligados entre si, a organização e formação das camadas, sendo classificadas como redes *feedforward* de simples e múltiplas camadas, redes recorrentes e redes em estrutura reticulada (KRIESEL, 2005). Uma breve descrição dessas redes é apresentada a seguir:

- **Arquitetura *feedforward* de camada simples:** este tipo de arquitetura se caracteriza por uma rede formada por duas camadas, uma de entrada e uma de saída. As informações nessa rede seguem apenas uma direção, ou seja, é acíclica. Geralmente essas redes são utilizadas em problemas que envolvem classificação de padrões e filtragem linear. Como exemplos de RNA que apresentam esse tipo de arquitetura estão as redes *Perceptron* e *Adaline*. A Figura 3.3 apresenta um exemplo genérico de uma Rede Neural Artificial de camada simples;



**Figura 4.3** Exemplo de uma RNA com arquitetura *feedforward* de camada simples.

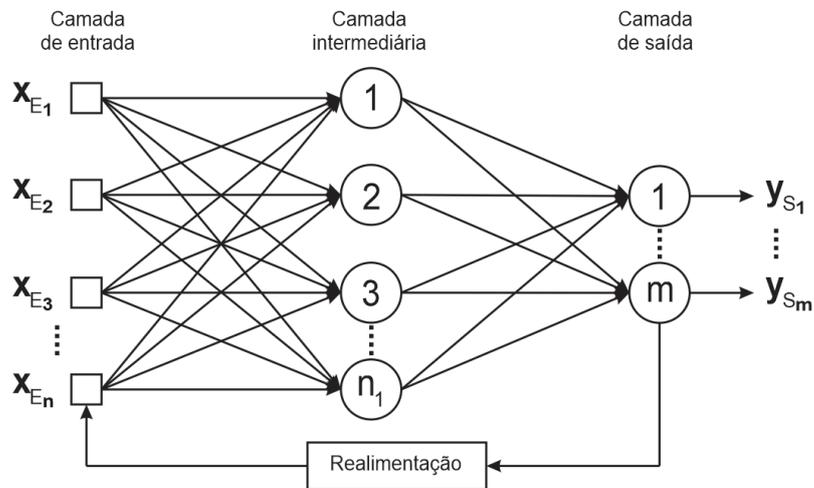
- **Arquitetura *feedforward* de múltiplas camadas:** este tipo de rede possui pelo menos uma camada intermediária (ou oculta) de neurônios na sua configuração. São comumente empregadas na solução de problemas que envolvem identificação de sistemas, otimização, controle de processos, robótica, aproximação e classificação de padrões. As redes que podem ser citadas como exemplos desse tipo de arquitetura são as *Perceptron* multicamadas (PMC) e as redes de base radial. Um exemplo de uma rede com esse tipo de arquitetura é apresentado na Figura 3.4;



**Figura 4.2** Exemplo de uma rede *feedforward* de múltiplas camadas.

- **Arquitetura recorrente ou realimentada:** neste caso os neurônios da camada de saída realimentam a rede como sinais de entrada. Este tipo de característica torna a rede apta para ser utilizada em processamento dinâmico de informações, ou seja, em

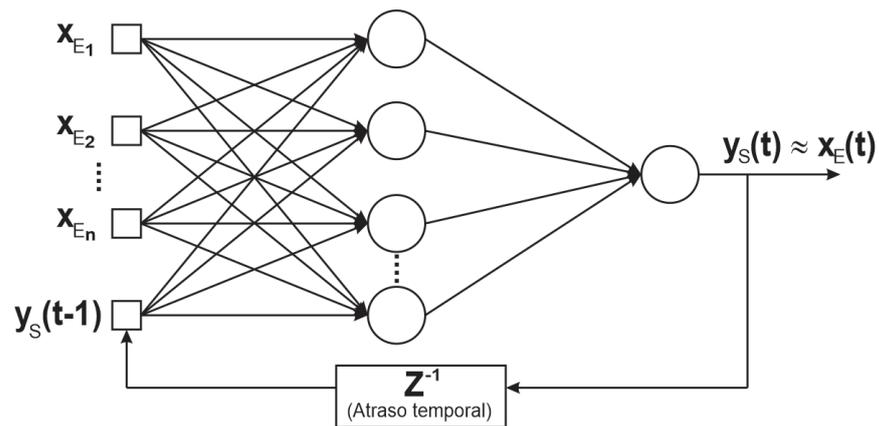
processos que variam com o tempo, como por exemplo, a otimização e identificação de sistemas, controle de processos e previsão de séries temporais. A Figura 3.5 exibe um exemplo generalizado de uma rede com arquitetura recorrente;



**Figura 4.3** Exemplo de uma rede com arquitetura recorrente.

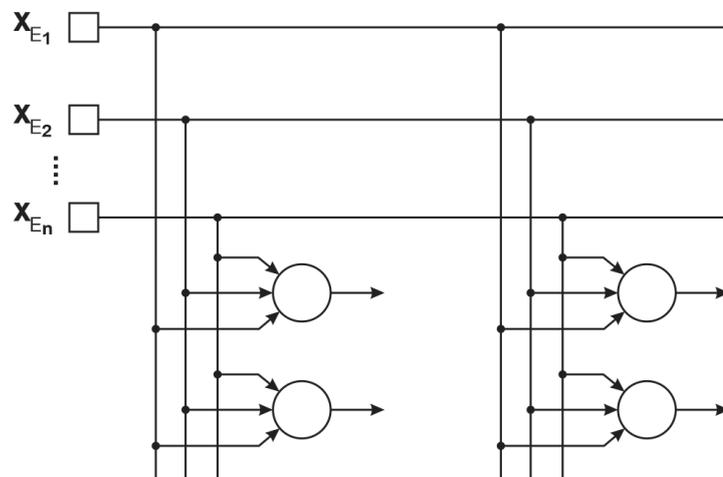
Como exemplos de redes que possuem esse tipo de arquitetura estão a rede de Hopfield e a rede *Perceptron* multicamadas com realimentação. Segundo Silva, Spatti & Flauzino (2010) as redes PMC com arquitetura recorrente podem ser configuradas visando sua vasta aplicabilidade em sistemas de controle. Um dos primeiros trabalhos realizado com esse objetivo foi o dos pesquisadores Narendra & Parthasarathy (1990), outros trabalhos relevantes que abordam esse estudo de forma mais detalhada foram realizados por Suykens *et al.* (2001); Leondres (2006) e Norgaard *et al.* (2006).

A Figura 3.6 apresenta um exemplo de uma rede PMC com arquitetura recorrente.



**Figura 4.4** Exemplo de uma rede do tipo PMC com arquitetura recorrente.

- **Arquitetura em estrutura reticulada:** neste tipo de arquitetura os neurônios ficam dispostos de acordo com o processo de ajuste dos seus pesos e dos limiares. Redes que apresentam esse tipo de arquitetura podem ser utilizadas em reconhecimento de padrões, otimização de sistemas, problemas de agrupamento e principalmente em extração de características (SILVA, SPATTI & FLAUZINO, 2010). Como exemplo desta arquitetura pode-se citar a rede de Kohonen. A Figura 3.7 traz um exemplo de uma rede de Kohonen que possui seus neurônios organizados no espaço bidimensional.



**Figura 4.5** Exemplo de uma rede de Kohonen com arquitetura em estrutura reticulada.

### 3.3 Processos de Treinamento

A Rede Neural Artificial se diferencia dos demais modelos computacionais por sua distinta capacidade de aprender a partir do ambiente no qual ela está inserida, tendo assim a habilidade de melhorar seu desempenho com esta aprendizagem. Esse processo de aprendizagem, que pode ser chamado também de treinamento, ocorre através de um algoritmo para ajuste dos pesos sinápticos e valores do bias (limiar de ativação).

A maneira como ocorre o processo de treinamento de uma RNA pode ser definido da seguinte forma: após a RNA sofrer um estímulo pelo ambiente, a rede vai alterar os seus parâmetros livres (pesos sinápticos e bias) e em seguida vai responder de maneira nova ao ambiente, devido as modificações sofridas.

O treinamento da RNA ocorre por épocas, ou seja, esse processo de aprendizagem é repetido de acordo com um determinado número de épocas até que os valores do limiar de ativação e dos pesos sinápticos se estabilizem e o valor do erro quadrático médio do conjunto de treinamento atinja um valor mínimo.

De acordo com Mendel & McClaren (1970), o que vai determinar o tipo de aprendizagem de uma Rede Neural Artificial é a forma como os parâmetros desta rede são modificados. Dessa forma, os cinco principais processos de aprendizagem ou treinamento são abordados a seguir:

- **Treinamento supervisionado:** este tipo de estratégia de treinamento foi proposta inicialmente pelo pesquisador Donald Hebb no ano de 1949, ela consiste em disponibilizar para a rede os sinais de saída esperados de acordo com os sinais de entrada recebidos pela rede. Dessa forma, é ensinado a RNA o modo como ela deve se comportar a cada amostra de dados de entrada recebido por ela, ou seja, a partir de um conhecimento prévio das saídas desejadas;
- **Treinamento não supervisionado:** neste caso inexistente uma informação sobre a saída de dados desejados para o sistema. Dessa forma, a RNA deve aprender a ajustar seus pesos sinápticos e o limiar de ativação sem o conhecimento prévio do sistema;
- **Treinamento com reforço:** neste tipo de treinamento o processo ocorre por tentativa e erro, ou seja, a rede avalia apenas se a resposta gerada para aquela entrada é

satisfatória ou não. Se a resposta for satisfatória então há uma atualização gradual nos valores dos pesos sinápticos e no limiar de ativação para reforçar esta situação comportamental do sistema;

- **Aprendizagem padrão por padrão (*on-line*):** neste processo de aprendizagem é apresentada a rede um padrão de amostras a cada instante de tempo. Após o ajuste dos parâmetros essas amostras são descartadas e novas amostras são consideradas. Usualmente este tipo de treinamento é utilizado para sistemas dinâmicos e que mudam seu comportamento de forma mais rápida. Devido a essa apresentação do padrão de amostras ser pontual, Reed & Marks II (1999) afirmaram que a rede necessita ser alimentada por um número grande de amostras para poder proporcionar uma resposta satisfatória;
- **Aprendizagem por lotes de padrões (*off-line*):** para realizar esse tipo de treinamento a rede precisa passar por todas as amostras de dados que forem oferecidas a ela. Antes de ocorrer a atualização dos pesos sinápticos e do limiar de ativação, são levados em consideração todos os desvios que ocorreram durante a leitura das amostras oferecidas.

O tipo de algoritmo de aprendizagem a ser utilizado para realizar o treinamento dos pesos sinápticos e do limiar de ativação de uma RNA é escolhido de acordo com o tipo de arquitetura desta rede e o seu propósito.

Geralmente, para as redes com arquitetura *feedforward* de camada simples como é o caso da rede *Perceptron*, utiliza-se a técnica de treinamento desenvolvida por Hebb (1949). No caso da rede *Adaline* o algoritmo de treinamento utilizado é o desenvolvido por Widrow & Hoff (1960) conhecido por regra Delta, o princípio básico desse algoritmo é a minimização da diferença entre o valor do combinador linear e a resposta de referência ou esperada. Para as redes com arquitetura *feedforward* de múltiplas camadas, como é o caso da rede *Perceptron* de múltiplas camadas, o algoritmo de aprendizado utilizado é o regra Delta generalizada.

Quando a rede apresenta uma arquitetura com realimentação, como as redes de Hopfield e a *Perceptron* multicamadas com realimentação, Silva, Spatti & Flauzino (2010) afirmam que os seus processos de treinamento são realizados com base na minimização de funções de energia e na regra Delta generalizada, conhecida também por método do Gradiente

Descendente. O treinamento da rede PMC com realimentação busca a minimizar o erro entre o valor de referência e a resposta real da rede.

## CAPÍTULO 4

### MATERIAIS E MÉTODOS

#### 4.1 Descrição da Bancada Experimental

O objeto de estudo deste trabalho foi uma bancada experimental (ver Figura 4.1), que simula um sistema de abastecimento, cuja estação elevatória bombeia água para duas zonas de consumo com topografias diferenciadas. A bancada experimental se encontra no Laboratório de Eficiência Energética e Hidráulica em Saneamento (Lenhs) na Universidade Federal da Paraíba (UFPB).

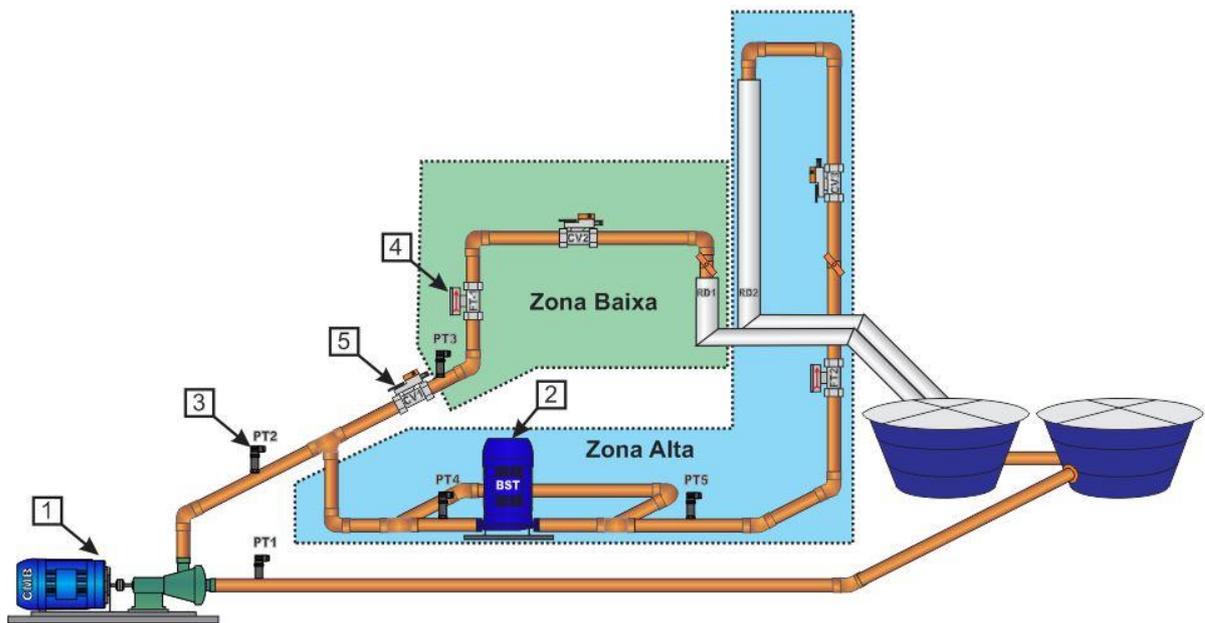


**Figura 5.1** Bancada experimental

O sistema de bombeamento é composto por um conjunto motor bomba (CMB), responsável por impulsionar a água do reservatório para todo o sistema, e um *booster* (BST),

que deve elevar a altura manométrica e assim garantir o fornecimento de água até a região mais elevada (Zona Alta). Os sistemas de impulsão são acionados por dois inversores de frequência independentes, dessa forma é possível alterar a velocidade de rotação do conjunto motor bomba e do *booster*. A montante da Zona Baixa encontra-se instalada uma válvula proporcional, que neste estudo atuou como uma válvula redutora de pressão (CV1).

As pressões no ramal 1 (Zona Baixa) são coletadas pelos transdutores de pressão PT1, PT2 e PT3, e a vazão neste trecho é mensurada pelo medidor de vazão FT1. No ramal 2 (Zona Alta) as pressões são mensuradas pelos transdutores PT4 e PT5, e a vazão pelo medidor de vazão FT2. Para simular a demanda do sistema, foram utilizadas duas válvulas proporcionais, a válvula CV2 fica localizada no ramal de descarga da Zona Baixa e a válvula CV3 está instalada no ramal de descarga da Zona Alta. A água fica reservada em duas câmaras interligadas de 310 L cada, funcionando, assim, como ponto de sucção e descarga, simultaneamente. Todos os elementos citados acima estão indicados na Figura 4.2.



**Figura 5.2** Imagem ilustrativa da bancada experimental.

As especificações técnicas dos elementos da bancada experimental exibidos na Figura 4.2 são apresentadas a seguir:

- 1. Conjunto Motor Bomba:** este sistema de impulsão é formado pelo acoplamento de um motor com uma bomba, cuja função é transportar água dos reservatórios até

as duas zonas de consumo. Este equipamento é acionado por um inversor de frequência o qual permite alterar a sua velocidade de rotação. As Tabelas 4.1 e 4.2 reúnem as especificações técnicas referentes a esse sistema de bombeamento.

**Tabela 5.1** Especificações técnicas do motor.

<b>Modelo / Fabricante</b>	<b>WEG</b>
Potência	3 CV
Tensão de alimentação	380 V AC
Frequência	60 Hz
Corrente	4,86 A
Rotações	3450 rpm
Fator de potência	0,84
IP	55

Fonte: Manual Geral de Instalação, Operação e Manutenção de Motores Elétricos para Atmosferas Explosivas, WEG Group – Motors Business Unit.

**Tabela 5.2** Especificações técnicas da bomba.

<b>Modelo / Fabricante</b>	<b>BC – 21R / Schneider Motobombas</b>
Altura manométrica	23 mca
Vazão máxima	41,5 m <sup>3</sup> /h
Diâmetro do rotor	121 mm
Pressão máxima sem vazão	25 mca
Rotações	3450 rpm

Fonte: Manual de Instruções das Bombas e Motobombas, Franklin Electric Indústria de Motobombas S.A.

2. **Booster:** é um sistema de impulsão instalado em linha que serve para aumentar a carga hidráulica a jusante da sua instalação. Este sistema encontra-se localizado a montante da zona alta e é utilizado para elevar a linha piezométrica e, assim, aumentar a pressão neste ramal. As principais especificações técnicas desse sistema são encontradas na Tabela 4.3.

