



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

**CONTROLE NEURO-FUZZY PARA EFICIÊNCIA
ENERGÉTICA DE SISTEMAS DE ABASTECIMENTO DE
ÁGUA COM DEMANDA VARIÁVEL**

por

Hugo Augusto Marinho Moreira

*Dissertação de Mestrado apresentada à Universidade Federal da Paraíba
para obtenção do grau de Mestre.*

HUGO AUGUSTO MARINHO MOREIRA

**CONTROLE NEURO-FUZZY PARA EFICIÊNCIA
ENERGÉTICA DE SISTEMAS DE ABASTECIMENTO DE
ÁGUA COM DEMANDA VARIÁVEL**

Dissertação apresentada ao curso de Pós-Graduação em Engenharia Mecânica da Universidade Federal da Paraíba, *campus* João Pessoa, em cumprimento às exigências para obtenção do Grau de Mestre.

**Orientador: Prof. Dr. Heber Pimentel
Gomes**

Catálogo na publicação
Seção de Catalogação e Classificação

M838c Moreira, Hugo Augusto Marinho.

Controle Neuro-Fuzzy para eficiência energética de sistemas de abastecimento de água com demanda variável / Hugo Augusto Marinho Moreira. - João Pessoa, 2020. 106 f. : il.

Orientação: Heber Pimentel Gomes.
Dissertação (Mestrado) - UFPB/CT.

1. Eficiência Energética. 2. Identificação de Sistemas. 3. Automação. 4. Inteligência Artificial. 5. Sistemas Hidráulicos. I. Gomes, Heber Pimentel. II. Título.

UFPB/BC

CONTROLE NEURO-FUZZY PARA EFICIÊNCIA ENERGÉTICA DE SISTEMAS DE ABASTECIMENTO DE ÁGUA COM DEMANDA VARIÁVEL

por

HUGO AUGUSTO MARINHO MOREIRA

Dissertação aprovada em 22 de julho de 2020



Prof. Dr. HEBER PIMENTEL GOMES

Orientador – UFPB



Prof. Dr. SIMPLICIO ARNAUD DA SILVA

Examinador Interno - UFPB



Prof. Dr. JUAN MOISES MAURICIO VILLANUEVA

Examinador Externo – UFPB



Prof. Dr. SAULO DE TARSO MARQUES BEZERRA

Examinador Externo – UFPE

*João Pessoa - PB
2020*

DEDICATÓRIA

Dedico este trabalho à minha Mãe, à minha Irmã e à minha Avó, minhas apoiadoras incondicionais. Dedico também à todas as pessoas que me ajudaram ou apoiaram em algum momento da construção desta dissertação.

AGRADECIMENTOS

Agradeço à minha MÃE, Rosineide Moreira da Silva, pelas lições de vida, motivações e aconselhamentos que venho recebendo nesses mais de 26 anos de vida. Sou grato também ao grande apoio emocional, psíquico e financeira que recebi, durante toda a minha vida, desta grande mulher.

Agradeço à minha AVÓ, Maria do Carmo da Silva, por todo apoio emocional, motivacional e aos aconselhamentos dados por ela.

Agradeço ao meu orientador e professor, Heber Pimentel Gomes, que me acompanhou na formulação e no desenvolvimento deste trabalho de mestrado.

Agradeço ao professor, Juan Moises Mauricio Villanueva, que me acompanhou no desenvolvimento deste trabalho de mestrado.

Por último, agradeço à todas as pessoas que de forma direta ou indireta contribuíram para o meu crescimento, principalmente, neste tempo em que realizei este trabalho de mestrado.

CONTROLE NEURO-FUZZY PARA EFICIÊNCIA ENERGÉTICA DE SISTEMAS DE ABASTECIMENTO DE ÁGUA COM DEMANDA VARIÁVEL

RESUMO

Este trabalho tem como objetivo aplicar a técnica Neuro-Fuzzy para o controle da pressão de um sistema de bombeamento de água com demanda variável. O controle atua na variação de velocidade do conjunto motobomba (CMB) e tem como principal objetivo elevar a eficiência energética do sistema. O controlador é testado em um sistema experimental de abastecimento de água instalado no Laboratório de Eficiência Energética e Hidráulica em Saneamento da Universidade Federal da Paraíba (LENHS/UFPB). O controlador é analisado com relação à performance (regime permanente, transiente e à distúrbios) e à economia de energia. Para tanto, a curva de demanda horária de água é implementada e indicadores hidroenergéticos (rendimento do CMB e o coeficiente de consumo específico de energia) são utilizados para mensurar o ganho de eficiência energética. Para validar o seu desempenho, o controlador projetado é comparado a outros dois controladores, sendo um Neural (redes neurais artificiais) e um Fuzzy. Como forma de analisar e interpretar as condições de operação são desenvolvidos modelos computacionais multivariáveis não-lineares, via técnicas de inteligência artificial. Os modelos desenvolvidos contemplam como variáveis de saída o rendimento do CMB, a pressão e a vazão do sistema. Os resultados mostram um ganho energético significativo do sistema de bombeamento, indicado pelos indicadores hidroenergéticos. As pressões foram mantidas próximas aos valores de referência, com baixo tempo de subida ($t_s < 7$ segundos) e sem ultrapassagem; além da ótima estabilidade (erro $< 8\%$) em situações severas de variação de demanda. Conclui-se que a técnica Neuro-Fuzzy garantiu resultados superiores aos demais controladores analisados.

Palavras chaves - Eficiência Energética, Identificação de Sistemas, Automação, Inteligência Artificial, Sistemas Hidráulicos.

NEURO-FUZZY CONTROL FOR ENERGY EFFICIENCY OF WATER SUPPLY SYSTEMS

ABSTRACT

This work aims to apply the Neuro-Fuzzy technique for pressure control of a water pumping system with variable demand. The control acts on the variation speed of the motor pump set (CMB) and its main objective is to raise the energy efficiency of the system. The controller were tested in an experimental system of water supply installed at the Energy and Hydraulic Efficiency Laboratory in Sanitation at the Federal University of Paraíba (LENHS / UFPB). The controller is analyzed regarding performance (permanent regime, transient and disturbances) and economy of energy. Therefore, the hourly water demand curve was implemented and indicators hydroenergetics (CMB yield and specific energy consumption coefficient) are used to measure energy efficiency gains. To validate your performance, the designed controller is compared to two other controllers, one being Neural (artificial neural networks) and a Fuzzy. As a way of analyzing and interpreting the operating conditions, non-linear multivariable computational modeling is also performed via artificial intelligence techniques. The developed models contemplate how output variables the yield of the CMB, the pressure and the flow of the system. The results show a significant energy gain from the pumping system, indicated by hydroenergetic indicators. The pressures were kept close to the set-points, with low rise time ($t_s < 7$ seconds) and without overshoot; in addition to the excellent stability (error $< 8\%$) in severe situations of demand variation. It is concluded that the Neuro-Fuzzy technique guaranteed superior results to the other controllers analyzed.

Keywords - Energy Efficiency, Systems Identification, Automation, Artificial Intelligence, Hydraulic System.

SUMÁRIO

1	INTRODUÇÃO	1
	1.1	3
	1.2	4
2	REVISÃO BIBLIOGRÁFICA	5
	2.1	5
	2.2	7
	2.3	12
	2.4	14
3	FUNDAMENTAÇÃO TEÓRICA	17
	3.1	17
	3.1.1	18
	3.2	20
	3.3	22
	3.3.1	23
	3.3.1.1	24
	3.3.1.2	25
	3.3.2	27
	3.3.3	29
4	METODOLOGIA	33
	4.1	33

4.2	IDENTIFICAÇÃO DA BANCADA	42
4.3	PROJETO DO CONTROLADOR	46
5	RESULTADOS	52
5.1	IDENTIFICAÇÃO DO SISTEMA	52
5.1.1	Desenvolvimento do banco de dados	53
5.1.2	Treinamento	54
5.1.3	Resposta do modelo SIMO (1 Input – 2 Output)	56
5.1.4	Resposta do modelo MIMO (2 Input – 2 Output)	58
5.1.5	Caracterização do rendimento do CMB	60
5.1.6	Análise dos modelos	63
5.2	ANÁLISE DO CONTROLADOR	63
5.2.1	Dados de treinamento	64
5.2.2	Resposta ao degrau	65
5.2.3	Variação do <i>set-point</i> do sistema	67
5.2.4	Variação contínua da VC	68
5.2.5	Variação pausada da VC	69
5.2.6	Ação de controle	70
5.3	ANÁLISE HIDROENERGÉTICA	71
6	CONCLUSÕES	75
6.1	SUGESTÕES PARA TRABALHOS FUTUROS	77
7	REFERÊNCIAS	78

LISTA DE FIGURAS

Figura 2.1 – Sistema de abastecimento de água com bombeamento direto.	5
Figura 2.2 – Interface gráfica do EPANET.	6
Figura 2.3 – Curva de demanda horária de água.	8
Figura 3.1 – Sistema de controle Fuzzy em malha fechada.	22
Figura 3.2 – Arquitetura Fuzzy Mandani.	23
Figura 3.3 – Conjunto Fuzzy ilustrando a variável altura à função de pertinência.	24
Figura 3.4 – Sistema de inferência Mandani.	25
Figura 3.5 – Sistema de inferência Sugeno para um conseqüente linear.	26
Figura 3.6 – Estrutura MIMO de uma Rede Neural.	29
Figura 3.7 – Estrutura de um controlador ANFIS.	30
Figura 3.8 – Fluxograma para obtenção de controlador Fuzzy.	32
Figura 4.1 – Bancada Experimental (BE).	34
Figura 4.2 – Esquema da bancada experimental.	34
Figura 4.3 – Curvas características das bombas do sistema experimental.	35
Figura 4.4 – Curvas características da bomba CAM-W10.	36
Figura 4.5 – Curva malha aberta para degraus de frequência.	37
Figura 4.6 – Válvula de controle ARB24-SR.	38
Figura 4.7 – Variação do ângulo de abertura da válvula versus a pressão para o CMB operando com frequência de 30 Hz.	38
Figura 4.8 – Variação do ângulo de abertura da válvula versus a pressão para o CMB operando com frequência de 60 Hz.	38
Figura 4.9 – Transdutor de Pressão Druck PTX 7217.	39
Figura 4.10 – Medidor de vazão eletromagnético VMS Pro.	40
Figura 4.11 – Supervisório.	41
Figura 4.12 – Sistema de aquisição de dados NI USB-6229.	41
Figura 4.13 – Diagrama dos modelos inteligentes desenvolvidos.	42
Figura 4.14 – Arquitetura MIMO da Rede Neural.	44
Figura 4.15 – Arquitetura MIMO do sistema Neuro-Fuzzy.	45

Figura 4.16 – Fluxograma metodológico para modelagem computacional de sistemas.	46
Figura 4.17 – Estrutura de treinamento do controlador ANFIS.....	47
Figura 4.18 – Estrutura do algoritmo de treinamento do ANFIS.....	48
Figura 4.19 – Sistema de controle em malha fechada.....	49
Figura 4.20 – Controlador intermediário Fuzzy – Mandani (Moreira, 2019a).....	49
Figura 5.1 – Relação dos dados de treinamento do modelo SIMO.	53
Figura 5.2 – Relação dos dados de treinamento do modelo MIMO.	54
Figura 5.3 – Gráfico de convergência do modelo MIMO Neural (a) e Neuro-Fuzzy (b).	55
Figura 5.4 – Resposta dos modelos inteligentes com dados de treinamento e validação.....	57
Figura 5.5 – Resposta dos modelos inteligentes com dados de treinamento e validação.....	59
Figura 5.6 – Influência da frequência no rendimento do CMB.	61
Figura 5.7 – Influência da demanda no rendimento do CMB.	62
Figura 5.8 – Superfície da caracterização da eficiência do sistema de bombeamento.	62
Figura 5.9 – Superfície de comportamento do sistema de abastecimento Neuro-Fuzzy.....	63
Figura 5.10 – Dados de treinamento do controlador primário PD.	64
Figura 5.11 – Dados de treinamento do controlador primário Fuzzy.	65
Figura 5.12 – Superfície de resposta do controlador NF.....	65
Figura 5.13 – Resposta ao Degrau 10 m.	66
Figura 5.14 – Resposta ao Degrau 15 mca.	67
Figura 5.15 – Variação do valor de referência com VC em 40°.	68
Figura 5.16 – Degrau em 10 m com variação contínua da VC.....	69
Figura 5.17 – Degrau em 15 m com variação contínua da VC.....	69
Figura 5.18 – Degrau em 10 m com variabilidade pausada da VC.....	70
Figura 5.19 – Ação de controle.....	71
Figura 5.20 – Rendimento do CMB.....	72
Figura 5.21 – Coeficiente de consumo específico de energia (CE).	73
Figura 5.22 – Pressões médias do sistema com demanda variável.	74