**Tabela 5.3** Especificações técnicas do *booster*.

<b>Modelo / Fabricante</b>	<b>Megaline / KSB</b>
Diâmetro nominal do rotor	160 mm
Potência do Motor	2 cv
Vazão	Até 500 m <sup>3</sup> /h
Temperatura	Até 90°C
Rotações	3500 rpm

Fonte: Manual de Serviço: Bomba Centrífuga em Linha para Uso Geral, KSB.

- 3. Transdutor de Pressão:** tem como principal função converter a grandeza física pressão em um sinal elétrico analógico. Na bancada experimental existem cinco transdutores de pressão instalados: PT1, a montante do CMB; PT2 a jusante do CMB; PT3, nas proximidades do ramal de descarga da zona baixa; PT4, a montante do BST; e PT5, próximo ao ramal de descarga da zona alta (vide Figura 4.2). As características técnicas desses transdutores são apresentadas na Tabela 4.4.

**Tabela 5.4** Especificações técnicas dos transdutores de pressão.

<b>Modelo / Fabricante</b>	<b>TP-ST18 / ACROS</b>
Sinal de saída	4 ~ 20 mA
Tensão de alimentação	24 V DC
Range (Faixa)	0 ~ 40 mca

Fonte: Instalação e Manutenção de Transmissores, ACROS Automação Industrial Ltda.

- 4. Medidor de Vazão:** com o objetivo de fornecer o valor de vazão em m<sup>3</sup>/h, os medidores de vazão da bancada experimental estão localizados próximos aos ramais de descargas das duas zonas de consumo. A Tabela 4.5 apresenta as principais características técnicas dos medidores de vazão.

**Tabela 5.5** Especificações técnicas dos medidores de vazão.

<b>Modelo / Fabricante</b>	<b>VMS 038 / Icontrol S/A</b>
Diâmetro interno	38 mm
Faixa de medição	1,24 a 40,8 m <sup>3</sup> /h
Tensão de alimentação	24 V DC
Saída analógica	4 a 20 mA

Fonte: Manual de Operação e Instalação: Medidor e Transmissor de Vazão, Icontrol S/A.

- 5. Válvula Proporcional:** nesta bancada experimental existem três válvulas proporcionais instaladas. A válvula CV1 encontra-se a jusante do conjunto motor bomba e funciona como uma válvula redutora de pressão. A válvula CV2 está instalada no ramal de descarga da zona baixa e a válvula CV3 está localizada no ramal de descarga da zona alta. Ambas atuam para simular a demanda das duas zonas de consumo. A Tabela 4.6 abaixo reúne as características técnicas das válvulas proporcionais.

**Tabela 5.6** Especificações técnicas das válvulas proporcionais.

<b>Modelo / Fabricante</b>	<b>ARB – 24 / Belimo</b>
Tensão de alimentação	24 V DC
Sinal de controle	2 a 10 V
Ângulo de fechamento	0 a 90 Graus

Fonte: Visual Instruction Sheet LRB24..., LRX24..., ARB24..., ARX24..., Belimo Aircontrols Inc.

A Figura 4.3 apresenta uma visão geral da bancada de testes. O sistema é composto por um notebook, uma fonte variável de tensão contínua, dois sistemas de aquisição de dados, dois inversores de frequência, um quadro com três transformadores de corrente e a bancada experimental. A atuação conjunta do *notebook* e as placas de aquisição de dados faz com que sejam enviados os sinais de excitação para os inversores de frequência e para as válvulas redutoras de pressão, ao mesmo tempo em que faz a leitura dos sinais de resposta dos transdutores de pressão e medidores de vazão. Esses sinais de excitação e de leitura são gerados e lidos por um programa desenvolvido na plataforma LabVIEW®.

**Figura 5.3** Visão geral da bancada de testes.

O notebook utilizado no experimento possui um processador Intel Core i7 de 2.40 GHz com 8 Gb de memória RAM. A comunicação entre o computador e a bancada

experimental ocorre por intermédio de duas placas de aquisição de dados, que fazem a interface do algoritmo de controle, através dos conversores D/A (digital/analógico) e A/D (analógico/digital). As características técnicas dos inversores de frequência, das interfaces de aquisição de dados e dos transformadores de corrente são apresentadas a seguir:

- 1. Inversor de Frequência:** este equipamento é responsável por regular a velocidade de rotação do motor elétrico mantendo seu torque. Nesta bancada experimental existem dois inversores de frequência (ver Figura 4.4), um se encontra conectado ao motor do *booster* e o outro ao motor do conjunto motor bomba.



**Figura 5.4** Inversores de frequência utilizados para acionar os sistemas de impulsão.

**Tabela 5.7** Especificações técnicas dos inversores de frequência.

<b>Modelo / Fabricante</b>	<b>CFW – 08 / WEG</b>
Alimentação	380 - 480 V AC / 3 ~ 7,8A / 50 – 60Hz
Temperatura de trabalho	0°C – 40°C – condições nominais
Umidade relativa do ar	5% - 90% - sem condensação
Altitude máxima	1000 m – condições nominais

Fonte: Manual do Inversor de Frequência, WEG Equipamentos Elétricos S.A.

- 2. Interfaces de Aquisição de Dados:** este componente é responsável pela comunicação entre os componentes eletrônicos da bancada experimental e o

computador. Nesta bancada experimental existem duas *interfaces* de aquisição de dados instaladas. A *interface* NI USB 6229 é responsável por enviar os sinais de excitação para os inversores e para as válvulas CV1 e CV2, além de receber os sinais dos transdutores de pressão e de vazão. A *interface* NI USB 6221 envia os sinais de excitação e recebe os sinais de resposta da válvula CV3. A Figura 4.5 apresenta uma *interface* de aquisição de dados semelhante as *interfaces* utilizadas na bancada experimental.



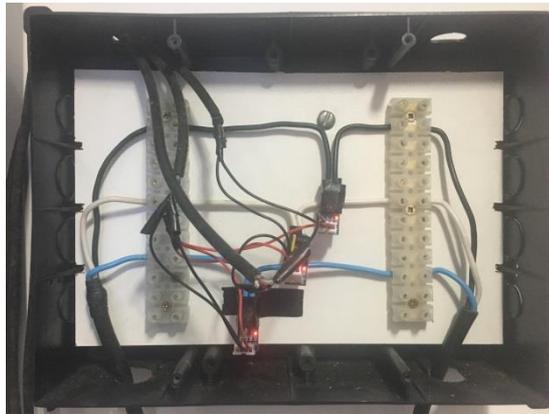
**Figura 5.5** *Interface* de aquisição de dados semelhante a utilizada na bancada experimental.

**Tabela 5.8** Especificações técnicas das *interfaces* de aquisição de dados.

<b>Modelo / Fabricante</b>	NI USB – 6229 <i>National Instruments</i>	NI USB – 6221 <i>National Instruments</i>
Alimentação	220 V AC	220 V AC
Canais de saída analógica	4	4
Canais de entrada analógica	32	32
Canais de entrada digital	32	32
Taxa de amostragem	50 ns	50 ns
Faixa de tensão de entrada	$\pm 10$ V	$\pm 10$ V
Faixa de tensão de saída	0 – 5 V	0 – 5 V
Corrente de saída	$\pm 20$ mA	$\pm 20$ mA
Transferência dos dados	Cabo USB	Cabo USB

Fonte: DAQ M Series: NI USB – 621x User Manual, National Instruments Corporation.

- 3. Transformadores de corrente (TC's):** Para se determinar a potência consumida pelo sistema de impulsão e inversores, foram instalados TC's com a função de medir a corrente total atuante. Essas placas eletrônicas captam a corrente que passa em um conduto por efeito *hall*, tendo como saída, um sinal de corrente, em escala pequena, e proporcional ao valor mensurado. Os TC's utilizados na bancada experimental são mostrados na Figura 4.6.



**Figura 5.6** TC's instalados na bancada experimental.

**Tabela 5.9** Especificações técnicas dos transformadores de corrente.

<b>Modelo / Fabricante</b>	ACS712
Alimentação	5 V
Corrente Máxima	30 A
Tempo de resposta	5 $\mu$ S
Largura de banda	80 kHz
Razão de saída	66 mV por Ampere
Dimensões (C x L x A)	32x13x14 mm
Peso	3,2 g

Fonte: Fully Integrated, Hall Effect-Based Linear Current Sensor IC with 2.1 kVRMS Isolation and a Low-Resistance Current Conductor, Allegro MicroSystems, LLC.

O esquema ilustrativo de todo o processo que envolve a bancada de testes é mostrado na Figura 4.7.

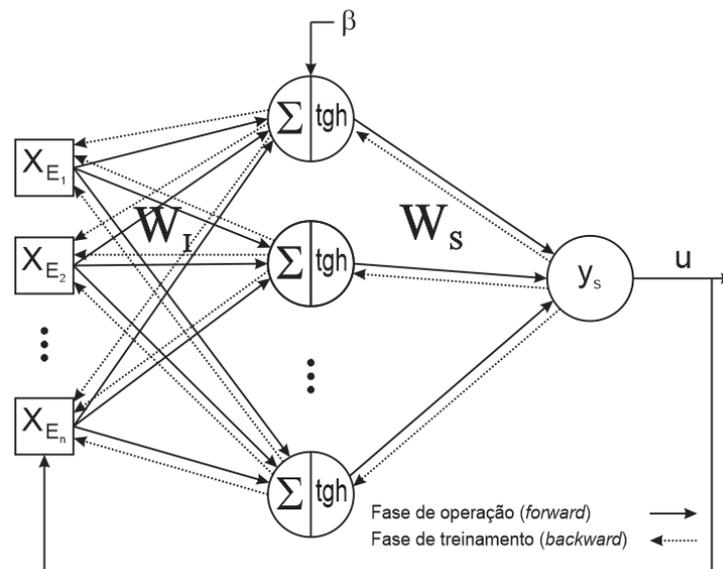


**Figura 5.7** Esquema ilustrativo da bancada de testes.

## 4.2 Projeto do Controlador Neural Aplicado na Bancada Experimental

O objetivo deste trabalho de tese foi controlar a pressão na localização do transdutor PT3 na região denominada de Zona Baixa (ZB) e a pressão dada por PT5, localizada no ramal da Zona Alta (ZA) da bancada experimental; para isto projetou-se um sistema de controle utilizando a técnica da Rede Neural Artificial com arquitetura recorrente. Entende-se por RNAs com arquitetura recorrente ou alimentação retroativa; as redes cujos sinais de entrada são retroalimentados com os sinais de saída dos neurônios da última camada. Devido a esse processo de realimentação, essas redes produzem saídas atualizadas considerando os sinais de saída calculados nos tempos anteriores, sendo comumente utilizadas em sistemas dinâmicos para otimização, identificação e controle de processos (SILVA, SPATTI & FLAUZINO, 2010). Para minimizar o erro entre a pressão real (mensurada) e a pressão de referência, foi empregado o algoritmo de aprendizado desenvolvido por Widrow & Lehr (1990), denominado de Retropropagação do Erro, que tem como objetivo minimizar o erro a partir do método do gradiente descendente (PRESS *et al.*, 1990).

Na Figura 4.8 mostra-se um exemplo genérico de uma RNA de multicamadas com alimentação retroativa, em que todos os elementos utilizados no cálculo durante as fases de operação e de treinamento estão ilustrados.



**Figura 5.8** Exemplo de uma rede neural com alimentação retroativa.

O funcionamento da Rede Neural Artificial ocorre em duas etapas conforme está explicado a seguir:

- **Fase de Operação:** esta fase abrange as etapas do cálculo dos sinais de saída dos neurônios da camada intermediária e dos sinais de saída da rede. Esta etapa ocorre de forma *forward* (para frente).

Na primeira camada, onde estão os sinais de entrada, a equação que representa a saída desses neurônios é dada de forma vetorial pela Equação 4.1. Neste caso, a função de ativação é linear.

$$\{x_{E_1}, x_{E_2}, \dots, x_{E_n}\} = \{y_{E_1}, y_{E_2}, \dots, y_{E_n}\} \quad (4.1)$$

O sinal de entrada que os neurônios da camada intermediária recebem é representado de forma matricial pela Equação 4.2,

$$\{x_{I_1}, x_{I_2}, \dots, x_{I_n}\} = \{y_{E_1}, y_{E_2}, \dots, y_{E_n}\} \cdot \begin{bmatrix} w_{I_{11}} & w_{I_{12}} & \dots & w_{I_{1n}} \\ w_{I_{21}} & \ddots & \dots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ w_{I_{m1}} & \dots & \dots & w_{I_{mn}} \end{bmatrix} - \{\beta_1, \beta_2, \dots, \beta_n\} \quad (4.2)$$

Onde,  $w_{I_{mn}}$  representa a matriz de pesos sinápticos, cujos elementos denotam o valor do peso sináptico conectando os neurônios da camada de entrada com os neurônios da camada intermediária;  $y_E$  é o vetor dos sinais de saída dos neurônios da camada de entrada; e  $\beta_{I_n}$  é o vetor do limiar de ativação ou bias presente nos neurônios da camada intermediária.

Os sinais de saída dos neurônios que pertencem à camada intermediária são calculados a partir da Equação 4.3,

$$y_{I_k} = f(x_{I_k}) = \frac{1 - e^{-\phi_{I_k} x_{I_k}}}{1 + e^{-\phi_{I_k} x_{I_k}}} \quad (4.3)$$

Onde,  $y_{I_k}$  é a função de ativação dos neurônios pertencentes à camada intermediária da rede neural. Para este trabalho a função escolhida foi a tangente hiperbólica, que se caracteriza por ser contínua, diferenciável e seu intervalo é limitado entre os valores -1 e 1. Já  $\phi_{I_k}$  é o parâmetro da função de ativação.

Os sinais de entrada dos neurônios da camada de saída ( $x_{S_l}$ ) são calculados pela Equação 4.4 abaixo.

$$x_{S_l} = \{y_{I_1}, y_{I_2}, \dots, y_{I_k}\} \cdot \begin{bmatrix} w_{S_{11}} & w_{S_{12}} & \dots & w_{S_{1n}} \\ w_{S_{21}} & \ddots & \vdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ w_{S_{m1}} & \dots & \dots & w_{S_{mn}} \end{bmatrix} \quad (4.4)$$

Neste caso,  $w_{S_{mn}}$  é a matriz de pesos responsável pela ponderação dos valores entre os neurônios da camada intermediária e os da camada de saída e  $y_{I_k}$  é o vetor de saída dos

neurônios da camada intermediária. A função de ativação utilizada no cálculo da saída da rede é linear, portanto o sinal de saída ( $y_{S_i}$ ) pode ser descrito pela Equação 4.5 da seguinte forma:

$$y_{S_i} = x_{S_i} = \{y_{I_1}, y_{I_2}, \dots, y_{I_k}\} \cdot \begin{bmatrix} w_{S_{11}} & w_{S_{12}} & \dots & w_{S_{1n}} \\ w_{S_{21}} & \vdots & \vdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ w_{S_{m1}} & \dots & \dots & w_{S_{mn}} \end{bmatrix} \quad (4.5)$$

Ao final dessa iteração, o sinal de saída da rede corresponde ao sinal de controle  $u_x$  que atua na planta. Assim, o sistema responde com um sinal  $y_R$  que representa a resposta real do sistema a uma dada atuação do sinal de controle. Depois de obtido o  $y_R$  são efetuados os cálculos do Erro ( $E$ ) e do Índice de Desempenho ( $I_D$ ), pelas Equações 4.6 e 4.7, respectivamente.

$$E = y_{ref} - y_R \quad (4.6)$$

$$I_D = \frac{1}{2} \times E^2 \quad (4.7)$$

O cálculo do erro é dado pela diferença entre o valor de referência ( $y_{ref}$ ) e a resposta real ( $y_R$ ). A cada interação da RNA é necessário ajustar os parâmetros das matrizes de pesos sinápticos até que o sinal de saída da rede se aproxime ou se iguale ao valor de referência desejado para o sistema. Esta etapa é conhecida como Fase de Treinamento, descrita abaixo:

- **Fase de Treinamento:** esta etapa ocorre de forma supervisionada e a propagação da rede se dá na forma *backward* (para trás). É nesta etapa em que o algoritmo de Retropropagação do Erro, em conjunto com o método do gradiente descendente, é utilizado com o intuito de minimizar o erro e, consequentemente, o índice de desempenho.

A Equação 4.8 mostra, de forma matricial, como foi realizada a atualização da matriz de pesos que conecta os neurônios da camada de saída da rede aos da camada intermediária.

$$w_{S_{mn}} = \begin{bmatrix} w_{S_{11}} & w_{S_{12}} & \cdots & w_{S_{1n}} \\ w_{S_{21}} & \ddots & \vdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ w_{S_{m1}} & \cdots & \cdots & w_{S_{mn}} \end{bmatrix} + \mu \left( \begin{bmatrix} E_{S_1} \\ E_{S_2} \\ \vdots \\ E_{S_l} \end{bmatrix} \cdot \{y_{I_1}, y_{I_2}, \dots, y_{I_k}\} \right) \quad (4.8)$$

Onde  $\mu$  é o coeficiente que representa a taxa de aprendizagem da rede e  $E_s$  é a diferença gerada entre o valor de saída da rede e o valor de referência, ou seja, o erro.

As Equações 4.9 e 4.10 abaixo são utilizadas para efetuar o ajuste do valor do limiar de ativação (bias) e do parâmetro da função de ativação, respectivamente.

$$\beta_l = \{\beta_1, \beta_2, \dots, \beta_n\} + \mu \left( \begin{bmatrix} x_{S_1} \\ x_{S_2} \\ \vdots \\ x_{S_l} \end{bmatrix} \cdot \begin{bmatrix} w_{S_{11}} & w_{S_{12}} & \cdots & w_{S_{1n}} \\ w_{S_{21}} & \ddots & \vdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ w_{S_{m1}} & \cdots & \cdots & w_{S_{mn}} \end{bmatrix} \times \frac{\phi_{I_k}}{2} [1 - y_l^2] \right) \quad (4.9)$$

$$\phi_l = \{\phi_1, \phi_2, \dots, \phi_n\} + \mu \left( \begin{bmatrix} E_{S_1} \\ E_{S_2} \\ \vdots \\ E_{S_n} \end{bmatrix} \cdot \begin{bmatrix} w_{S_{11}} & w_{S_{12}} & \cdots & w_{S_{1n}} \\ w_{S_{21}} & \ddots & \vdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ w_{S_{m1}} & \cdots & \cdots & w_{S_{mn}} \end{bmatrix} \times \frac{x_l}{2} [1 - y_l^2] \right) \quad (4.10)$$

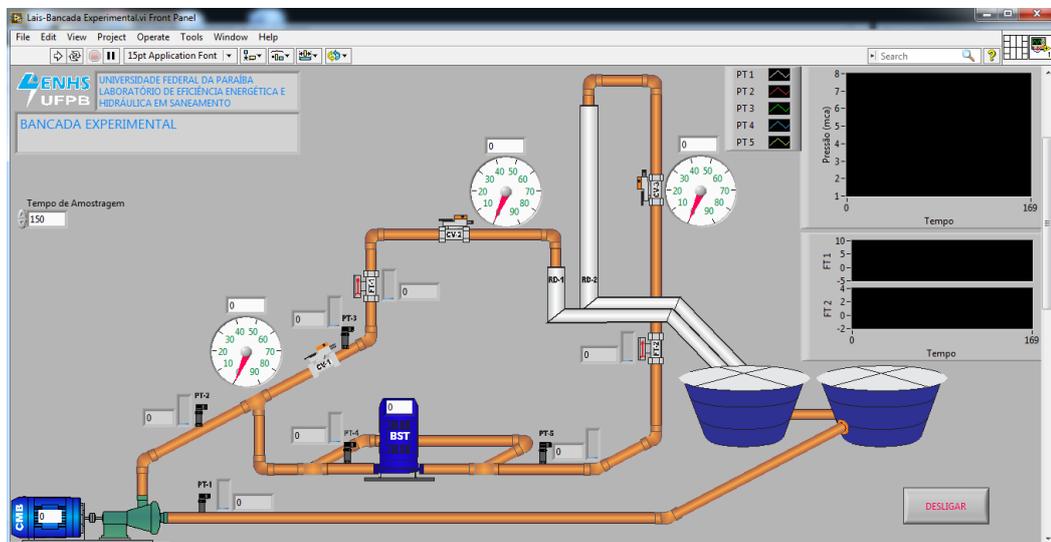
O ajuste dos pesos localizados entre as camadas de entrada e intermediária ocorre a partir da aplicação da Equação 4.11.

$$w_l = \begin{bmatrix} w_{I_{11}} & w_{I_{12}} & \cdots & w_{I_{1n}} \\ w_{I_{21}} & \ddots & \vdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ w_{I_{m1}} & \cdots & \cdots & w_{I_{mn}} \end{bmatrix} + \mu \left( \begin{bmatrix} E_{S_1} \\ E_{S_2} \\ \vdots \\ E_{S_n} \end{bmatrix} \cdot \begin{bmatrix} w_{S_{11}} & w_{S_{12}} & \cdots & w_{S_{1n}} \\ w_{S_{21}} & \ddots & \vdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ w_{S_{m1}} & \cdots & \cdots & w_{S_{mn}} \end{bmatrix} \times \frac{\phi_l}{2} [1 - y_l^2] x_l \right) \quad (4.11)$$

As equações descritas acima foram utilizadas para a elaboração do algoritmo da RNA como sistema de controle a ser implementado na bancada experimental. Para controlar as

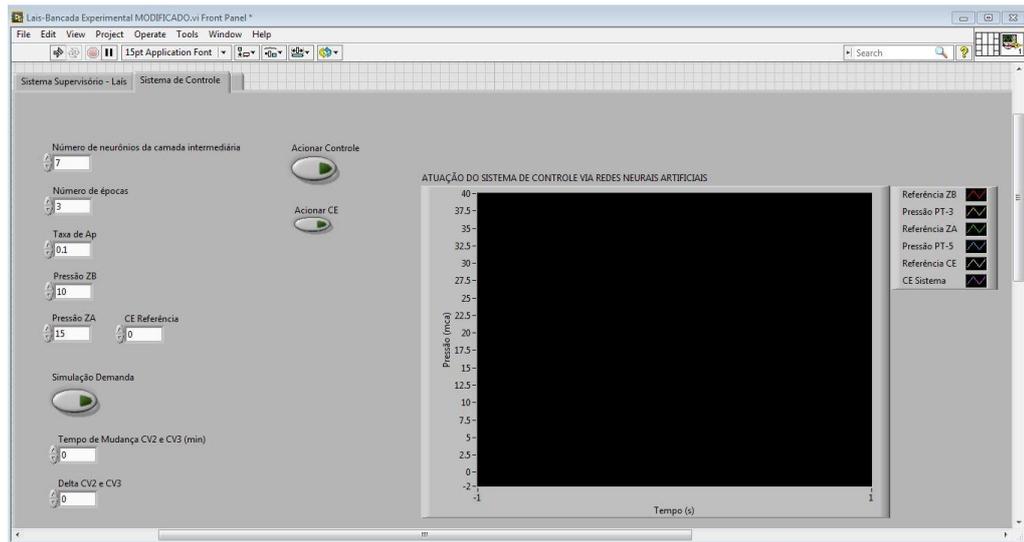
pressões nas zonas baixa e alta, o sinal de controle deve atuar nos elementos atuadores da bancada, dentre os quais: o inversor de frequência, que aciona o conjunto motor bomba (CMB); o inversor de frequência, que aciona o *booster* (BST); e a válvula proporcional CV1. Desta forma, a RNA precisa ter três neurônios na camada de saída, para que cada sinal de saída atue em um elemento de controle diferente.

Toda programação foi desenvolvida em Linguagem G na plataforma LabVIEW®. Com este fim, foi desenvolvido um supervisor para o acionamento e coleta dos sinais dos elementos atuadores da bancada experimental (conjunto motor bomba, *booster*, válvulas CV1, CV2 e CV3), assim como, visualização e coleta dos valores de pressão (PT1, PT2, PT3, PT4 e PT5) e vazão (FT1 e FT2). A Figura 4.9 apresenta a tela principal (denomina-se *Front Painel*) do LabVIEW® onde é realizado o acionamento e visualização dos valores reais mensurados de todos os elementos da bancada.



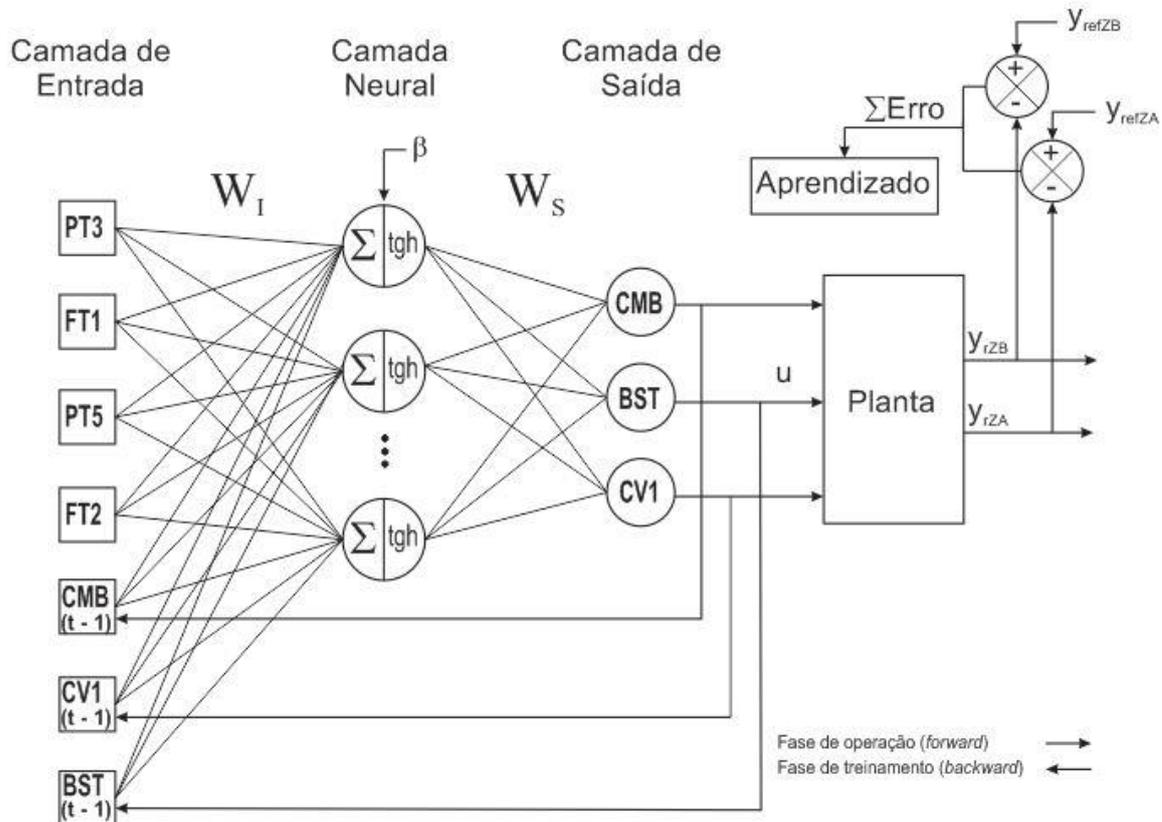
**Figura 5.9** Tela principal (*Front Painel*) do LabVIEW®.

A Figura 4.10 mostra a tela em que ocorre o acionamento do sistema de controle.



**Figura 5.10** Tela do LabVIEW® aonde o controlador é acionado.

A configuração da Rede Neural Artificial que representa o algoritmo projetado para este estudo é apresentada na Figura 4.11.



**Figura 5.11** Configuração da RNA utilizada como sistema de controle na bancada experimental.

A RNA com arquitetura recorrente utilizada neste trabalho é constituída por sete neurônios na camada de entrada, os quais são: valor da pressão na zona baixa (PT3); vazão medida na zona baixa (FT1); valor da pressão na zona alta (PT5); vazão mensurada na zona alta (FT2); atraso do sinal de controle do conjunto motor bomba ( $CMB_{(t-1)}$ ); valor de atraso do sinal de controle da válvula ( $CV1_{(t-1)}$ ); valor de atraso do sinal de controle do *booster* ( $BST_{(t-1)}$ ). Para esta camada a função de ativação é linear. As camadas de entrada e intermediária estão conectadas pela matriz de pesos  $W_I$ .

A camada intermediária possui sete neurônios (valor escolhido experimentalmente), e, devido a não-linearidade dos neurônios presentes nesta camada, a função de ativação utilizada foi a tangente hiperbólica. A ligação entre os neurônios da camada intermediária e os neurônios da camada de saída é efetuada pela matriz de pesos  $W_S$ .

A camada de saída da RNA, cuja função de ativação é linear, dispõe de três neurônios, os quais são: sinal de controle, que atua no inversor de frequência conectado ao conjunto motor bomba (CMB); sinal de controle, que atua na válvula CV1; e o sinal de controle, que atua no inversor de frequência associado ao *booster* (BST).

A seguir estão escritas as etapas da atuação do sistema de controle para manter as pressões, nas duas zonas de abastecimento da bancada experimental, sob as referências pré-definidas:

- **Etapa 1:** acionamento da bancada experimental para verificar os valores de pressão e vazão. Neste momento o valor da frequência da CMB e do BST é 0 Hz, e o ângulo de fechamento da CV1 é 0°;
- **Etapa 2:** acionamento do sistema de controle. Neste instante a camada de entrada da RNA recebe os sinais de pressão, vazão, frequência e ângulo de fechamento da válvula que são mensurados em tempo real;

As etapas descritas a seguir se referem a Fase de Operação (sentido *forward*):

- **Etapa 3:** os sinais da camada de entrada são calculados pela Equação 4.1 e em seguida pela Equação 4.2. A ponderação é feita usando a matriz de pesos sinápticos  $W_I$ , que na primeira iteração recebem valores aleatórios entre -1 e 1. Nesta etapa o limiar de ativação (bias) recebe um valor aleatório entre 0 e 1;

- **Etapa 4:** os sinais já ponderados saem da camada intermediária após passarem pela função de ativação, de acordo com a Equação 4.3;
- **Etapa 5:** os sinais que saem da camada intermediária são ponderados pela matriz de pesos sinápticos  $W_s$  pela Equação 4.4;
- **Etapa 6:** os sinais agora ponderados entram na camada de saída e passam por uma função de ativação linear, em que os três sinais de saída dessa camada (sinais de controle) são calculado pela Equação 4.5;
- **Etapa 7:** os sinais de controle atuam na planta do sistema, ou seja, esses sinais são enviados para os inversores de acionam o conjunto motor bomba e o *booster*, e para a válvula CV1;
- **Etapa 8:** neste momento é realizada uma comparação entre o valor da pressão de referência e o valor da pressão medida naquele instante na zona baixa e na zona alta. A partir desta análise é calculada diferença entre essas pressões pela Equação 4.6 (somatório dos erros). Ainda nesta etapa, a RNA verifica o índice de desempenho pela Equação 4.7;

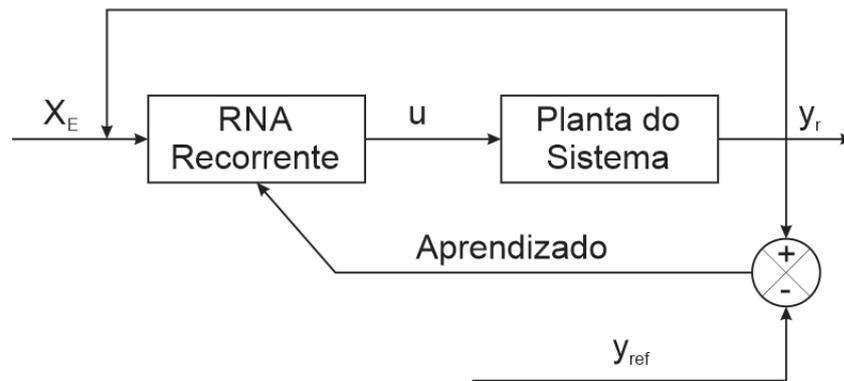
No intuito de minimizar o valor do seu índice de desempenho, ou seja, fazer com que o valor da pressão real se iguale a pressão de referência; a RNA entra na Fase de Treinamento (sentido *backward*) que ocorre de forma não supervisionada e *online*. Nesta etapa será realizado o ajuste dos pesos sinápticos e do limiar de ativação que na primeira iteração receberam valores aleatórios como descrito abaixo:

- **Etapa 9:** nesta etapa são calculados novos valores de pesos sinápticos para a matriz  $W_s$  pela Equação 4.8;
- **Etapa 10:** ocorre o ajuste dos valores do limiar de ativação (bias) e dos parâmetros da função de ativação tangente hiperbólica pelas Equações 4.9 e 4.10, respectivamente;
- **Etapa 11:** são calculados novos valores de peso sinápticos para a matriz  $W_l$ .

As etapas 9, 10 e 11 vão se repetir três vezes (número de épocas) com o objetivo de minimizar o erro calculado na saída da RNA. Ao término da Fase de Operação, a RNA atualiza seus sinais de entrada com os valores mensurados em tempo real e posteriormente repete todas as etapas descritas acima. A taxa de aprendizagem escolhida foi de 0,1. Todo

esse processo ocorre a cada iteração e o tempo de amostragem do sistema obtido experimentalmente foi de 150 ms.

A Figura 12 apresenta o diagrama de blocos que representa o sistema de controle descrito.



**Figura 5.12** Diagrama de blocos do sistema.

Para controlar as pressões nas zonas de consumo de forma a minimizar o gasto energético do sistema, foi utilizado, além do controle das pressões PT3 (Zona Baixa) e PT5 (Zona Alta), a redução do Consumo Específico de Energia (CE). Dessa forma, foi calculada a cada instante de tempo, a potência elétrica em corrente alternada para motores trifásicos consumida pelos elementos atuadores da bancada experimental, por meio da Equação 4.12,

$$P_e = \sqrt{3} \cdot V \cdot I \cdot \cos \varphi \quad (4.12)$$

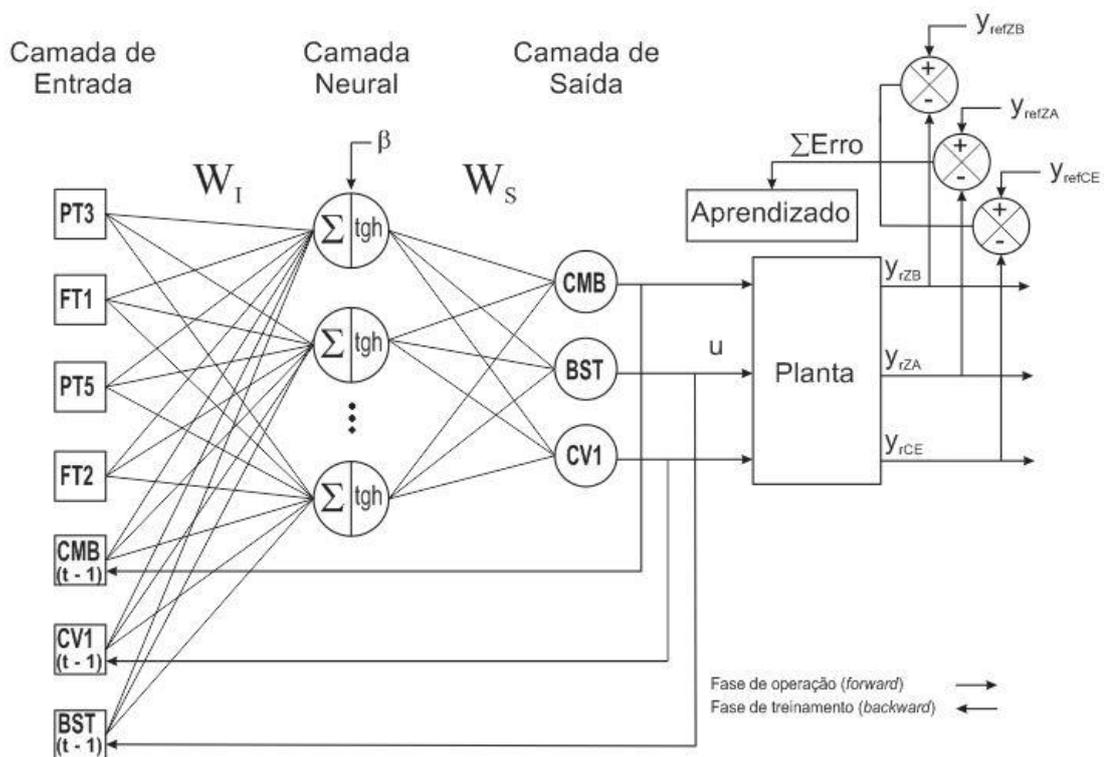
A partir de medições elétricas realizadas no sistema, foi mensurado um valor de tensão  $V$  equivalente a 368 Vca e para o fator de potência  $\cos \varphi$  um valor de 0,92. O valor médio da corrente  $I$  é mensurado constantemente quando a bancada experimental está em funcionamento. Esse valor da potência foi utilizado no cálculo do CE.