LISTA DE TABELAS

Tabela 4.1 – Especificações do Motor do CMB.	35
Tabela 4.2 – Especificações técnicas do Transdutor de Pressão (PT).....	39
Tabela 4.3 – Especificações técnicas do transdutor de vazão eletromagnético VSM 038.	40
Tabela 4.4 – Descrição das variáveis utilizadas nos ensaios.	43
Tabela 4.5 – Formato do conjunto de dados.....	47
Tabela 4.6 – Conjunto de regras para o controlador primário Fuzzy.....	50
Tabela 5.1 – Dados de performance dos modelos computacionais testados com dados de validação.	58
Tabela 5.2 – Dados de performance dos modelos testados com dados de validação.....	60
Tabela 5.3 – Análise do desempenho dos controladores.....	66

LISTA DE SÍMBOLOS

$\mu_A(x)$	Grau de Pertinência
A	Conjunto Fuzzy do sistema Neuro-Fuzzy
a	Conjunto Fuzzy de entrada
d	Conjunto Fuzzy de saída
e	Erro
ef	Erro final
H_{man}	Altura manométrica
$KWhe$	Energia consumida
m, W_{ij} , W_{ik} , W_{jk}	Pesos sinápticos
na	Ordem do vetor A dos modelos paramétricos
nb	Ordem do vetor B dos modelos paramétricos
nc	Ordem do vetor C dos modelos paramétricos
nf	Ordem do vetor F dos modelos paramétricos
nk	Ordem do vetor K dos modelos paramétricos
T_d	Tempo de atraso
T_r	Tempo de subida
T_p	Instante de pico
T_s	Tempo de assentamento
η	Rendimento
γ	Peso específico do fluido
Y, y	Valor de saída do sistema Neuro-Fuzzy
\hat{y}	Vetor norma de saída
w, W	Valor de pertinência
\bar{w}	Valor de pertinência normalizado
P	Número total de pares de treinamento ou de validação
P'	energia consumida [kWh]

Q	Vazão volumétrica [m ³ /s]
V	Volume bombeado [m ³].
X	Valor de entrada do sistema Fuzzy
x	Valor de entrada do sistema Neuro-Fuzzy
θ	Parâmetros do vetor FPE

LISTA DE ABREVIATURAS

ABES	Associação Brasileira de Engenharia Sanitária e Ambiental
AMPC	<i>Adaptive Model Predictive Controller</i>
ANNMPC	<i>Adaptive Neural Network Model Predictive Control</i>
ANEEL	Agência Nacional de Energia Elétrica
ANFIS	<i>Adaptive Neural Fuzzy Inference System</i>
ARMAX	Autorregressivo com Entradas Exógenas com Média Móvel
ARX	Autorregressivo com Entradas Exógenas
CE	Consumo Específico de Energia Elétrica
CLP	Controlador Lógica Programável
CMB	Conjunto Motor Bomba
DAQ	Dispositivo De Aquisição de Dados
ETA	Estação de Tratamento de Água
FPE	Erro Final de Predição
FT	Medidor de Vazão
IHM	Interface Homem Máquina
LENHS	Laboratório de Eficiência Energética e Hidráulica em Saneamento
LF	Lógica Fuzzy
LMI	Desigualdades Lineares Matriciais
m	Carga hidráulicas em metros de coluna de água
MF	Funções de Pertinência
MISO	<i>Multiple Input Single Output</i>
MIMO	<i>Multiple Input Multiple Output</i>
MPC	<i>Model Predictive Control</i>
MPPT	Ponto de Máxima Potência
NARX	Neural-Autorregressivo com Entradas Exógenas
NBR	Normas Brasileiras

NC	Controlador Neural
NF	Neuro-Fuzzy
NFC	Controlador Neuro-Fuzzy
NRMSE	Raiz do Erro Médio Quadrático Normalizado
RNA	Redes Neurais Artificiais
RMSE	Raiz do Erro Médio Quadrático
SAA	Sistema de Abastecimento de Água
SCFN	Sistema de Controle Fuzzy Neural
SCNA	Sistema de Controle Neural Adaptativo
SF	Sistemas Fuzzy
SISO	<i>Single Input Single Output</i>
SIMO	<i>Single Input Multiple Output</i>
SS	Equações de Espaço de Estados
VC	Válvula de Controle
PIB	Produto Interno Bruto
PID	Proporcional-Integrativo-Derivativo
PMEE	Ponto de Máxima Eficiência Energética
PT	Transdutor de Pressão
PWM	Modulação por Largura de Pulso
POT	Potência
TSK	Takagi-Sugeno-Kang
TF	Funções de Transferência
NG	Negativo grande
Z	Zero
PG	Positivo grande
IG	Incremento grande
DG	Decremento grande

TRABALHOS PUBLICADOS PELO AUTOR

CONFERÊNCIAS:

Moreira, H. A. M., Gomes, H. P., Villanueva, J. M., 2019a. FUZZY – MANDANI CONTROLLER FOR A SUPPLY SYSTEM. Anais do 25th ABCM International Congress of Mechanical Engineering October 20-25, 2019, Uberlândia, MG, Brazil. DOI: <http://dx.doi.org/10.26678/ABCM.COBEM2019.COB2019-0508>.

Moreira, H. A. M., Gomes, H. P., Villanueva, J. M., 2019b. Controle inteligente aplicado à um sistema de bombeamento de água. n: 14º Simpósio Brasileiro de Automação Inteligente, 2019, Ouro Preto, MG. Anais do 14º Simpósio Brasileiro de Automação Inteligente, 2019.

Flores, S. K. T., Moreira, H. A. M., Villanueva, M. M. J., Gomes, H. P., 2019. Controle Inteligente Aplicado a Sistemas Hidráulicos com Demanda Variável. In: 14º Simpósio Brasileiro de Automação Inteligente, 2019, Ouro Preto, MG. Anais do 14º Simpósio Brasileiro de Automação Inteligente, 2019.

CAPITULO I

1 INTRODUÇÃO

Os sistemas de abastecimento de água são o conjunto de equipamentos, obras e serviços voltados para o suprimento de água, para fins de consumo doméstico, industrial e público. A concepção e o dimensionamento dos sistemas de bombeamento de água ocorrem de forma integrada, o que requer o emprego de uma equipe de multiprofissionais especializados (Gomes, 2019). Entretanto, devido às suas dimensões e particularidades, estes sistemas apresentam elevada complexidade que dificultam o seu projeto, análise e operação.

Apesar de amplamente estudados, sistemas de bombeamento de água ainda apresentam certas problemáticas envolvendo o alto consumo energético no bombeamento e o elevado desperdício de água na sua condução até o consumidor final, ocasionado, principalmente, devido a pressões excessivas nas tubulações. Dados atuais da Agência Nacional de Energia Elétrica - ANEEL (2019) mostram que ocorre um vertiginoso crescimento do consumo elétrico no Brasil, onde a taxa de crescimento do consumo de energia elétrica é maior que a taxa de crescimento do Produto Interno Bruto (PIB). É evidente, também, que nos últimos anos as termelétricas foram constantemente acionadas, devido ao baixo nível hidrológico das usinas hidroelétricas do país, atribuído às escassas chuvas. Isso se reflete na utilização das bandeiras tarifárias, as quais adicionam custos extras na produção de energia elétrica. Concomitante a isso, os sistemas de abastecimento e de esgotamento sanitário são responsáveis por, aproximadamente, 3% da energia consumida no mundo, sendo 90% desse montante consumido pelos sistemas de bombeamento (Gomes e Carvalho, 2012), ressaltando a necessidade da utilização de ações de racionalização energética. Outra problemática está relacionada à baixa qualidade na distribuição de água, associada aos desperdícios, provocados por grandes e pequenos vazamentos, muitas vezes invisíveis. As duas problemáticas apontadas mostram que é necessário o desenvolvimento

de tecnologias que minimizem as consequências do alto consumo elétrico e a má qualidade no fornecimento de água.

Técnicas de automação têm sido recentemente aplicadas em sistemas de bombeamento de água, como forma de torná-los mais eficientes e eficazes do ponto de vista energético e de atendimento das demandas. As técnicas de automação fazem uso de dispositivos atuadores, tais como inversores de frequência e válvulas de controle, e sensores. Além disso, é possível realizar o monitoramento em tempo real do sistema e controlar parâmetros importantes, como as pressões e vazões da rede de distribuição de água. Sendo assim, o controle das pressões da rede de distribuição é visto como uma medida poderosa de eficiência energética e de redução dos índices de vazamentos (Gomes e Carvalho, 2012).

Devido ao alto consumo energético, usualmente são aplicadas soluções de engenharia como a de métodos que utilizam inversores de frequência (Brogan *et al.*, 2016) unido às técnicas de controle em malha fechada para o monitoramento da velocidade de rotação dos conjuntos motobombas (CMBs). Neste modo de operação é possível aumentar a eficiência energética do sistema de bombeamento, reduzindo a energia consumida pelo CMB ao operar fora da velocidade nominal. As estratégias de controle podem ser aprimoradas por meio da aplicação de controle clássico PID (Proporcional-Integral-Derivativo). Entretanto, os sistemas de abastecimento de água apresentam características de alta não-linearidade. Além de serem variantes no tempo, pois são dependentes da demanda horária de água, falhas e manutenção, o que inviabiliza a utilização de métodos convencionais de controle que exigem o modelo matemático da planta, sendo necessária a utilização de técnicas robustas de monitoramento, controle e operação (Babunski *et al.*, 2018). Desta forma, os controladores puramente heurísticos não satisfazem o desempenho exigido pelos sistemas de abastecimento de água, principalmente em condições de demanda variável. Além disso, o projeto destes controladores exige a expertise de um operador do sistema a ser controlado na construção da base de regras e formação dos conjuntos Fuzzy, que, por vezes, é realizada por tentativa e erro. Concomitante a isso, a complexidade do projeto de controladores Neurais e Adaptativos, exige do projetista um grande conhecimento em linguagem de programação. A grande vantagem da técnica Neuro-Fuzzy é a não exigência de um especialista sobre o sistema para o projeto do controlador, o que é necessário no projeto de controladores Fuzzy; do modelo matemático do sistema, comumente utilizado no projeto de controladores convencionais (PID); e baixa complexidade de programação e projeto, em relação ao exigido nos sistemas Neurais e Adaptativos. Nessa técnica, a planta

pode ser considerada um sistema do tipo caixa preta. Além disso, inúmeras vantagens são obtidas ao combinar as propriedades das Redes Neurais Artificiais e da Lógica Fuzzy, como a capacidade de aprendizagem, generalização e interpretação.

Muitos trabalhos foram desenvolvidos acerca do controle de sistemas de bombeamento de água através da automação, principalmente nas dependências do LENHS/UFPB (Laboratório de Eficiência Energética e Hidráulica em Saneamento da Universidade Federal da Paraíba), tornando-se referência em pesquisas de eficiência energética para sistemas de saneamento. Estas pesquisas culminaram no desenvolvimento de diversas técnicas, principalmente, acerca da eficiência energética e da redução das perdas hidráulicas em sistemas de abastecimentos.

Este trabalho consiste no aprofundamento das pesquisas já realizadas com controladores baseados em inteligência artificial aplicados à sistemas de bombeamento de água. O foco recai no desenvolvimento de um controlador Neuro-Fuzzy. A técnica Neuro-Fuzzy é aplicada em um sistema de bombeamento de água com demanda variável. O controle é exercido na manipulação da velocidade do CMB, alterando-a conforme a necessidade. O objetivo é a regularização das pressões de serviço da rede de abastecimento, aumentando, por consequência, a eficiência energética do sistema. Outra grande contribuição deste trabalho, consiste na análise hidroenergética através da implementação da curva de demanda horária de água e do uso de indicadores hidroenergéticos (rendimento e CE) para contabilizar o ganho energético do sistema. Para validar o desempenho do controlador projetado, um estudo comparativo foi realizado com dois outros controladores, sendo um Neural (Redes Neurais Artificiais) e um Heurístico (Fuzzy).

1.1 OBJETIVOS

Este trabalho está centrado no desenvolvimento de um controlador Neuro-Fuzzy para o controle das pressões de um sistema de bombeamento. O objetivo geral consiste em controlar as pressões do sistema experimental sob demanda variável de água e, como consequência, reduzir os gastos energéticos.

Os objetivos específicos são:

- Identificar a bancada experimental através de métodos de inteligência artificial para análise dos padrões de comportamento da planta;

- Desenvolver e implementar um controlador Neuro-Fuzzy, através do MATLAB e LABVIEW, para o controle da pressão;
- Analisar a performance do controlador em relação ao regime transiente, permanente e distúrbios inseridos no sistema, comparando os seus resultados aos de outros três controladores;
- Simular diversos cenários de operação através da implementação da curva de variação de demanda de água;
- Implementar e analisar indicadores para análise hidroenergética.