Segundo Otero, Gomes & Coura (2010, p.251), o cálculo do Consumo Específico de Energia é amplamente utilizado para avaliar a eficiência energética de sistemas de abastecimento através da relação entre a energia consumida e o volume bombeado (ver Equação 4.13).

$$CE = \frac{P_e \times tempo}{V_{ol}} \quad (4.13)$$

Onde  $P_e$  é o valor da potência elétrica consumida, em kW, e  $V_{ol}$  é o volume bombeado, em m<sup>3</sup>.

Portanto, quando o sistema de controle é acionado para controlar as pressões nas duas zonas de consumo e minimizar o custo energético, o controlador deve manter as pressões reais nos seus valores de referência, ao mesmo tempo em que faz o mesmo procedimento para o CE. Desse modo, a RNA deve controlar ao mesmo tempo três grandezas distintas: pressão na Zona Baixa (PT3), pressão na Zona Alta (PT5) e o Consumo Específico de Energia (CE). Nesta configuração a RNA projetada para o sistema é representada pela Figura 4.13.



**Figura 5.13** Configuração da RNA utilizada para controlar as pressões e minimizar o CE.

Para validar o desempenho do controlador projetado foram calculados os seguintes parâmetros: valor do sobressinal máximo, tempo de acomodação e o erro em regime permanente.

Segundo Nise (2002), o sobressinal é definido como sendo o valor máximo do pico da curva de resposta, cujo valor numérico em porcentagem pode ser calculado pela Equação 4.14,

$$M_p(\%) = \frac{c_{m\acute{a}x} - c_{final}}{c_{final}} \times 100 \quad (4.14)$$

Onde,  $c_{m\acute{a}x}$  é o valor máximo obtido no instante de pico e o termo  $c_{final}$  equivale ao valor final atingido.

O tempo necessário para que a curva de resposta consiga atingir valores dentro de uma faixa de 2% a 5%, em relação ao valor do estado estacionário, é definido como tempo de acomodação ou de assentamento. O erro em regime permanente é a diferença entre a saída do sistema em regime permanente e o valor de referência (OGATA, 2010).

Os testes realizados para validação do sistema de controle são apresentados no capítulo seguinte.

## CAPÍTULO 5

### RESULTADOS E DISCUSSÕES

Com o propósito de avaliar o sistema de controle desenvolvido, foram realizados oito experimentos, organizados em três grupos. Os ensaios Tipo 1 tem por objetivo atestar a eficiência do sistema de controle proposto; os Tipo 2 visam analisar o comportamento do controlador quando sujeito a perturbações na planta; já os Tipo 3 permitem verificar a acurácia do sistema de controle em relação ao valor de referência definido.

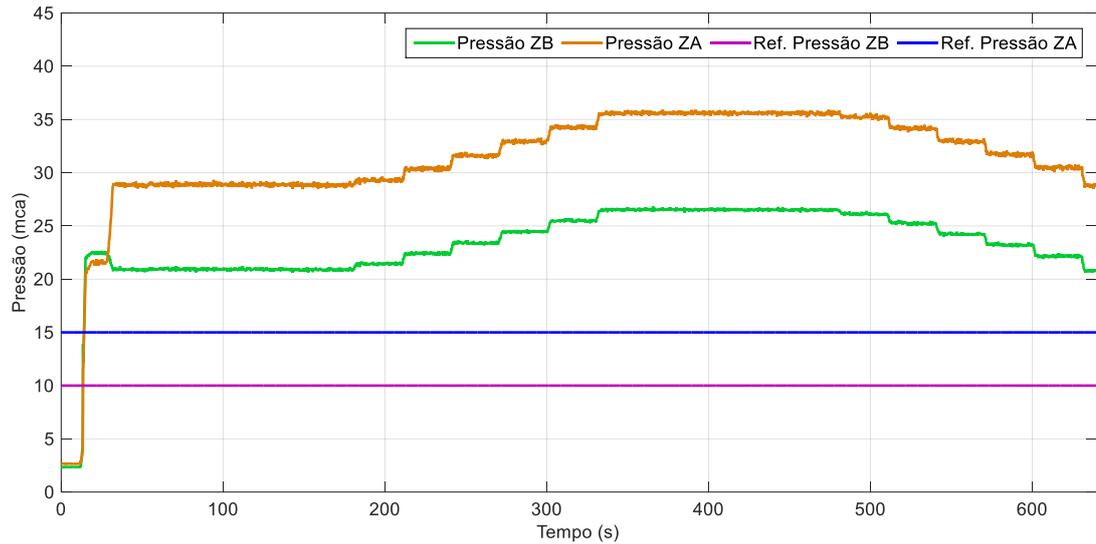
A seguir todos os ensaios realizados são descritos detalhadamente.

#### 5.1 Ensaio Tipo 1

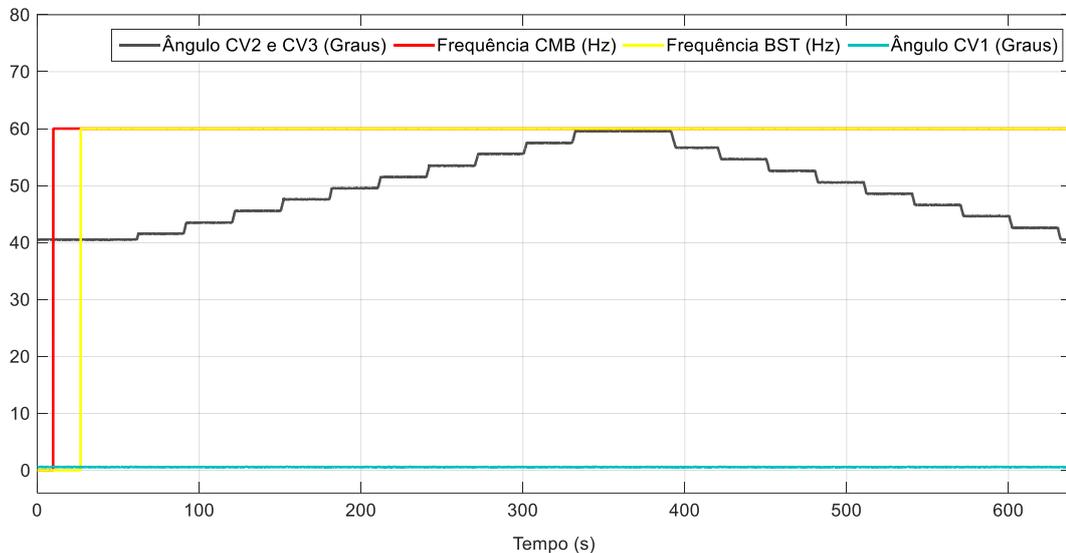
Os testes se iniciaram com a simulação da demanda máxima, com o ângulo de fechamento das válvulas CV2 e CV3 a 40°; posteriormente, esse ângulo sofreu acréscimos de 2° a cada 30 s até atingir 60°, que corresponde à demanda mínima. A partir da variação angular descrita, o sistema volta a simular a máxima demanda antes de finalizar o ensaio. Este ensaio se divide em três experimentos:

- **Ensaio Tipo 1.a:** neste primeiro ensaio não foi utilizado o sistema de controle. Os elementos atuadores – conjunto motor-bomba (CMB) e *booster* (BST) – foram acionados com a frequência nominal (60 Hz) e o ângulo de fechamento da válvula de controle CV1 foi mantido em 0° durante todo o teste.

Na Figura 5.1 é apresentado o comportamento das pressões nos pontos de medição do sistema para a zona baixa (ZB) e zona alta (ZA) durante o experimento. O objetivo deste ensaio foi verificar o comportamento do sistema sem a ação do controlador projetado, simulando assim o que ocorre em um sistema de abastecimento real sem controle de pressão. O comportamento dos elementos de controle (atuadores) é exposto na Figura 5.2.



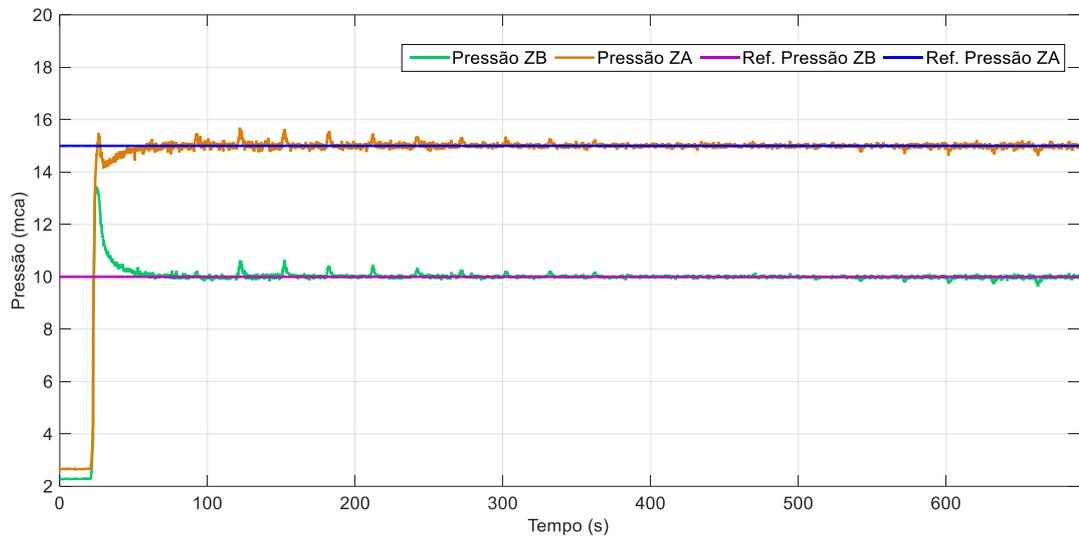
**Figura 6.1** Desempenho da variável pressão sem ação do controlador no Ensaio Tipo 1.a.



**Figura 6.2** Comportamento dos atuadores da bancada no Ensaio Tipo 1.a.

- **Ensaio Tipo 1.b:** esse ensaio foi realizado com as mesmas condições de operação (variação da demanda) do Ensaio Tipo 1.a, porém com o sistema de controle projetado atuando na planta, dessa forma, os elementos atuadores (conjunto motor-bomba, *booster* e a válvula CV1) foram acionados pelo controlador para manter a pressão na zona baixa (ZB) a 10 mca e na zona alta (ZA) a 15 mca.

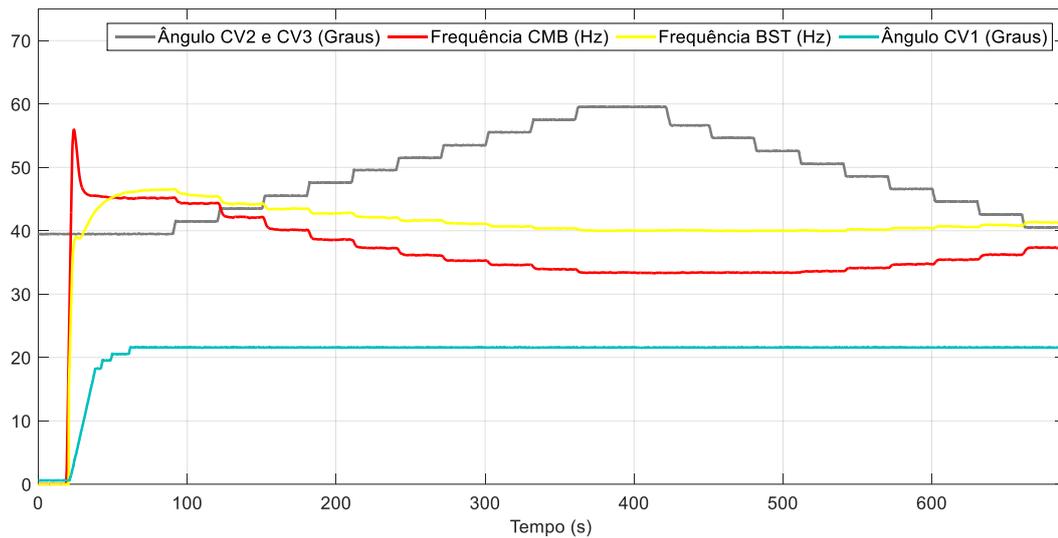
Na Figura 5.3 mostra-se o comportamento da variável controlada (pressão) nas zonas baixa e alta da bancada experimental.



**Figura 6.3** Desempenho da variável pressão sob ação do controlador no Ensaio Tipo 1.b.

Com o acionamento do controlador neural aos 21 segundos do experimento, durante a simulação da máxima demanda, foi calculado um valor de sobressinal de 34,5% (13,45 mca) na zona baixa e de 2,53% (15,37 mca) na zona alta. O tempo de assentamento para as duas zonas de consumo, nesta fase inicial, foi de aproximadamente 36 s. O valor do erro em regime permanente ficou dentro de uma faixa de  $\pm 0,34$  mca, para a zona alta, e  $\pm 0,22$  mca, para a zona baixa. Nesta situação o controlador projetado fez com que as pressões atingissem seus valores de referência, mesmo com a variação da demanda nas duas zonas de abastecimento.

Na Figura 5.4 apresenta-se o desempenho das variáveis de controle do sistema e a variação do ângulo de fechamento das válvulas proporcionais CV2 e CV3.



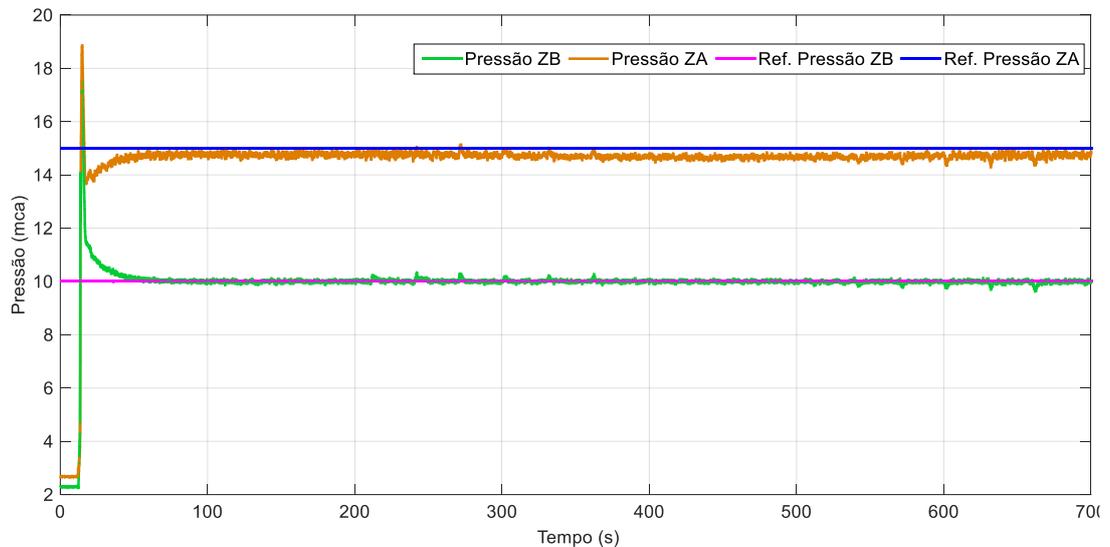
**Figura 6.4** Comportamento dos atuadores da bancada no Ensaio Tipo 1.b.

A partir da Figura 5.4, observa-se que no início da atuação do sistema de controle o valor de frequência, para o conjunto motor bomba, atinge um patamar próximo a 57 Hz e, para o *booster*, 39 Hz. Esses valores de frequência elevados ocorrem porque o controlador está atuando para diminuir a grande diferença que existe entre o valor de pressão mensurado e o valor de referência nas duas zonas abastecidas.

Quando o valor da pressão se aproxima da referência, o comportamento das frequências dos atuadores é alterado. Como esperado, os valores elevados da frequência correspondem aos intervalos em que a demanda do sistema é máxima, enquanto os valores mais baixos representam períodos em que a demanda é mínima. A atuação do controlador fez com que a válvula CV1 atingisse um ângulo de fechamento de 22° e assim permanecesse durante todo o ensaio.

- **Ensaio Tipo 1.c:** este experimento segue a mesma metodologia descrita no Ensaio Tipo 1.b, porém, neste caso, além de controlar a pressão nas duas zonas, foi imposto ao controlador a minimização do Consumo Específico de Energia (CE), cujo valor de referência para o CE foi 0 (zero) kWh/m<sup>3</sup>. A proposta principal deste ensaio não é promover somente o controle de pressão, mas aumentar a eficiência energética do sistema.

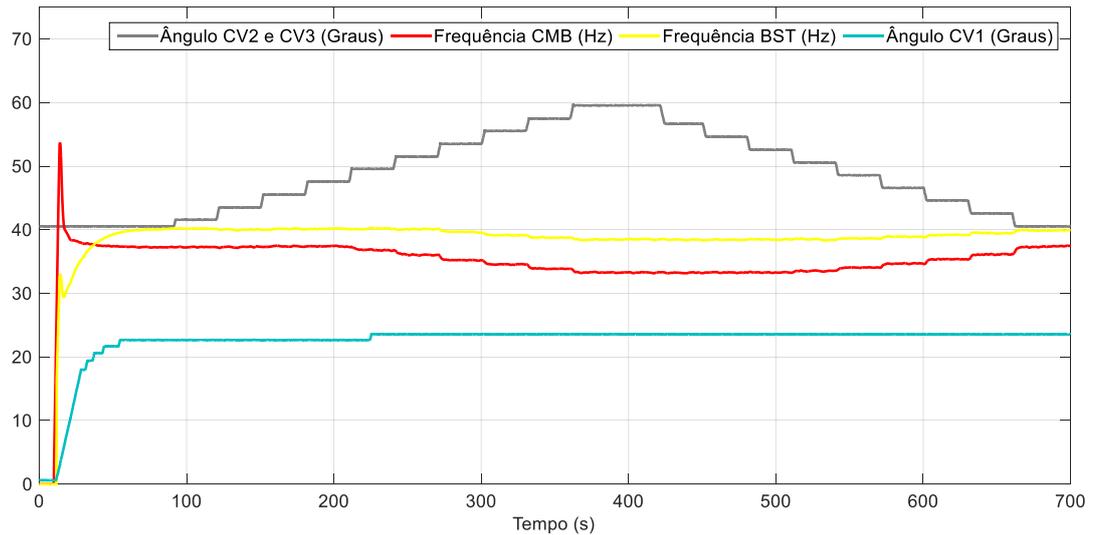
O comportamento da pressão nas zonas de consumo no decorrer do ensaio pode ser visualizado no gráfico da Figura 5.5.



**Figura 6.5** Desempenho da variável pressão sob ação do controlador no Ensaio Tipo 1.c.

Quando o sistema de controle foi acionado, a pressão real se igualou a pressão de referência, na zona baixa, em 43 segundos. O valor de sobressinal calculado para esta mesma zona foi de 75,3% (17,53 mca) e o erro em regime permanente medido para todo o ensaio foi de  $\pm 0,21$  mca. Em relação à zona alta, o sobressinal inicial foi de 25,73% (18,85 mca), neste caso, com a condição imposta de minimização do CE, independente da variação da demanda, a pressão real não atingiu o valor da pressão de referência, contabilizando um erro em regime permanente de aproximadamente  $\pm 0,78$  mca.

A Figura 5.6 apresenta a atuação dos elementos de controle (atuadores) da bancada experimental no decorrer do ensaio.



**Figura 6.6** Comportamento dos atuadores da bancada no Ensaio Tipo 1.c.

De acordo com a Figura 5.6, o valor da frequência do CMB chega a 53 Hz, enquanto para o BST esse valor é de 32 Hz no momento em que o controlador neural foi acionado. A atuação do sistema de controle na válvula fez com que seu ângulo variasse de 0° para 24° e assim permanecesse até a conclusão do ensaio. Vale ressaltar que o fechamento da válvula CV1 provoca uma perda de carga que repercute na redução da pressão a jusante da sua instalação (zona baixa), ao mesmo tempo, proporciona um ganho de pressão a montante, beneficiando a zona alta.

▪ **Análise comparativa entre os Ensaios Tipo 1:**

A Tabela 5.1 reúne as principais características dos três ensaios realizados, após a estabilização do sistema na simulação da máxima demanda, ou seja, quando os ângulos de fechamento das válvulas CV2 e CV3 assumem um valor de 40°.

**Tabela 6.1** Principais características do sistema na demanda máxima do Ensaio Tipo 1.

Ensaio	Intervalo (s)	Zona de Consumo	CMB (Hz)	BST (Hz)	CV1 (Graus)	Pressão (mca)	CE (kWh/m <sup>3</sup> )
Tipo 1.a	10 - 62	Z. B. Z. A.	60	60	0	20,8 28,6	0,265
Tipo 1.a	630 - 640	Z. B. Z. A.	60	60	0	20,8 28,6	0,277
Tipo 1.b	21 - 39	Z. B. Z. A.	45	46	22	10,3 15,5	0,221

Tipo 1.b	665 - 690	Z. B. Z. A.	37	41	22	10,3 15,05	0,253
Tipo 1.c	10 - 90	Z. B. Z. A.	37	40	23	10,1 14,70	0,218
Tipo 1.c	664 - 700	Z. B. Z. A.	37	39	24	10,08 14,77	0,234

Analisando a Tabela 5.1 nota-se que, quando o sistema funciona sem a ação do controlador neural (Ensaio Tipo 1.a), as pressões mensuradas não coincidem com a de referência, o mesmo não ocorre quando o sistema funciona sob ação do controlador. Durante a simulação da demanda máxima, o ensaio que se mostrou mais eficiente energeticamente, após a estabilização do sistema de controle, foi o Ensaio Tipo 1.c, o qual apresentou uma economia de 18,37% no indicador de consumo específico de energia, em relação ao ensaio Tipo 1.a e de 8,11%, se comparado ao ensaio Tipo 1.b.

As características do sistema durante a simulação da mínima demanda estão reunidas na Tabela 5.2.

**Tabela 6.2** Principais características do sistema na demanda mínima do Ensaio Tipo 1.

Ensaio	Intervalo (s)	Zona de Consumo	CMB (Hz)	BST (Hz)	CV1 (Graus)	Pressão (mca)	CE (kWh/m <sup>3</sup> )
Tipo 1.a	334 - 390	Z. B Z. A	60	60	0	26,5 35,7	0,377
Tipo 1.b	362 - 420	Z. B Z. A	33	40	22	10,02 15,04	0,328
Tipo 1.c	362 - 420	Z. B Z. A	33	38	24	10,03 14,60	0,320

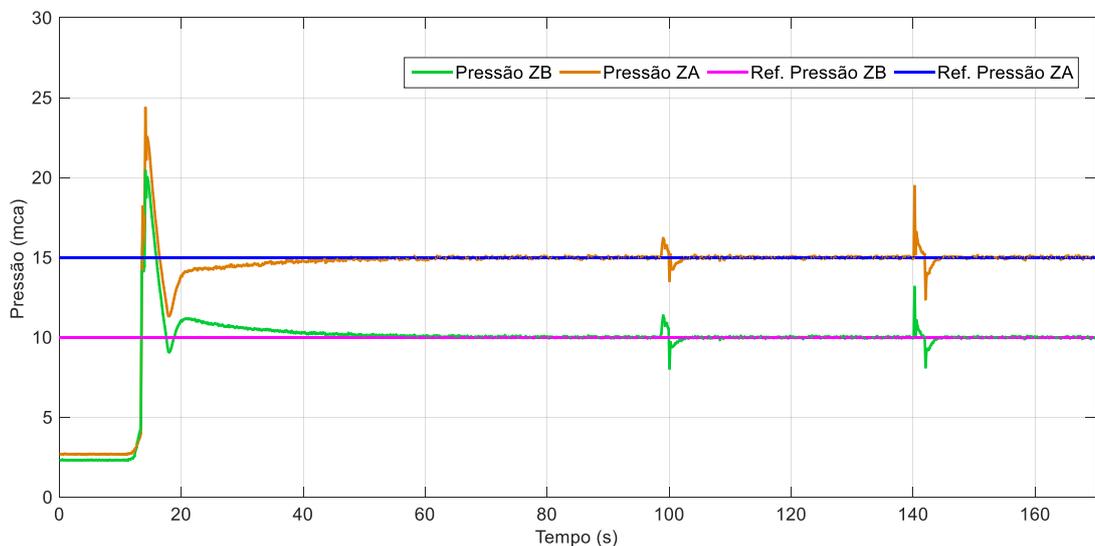
Para esta situação, observa-se (ver Tabela 5.2) que, quando a bancada experimental opera sem a ação do controlador (Ensaio Tipo 1.a), durante a simulação da mínima demanda, a pressão na zona baixa excedeu o valor de referência (10 mca) em 165% (26,5 mca). Para a zona alta, esse valor foi de 138% (35,7 mca). Em relação à economia de energia por volume bombeado, o ensaio Tipo 1.c (controle da pressão com a minimização do CE) apresentou uma redução de 17,81%, quando comparado ao ensaio Tipo 1.a, e de 2,5%, em relação ao ensaio Tipo 1.b (controle da pressão).

## 5.2 Ensaio Tipo 2:

Foram realizados quatro experimentos com a finalidade de testar a eficiência do controlador neural projetado em meio a perturbações no sistema. Em todos os ensaios a pressão deve ser controlada a 10 mca na Zona Baixa (ZB) e 15 mca na Zona Alta (ZA). Após a estabilização do sistema sob a atuação do controlador, foi realizada uma perturbação, primeiro na Zona Baixa, através do fechamento do registro, e, em seguida, a abertura deste mesmo acessório localizado próximo ao ramal de descarga desta zona. Depois da estabilização do sistema, uma nova perturbação foi introduzida repetindo-se o procedimento anterior, porém desta vez no ramal de descarga da Zona Alta.

- **Ensaio Tipo 2.a:** este ensaio ocorreu durante a simulação da demanda mínima nas zonas de consumo, para isto, o ângulo de fechamento das válvulas CV2 e CV3 permaneceram em 60°.

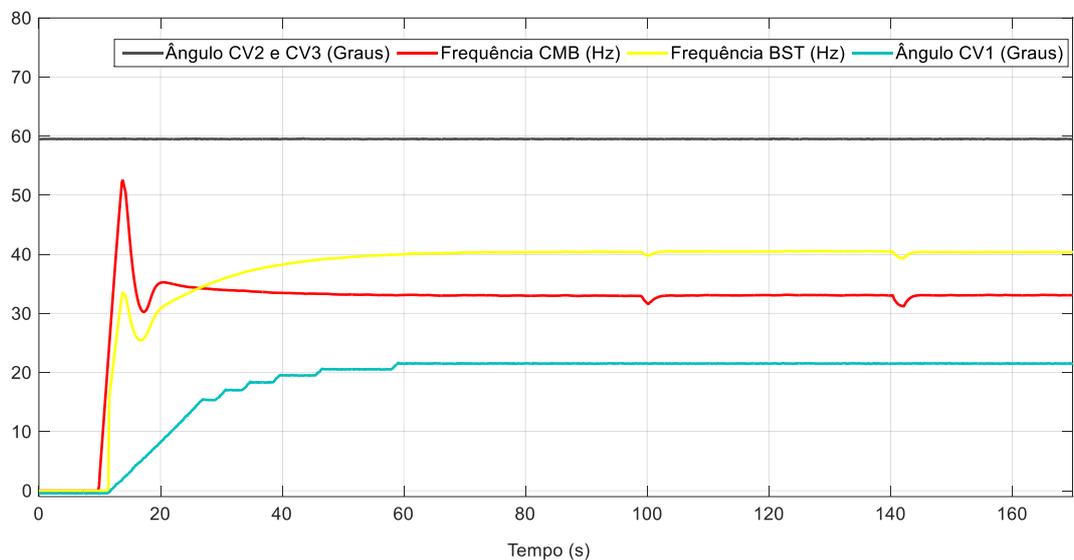
A Figura 5.7 retrata o comportamento da variável a ser controlada (pressão) durante todo o ensaio para as zonas Baixa e Alta. Nota-se que as pressões se estabilizaram nos valores de referência escolhidos para as zonas Baixa e Alta em, aproximadamente, 33 segundos. Nesta fase inicial, o sobressinal calculado para a Zona Baixa foi de 100% (20 mca), enquanto para a Zona Alta esse parâmetro foi de 60% (24 mca).



**Figura 6.7** Desempenho da variável pressão sob ação do controlador no Ensaio Tipo 2.a.

Quando o sistema sofreu a primeira perturbação na Zona Baixa, as pressões nas duas zonas saíram dos valores de referência, mas logo em seguida, com a atuação do controlador, voltaram para os patamares pré-definidos. Nesta etapa, a RNA já tem todos os seus pesos calculados pelo treinamento *online*, logo se percebe uma otimização no tempo de assentamento e ausência de sobressinal. O mesmo fato ocorreu quando o sistema foi submetido à segunda perturbação na Zona Alta.

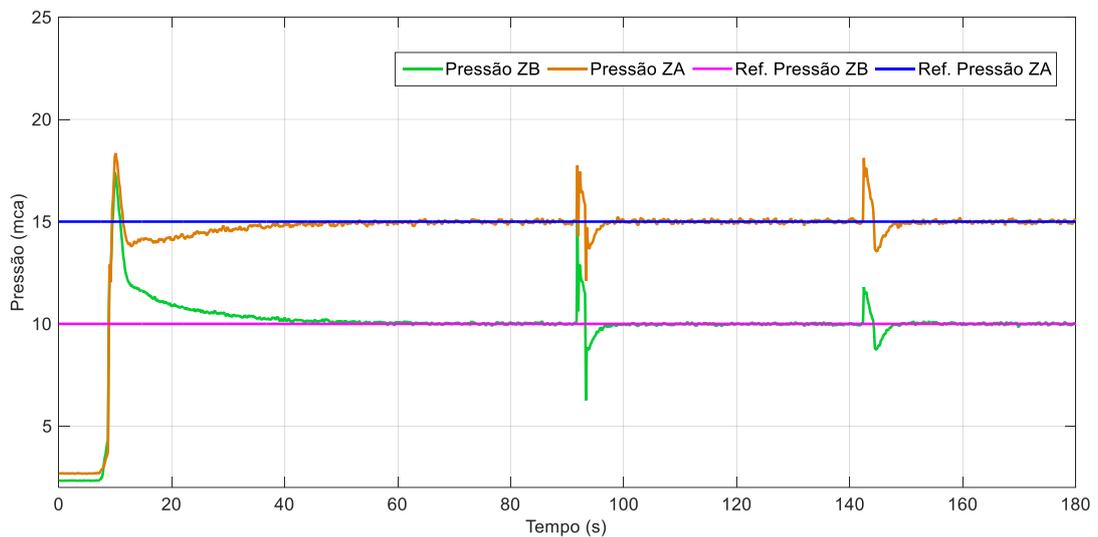
Após a primeira perturbação, que ocorreu na Zona Baixa, as pressões nas duas zonas voltaram aos seus valores de referência em apenas 5 segundos. O tempo de assentamento calculado após a segunda perturbação, que dessa vez ocorreu na Zona Alta, também foi de 5 segundos. O erro em regime permanente para as duas regiões de consumo permaneceu dentro de uma faixa de  $\pm 0,18$  mca. A atuação dos elementos de controle é apresentada na Figura 5.8.



**Figura 6.8** Comportamento dos atuadores da bancada no Ensaio Tipo 2.a.

Quando o controlador é acionado, o valor de frequência do conjunto motor bomba é elevado para 53 Hz e o do *booster* para 33 Hz. Com a atuação da válvula CV1, a frequência de rotação do CMB é reduzida para 34 Hz e a do *booster* é elevada para 40Hz. A válvula CV1 alterou seu ângulo de fechamento de 0° para 20° nos primeiros 60 segundos e posteriormente para 21°, permanecendo assim até o final do experimento.

- **Ensaio Tipo 2.b:** durante esse experimento os ângulos de fechamento das válvulas CV2 e CV3 permaneceram em 40°, simulando a máxima demanda para as duas zonas de consumo. O sistema foi submetido às mesmas perturbações do Ensaio Tipo 2.a. O comportamento das pressões nos pontos de medição do sistema são apresentadas na Figura 5.9.



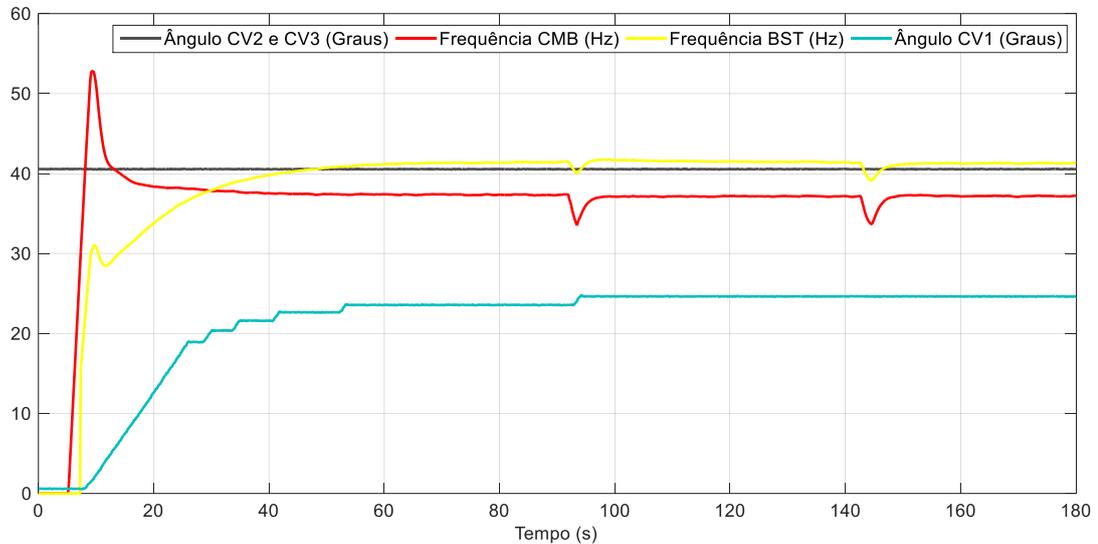
**Figura 6.9** Desempenho da variável pressão sob ação do controlador no Ensaio Tipo 2.b.

Assim como no ensaio Tipo 2.a, a atuação do controlador neural foi satisfatória e as pressões mensuradas se igualaram as pressões estimadas nas duas zonas de abastecimento. O erro em regime permanente foi de  $\pm 0,18$  mca.

No início do ensaio, a RNA ainda não tem seus valores de pesos treinados, resultando em um valor de sobressinal alto. Para a Zona Baixa, esse valor de ultrapassagem em relação à pressão de referência chega a 70% (17 mca), enquanto na região alta esse valor corresponde a 20% (18 mca). Para essa mesma situação, o tempo de assentamento para ambas as zonas de consumo foi de 42 segundos. Diante das perturbações, o sistema de controle consegue fazer com que a pressão medida na zona de consumo volte ao seu valor de referência em 7 segundos.