1.2 ORGANIZAÇÃO DO TRABALHO

Este trabalho está organizado em seis capítulos, como se segue. O primeiro descreve a relevância deste trabalho, bem como a sua motivação e contribuição, seguida dos objetivos gerais e específicos. O segundo capítulo contém a revisão bibliográfica relacionada aos sistemas de abastecimento de água, sistemas de controle aplicados ao bombeamento de água, identificação de sistemas e, finalmente, da técnica Neuro-Fuzzy. O terceiro capítulo contém o referencial teórico das técnicas utilizadas neste trabalho para a identificação computacional da bancada instrumentalizada e para o projeto do controlador Neuro-Fuzzy. O quarto capítulo descreve o sistema experimental utilizado, bem como a metodologia para o projeto do controlador e os indicadores usados na análise hidroenergética. Os resultados estão no quinto capítulo, onde são apresentadas as vantagens e desvantagens deste método de controle em sistemas de bombeamento de água. Por fim, o sexto capítulo traz as conclusões do método aplicado e as recomendações para trabalhos futuros.

CAPITULO II

2 REVISÃO BIBLIOGRÁFICA

2.1 SISTEMAS DE ABASTECIMENTO

Um sistema de abastecimento típico, se caracteriza por possuir uma estrutura funcional composta por: captação, estação de tratamento de água (ETA), reservatório, estação elevatória, adutora e a própria rede de distribuição, como ilustrado na Figura 2.1. A última etapa deste processo é a distribuição de água na forma de condução pressurizada. A NBR 12211/1992 determina os procedimentos para a elaboração dos estudos de concepção dos sistemas de bombeamento de água.

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




Figura 2.1 – Sistema de abastecimento de água com bombeamento direto.

Fonte: Adaptado de Tsutiya (2006).

A ferramenta mais utilizada para projetar, simular e diagnosticar problemas em sistemas de abastecimento é o EPANET 2.0.1, software de código aberto desenvolvido nos Estados Unidos e que conta com uma versão em português desenvolvida pelo LENHS/UFPB. O EPANET permite o projeto gráfico de sistemas de abastecimento – como ilustrado na Figura 2.2 – e a sua posterior simulação com diferentes cenários de operação em conjunto com o uso de indicadores de eficiência energética. Uma aplicação prática do EPANET pode ser vista em Montenegro (2009), que realizou um estudo na estação de bombeamento do bairro de Mangabeira em João Pessoa-PB. Com o objetivo de avaliar o sistema e propor o desligamento de uma das estações de bombeamento, sem reduzir a qualidade do fornecimento de água, a rede de distribuição de água foi modelada no EPANET. Através do balanço hidráulico do sistema uma das estações foi desligada, aumentando a eficiência energética e operacional do sistema, sem que houvessem custos para a alteração da planta.

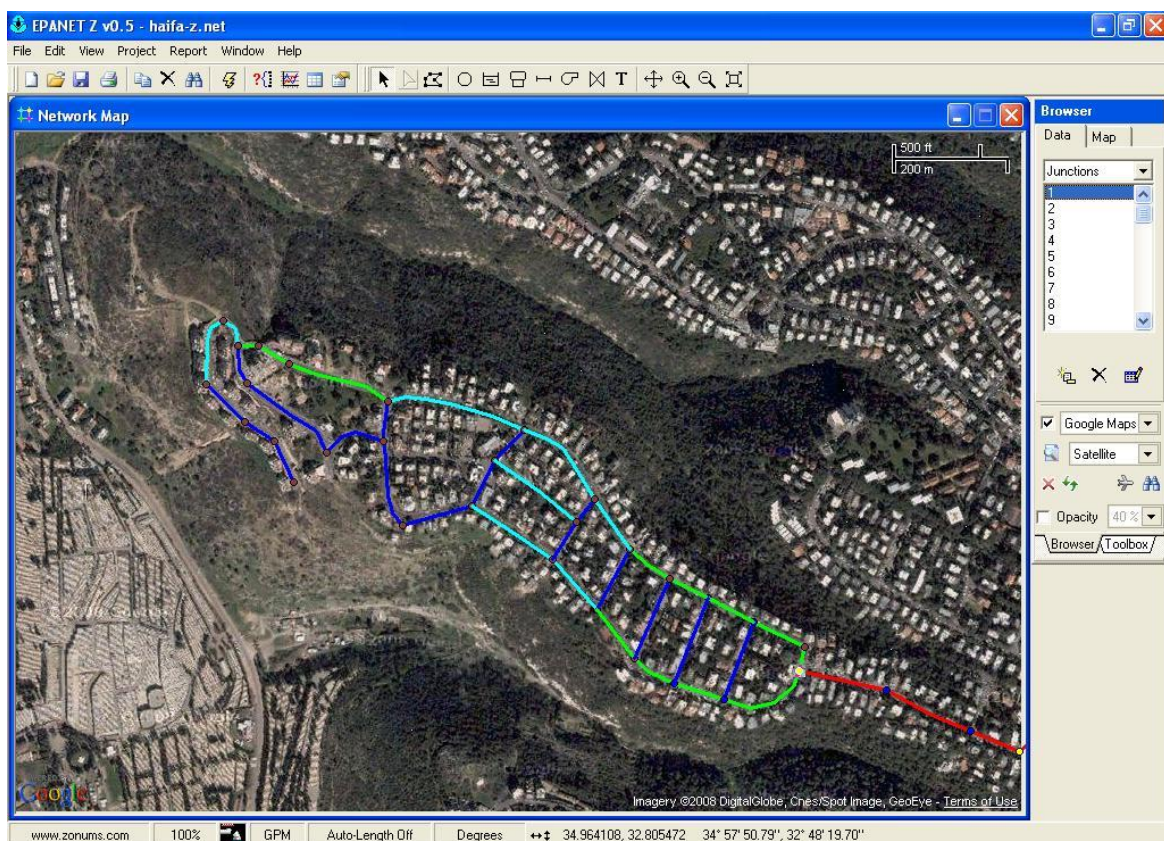


Figura 2.2 – Interface gráfica do EPANET.

Disponível em: optimizaciondeprocesosstorin.blogspot.com. Acesso em 13 de Março de 2020.

No Brasil, este recurso não é comumente utilizado por companhias de saneamento, o que é refletido no péssimo serviço de fornecimento de água. Segundo o Instituto Trata Brasil (2018), cerca de 37% da água se perde entre a estação de tratamento e o consumidor final, acarretando um prejuízo anual de R\$ 8 bilhões de reais. Estes desperdícios se devem aos vazamentos ocasionados pela sobrecarga de pressão na tubulação em períodos de menor demanda de água. Além das aplicações referentes ao EPANET, a automação tem sido cada vez mais implementada em sistemas de bombeamento de água. Ela permite monitorar e controlar os sistemas de tratamento, de bombeamento e a rede de distribuição de água em tempo real e através de uma central computadorizada. Uma das possibilidades da automação é monitorar o consumo energético do sistema, vazamentos na rede de distribuição, ou a de realizar o controle das pressões à jusante. Além disso, ela pode ser utilizada para facilitar a identificação de falhas em equipamentos eletromecânicos, o que resulta no maior ciclo de vida.

2.2 AUTOMAÇÃO DE SISTEMAS DE BOMBEAMENTO DE ÁGUA

Existem duas formas, comumente, utilizadas para abastecer a rede de distribuição de água, por **gravidade** e por **bombeamento direto**. No primeiro caso a rede é abastecida através de um reservatório cuja carga hidráulica varia muito pouco, podendo-se considerar que a cota piezométrica (pressão a montante) é fixa e que não há modulação na sua altura manométrica, sendo que este reservatório tem seu nível regularizado através de uma elevatória de recalque. Já para o segundo caso, a vazão e a altura manométrica da rede variam ao longo do dia em função da demanda horária de água - ilustrada na Figura 2.3. Devido a essa variação, a potência requerida pelo CMB e, conseqüentemente, a energia gasta, obedecerá uma relação entre a altura manométrica e a vazão, dada pela Eq. (2.1). Desta forma, se o CMB trabalha em uma rotação fixa, estabelecida para atender a situação de máxima demanda de água, a bomba irá pressurizar a rede com uma altura manométrica elevada em situações de mínima demanda. Essa situação é desfavorável porque provoca um excesso de pressão na tubulação, resultando no aumento das perdas de água na rede e em um consumo desnecessário de energia. Em busca de atenuar o excesso de pressão e o consumo energético, são utilizados inversores de frequência e sistemas de controle para a regulação automática da velocidade do CMB.




Figura 2.3 – Curva de demanda horária de água.

Fonte: Adaptado de Gomes (2009).

$$POT = \frac{\gamma * Q * H_{man}}{\eta} \quad (2.1)$$

Apesar do controle das pressões de serviço resultarem em diversos benefícios para o sistema, como o menor consumo de água e energia, menor índice de vazamentos e o menor desgaste dos equipamentos eletromecânicos, ainda são utilizados métodos manuais de controle, onde operários são instruídos a abrirem ou fecharem registros de acordo com uma tabela de horários. A automação de sistemas de abastecimento permite a operação assistida e o controle automático de todos os processos envolvendo o sistema, sendo possível realizar o monitoramento e controle das variáveis de interesse da rede de abastecimento através de uma Interface Homem Máquina (IHM) em tempo real. Uma das aplicações mais relevantes da automação é o controle das pressões de serviço do sistema, o que resulta em uma poderosa medida de eficiência energética. Outros pontos atrativos da automação residem na melhoria da qualidade dos serviços de abastecimento, no maior desempenho operacional e na redução de mão de obra não especializada e dos custos com energia elétrica; entretanto, em alguns casos, ainda representa um investimento elevado para o setor de saneamento.

Resumidamente, a automação apresenta poderosos benefícios técnicos e econômicos, dentre as vantagens estão:

- Monitoramento do sistema de bombeamento e da rede de distribuição;
- Diagnóstico, em tempo real, de falhas em equipamentos e vazamentos na rede;
- Controle das pressões e das vazões;

- Redução do consumo energético;
- Redução das perdas físicas de água;
- Maior ciclo de vida dos equipamentos eletromecânicos.

Dentre os elementos existentes na automação, o controlador é um dos principais; basicamente é uma lógica de programação elaborada para interpretar as variáveis monitoradas do sistema - através de sensores - e emitir um sinal de controle - através dos atuadores - para manter as condições desejadas de operação.

Alguns métodos foram desenvolvidos objetivando a eficiência energética de sistemas de bombeamento, sem atuar no controle das pressões (Brion e Mays, 1991; Mora et al., 2013; Larsen et al., 2016; Rinas et al., 2018) e atuando no controle das pressões do sistema (Wei et al., 2013; Galuppini et al., 2020). Entretanto, a não utilização de inversores de frequência limitam as ações de eficiência energética. É também observado o uso frequente de Válvulas de Controle (VCs) para o gerenciamento da pressão e vazão ao longo da rede de distribuição de água (Prescott e Ulanicki, 2008). No entanto, estas VCs introduzem perdas de carga consideráveis no sistema, o que culmina na redução da eficiência do sistema (Signoreti et al., 2016). Assim, diversos trabalhos aplicaram técnicas de controle Fuzzy e Neural em conjunto com inversores de frequência visando o controle das pressões da rede de distribuição de água.

Carvalho (2012) modelou um sistema de abastecimento descrevendo as suas condições de operação para o desenvolvimento de um algoritmo, Fuzzy Mandani, na plataforma computacional LABVIEW. Os resultados mostraram o comportamento das pressões e do consumo nos nós de acordo com o que foi definido no valor de referência, além de apresentar uma redução do gasto energético da ordem de 12,17%. O autor avaliou ainda a resposta do controlador a distúrbios do tipo degrau; concluindo que o controlador Fuzzy alcançou o nível de eficiência desejado, controlando as pressões do sistema de bombeamento nos níveis pré-estabelecidos da rede, com a ação de dois CMBs atuando simultaneamente. Entretanto, foram observados elevados tempos de subida quando o sistema parte do repouso, apresentando, ainda, alta ultrapassagem.

Camboim (2012) realizou o controle de dois CMBs em paralelo, acionados por inversores de frequência, através de Lógica Fuzzy Mandani para a otimização do consumo elétrico. O algoritmo foi desenvolvido, através da expertise do operador, para atender à diversos cenários de operações e critérios de volume e pressão até encontrar a combinação

de velocidade ótima dos CMBs. O autor conclui mostrando que, além da redução do consumo energético, a pressão foi mantida em níveis constantes, havendo aumento no grau de confiabilidade do sistema e a provável redução dos custos com manutenção dos equipamentos eletromecânicos. Entretanto, não foram realizados estudos mais aprofundados relacionando cenários de operação, como a variação de demanda, ao uso de indicadores hidroenergéticos.