O comportamento dos elementos atuadores da bancada experimental pode ser observado na Figura 5.10. Neste ensaio, após o acionamento do controlador e estabilização do sistema nas pressões estimadas, o conjunto motor bomba assume uma frequência de 38 Hz enquanto o *booster* atua com um valor de 41 Hz. Esses valores

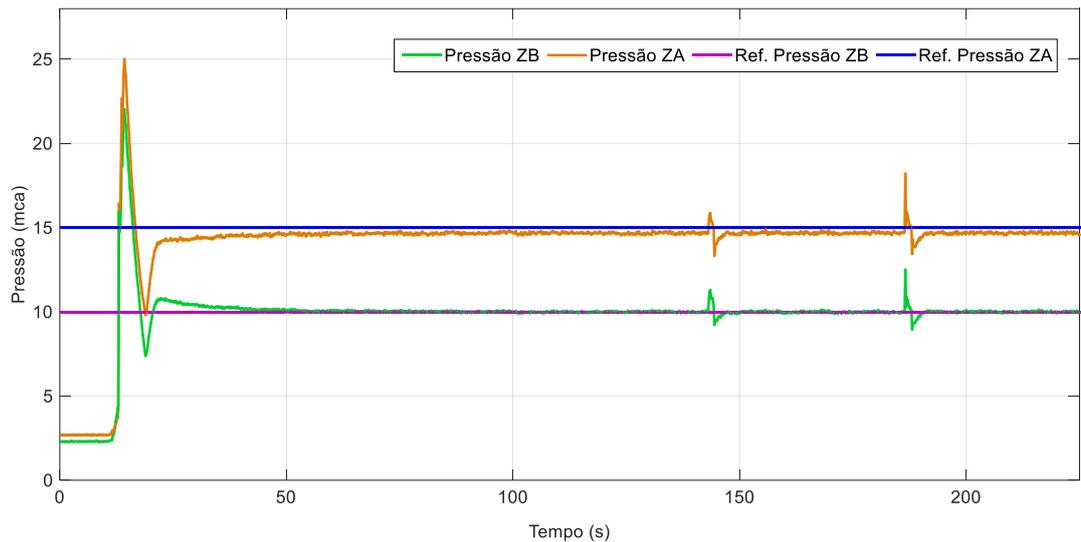
são alterados no momento em que o sistema sofre as perturbações, mas logo em seguida os atuadores assumem os valores citados anteriormente. Inicialmente, a válvula CV1 alterou seu ângulo de fechamento de  $0^\circ$  para  $23^\circ$ ; após a primeira perturbação esse ângulo passou a ser  $25^\circ$  e assim permaneceu durante todo o ensaio.



**Figura 6.10** Comportamento dos atuadores da bancada no Ensaio Tipo 2.b.

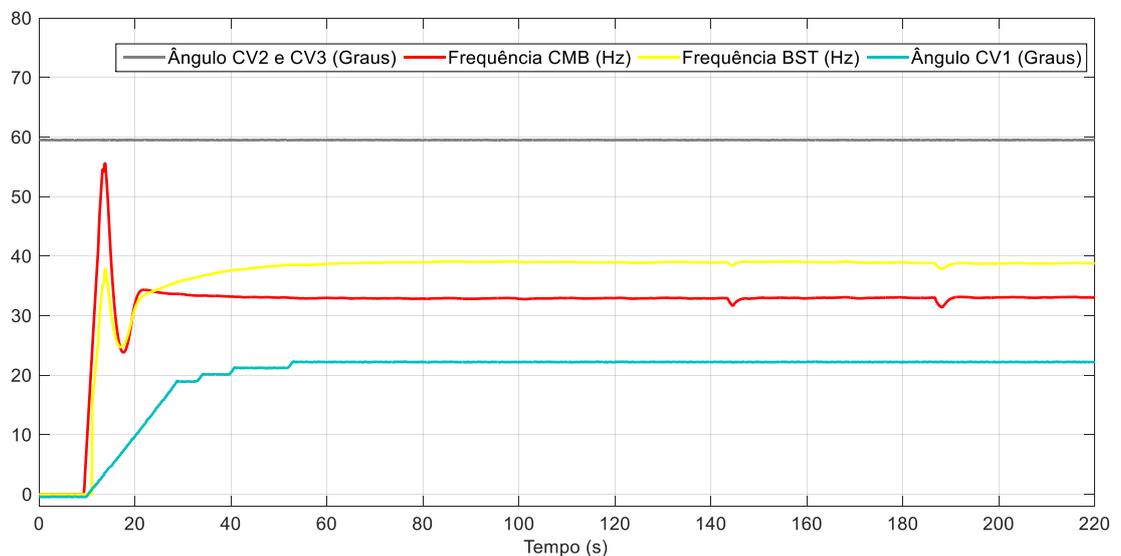
- **Ensaio Tipo 2.c:** este ensaio segue a mesma metodologia do experimento Tipo 2.a, com o acréscimo do Consumo Específico de Energia (CE) como variável de decisão do controlador, a fim de buscar a otimização energética do sistema.

O monitoramento das pressões das duas regiões de consumo pode ser observado na Figura 5.11.



**Figura 6.11** Desempenho da variável pressão sob ação do controlador no Ensaio Tipo 2.c.

Analisando o gráfico anterior, observa-se que após um sobressinal de 120% (22 mca), a pressão na Zona Baixa foi controlada de acordo com o valor de referência, ou seja, 10 mca em apenas 35 segundos. Mesmo após as perturbações sofridas pelo sistema, a pressão volta a ser controlada no valor escolhido em 6 segundos, sem a presença de sobressinal. Em relação à Zona Alta, a pressão real fica próxima da pressão estimada (15 mca), apresentando um erro em regime permanente de 0,46 mca durante todo o ensaio. O comportamento das variáveis de controle durante o experimento pode ser visto na Figura 5.12.

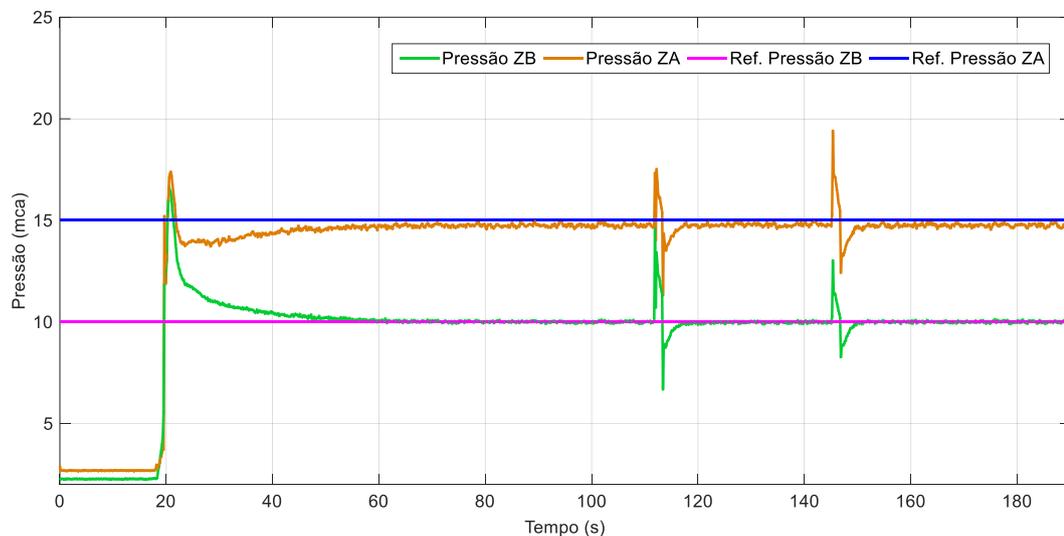


**Figura 6.12** Comportamento dos atuadores da bancada no Ensaio Tipo 2.c.

Nesta situação, durante o regime permanente, com a busca da eficiência energética pelo controlador neural, a frequência de rotação do CMB se manteve 32 Hz e do *booster*, 39 Hz. Após a estabilização do sistema, a angulação da válvula CV1 permaneceu em 22°.

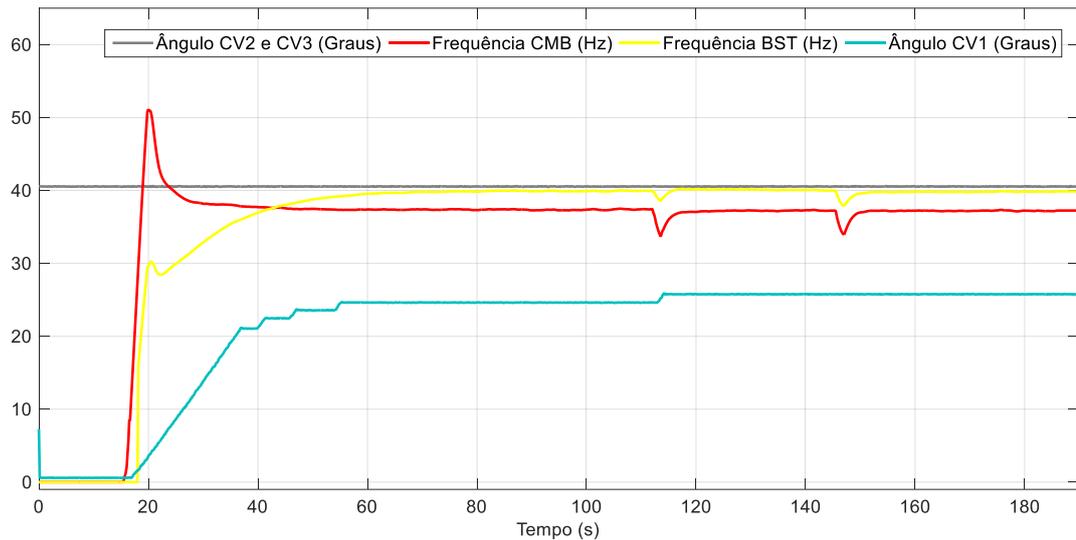
- **Ensaio Tipo 2.d:** este ensaio é semelhante ao experimento Tipo 2.c, porém ocorre durante a simulação da demanda máxima, desta forma, o ângulo de fechamento das válvulas CV2 e CV3 assume um valor de 40°.

O comportamento das pressões na Zona Baixa e na Zona Alta durante esse ensaio é apresentado na Figura 5.13.



**Figura 6.13** Desempenho da variável pressão sob ação do controlador no Ensaio Tipo 2.d.

Nesta conjuntura, a pressão real mensurada se igualou a pressão de referência na Zona Baixa, durante o regime permanente, em 41 segundos. Após as perturbações sofridas, as pressões se igualaram em 6 segundos. Entretanto, na Zona Alta houve um erro de 0,37 mca entre o valor estimado e o valor real da pressão em regime permanente. Na fase inicial do ensaio (acionamento do controlador) há um sobressinal de 66% (16,65 mca), na Zona Baixa, e de 15,93% (17,39 mca), na Zona Alta. A Figura 5.14 exhibe o comportamento, ao longo do tempo, das variáveis de controle, e a simulação da demanda deste ensaio.



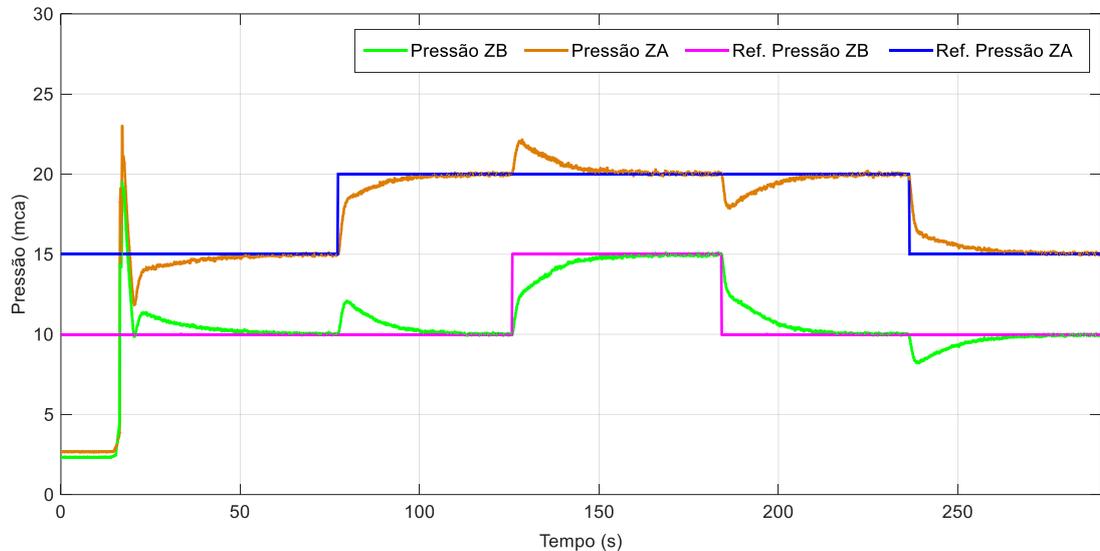
**Figura 6.14** Comportamento dos atuadores da bancada no Ensaio Tipo 2.d.

Para este cenário de controle com otimização energética, a frequência do conjunto motor bomba, após a estabilização do sistema, se fixou em 37,38 Hz e assim permaneceu até a primeira perturbação sofrida, quando esse valor passou a ser 37,20 Hz. No caso do *booster*, essa frequência foi de 40 Hz. A alteração angular da válvula CV1 ocorreu em uma faixa de 0° a 25°, após a primeira perturbação sofrida pelo sistema, o ângulo de fechamento da válvula CV1 foi alterado para 26°.

### 5.3 Ensaio Tipo 3:

O principal objetivo deste experimento foi testar a eficiência do controlador neural projetado durante a alteração do valor de referência proposto. Inicialmente, a RNA deve controlar a pressão na Zona Baixa a 10 mca, ao mesmo tempo em que controla a pressão na Zona Alta a 15 mca. Passados alguns segundos, esses valores de referência são alterados para 20 mca, na Zona Alta, e 15 mca, na Zona Baixa; posteriormente, o sistema de controle deve controlar a pressão na Zona Alta a 15 mca e a 10 mca, na Zona Baixa. Todo o teste ocorreu durante a demanda mínima, para ambas as zonas de consumo, ou seja, os ângulos de fechamento das válvulas CV2 e CV3 assumem o valor de 60°.

A Figura 5.15 apresenta o comportamento das pressões a serem controladas nas duas zonas de consumo. A Tabela 5.3 apresenta os parâmetros calculados para cada alteração do valor de referência nas duas zonas de consumo.



**Figura 6.15** Desempenho da variável pressão sob ação do controlador no Ensaio Tipo 3.

**Tabela 6.3** Parâmetros de controle calculados do ensaio Tipo 3.

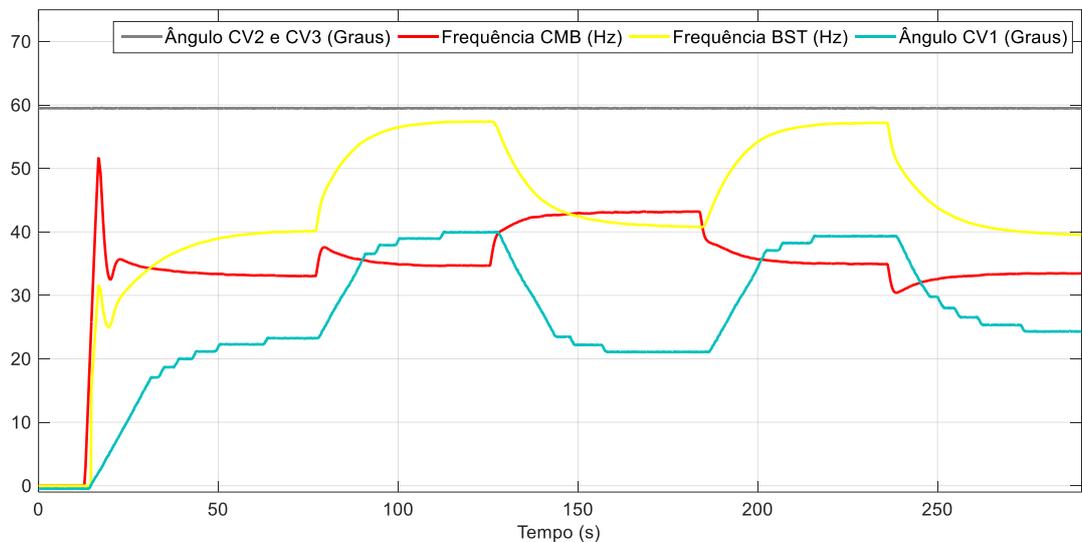
Tempo (s)	Valor de Referência (mca)	Zona de Consumo	Sobressinal (%)	Tempo de Assentamento (s)	Erro em Regime Permanente (mca)
0 – 77	15	ZA	53	42	$\pm 0,17$
	10	ZB	90	42	$\pm 0,14$
77 – 126	20	ZA	-	32	$\pm 0,19$
	10	ZB	20	32	$\pm 0,14$
126 – 184	20	ZA	10,03	29	$\pm 0,21$
	15	ZB	-	40	$\pm 0,16$
184 – 236	20	ZA	10	27	$\pm 0,20$
	10	ZB	-	31	$\pm 0,15$
236 – 290	15	ZA	-	30	$\pm 0,16$
	10	ZB	17,4	38	$\pm 0,15$

Legenda: (-) Ausência de sobressinal.

Observa-se que 42 segundos após o acionamento do controlador, a pressão na Zona Alta atinge seu valor de referência (15 mca) e o mesmo ocorre com a Zona Baixa (10 mca). Nesta fase inicial, o sistema atinge seu maior valor de sobressinal, sendo de 53% (23 mca), na Zona Alta, e 90% (19 mca), na Zona Baixa. Já o erro em regime permanente não ultrapassa a faixa de  $\pm 0,21$  mca para todas as alterações realizadas no valor de referência das duas zonas de consumo. Este fato comprova que o sistema de

controle se mostrou eficiente ao controlar as pressões nas duas zonas em seus valores de referência. Nota-se ainda que, ao alterar o valor de referência de uma zona de consumo, há um distúrbio na outra zona abastecida, demonstrando que o sistema é acoplado, ou seja, que ajustes feitos em uma das zonas interferem na outra e vice-versa. Esse fato demonstra a complexidade do controle de pressão simultânea dos pontos de medição da bancada experimental, e aponta para a aplicação de sistemas de controle mais robustos.

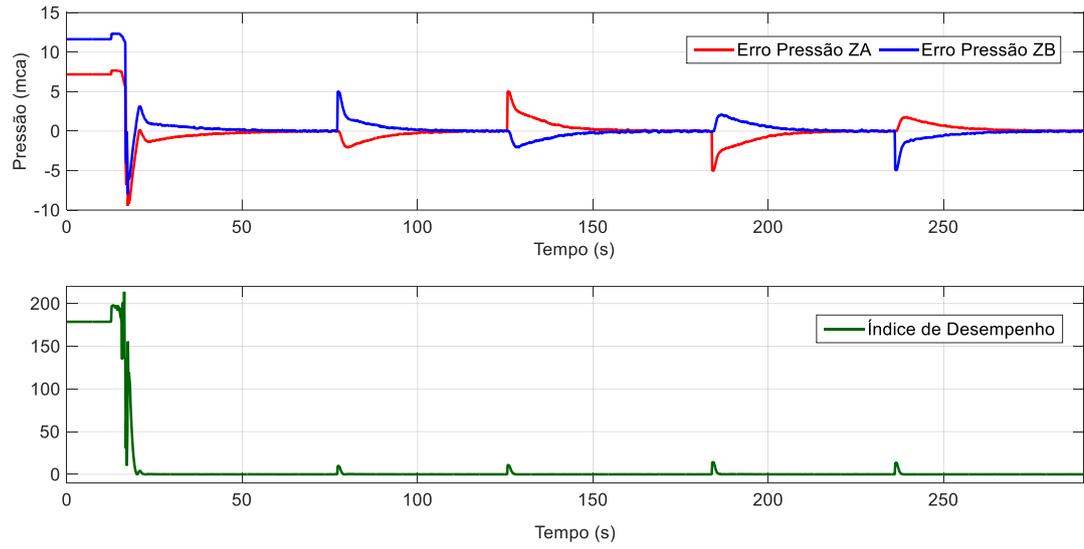
A Figura 5.16 exibe o comportamento das variáveis de controle (Frequência CMB, Frequência BST e Ângulo CV1), além do ângulo de fechamento das válvulas CV2 e CV3, simulando a demanda mínima nas duas zonas abastecidas.



**Figura 6.16** Comportamento dos atuadores da bancada no Ensaio Tipo 3.

Aos 13 segundos, momento em que o controlador é acionado, a frequência do CMB vai para 51,65 Hz e a do BST para 31,61 Hz, a fim de tentar reduzir o erro entre as pressões mensuradas e as de referência. Sempre que a pressão de referência é alterada nas zonas de consumo, percebe-se que é necessário um ajuste nas três variáveis de controle, de forma a controlar as pressões em seus valores de referência atuais.

O monitoramento da variável erro e o índice de desempenho calculado pela Rede Neural Artificial, para as duas regiões de consumo, são apresentados na Figura 5.17.



**Figura 6.17** Monitoramento dos parâmetros Erro da Pressão (nas zonas Baixa e Alta) e Índice de Desempenho da RNA.

## CAPÍTULO 6

### CONCLUSÕES

O principal objetivo desta tese foi projetar e implementar em LabVIEW® uma Rede Neural Artificial com arquitetura recorrente, que funcionasse como um sistema de controle direto, a fim de manter a pressão de serviço em pontos de uma rede de abastecimento de água, sob um valor de referência. O controlador desenvolvido foi aplicado em uma bancada experimental que simula o abastecimento de um sistema com duas regiões com topografias diferenciadas. Como este propósito, o controlador atuou em três elementos da bancada experimental: um conjunto motor bomba, um *booster* e uma válvula proporcional, que para esta finalidade, atuou como uma válvula redutora de pressão. Além disso, vale salientar que a RNA foi aplicada de forma direta, ou seja, não houve um treinamento supervisionado dos seus pesos sinápticos, sendo assim, todo o treinamento da rede aconteceu de forma *online*. A atuação do controlador neural sobre os sistemas de bombeamento foi realizada por meio programação em LabVIEW® em conjunto com as *interfaces* de aquisição de dados, que só foi possível com a utilização dos inversores de frequência para variar a velocidade de rotação dos motores de acionamento das bombas.

Com o propósito de avaliar o desempenho da RNA no controle da pressão, esta foi aplicada sob três cenários distintos. No primeiro, o objetivo foi controlar a pressão a 10 mca, na Zona Baixa, e a 15 mca, na Zona Alta, enquanto a demanda destas duas regiões foi alterada; o segundo teste teve por finalidade controlar a pressão nas mesmas referências do primeiro ensaio, porém foram geradas adicionalmente perturbações ao sistema, através do fechamento e abertura de registros localizados no ramal de descarga de cada zona; por fim, o terceiro ensaio consistiu em atribuir diversos valores de referência em cada zona abastecida. Em todos os três tipos de ensaio, também foram realizados experimentos que o controlador deveria, além de controlar a pressão e minimizar o Consumo Específico de Energia (CE) a 0 (zero) kWh/m<sup>3</sup>.

A análise do desempenho do controlador projetado foi realizada a partir do cálculo de parâmetros como sobressinal, tempo de assentamento e erro em regime permanente, além da aferição do Consumo Específico de Energia. Em todos os testes experimentais, a RNA controlou as pressões medidas no valor de referência em menos de 45 segundos, e os ensaios

não apresentaram sobressinal após o treinamento *online* da RNA. Além disso, o erro em regime permanente se manteve em uma faixa inferior a  $\pm 0,78$  mca.

Nos ensaios em que o sistema foi controlado em conjunto com a otimização do CE, durante a simulação da variação da demanda, a redução do consumo específico de energia chegou a 18,37%, em relação ao ensaio sem controle de pressão, e a 8,11%, em comparação ao experimento no qual a RNA controlou apenas a pressão na demanda máxima. Durante a simulação da mínima demanda, o controlador com minimização do CE garantiu uma redução no consumo energético de 17,81%, em relação ao ensaio com ausência da atuação do controlador, e de 2,5%, quando comparado ao caso em que a RNA se limitou ao controle da pressão.

A partir dos resultados pode-se concluir que a RNA com arquitetura recorrente projetada para atuar como um sistema de controle desempenhou sua função de forma eficiente, independentemente da variação da demanda do sistema, das perturbações externas e das mudanças bruscas no valor de referência. Além disso, nos ensaios em que RNA deveria controlar a pressão e simultaneamente minimizar o Consumo Específico de Energia, constatou-se uma redução energética significativa no sistema.

Portanto, esta pesquisa científica comprova que, ao automatizar um sistema de abastecimento de água utilizando um sistema de controle, são gerados inúmeros benefícios como: otimização operacional; garantia das pressões de serviço exigidas; redução das perdas de água, em decorrência do controle das pressões; e redução do consumo energético dos sistemas de bombeamento, podendo assim ser aplicada em casos reais. Em consonância com outras pesquisas recentes que aplicaram controladores neurais, espera-se que o controlador desenvolvido possa ser aplicado a sistemas reais similares, em virtude, principalmente, da capacidade de aprendizado em tempo real do sistema de controle proposto.

Como sugestões de trabalhos futuros para complementar essa pesquisa pode ser realizada uma modelagem matemática do sistema objeto desse estudo, além de controlar as pressões na rede utilizando algoritmos genéticos.

## REFERÊNCIAS

ALLEGRO MICROSYSTEMS LLC. **Fully Integrated, Hall Effect-Based Linear Current Sensor IC with 2.1 kVRMS Isolation and a Low-Resistance Current Conductor**. USA.

ANTSAKLIS, P. J.; PASSINO, K. M. **Towards intelligent autonomy control systems: architecture and fundamental issues**. *Journal of Intelligent and Robotic Systems*. v. 1, p. 315–342, 1989.

BARROS FILHO, E. G.; SALVINO, L. R.; BEZERRA, S. T. M.; SALVINO, M. M.; GOMES, H. P. **Intelligent system for control of water distribution networks**. *Water Science & Technology: Water Supply*, p. 1-12, 2017.

BELIMO AIRCONTROLS INC. **Visual Instruction Sheet LRB24..., LRX24..., ARB24..., ARX24...** . USA.

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

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

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

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

CASSANDRA, A. N.; FABIANA, V. K. O. M.; DANIELLE, C. S. S. **Automação como ferramenta de análise de eficiência energética**. In: Congresso Brasileiro de Automática, 20., 2014, Belo Horizonte, MG, Brasil, **Anais...**

CEMBRANO, G.; WELLS, G.; QUEVEDO, J.; PÉREZ, R.; ARGELAGUET, R. **Optimal control of a water distribution network in a supervisory control system.** *Control Engineering Practice*, v. 8, p. 1177–1188, 2000.

CHANDRA, P.; SINGH, Y. **An activation function adapting training algorithm for sigmoidal feedforward networks.** *Neurocomputing*, v. 61, no. 7, p. 429-443, 2004.

CHENGSONG, D.; LIJUN, C. **Self-adaptative fuzzy pid controllet for water supply system.** *IEEE Computer Society*, p. 311–314, 2010.

CUNHA, E. N.; DÓREA, C. E. T. **Modeling, simulation and control of water supply system.** *IEEE First Int Smart Cities Conf*, p. 1-6, 2015.

ELBELKACEMI, M.; LACHHAB, A.; LIMOURI, M.; DAHHOU, B.; ESSAID, A. **Adaptive control of a water supply system.** *Journal of Control Engineering Practice*, v. 9, p. 343–349, 2001.

ELKER, I.; KARA, T. **Operation and control of a water supply system.** *ISA Transactions*, v. 42, p. 461–473, 2003.

GOBIS, V.; BASKYS, A.; ZLOSNIKAS, V.; MEILE, E.; PLATAKIS, A. **Controller with the set point shift of domestic water supply control system.** *Elektronika ir Elektrotechnika*, v. 19, p. 3–6, 2013.

GONÇALVES, F. V.; RAMOS, H. M.; REIS, L. F. R. **Hybrid energy system evaluation in water supply system energy production: neural network approach.** *International Journal of Energy and Environment*, v. 1, n.1, p. 21–30, 2010.

GONÇALVES, R. F.; JORDÃO, E. P.; JANUZZI, G. **Introdução.** In: GONÇALVES, R. F. (Coord). **Conservação de água e energia em sistemas prediais e públicos de abastecimento de água.** Rio de Janeiro: ABES, 2009. p. 21-35.

GURNEY, K. **An introduction to neural networks.** 1. ed. London: UCL Press Limited, 1997. 317p.

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

HEBB, D. O. **The organization of behavior: a neuropsychological theory**. 1. ed. New York: John Wiley and Sons, 1949. 335p.

HONGFENG, L.; ZHENFEI, C.; WEI, C. **Research of network pressure-superposed water supply system based on fuzzy-pid controller**. *IEEE International Conference on Robotics and Biomimetics*, p. 1194–1199, 2009.

INCONTROL S/A. **Manual de Operação e Instalação: Medidor e Transmissor de Vazão**. Série: VMS, São Paulo, SP, Brasil, 2007.

JAMES, K.; CAMPBELL, S. L.; GODLOVE, C. E. **Água e Energia** – Aproveitando as oportunidades de eficientização de água e energia não exploradas nos sistemas municipais. Washinton: Alliance – Aliança para Conservação de Energia, 2002. 159p.

KRIESEL, D. **A Brief Introduction to Neural Networks**. Bonn, Germany, 2005. 226p.

KSB. **Manual de Serviço: Bomba Centrífuga em Linha para Uso Geral**. São Paulo, SP, Brasil, 2010.

LEONDES, T. L. **Control and dynamic systems – neural network systems techniques and applications**. *Academic Press*, 2006.

LOPES, S. **Bio**. 1. ed. São Paulo: Editora Saraiva S. A., 2004. 606p.

MACHADO, E. C. M. N.; SANTANA, C. W. S.; BRASILEIRO, E. V.; GALVÃO, C. O.; BRASILEIRO, F. V. **Otimização da operação de redes de adução de água utilizando algoritmos genéticos**. In: SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS, 16., 2005, João Pessoa, PB, Brasil, **Anais...**

MACINTYRE, A. J. **Bombas e Instalações de Bombeamento**. 2. ed. Rio de Janeiro: Editora LTC, 2013. 782p.

MENDEL, J. M.; MACLAREN, R. W. **Reinforcement-learning control and pattern recognition systems**. *Academic Press*, v. 66, p. 287-318, 1970.

MENDONÇA, K. H. **Sistema de controle fuzzy na operação otimizada de redes setorizadas com bombeamento direto**. 2016. 136 f. Dissertação (Mestrado em Engenharia

Mecânica) – Programa de Pós Graduação em Engenharia Mecânica, UFPB, João Pessoa, PB, 2016.

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

MOURA, G. A. **Sistemas de controle fuzzy neural e neural adaptativo destinados ao controle de pressão em rede de distribuição de água.** 2016. 140f. Tese (Doutorado em Engenharia Mecânica) – Programa de Pós Graduação em Engenharia Mecânica, UFPB, João Pessoa, PB, 2016.

NARENDRA, K. S.; PARTHASARATHY, K. **Identification and Control of Dynamical Systems using Neural Network.** *IEEE Transactlons on Neural Networks*, v. 1, n 1, p. 4–27, 1990.

NATIONAL INSTRUMENTS CORPORATION. **DAQ M Series: NI USB – 621x User Manual.** Austin, Texas, USA, 2009.

NETTO, A.; FERNANDEZ, M. F.; ARAUJO, R.; ITO, A. E. **Manual de Hidráulica.** 8. ed. São Paulo: Editora Edgard Blücher, 1998. 669p.

NGUYEN, D. H.; WIDROW, B. **Neural networks for self-learning control systems.** *IEEE Control Systems Magazine*, p. 18–23, 1990.

NISE, N. S. **Engenharia de Sistemas de Controle.** 3. ed. Rio de Janeiro: Editora LTC, 2002.

NORGAARD, M.; RAVN, O.; POULSEN, N. K.; HANSEN, L. K. **Neural networks for modelling and control of dynamic systems.** *Springer – Verlag*, 2006.

OGATA, K. **Engenharia de Controle Moderno.** 5. ed. São Paulo: Editora Pearson, 2010. 809p.

OLIVEIRA, J. K. C. **Lógica fuzzy aplicada na otimização operacional de rede setorizada de distribuição de água.** 2017. 147f. Tese (Doutorado em Engenharia Mecânica) – Programa de Pós Graduação em Engenharia Mecânica, UFPB, João Pessoa, PB, 2017.

OTERO, O. L. C.; GOMES, A. S.; COURA, S. P. **Diagnóstico de sistemas**. In: GOMES, H. P. (Org). **Sistemas de Saneamento – Eficiência Energética**. 1. ed. João Pessoa: Editora Universitária/UFPB, 2010. p. 251-296.

PILSČIKOVŠ, D.; DZELZĪTIS, E. **Method of evaluation of efficiency improvement potential for water supply systems with focus on variable speed centrifugal pumps**. *Journal Drinking Water Engineering and Science*, v. 5, p. 533-553, 2012.

PRESS, W. H.; FLANNERY, B. P.; TEUKOLSKY, S. A.; VETTERLING, W. T. **Numerical Recipes: The Art of Scientific Computing (Fortran Version)**. 2. ed. United Kingdom: Cambridge University Press, 1990. 921p.

QUADROS, A. S.; PINTO, A. M. A. **Controle PID com sintonia automática e adaptativa de válvulas redutoras de pressão em sistemas de abastecimento de água**. In: Simpósio Brasileiro de Automação Inteligente, 11., 2013, Fortaleza, CE, Brasil, **Anais...**

REED, R. D.; MARKS II, R. J. **Neural simithing: supervised learning in feedforward artificial neural networks**. Massachusetts: MIT Press, 1999. 358p.

SALVINO, M. M.; GOMES, H. P.; BEZERRA, S. T. M.; HENRIQUES, K. R. S.; REGIS, L. P.; SILVA, S. A.; BARROS FILHO, E. G. **Automação e controle em sistemas de abastecimento com vistas à redução de perdas de água e energia**. In. CONGRESO LATINOAMERICANO DE HIDRÁULICA, 25., 2014, Santiago, CL. **Anais...** Santiago: Hotel Sheraton, 2014.

SARBU, I. **A study of energy optimisation of urban water distribution systems using potential elements**. *Water*, v. 8, 2016.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas**. 1. ed. São Paulo: Editora Artliber, 2010. 399p.

SILVA, M. J. G.; ARAÚJO, C. S.; BEZERRA, S. T. M.; SILVA, S. A.; SOUTO, C. R.; GOMES, H. P. **Sistema de controle adaptativo aplicado a um sistema de distribuição de água com ênfase na eficiência energética**. *Engenharia Sanitária e Ambiental*, v. 20, p. 405–413, 2015.

SNIS – Sistema Nacional de Informações sobre Saneamento. Ministério das Cidades, Secretaria Nacional de Saneamento Ambiental. **Sistema Nacional de Informações sobre Saneamento: Diagnóstico dos Serviços de Água e Esgotos – 2013**. Brasília: SNSA/MCIDADES, 2014.

SUYKENS, K.; VANDERWALLE, J. P. L.; DE MOOR, B. L. **Artificial neural networks for modelling and control of non-linear systems**. *Springer – Verlag*, 2001.

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

TSUTIYA, M. T. **Uso de Inversores de Frequência para Diminuição do consumo de Energia em Bombeamentos**. In: Heber Pimentel Gomes; Rafael Pérez Garcia; Pedro L. Iglesias Rey. (Org.). **Abastecimento de Água: o estado da arte e técnicas avançadas**. João Pessoa: Editora Universitária/UFPB, 2007. p. 103–122.