Silva (2014) propôs um método adaptativo para a modelagem e o controle de CMBs e VCs de um sistema de bombeamento, visando reduzir o consumo de água e energia elétrica. Na bancada instrumentalizada foi implementada a técnica de Variância Mínima Generalizados auto ajustáveis, com o intuito de modelar e identificar parametricamente os CMBs, assim, como projetar e implementar controladores adaptativos, atuando estes no controle de rotação dos CMBs e no ângulo de abertura da VC. Mesmo atuando na situação mais desfavorável para o consumo energético o sistema apresentou uma redução de 19,2% na energia consumida e 16,7% no consumo específico de energia elétrica. Entretanto, o sistema apresentou elevado tempo de assentamento, de 121 segundos, o que representa um elevado tempo de subida. Em situações desfavoráveis como a variação de demanda, o erro de regime permanente fica acima de 10%, valor insatisfatório para a aplicação.

Mendonça (2016) aplicou a Lógica Fuzzy Mandani em um sistema experimental que emula sistemas de abastecimento com zonas topológicas diferentes. Neste trabalho foram desenvolvidos dois controladores distintos, um para a zona centralizada e outra para a descentralizada, cujo objetivo era garantir as pressões de serviços a partir do controle de duas VCs, de um CMB e de um *Booster*. Os resultados mostraram que as pressões atingiram os valores de referência, reduzindo o consumo energético em comparação com a planta sem controlador. Entretanto, não foram utilizados indicadores hidroenergéticos para contabilizar o ganho energético alcançado com o sistema de controle. Também não foram simulados cenários de operação objetivando verificar o desempenho do controlador.

Buscando minimizar as perdas de água nas tubulações e o gasto de energia em um sistema de bombeamento experimental e de comparar o desempenho de duas técnicas de controle, Moura (2016) e Moura *et al.* (2018) implementaram um Sistema de Controle Fuzzy Neural (SCFN) e um Sistema de Controle Neural Adaptativo (SCNA). O sistema instrumental continha um CMB e uma rede de distribuição de água. Os resultados mostraram que o SCNA apresentou especificações superiores ao SCFN em quase sua totalidade, sendo que este último apresentou elevada ultrapassagem, o que representa risco de rompimento das

tubulações. Entretanto, ambos os controladores apresentaram tempo de pico e de assentamento considerados elevados para o caso ideal - sem variação de demanda -, indicativos de elevado tempo de subida.

Oliveira (2017) demonstrou a eficiência de um sistema de controle Fuzzy Mandani para manter a pressão constante em diversos pontos (nós) de um SAA, sendo observada uma redução de 19,46% da potência ativa. Entretanto, a pressão em condições de variação de demanda apresentaram variações de até 60%, extremamente indesejável para a aplicação em questão. A máxima ultrapassagem também considerada alto para a aplicação, atingiu valores superiores a 10%. O mesmo ocorre no trabalho de Barros *et al.* (2017), neste caso o controlador utilizado é baseado em RNA com arquitetura recorrente, com o intuito de promover o controle da pressão em um SAA com dois CMB em paralelo. É observado uma ultrapassagem praticamente nula e um baixo erro de regime permanente, da ordem de 3%. Entretanto, a ausência de indicadores hidroenergéticos e de simulação de cenários de operação nestes trabalhos, faz com que não seja possível realizar comparações práticas de desempenho.

Flores (2019) desenvolveu um controlador inteligente baseado na lógica Fuzzy Mandani, com Funções de Pertinência (MF) triangulares, para o controle de um sistema de abastecimento emulado na forma de bancada experimental com dois CMBs operando em série-paralelo. O controle visava a redução do consumo energético através do controle das pressões de serviço do sistema. Para tanto, foram utilizados inversores de frequência que recebiam sinal de atuação do controlador para alterar a rotação dos CMBs. Os resultados mostraram que o desempenho do controlador foi satisfatório, reduzindo o erro em regime permanente e diminuindo o tempo de subida em 56% e de assentamento em 82,78%, quando comparado ao controlador clássico (Proporcional). Neste trabalho também não foram utilizados indicadores hidroenergéticos para avaliar o ganho energético do sistema controlado.

Salvino (2018) realizou o controle de dois CMB utilizando Redes Neurais Recorrentes e simulando a demanda de água através da implementação da curva de consumo para duas regiões com cotas piezométricas diferentes. Através do Consumo Específico de Energia (CE), o autor realizou a otimização operacional, como resultados obteve-se uma redução do gasto energético em até 1/3. O desempenho do controlador também foi satisfatório, quando avaliado com relação a distúrbios, como o fechamento parcial ou total de uma válvula. Este trabalho trouxe avanços significativos ao utilizar um indicador

hidroenergético - consumo específico de energia (CE) - para analisar o ganho energético em condições simuladas de operação.

Moreira *et al.* (2019a) demonstraram a eficiência energética da automação em sistemas de bombeamento com demanda variável. Através da aplicação de um controlador Fuzzy Mandani com Funções de Pertinência (MF) Gaussianas foi realizado um estudo energético comparativo para um sistema sem controle, com controle manual e com controlador inteligente. O objetivo consistiu no controle das pressões de serviço, através da manipulação da velocidade do CMB. Foram simulados cenários de operação através da implementação da curva de demanda horária de água. Para avaliar o ganho energético foram utilizados dois indicadores hidroenergéticos. Como resultados foi observada uma redução de até 383% do CE, em horários de baixa demanda, e um aumento de 9,16% no rendimento médio do CMB.

2.3 CONTROLADOR NEURO-FUZZY

A técnica Neuro-Fuzzy (NF) tem amplo uso em aplicações especiais e em diversas áreas da engenharia (Gopal e Shivakumar, 2019; Teklehaimanot *et al.*, 2019; Thangaraj e Somasundaram, 2019; Ferdous *et al.*, 2020; Ghanooni *et al.*, 2020). Proposta por Jang (1993), onde foi nomeada de *Artificial Neural Fuzzy Inference System* (ANFIS), o sistema Neuro-Fuzzy fornece inúmeras vantagens ao combinar as propriedades das Redes Neurais Artificiais (RNA) e da Lógica Fuzzy (LF); como permitir a modelagem de sistemas não-lineares e multivariáveis, características difíceis de serem modeladas por modelos fenomenológicos e até por lógica Fuzzy. Nesta técnica o modelo matemático do sistema a ser controlado não é necessário. A expertise do projetista, para o desenvolvimento da base de regras e formação dos conjuntos Fuzzy, é também dispensada.

Sivakumar *et al.* (2012) projetaram um controlador e um estimador ANFIS para um sistema multivariável de colunas de destilação. Três controladores distintos tiveram seus resultados comparados; um ANFIS, um PID e um modelo de controle preditivo (MPC). Os dados para o treinamento do ANFIS foram advindos de um controlador PID através da resposta ao degrau unitário. Dois tipos de Funções de Pertinência (MF) foram utilizadas para comparação, Triangulares e Gaussianas, em todas as 5 entradas, com um total de 100 amostras para o treinamento. Os resultados apontaram um melhor desempenho com o uso

das MF gaussianas. O autor conclui que as funções gaussianas se adaptaram melhor ao problema multivariável e não-linear estudado, isso porque são funções não-lineares.

Sagayaraj e Thangavel (2014) realizaram experimentos através do Simulink/MATLAB com controladores Fuzzy, PI e ANFIS com o objetivo de realizar o controle das distorções harmônicas, ocasionadas por motores de indução, de uma rede trifásica através de inversores. Para o treinamento do ANFIS foram coletados dados do sistema controlado através de um controlador com ajuste pela média quadrática do erro. Para o controlador ANFIS foram utilizadas MF Trapezoidais e Triangulares, com 2 camadas de neurônios treinados através do algoritmo de aprendizagem *backpropagation*. A comparação entre os três controladores mostrou a superioridade do ANFIS, principalmente na região transitória e em situações dinâmicas. Entretanto, o controlador Fuzzy se aproxima em desempenho do ANFIS. Por fim, o controlador PI é desacreditado devido ao elevado sobressinal e a falta de estabilidade dinâmica.

Tentando mostrar a versatilidade dos controladores Neuro-Fuzzy, Cavallaro (2015) desenvolveu um controlador NF para aplicações em sustentabilidade. O objetivo era de realizar o controle inteligente de um biodigestor para a produção de biomassa. Inicialmente, foi construído um modelo Fuzzy - com 4 variáveis de entrada e 1 de saída - utilizando a expertise humana. Realizado o controle inicial, o autor reuniu em um banco de dados a inter-relação entre os dados de entrada e saída do sistema para o treinamento do ANFIS. Os resultados mostraram o melhor desempenho do controlador ANFIS frente ao modelo Fuzzy. O autor conclui que o sistema de inferência TSK possui maior eficiência para o processamento de dados em problemas de otimização.

Chaya *et al.* (2015) implementaram um controlador ANFIS no Simulink/MATLAB para simular o controle de redes de distribuição de energia renovável através de conversores, cujo objetivo era de balancear as cargas do sistema, que são altamente não-lineares. O uso da técnica NF se justificou, segundo o autor, pela capacidade do controlador em trabalhar com sistemas altamente não-lineares e prever determinadas incertezas, além da capacidade de aprendizagem e generalização. Os dados utilizados no treinamento foram obtidos através de um controlador PI simulado no Simulink. Foram também utilizadas três funções de pertinência triangulares em cada entrada. Os resultados mostraram que houve uma redução dos harmônicos na rede e um aumento da potência ativa. O autor conclui que o controlador ANFIS se adequou bem à dinâmica do desbalanceamento de cargas da rede e do inversor, ao mesmo tempo que operou com uma menor ação de controle, frente ao controlador PI.

Mahmoud *et al.* (2016) realizaram um estudo comparativo de três controladores MIMO para um sistema de produção de amônia não-linear e com distúrbios. Foram testados o *Adaptive model predictive controller* (AMPC), *Adaptive Neural Network Model Predictive Control* (ANNMPC) e o Neuro-Fuzzy. A análise comparativa mostrou a superioridade do método NF diante interferências, distúrbios externo e mudanças nos parâmetros do sistema, apresentando tempo de estabilização até 5,5 vezes menor, quando comparado ao AMPC e menor variância das temperaturas do processo, representativo da menor ação do controle do controlador; estando, a estabilidade em regime permanente de um sistema, intimamente ligada à ação de controle. De modo, que a vida útil de equipamentos eletromecânicos também pode ser influenciada, devido as variações constantes nos parâmetros de operação.

Ghanooni (2020) projetou um controlador Neuro-Fuzzy para o controle preciso da trajetória de um motor *Hybrid Stepper Motor* modelado com o auxílio computacional do Simulink/MATLAB. O método de aprendizagem utilizado foi o *backpropagation* e as MF utilizadas foram as Gaussianas, como forma de melhorar a representação das não-linearidades do sistema. A análise concentrou-se na robustez e na exatidão com mudanças nos parâmetros do sistema, como carga e indução de distúrbios na forma de impactos. Os resultados mostraram que, quando comparado ao controlador PI (o mesmo utilizado para construir o banco de dados para o treinamento), o controlador propostos apresentou melhor adequação às não-linearidades e incertezas do sistema, apresentando, por isso, melhores condições de aplicações reais e práticas.

2.4 IDENTIFICAÇÃO DE SISTEMAS

A obtenção do modelo do sistema está associado a sua importância para o estudo, otimização, análise e projeto de algoritmos de sistemas controle (malha aberta, adaptativos, dentre outros). As técnicas de identificação de sistemas consistem na construção de modelos dinâmicos baseado em dados medidos (Ljung, 2017). As técnicas computacionais progrediram muito nos últimos anos e estão tomando o lugar da matemática clássica na modelagem e no projeto de muitos sistemas dinâmicos (Moreira *et al.*, 2019a). De certo, sistemas muito complexos e com não-linearidades severas são melhores representados por modelos computacionais, principalmente por modelos inteligentes, como as redes neurais, os sistemas Fuzzy (SF) e Neuro-Fuzzy. Há ainda os modelos paramétricos, amplamente utilizados para sistemas lineares.

Os modelos paramétricos são formados pelas Equações de Espaço de Estados (SS), Funções de Transferência (TF), Autorregressivo com Entradas Exógenas (ARX) e Autorregressivo com Entradas Exógenas com Média Móvel (ARMAX). Diversos trabalhos utilizaram modelos paramétricos para a identificação de sistemas lineares ou com poucas não-linearidades. Cavalcanti *et al.* (2018) realizaram a modelagem SISO (1 Input - 1 Output) de um sistema de bombeamento de água utilizando modelos paramétricos, onde o ARMAX apresentou o melhor ajuste e menor Erro Final de Predição (FPE). Por ser o sistema aproximadamente linear, os modelos regressivos apresentaram resultados satisfatórios.

Coutinho (2018) objetivando realizar uma análise comparativa, realizou a modelagem MISO (2 entradas - 1 saída) de um sistema de bombeamento fotovoltaico por RNA e por modelos polinomiais, a RNA apresentou Raiz do Erro Médio Quadrático (RMSE) 45 vezes menor, justamente por ser o sistema não-linear. Oliveira *et al.* (2010), por sua vez, demonstraram a capacidade das RNA em representar sistemas altamente não-lineares através da modelagem MIMO (4 entradas - 3 saídas) de um motor de indução trifásico acionado por tensões desequilibradas. Os resultados mostraram que a RNA teve RMSE até 13 vezes menor que os modelos matemáticos para o caso. Kilic *et al.* (2012) realizaram a modelagem MIMO (3 entradas - 2 saídas) de uma válvula hidráulica servo-controlada através de RNA, como resultados obteve um modelo computacional até 7 vezes mais eficiente que um NARX, uma hibridização entre RNA e ARX. Outros trabalhos também focaram no desenvolvimento de modelos matemáticos (Feng *et al.*, 2019; Ha *et al.*, 2019) e paramétricos (Meunier *et al.*, 2019; Xião *et al.*, 2019) para sistemas hidráulicos lineares, alcançando resultados apenas satisfatórios.

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

Coura (2018) com o objetivo de corrigir valores atípicos em redes elétricas inteligentes, utilizou o ANFIS para a identificação e a correção dos *Outliers*. Na análise dos resultados foi constatado que o ANFIS apresentou, em todos os casos, um menor erro relativo máximo, quando comparado às RNA.

Outros trabalhos também foram desenvolvidos ressaltando a robustez dos modelos Neuro-Fuzzy (Amirkhani *et al.*, 2015; Sierra *et al.*, 2017; Gao *et al.*, 2019 e Mitra e Miriyala, 2019).

CAPITULO III

3 FUNDAMENTAÇÃO TEÓRICA

3.1 IDENTIFICAÇÃO DE SISTEMAS

A identificação de sistemas permite obter um modelo, que é uma representação computacional ou numérica do sistema. “O modelo obtido pode ser usado para obter uma noção do comportamento do sistema, como predição, controle, estimação do estado, simulação, etc.” (Moscinski e Ogonowski, 1995). Modelos matemáticos constituem um eficiente mecanismo para resumir o conhecimento acerca de um processo ou sistema (Furtado *et al.*, 2002). Entretanto, a complexidade do sistema, por vezes, impede a obtenção do modelo matemático.

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

Segunda Lima (2000) as etapas para a obtenção de um modelo computacional são:

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

- iii. Estimaco de parmetros: ajuste dos parmetros livres usando as estatsticas obtidas dos dados;
- iv. Validao: avaliao do desempenho do modelo para os dados de teste.

A identificao de sistemas por modelos computacionais  possvel devido as diversas ferramentas computacionais oferecidas atualmente, como o *system identification* do Matlab. A ampla oferta destes pacotes permite a modelagem em mais de uma tcnica, permitindo a comparao e a seleo do modelo mais eficiente. Entretanto, para a realizao deste tipo de modelagem  necessrio uma grande disponibilidade de dados amostrais de toda regio de operao do sistema, que devem ser obtidos atravs de ensaios experimentais da planta. Dentre os modelos mais utilizados esto os paramtricos e os inteligentes. Segundo Bittencourt (2007) h algumas estruturas de modelos padres utilizadas na identificao paramtrica, que normalmente so estruturas de modelos discretos. Dentre os diferentes modelos utilizados, destacam-se: Box-Jenkins (BJ), Output Error (OE), Auto Regressivo com Entradas Exgenas (ARX), Auto Regressivo com Mdia Mvel e Entradas Exgenas (ARMAX) e estrutura de Espao de Estados (SS).

Tcnicas de inteligncia artificial, como as redes neurais, so tambm utilizadas para a identificao de sistemas, devido a sua capacidade de relacionar variveis de entrada para saidas com caractersticas no-lineares.

3.1.1 Anlise e validao do modelo

Obtido o modelo computacional,  necessrio utilizar indicadores ou mtodos para avali-lo quantitativamente, e valid-lo. A validao de um modelo  mais um princpio quantitativo do que qualitativo, pois depende fortemente da aplicao. Um mtodo de estimao de parmetros bastante comum e geral  o mtodo de Erro Final de Predio (FPE), onde os parmetros do modelo so escolhidos de forma a minimizar a diferena entre a saida do modelo (predio) e a saida medida (Ljung, 2020). Para cada valor do vetor de parmetros (θ), o modelo  capaz de prever qual ser a saida $y(t)$ – como mostrado na Equao (3.1) -, baseado nas medidas de entrada e saida, $u(s)$ e $y(s)$, respectivamente, para $s \leq t-1$, ou seja, entradas e saidas anteriores.

$$y(t) = Q(q)u(t) + H(q)e(t) \quad (3.1)$$

No caso geral, a Equação (3.2) pode ser utilizada para obter o FPE, a predição pode ser deduzida da seguinte forma:

$$H^{-1}(\theta, q)y(t) = H^{-1}(\theta, q)Q(\theta, q)u(t) + e(t) \quad (3.2)$$

Segundo Bittencourt (2007), a Equação (3.3) é uma expressão geral de como os modelos realizam a predição do próximo valor da saída, dados os valores antigos de entrada e saída. Assim, pode-se verificar quão boa é essa predição calculando o erro de predição (Ljung e Glad, 1994):

$$\epsilon(t, \theta) = y(t) - \hat{y}(t|\theta) \quad (3.3)$$

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

Além disso, é possível confrontar a saída do modelo com uma nova sequência de dados de validação. Em termos estatísticos esse método é chamado de validação cruzada e é um método natural de comparação, pois se um modelo é capaz de prever uma sequência de dados melhor que outro, ele deve ser tratado como o melhor modelo encontrado (Ljung e Glad, 1994). Segundo Bittencourt (2007) o problema da validação cruzada é que quanto maior for a ordem do modelo menor será a função de custo. Se os valores dessa função forem plotados como uma função da ordem do modelo, será obtida uma função decrescente. Assim, mesmo depois que a ordem “correta” do modelo tiver passado, a função de custo continuará diminuindo. A razão é que parâmetros extras (e não necessários) são usados para ajustar o modelo às perturbações específicas dos dados usados. Isso é chamado de sobre ajuste e não tem nenhum benefício se o modelo for usado quando outras perturbações afetarem o sistema. Pelo contrário, o modelo será na verdade pior por causa do sobre ajuste (Ljung e Glad, 1994).

Outras métricas são utilizadas para avaliar o desempenho de cada modelo, Raiz do Erro Médio Quadrático (RMSE), Raiz do Erro Médio Quadrático Normalizado (NRMSE) e percentual de Ajuste, mostradas nas Equação (3.4) à (3.6), respectivamente.

$$RMSE = \sqrt{\frac{\sum_{k=1}^P (y^k - \hat{y}^k)^2}{n}} \quad (3.4)$$

$$NRMSE = \frac{1}{y_{max} - y_{min}} * RMSE \quad (3.5)$$

$$AJUSTE = \left(1 - \frac{1}{P \sum_{k=1}^P |y^k - \hat{y}^k|} \right) * \frac{100}{\hat{y}^k} \quad (3.6)$$

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

Em geral, as características referentes a qualidade do modelo devem ser sempre em base quantitativa, predizer que um modelo realmente é bom, depende da sua aproximação numérica com o sistema real. Na prática, nem sempre se tem uma descrição exata disponível, e a qualidade do modelo deve, sempre que possível, ser julgada em diferentes aspectos (Ljung e Glad, 1994):

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

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

3.2 SISTEMAS DE CONTROLE

Um sistema de controle é o conjunto de equipamentos e dispositivos que gerenciam, ou controlam, o comportamento automático de máquinas, componentes elétricos ou outros sistemas físicos dinâmicos. Através do monitoramento das variáveis de entrada, o

controlador emite um sinal para controlar as variáveis de saída, visando mantê-las dentro de valores pré-estabelecidos pelo projetista. O controlador pode ser avaliado segundo o seu desempenho em regime transitório, permanente ou em relação aos distúrbios, através das respostas apresentadas pelo sistema controlado. A análise em regime transitório e em regime permanente são comumente utilizadas para verificar e comparar o desempenho de sistema de controle e controladores.

A partir da aplicação do controlador na planta é necessário realizar a análise de alguns parâmetros, com o intuito de caracterizar o controlador e sua eficiência (Nise, 2002).

- i. Tempo de atraso (T_d): tempo necessário para o sinal alcançar, pela primeira vez, metade do valor final;
- ii. Tempo de subida (T_r): tempo necessário para o sinal ir de 10% a 90% de seu valor final;
- iii. Instante de pico (T_p): Tempo necessário para a resposta atingir seu valor máximo pela primeira vez;
- iv. Máxima ultrapassagem percentual: valor em porcentagem que representa o quanto o pico alcança em relação ao valor de referência;
- v. Tempo de assentamento ou tempo de acomodação (T_s): tempo necessário para que a resposta permaneça no interior de uma faixa de $\pm 2\%$ em torno de seu valor de referência.

Os sistemas em malha fechada podem operar de diversas formas, mediante o algoritmo de programação proposto: on-off (liga-desliga), proporcional, integral, derivativo, ou ainda combinações dos três anteriores, como PID. Neste trabalho, um controlador baseado na lógica Fuzzy é utilizado. Os sistemas de controle baseados na LF apresentam uma metodologia mais intuitiva, quando comparado a outros controles, exigindo para sua implantação um conhecimento detalhado da planta ou processo. Isto porque sua base de regras e suas funções de pertinência devem ser baseadas no conhecimento do projetista (expertise) sobre a planta ou processo a ser controlador.

A Figura 3.1 – Sistema de controle Fuzzy em malha fechada. ilustra um sistema de controle de malha fechada com controlador baseado na Lógica Fuzzy. A estrutura do controlador é representada por quatro componentes: Base de regras, Fuzzificador, Defuzzificador e o Mecanismo de inferência.

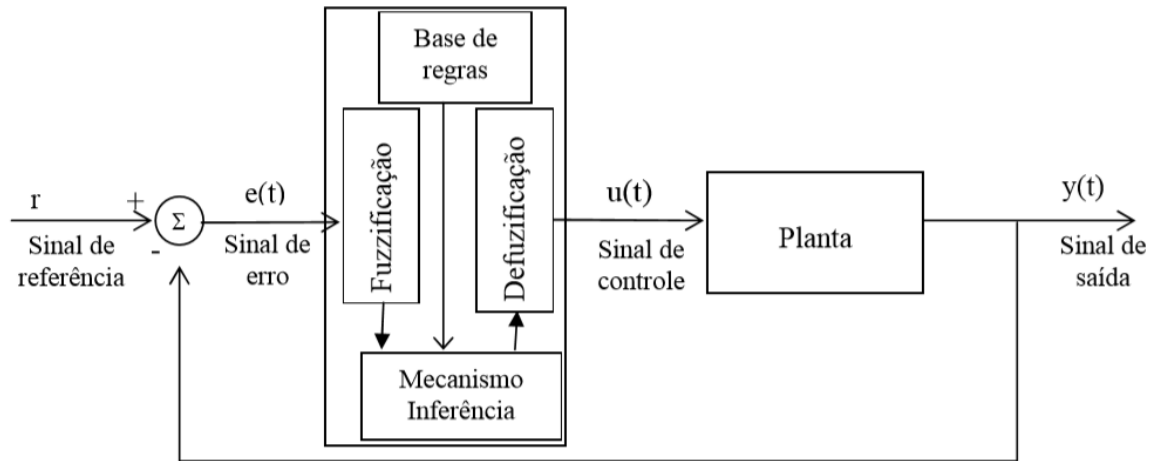


Figura 3.1 – Sistema de controle Fuzzy em malha fechada.

Fonte: Donadel (2012).