XIAOHONG, P.; LAISHENG, X.; ZHI, M.; GUODONG, L. **The variable frequency and speed regulation constant pressure water supply system based on PLC and fuzzy control**. *IEEE Computer Society*, p. 910–913, 2009.

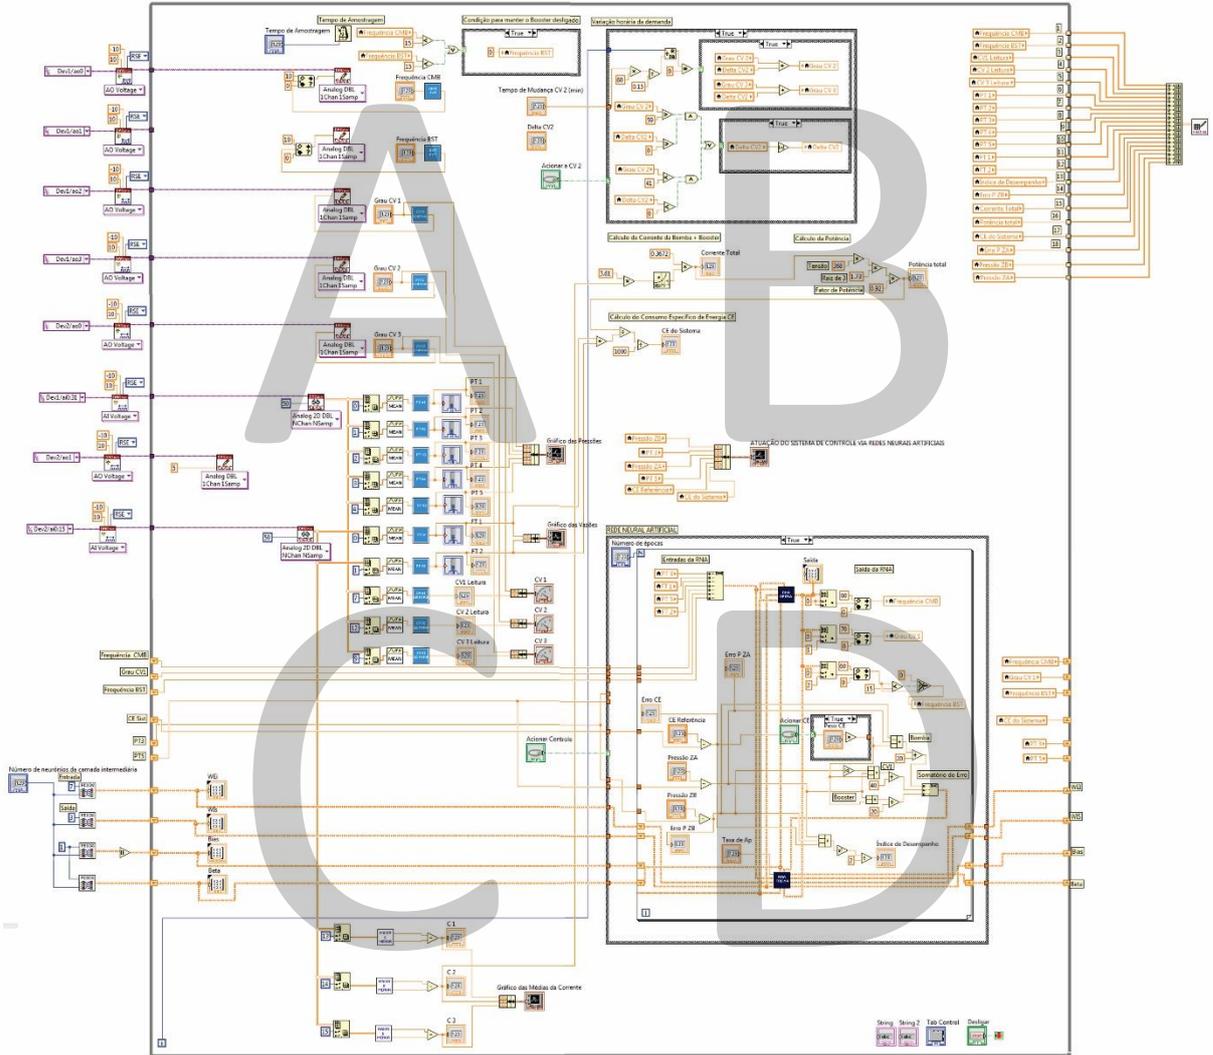
WEG EQUIPAMENTOS ELÉTRICOS S.A. **Manual do Inversor de Frequência**. Jaraguá do Sul, Santa Catarina, Brasil, 2009.

WEG GROUP – MOTORS BUSINESS UNIT, **Manual Geral de Instalação, Operação e Manutenção de Motores Elétricos para Atmosferas Explosivas**. Jaraguá do Sul, Santa Catarina, Brasil.

WIDROW, B.; LEHR, M. A. **30 years of adaptive neural networks: perceptron, madaline and backpropagation**. *Proceedings of the IEEE*, U.S.A., v. 78, n. 9, p. 1415–1442, 1990.

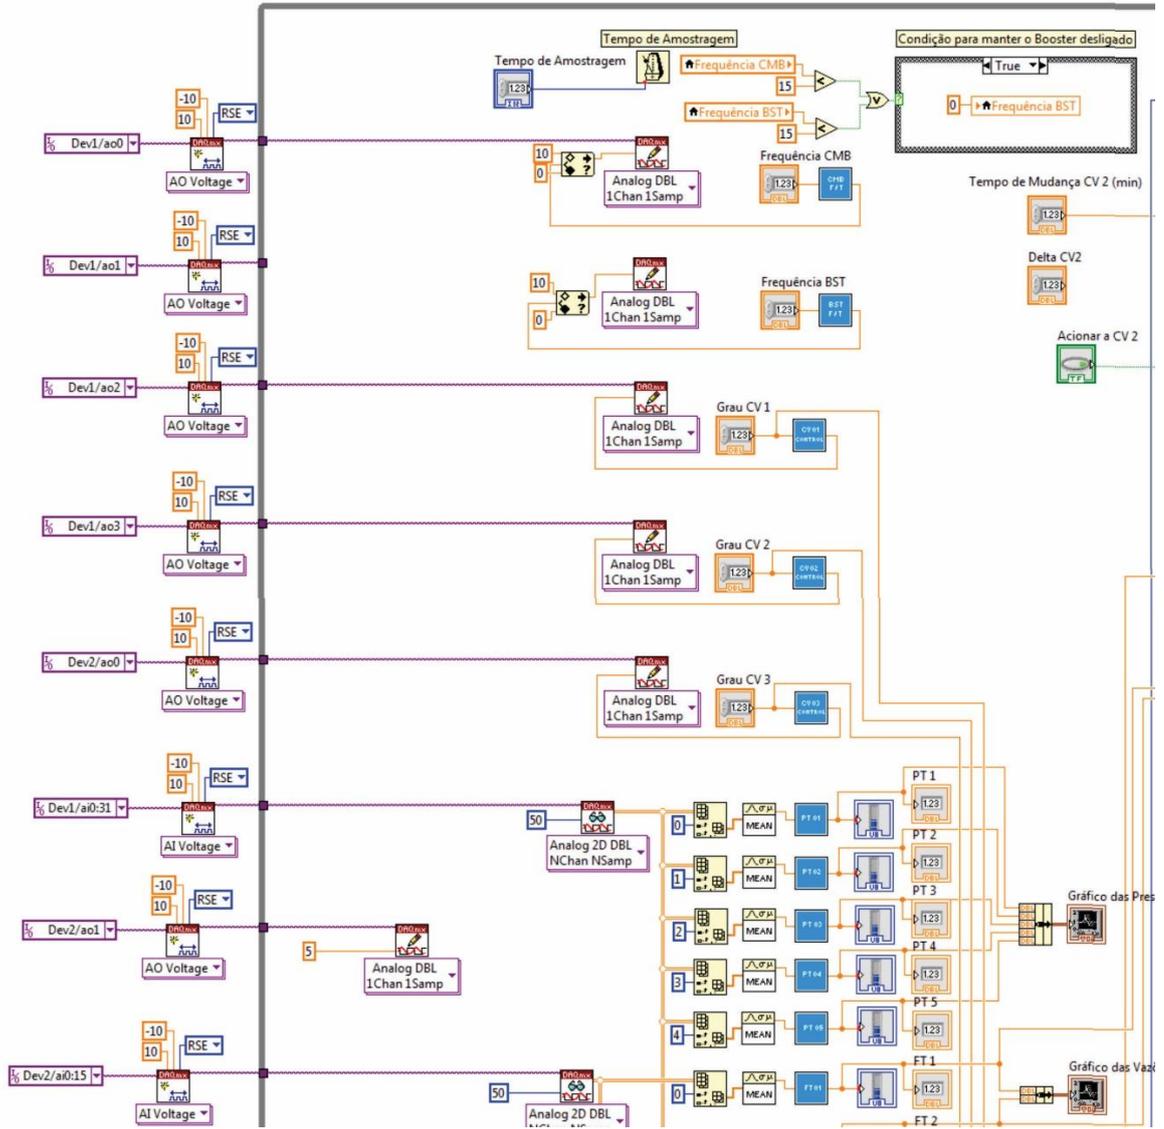
# APÊNDICE

## CÓDIGO FONTE DO PROGRAMA DESENVOLVIDO EM LABVIEW



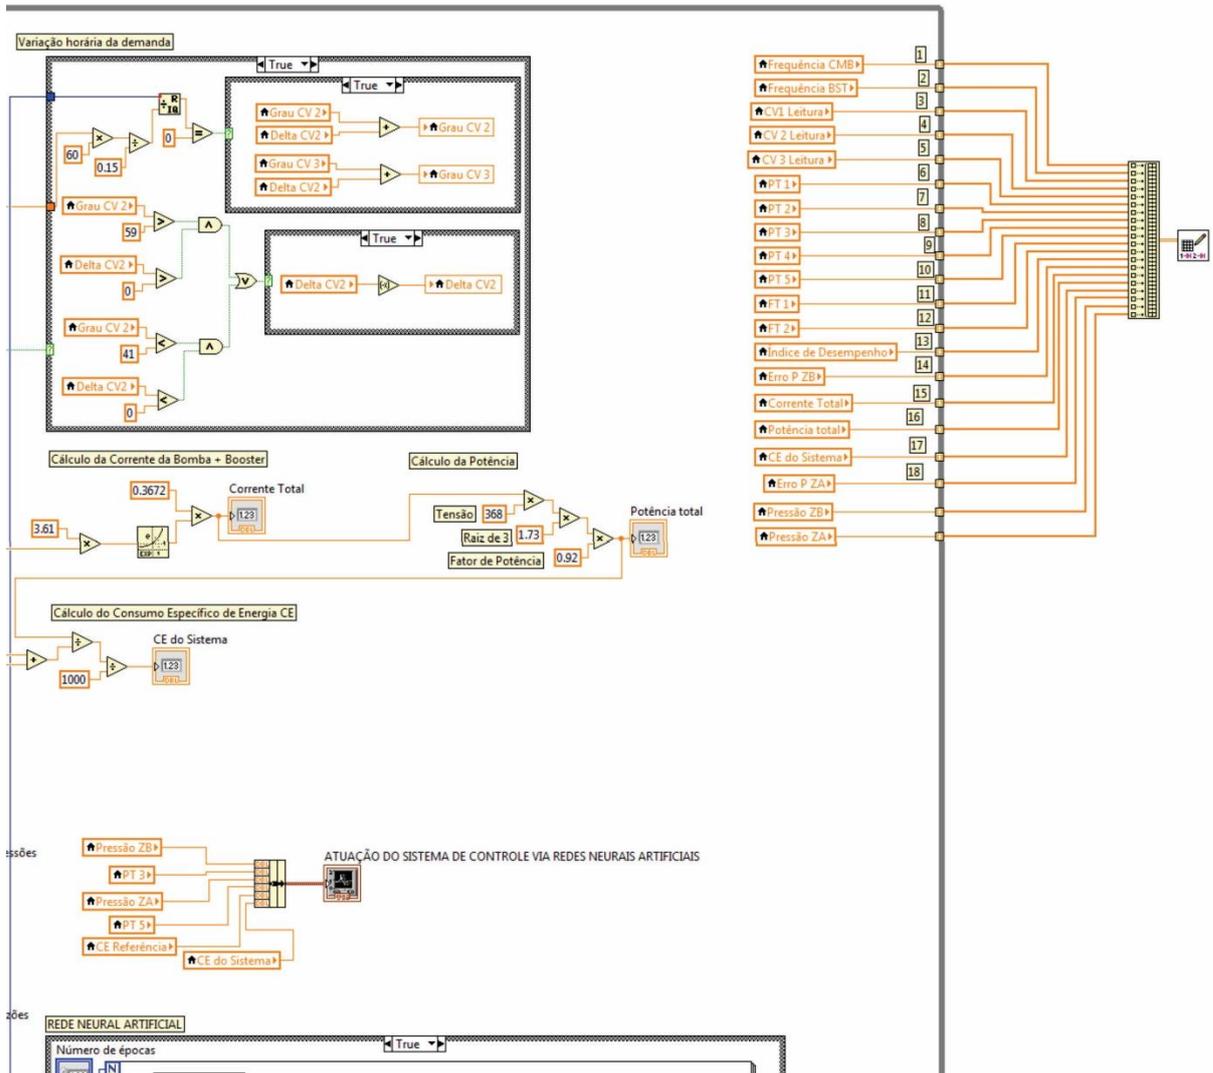
# CÓDIGO FONTE DO PROGRAMA DESENVOLVIDO EM LABVIEW

## PARTE – A



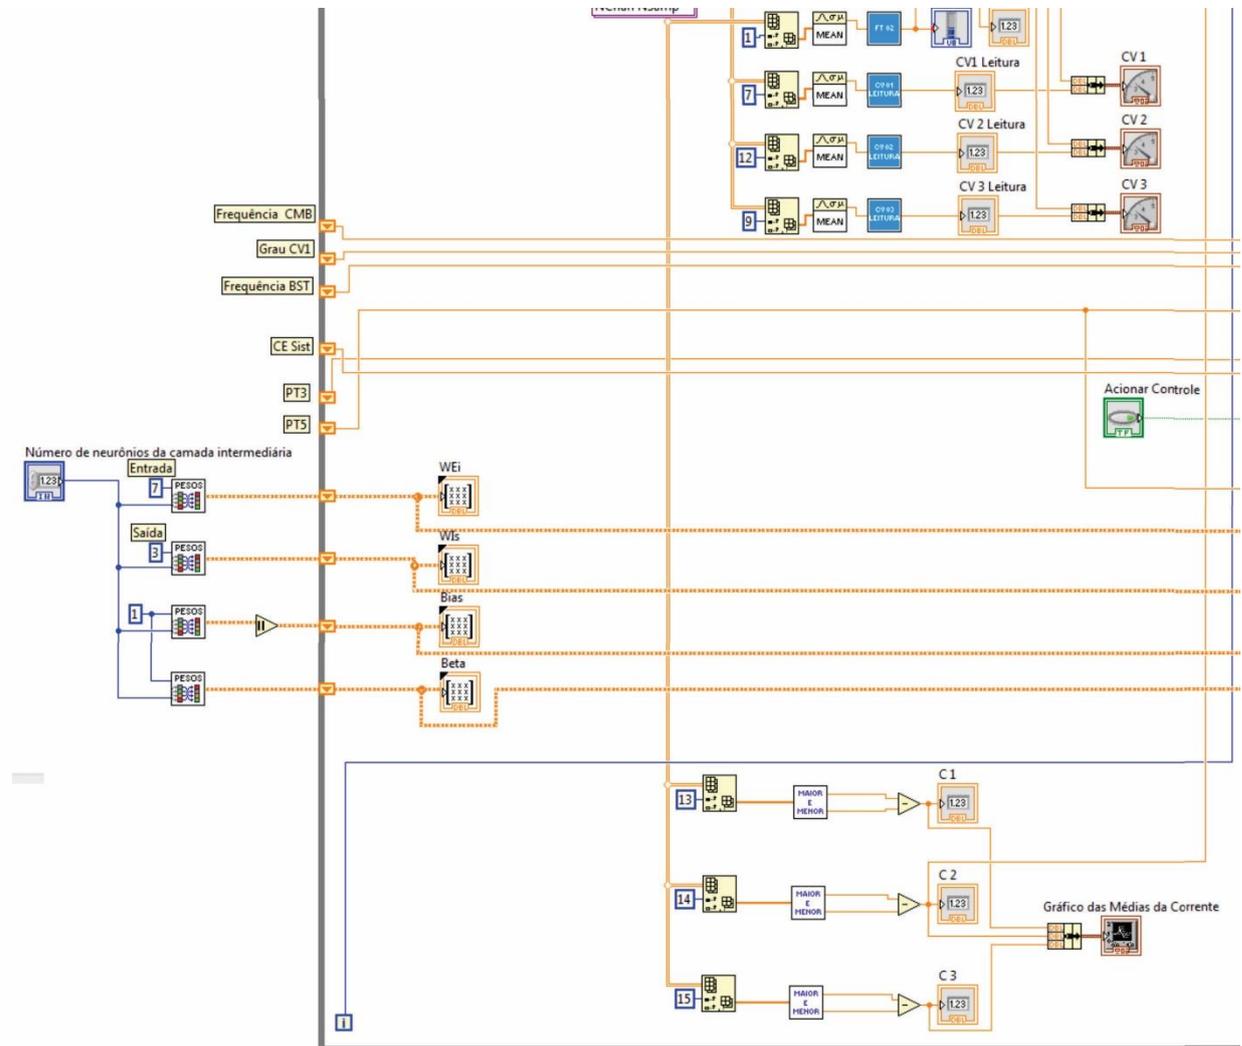
# CÓDIGO FONTE DO PROGRAMA DESENVOLVIDO EM LABVIEW

## PARTE – B



## CÓDIGO FONTE DO PROGRAMA DESENVOLVIDO EM LABVIEW

### PARTE – C



# CÓDIGO FONTE DO PROGRAMA DESENVOLVIDO EM LABVIEW

## PARTE – D