3.3 INTELIGÊNCIA ARTIFICIAL

Uma área que tem apresentado um grande avanço nos últimos anos é o da inteligência artificial; em particular as Redes Neurais Artificiais, Sistemas Nebulosos (lógica Fuzzy) e suas hibridizações têm motivado inúmeros trabalhos, e uma larga gama de aplicações vêm sendo propostas na literatura. Um dos principais objetivos das pesquisas em inteligência artificial é o de criar sistemas computacionais que emulem características especiais inerentes aos seres humanos, como aprendizado, intuição, raciocínio lógico aproximado, capacidade de generalização, entre outras (Haykin, 2007). Aplicações de sistemas inteligentes na modelagem de vários sistemas dinâmicos têm se mostrado altamente promissoras (Lopes, 2010; Oliveira, 2010; Coutinho, 2018; Coura, 2018). Diversas outras aplicações também foram realizadas no controle de sistemas dinâmicos (Carvalho, 2012; Chaya *et al.*, 2015; Cavallaro, 2015). As técnicas inteligentes também já foram exploradas na modelagem de sistemas de bombeamento de água (Gonçalves *et al.*, 2011; Meirelles *et al.*, 2017; Nourani *et al.*, 2018 Cavalcanti *et al.*, 2018) e no controle (Salvino, 2016; Mendonça, 2016; Oliveira, 2017; Barros *et al.*, 2017; Moura *et al.*, 2018; Moreira, 2019a).

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

3.3.1 Lógica Fuzzy

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

Um sistema baseado em regras Fuzzy contém, ao menos, três componentes:

- i. Dicionário, que define os conjuntos Fuzzy sobre as variáveis: Fuzzificação;
- ii. Base de regras, que estabelece uma relação entre as variáveis de entrada e de saída;
- iii. Método de inferência, usado para determinar a saída dado uma certa entrada.

Eventualmente, pode-se acrescentar um quarto componente, chamado de defuzzificador, que transforma uma saída Fuzzy em um número real ou um conjunto clássico. A Figura 3.2 ilustra um sistema de inferência do tipo Mandani, comumente utilizado em aplicações de controle.

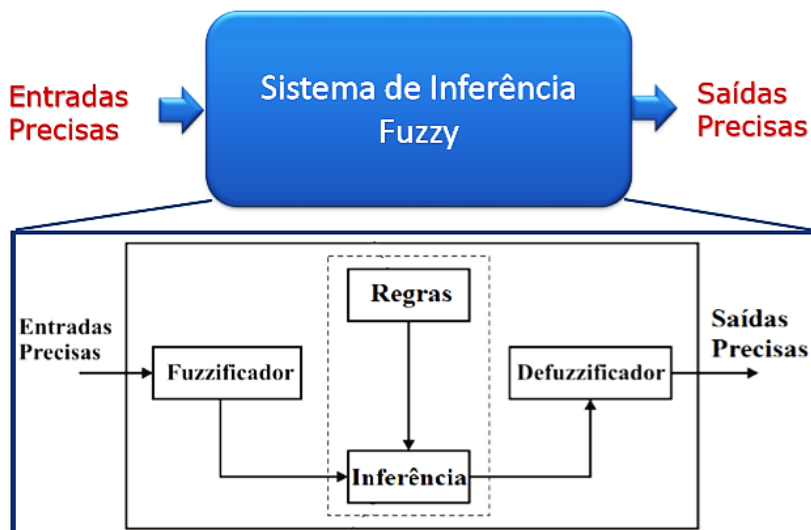


Figura 3.2 – Arquitetura Fuzzy Mandani.

Fonte: Villanueva (2019).

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

numérico para linguístico dá-se o nome de Fuzzificação. Toma-se como exemplo a altura de um elevador; em determinado momento ela pode ter um conjunto de diferentes distâncias em relação ao solo, como {baixa, média, alta}, cada conjunto representa um intervalo numérico da altura, como pode ser visto na Figura 3.3.




Figura 3.3 – Conjunto Fuzzy ilustrando a variável altura à função de pertinência.
Disponível em: www.tutorialspoint.com. Acesso em 16 de novembro de 2019.

Para definir o comportamento do sistema Fuzzy uma base de regras deve ser elaborada. No geral, “as regras descrevem situações específicas que podem ser submetidas à análise de especialistas, e cuja inferência conduz a algum resultado desejado” (Ortega, 2001). A base de regras representa, não somente, o conjunto de regras que através de um antecedente são programadas para gerarem um consequente através de proposições condicionais do tipo “**Se – Então**”, mas também o processo que determina o conjunto de saída, consequentemente, o valor numérico da saída.

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

3.3.1.1 Fuzzy – Mandani

No modelo de inferência Mamdani (1977) as saídas são construídas pela superposição dos consequentes das regras individuais do tipo: Regra i : Se x é A_i então y é B_i onde $i = 1, 2, \dots, n$, n é o número de regras, x é a variável linguística de entrada, y é a

variável linguística de saída e A_i e B_i são subconjuntos Fuzzy, respectivamente, dos universos de discursos U e V .

De acordo com o algoritmo de Mamdani, a inferência Fuzzy é executada utilizando a base difusa de conhecimento, ilustrado através da Equação (3.7) e Figura 3.4.

$$\begin{aligned}
 & \text{if } (X_1 \text{ é } a_{1,1}) \text{ e } (X_2 \text{ é } a_{1,2}) \text{ e } \dots \text{ e } (X_n \text{ é } a_{1,n}) \text{ então } (Y \text{ é } d_1)(W_1) \\
 & \text{if } (X_1 \text{ é } a_{2,1}) \text{ e } (X_2 \text{ é } a_{2,2}) \text{ e } \dots \text{ e } (X_n \text{ é } a_{2,n}) \text{ então } (Y \text{ é } d_2)(W_2) \quad (3.7) \\
 & \text{if } (X_1 \text{ é } a_{m,1}) \text{ e } (X_2 \text{ é } a_{m,2}) \text{ e } \dots \text{ e } (X_n \text{ é } a_{m,n}) \text{ então } (Y \text{ é } d_m)(W_m)
 \end{aligned}$$

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

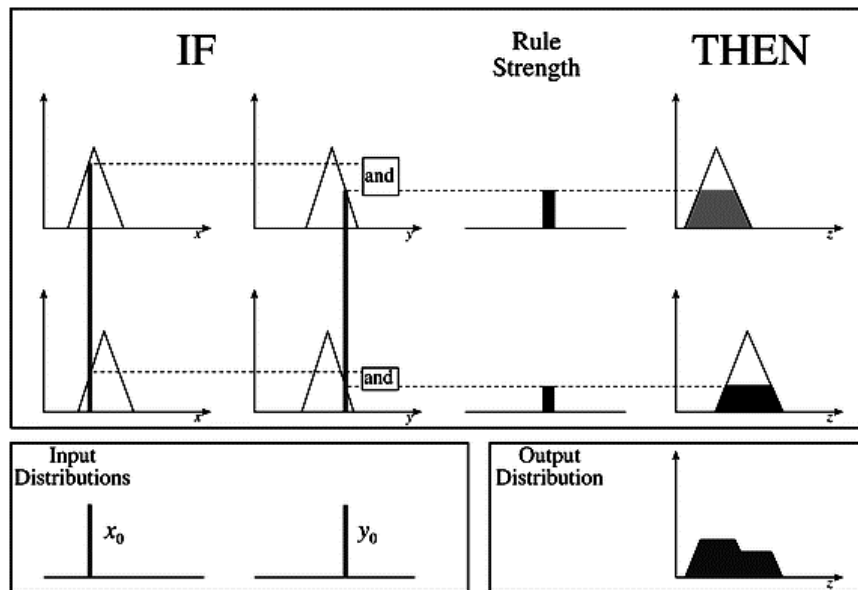


Figura 3.4 – Sistema de inferência Mamdani.

3.3.1.2 Fuzzy – Sugeno

O controlador de Sugeno, ou TSK (Takagi, Sugeno e Kang, 1983), consiste em uma simplificação do controlador de Mamdani, onde o consequente de cada regra é definido como uma função das variáveis linguísticas de entrada. No modelo de Sugeno, as regras são também da forma “Se – Então”, onde o consequente pode ser uma constante ou uma função linear, tal como mostrado na Equação (3.8):

$$\text{SE } X_1 \text{ é } A_{1i} \text{ e } X_2 \text{ é } A_{2i} \text{ e } \dots \text{ e } x_n \text{ é } A_{ni}, \text{ ENTÃO } y = f_i(X_1, X_2, \dots, X_n) \quad (3.8)$$

Em que A_{1i} , A_{2i} , ..., A_{ni} são conjuntos Fuzzy dos antecedentes, enquanto que o consequente é uma função das variáveis de entrada, que pode ser linear ou uma constante a ser definida pelos requisitos do projeto. Quando for linear, o consequente se tratará de uma representação em forma de uma função de primeiro grau. Quando o consequente for constante, a saída será um valor fixo e não dinâmico. “O modelo consiste em um sistema de inferência capaz de descrever, de forma exata ou aproximada, sistemas dinâmicos não-lineares por meio de um conjunto de sistemas dinâmicos lineares localmente válidos, interpolados de forma suave, não-linear e convexa” (Lopes, 2017).

Um exemplo para o sistema de inferência Sugeno é ilustrado na Figura 3.5, onde duas variáveis de entrada tem os seus valores apresentados; atribuído um valor de pertinência a cada conjunto, são atreladas uma função linear definida no projeto e que posteriormente são ponderadas por meio de uma média, em que w_i é o peso da função de inferência em função do valor de pertinência do conjunto Fuzzy.




Figura 3.5 – Sistema de inferência Sugeno para um consequente linear.

Fonte: Jang (1993).

Dada uma entrada (X_1, X_2, \dots, X_n) , a saída com um número k de regras “Se-Então” é dada pela média ponderada das Funções de pertinência ativadas pelo antecedente, que pode ser resumida pela Equação (3.9):

$$y = \frac{\sum_{i=1}^k w_i \cdot f_i(x_1, x_2, \dots, x_n)}{\sum_{i=1}^k w_i} \quad (3.9)$$

Outra aplicação prática de sua saída é ter um interpolador não-linear para funções lineares (Passino e Yorkovich, 1998). A estrutura dos modelos TSK é intrinsecamente adequada para a representação de sistemas dinâmicos complexos, não-lineares e multivariáveis (Filev, 1991). O consequente Fuzzy TSK possui uma saída dinâmica representada por funções cuja complexidade dependem da região de saída. Caso a saída seja trivial pode-se utilizar funções mais simples de forma a reduzir o número de regras. Caso a região precise representar uma não-linearidade, funções mais complexas podem ser utilizadas em um número maior na região de saída. Neste tipo de modelo de inferência utiliza-se o conceito de linearidade ou não-linearidade locais. Assim, o modelo Fuzzy TSK é capaz de aproximar um sistema não-linear com uma combinação de vários sistemas lineares, através da decomposição de todo o espaço de entrada em vários espaços parciais.

Algumas das vantagens desse método frente ao de Mandani residem na:

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

3.3.2 Redes Neurais Artificiais (RNA)

As RNA são um algoritmo computacional derivado do conceito de *Machine Learning* e que apresentam como características a capacidade de aprendizado através de dados mensurados do sistema, mesmo que imprecisos e não-lineares (Haykin, 2007). Sua estrutura é semelhante a de um neurônio biológico com corpo e linhas de transmissão, axônio e dendrito, respectivamente.

Algumas revisões sobre a área costumam “pular” os anos 1960 e 1970 e apontar um reinício da área com a publicação dos trabalhos de Hopfield (1984), relatando a utilização de redes simétricas para otimização e de Rumelhart, Hinton e Williams que introduziram o método *Backpropagation*, no qual proporcionou que os algoritmos de RNA pudessem ter mais de uma camada, sendo possível a representação de sistemas não-lineares, multivariáveis e a retro-propagação do erro.

Uma RNA é composta por uma rede variada de neurônios organizados em camadas; eles são bem básicos e interligados entre si por uma entrada e uma saída, a qual possuem pesos e estes podem assumir diferentes valores até atingir-se uma determinada saída. Cada camada pode possuir um número diferente de neurônios. As unidades (neurônios) fazem operações apenas sobre seus dados locais, que são as entradas recebidas pelas suas conexões. Segundo McCullock e Pitts (1943) as operações básicas de processamento são:

- Sinais são apresentados à entrada (que não realizam cálculos);
- Cada sinal é multiplicado por um peso (aleatório), que indica a sua influência na saída da unidade;
- É feita a soma ponderada dos sinais que produz um nível de atividade;
- Se este nível de atividade exceder um certo limite (*threshold*) a unidade produz uma determinada resposta de saída, que pode ser única ou composta.

A estrutura é organizada em três camadas, como ilustrado na Figura 3.6:

- Camada de entrada: Entrada do sinal.
- Camada intermediária: Onde é realizado o processamento, os pesos (w) são ponderados, também podem ser considerada de extratora de regras.
- Camada de saída: Conclusão do resultado final e envio do sinal novamente à entrada em um processo iterativo para reduzir o erro (e); o truncamento se dá através de algum critério como o número de interações ou o erro final admissível (e_f).

Por fim, existem diversos algoritmos que determinam a forma de treinamento de uma Rede Neural. Assim, de acordo com as características dos dados de treinamento, um método de aprendizagem é utilizado, normalmente o *backpropagation* com um método de minimização, como os mínimos quadrados. Este algoritmo realiza um processo iterativo de ajuste de pesos sinápticos (w_i) dos neurônios da camada intermediária. A otimização dos

pesos, que acarreta na redução do erro final, é realizada através da soma quadrática das diferenças entre a saída real e a simulada.

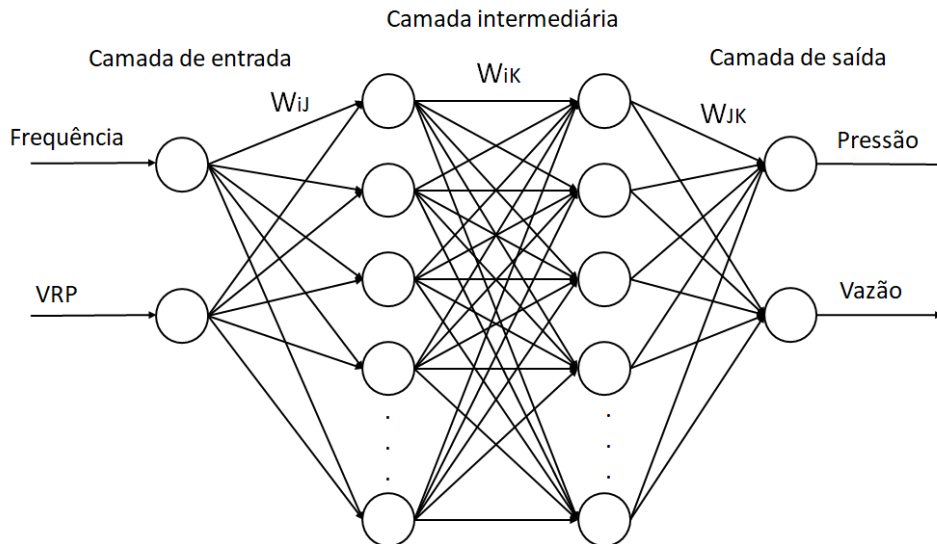


Figura 3.6 – Estrutura MIMO de uma Rede Neural.

3.3.3 Artificial Neural Fuzzy Inference System (ANFIS)

O modelo Neuro-Fuzzy, também nomeado de ANFIS, é o resultado da hibridização de dois métodos inteligentes. Neste tipo de técnica é aproveitada a capacidade da lógica Fuzzy com a utilização dos termos linguísticos e sua modelagem, juntamente com a capacidade de aprendizado e generalização das Redes Neurais Artificiais. As vantagens das Redes Neurais sobre os sistemas convencionais são a sua performance para o mapeamento de entradas e saídas não-lineares, generalização, adaptabilidade e a baixa tolerância. Entretanto, a sua interpretabilidade é de difícil compreensão, dificultando o seu uso. Para solucionar esse problema técnicas Fuzzy podem ser utilizadas com o objetivo de expressar – através dos seus conjuntos e da sua base de regras – o conhecimento humano e a ambiguidade das informações. A grande desvantagem das técnicas Fuzzy é que elas não fornecem a capacidade de aprendizagem para a construção da base de regras e das MF, sendo definidas pela expertise humana, o que resulta em certo grau de incertezas no projeto de controladores. Desta forma, lógica Fuzzy (Zadeh, 1965) e as Redes Neurais Artificiais são tecnologias complementares no projeto de controladores inteligentes (Azar, 2010). Devido a sua versatilidade, há diversas aplicações para o seu uso, como modelagem, identificação e controle de sistemas dinâmicos não-lineares.

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

De forma geral, as RNA são utilizadas para ajustar o intervalo das funções de pertinência e criar a base de regras com o objetivo de atender o critério de saída através da manipulação das constantes de Sugeno. As constantes também podem ser obtidas por outros métodos como, por exemplo, através da solução do problema de Desigualdade Linear Matricial (LMI) (Gomes, 2013) ou também por modelagem matemática (Vitor, 2011) através de Equações de Espaço de Estado acopladas do sistema. A determinação dos parâmetros do modelo de Sugeno dependem da forma da função de pertinência (MF – *membership function*) utilizada e das mudanças dos valores da entrada e saída. Basicamente o algoritmo cria MF para cada regra observando a inter-relação entre os dados de entrada e saída, de forma a ajustar cada parâmetro da MF (antecedente) e das funções de saída (consequente), também chamadas de constantes de Sugeno, o que condiz com a condição de aprendizagem das RNA. Existem diversos tipos as MF (triangulares, trapezoidais, gaussianas...) e que são escolhidas de acordo com os parâmetros do sistema. Em muitas situações não se pode discernir qual a MF olhando apenas para os dados, tal que a escolha da MF é, às vezes, arbitrário.

O algoritmo do ANFIS é composto por cinco camadas, utilizadas no processo de aprendizagem e que alteram continuamente os parâmetros finais do FIS. Os parâmetros (pesos) são alterados de acordo com o erro de cada interação que é obtido através do método dos mínimos quadráticos. Sua estrutura pode ser resumida como ilustrado na Figura 3.7, onde A_{ij} são os conjuntos Fuzzy.

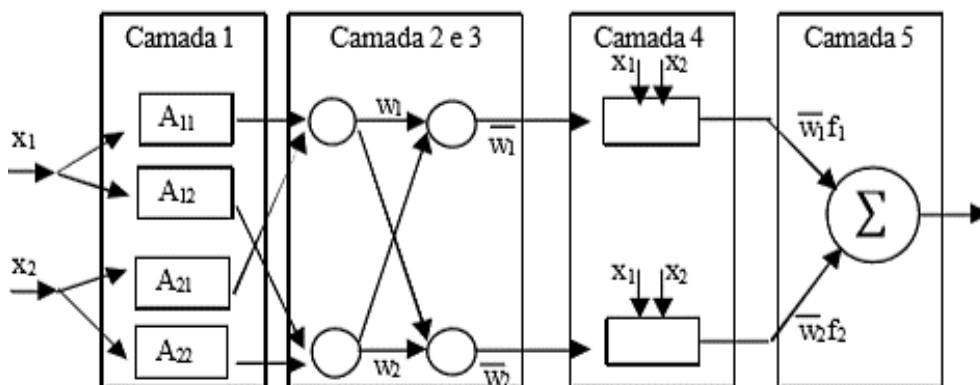


Figura 3.7 – Estrutura de um controlador ANFIS.

A função de cada camada mostrada na Figura 3.7 é descrita por (Jang, 1993):

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

$$w_i = m_{Ai}(x_1)m_{Bi}(x_2) \dots, i = 1, 2, \dots, n \quad (3.10)$$

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

$$y = \frac{\sum_{i=1}^k w_i f_i(x_1, x_2, \dots, x_n)}{\sum_{i=1}^k w_i} = \frac{w_1 f_1 + w_2 f_2 + \dots + w_n f_n}{w_1 + w_2 + \dots + w_n} \quad (3.11)$$

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

$$\bar{w}_{1,2 \dots n} = \frac{w_{1,2 \dots n}}{w_1 + w_2 + w_n} \quad (3.12)$$

4° Camada – Nesta camada, as saídas dos neurônios são calculadas pelo produto dos valores dos conseqüentes da regra, tal como na equação (3.9).

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

$$f = \bar{w}_1 f_1 + \bar{w}_2 f_2 + \bar{w}_n f_n \quad (3.13)$$

Onde n representa o número de variáveis.

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

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

Em resumo, o ANFIS é utilizado para obter um modelo dinâmico de controlador TSK baseado na Lógica Fuzzy. A Figura 3.8 ilustra um fluxograma metodológico para a obtenção de controladores inteligentes baseados na Lógica Fuzzy. O controlador Fuzzy tradicional (Mandani) é obtido, geralmente, por expertise de um operador/projetista. Já para obter um controlador TSK existem três caminhos prováveis: Modelagem matemática através de Equações de Espaço de Estado acopladas, desigualdades matriciais lineares (LMI) ou Modelagem Computacional, os trabalhos de Vitor (2011), Gomes (2013) e Ghanooni *et al.* (2020) descrevem, respectivamente, os métodos mencionados para a obtenção do controlador TSK. As RNA são utilizadas para realizar o mapeamento das Funções de Pertinência dos conjuntos Fuzzy de entrada e saída; para tanto, é necessário um banco de dados, que em geral é obtido do sistema experimental através de um controlador primário.

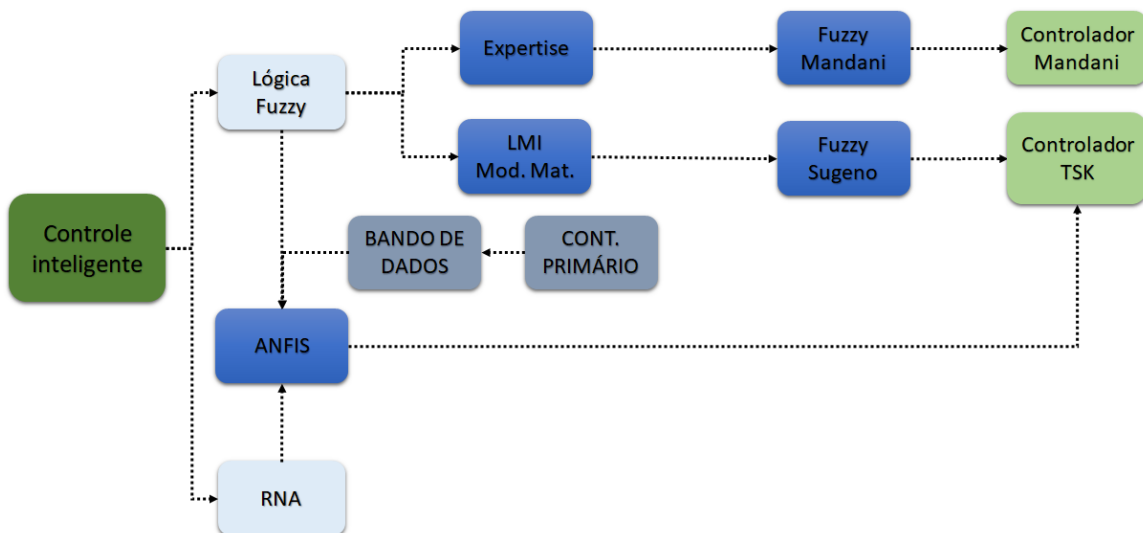


Figura 3.8 – Fluxograma para obtenção de controlador Fuzzy.

CAPITULO IV

4 METODOLOGIA

Esta seção está centrada na apresentação do sistema experimental, mostrando detalhadamente os equipamentos utilizados para a realização dos ensaios experimentais e testes relacionados ao controlador e à eficiência energética. São detalhados, também, os procedimentos metodológicos utilizados para obter o modelo computacional do sistema e para realizar o projeto do controlador Neuro-Fuzzy. Por último, são apresentados os procedimentos utilizados para a realização da análise hidroenergética, por meio da implementação da curva de demanda horária.

4.1 SISTEMA EXPERIMENTAL

A bancada experimental é apresentada na Figura 4.1 – Bancada Experimental (BE)., sendo composta de um reservatório circular com 7,64 m³, dois conjuntos motor bombas (CMBs), dois inversores de frequência, uma válvula de controle eletrônico (VC), cinco transdutores de pressão (PT), dois transdutores de vazão (FT), uma fonte de alimentação, além das instalações elétricas e eletrônicas, e conexões e tubos de PVC (DN 50, DN 75 e DN 100) da rede hidráulica.

Para a objetividade deste trabalho, os testes experimentais foram realizados utilizando apenas parte da bancada experimental, como ilustrada na Figura 4.2.



Figura 4.1 – Bancada Experimental (BE).




Figura 4.2 – Esquema da bancada experimental.

Os CMB adotados são monoblocos, constituídos de um motor de indução trifásico e uma bomba DANCOR, modelo CAM-W10, instalados em uma cota inferior ao nível do

reservatório (“afogada”); a altura manométrica do reservatório é sempre mantida constante. As bombas são centrífugas, de um estágio, com NPSH máximo de 6 metros, diâmetro do rotor de 162 mm, altura manométrica máxima de 45 mca e vazão máxima de 12 m³/h; as especificações do motor são descritas na Tabela 4.1.

Tabela 4.1 – Especificações do Motor do CMB.

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

Na Figura 4.3 são apresentadas as curvas obtidas experimentalmente com a variação da frequência de acionamento do CMB e da vazão, controlada através da abertura da válvula de controle; a variação de frequência tem como objetivo deslocar a curva da bomba, equilibrando o ponto de operação com uma nova curva da tubulação. As curvas do CMB para diferentes configurações de motores estão ilustradas na Figura 4.4, onde a curva 5 representa a do motor utilizado neste trabalho.

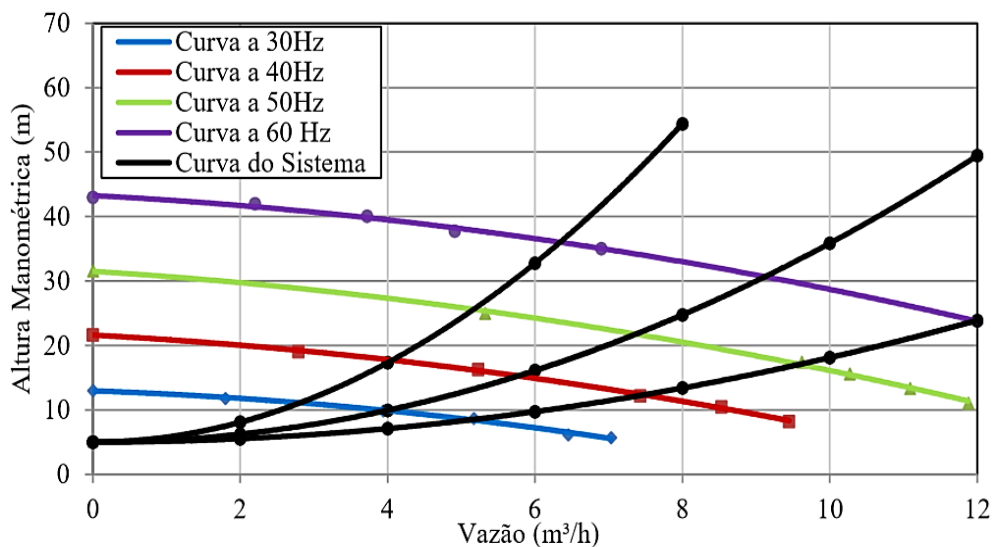


Figura 4.3 – Curvas características das bombas do sistema experimental.




Figura 4.4 – Curvas características da bomba CAM-W10.

Disponível em: <http://www.dancor.com.br>. Acesso em 15 de Março de 2020.

Na Figura 4.5 são apresentadas as curvas em malha aberta para degraus de frequência no inversor e CMB; para curvas, especificadamente, em malha aberta o inverso foi

programado para apresentar tempo de subida suave, como forma de evitar acelerações abruptas no CMB.




Figura 4.5 – Curva malha aberta para degraus de frequência.

Foi utilizado um inversor de frequência, responsável pelo controle de velocidade do CMB. O modelo do inversor é o Altivar 31 da Schneider Electric, o mesmo possui tecnologia de modulação por largura de pulso (PWM), alimentação trifásica com frequência de alimentação 50/60 Hz com tensão de 380 a 500 V.

Foi utilizada uma válvula de controle com o objetivo de variar a perda de carga da rede de abastecimento – linha de descarga – e, conseqüentemente, deslocar a curva da tubulação, visando simular a variação de demanda do consumo de água; tal ação insere distúrbios na planta e força o controlador a estabilizar a pressão do sistema. A válvula é proporcional, tipo esfera, acionada por um motor elétrico que é alimentado por uma tensão de alimentação de $24 V_{ca} \pm 20\%$ ou $24 V_{cc} \pm 10\%$ e torque de 20 Nm. O ângulo de fechamento varia de 0° a 90° (podendo ser ajustado manualmente). A pressão máxima de operação é 140,62 mca. A VC é apresentada na Figura 4.6; na Figura 4.7 e Figura 4.8 são ilustradas, respectivamente, as curvas características da VC dada em função da variação do seu ângulo de abertura para CMB operando com 30 e 60 Hz. Desta forma, a dinâmica do sistema é alterada para cada ângulo de abertura da VC, ou seja, tais mudanças alteram as características do sistema e conseqüentemente a dinâmica de atuação do controlador.



Figura 4.6 – Válvula de controle ARB24-SR.

Disponível em: <http://webmercato.com.br>. Acesso em 09 de janeiro de 2020.




Figura 4.7 – Variação do ângulo de abertura da válvula versus a pressão para o CMB operando com frequência de 30 Hz.




Figura 4.8 – Variação do ângulo de abertura da válvula versus a pressão para o CMB operando com frequência de 60 Hz.

Foram utilizados três transdutores de pressão, modelo Druck PTX 7217, apresentados na Figura 4.9. O primeiro transdutor foi instalado a montante da válvula de controle para representar a pressão de serviço atuante no sistema de distribuição de água – tal como na Figura 4.2. Os demais transdutores foram dispostos a montante e a jusante do conjunto motor-bomba para o cálculo da altura manométrica e pressão de sucção da bomba. Os transdutores de pressão são do tipo piezoresistivo de silício, cujas principais características são apresentadas na Tabela 4.2.



Figura 4.9 – Transdutor de Pressão Druck PTX 7217.

Disponível em: <http://www.davis.com>. Acesso em 09 de janeiro de 2020.

Tabela 4.2 – Especificações técnicas do Transdutor de Pressão (PT).

Fabricante	GENERAL ELECTRIC
Faixa de medição	0 a 42,18 mca
Sinal de saída	4 a 20 mA
Tempo de resposta	1 ms
Precisão	$\pm 0,2\%$ (Fundo de escala)
Tensão de alimentação	24 V

O transdutor de vazão eletromagnético, apresentado na Figura 4.10, foi instalado a jusante do conjunto motor-bomba, respeitando os trechos retos de medição (comprimento mínimo de trecho reto, sem singularidades, a montante e a jusante do medidor) exigidos pelo fabricante. Na Tabela 4.3 são apresentadas as características desse equipamento.



Figura 4.10 – Medidor de vazão eletromagnético VMS Pro.

Disponível em: www.incontrol.ind.br. Acesso em 09 de janeiro de 2020.

Tabela 4.3 – Especificações técnicas do transdutor de vazão eletromagnético VSM 038.

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

O programa computacional utilizado para o gerenciamento do sistema e desenvolver a Interface Homem Máquina (IHM), tal como ilustrado na Figura 4.11, é o LabVIEW™ – *Laboratory Virtual Instruments Engineering Workbench*, que utiliza uma linguagem de programação desenvolvida pela *National Instruments*. O LabVIEW™ é diferente das usuais linguagens de programação porque utiliza linguagem gráfica conhecida como Linguagem G e tem um compilador gráfico aperfeiçoado para maximizar o desempenho dos sistemas, em vez de utilizar linhas de código. O fato de ser totalmente compatível com o dispositivo de aquisição de dados (DAQ) - ilustrado na Figura 4.12 - e a facilidade para processar, armazenar e analisar os dados, foram imperativos para a sua escolha na pesquisa. Os programas gerados no LabVIEW™ são chamados de instrumentos virtuais, porque possuem a aparência e as operações que emulam equipamentos reais (BEZERRA, 2009, p. 77).

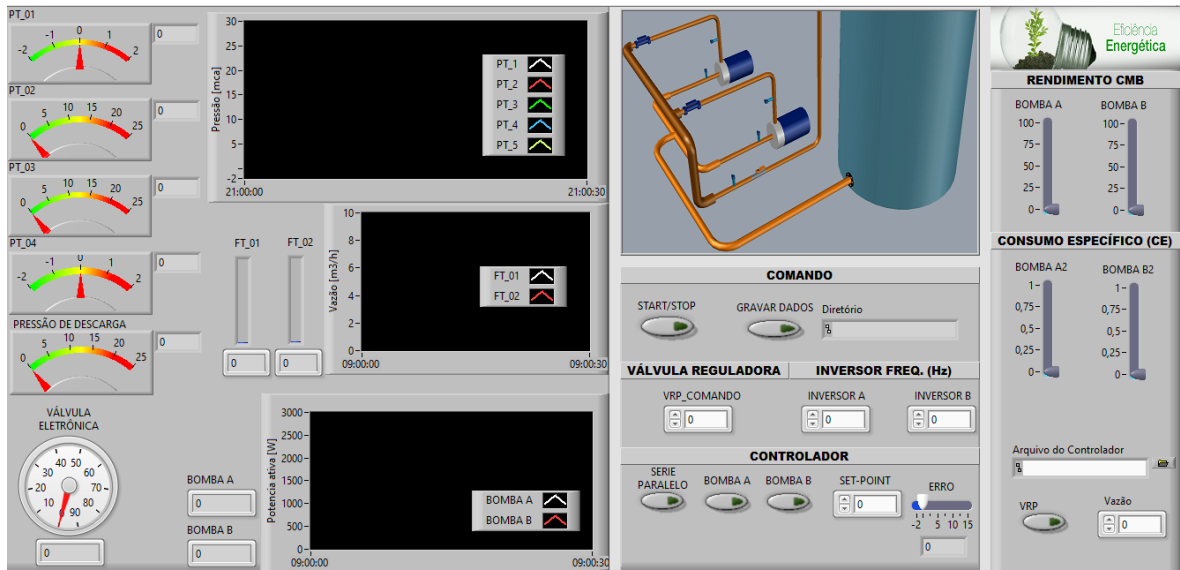


Figura 4.11 – Supervisório.



Figura 4.12 – Sistema de aquisição de dados NI USB-6229.

4.2 IDENTIFICAÇÃO DA BANCADA

O sistema experimental foi identificado com o objetivo de estudar o seu comportamento dinâmico. Possibilitando a realização de simulações, análises e, futuramente, o desenvolvimento de algoritmos de controle (malha aberta e adaptativo). Para tanto, foi construído um banco de dados a partir de ensaios experimentais para o treinamento do modelo. O procedimento experimental consiste da manipulação das variáveis de entrada em observância com as variáveis de saída.

São desenvolvidos cinco modelos mediante a utilização de duas técnicas inteligentes (RNA e ANFIS) - como ilustrado na Figura 4.13 - são dois modelos com demanda fixa (SISO), dois modelos com demanda variável (MIMO) e um modelo da caracterização rendimento do CMB com demanda variável (MISO). Ambas foram desenvolvidas em linguagem de código C no MATLAB/2018. Tendo em vista a importância de comparar os modelos obtidos e utilizar o mais eficiente para cada caso, é realizado um estudo comparativo utilizando os indicadores descritos na seção 3.1.1.

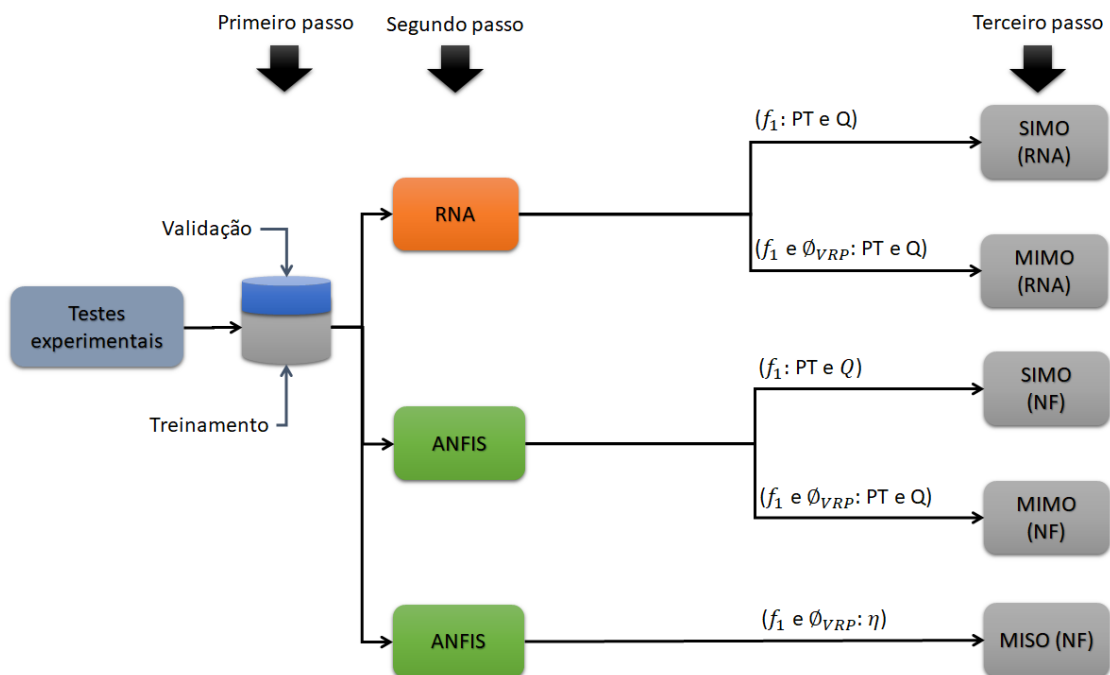


Figura 4.13 – Diagrama dos modelos inteligentes desenvolvidos.

O sistema experimental possui cinco variáveis de interesse, sendo duas de entrada e três de saída; um modelo de múltiplas entradas e múltiplas saídas (MIMO) é necessário para

descrever o seu comportamento. As variáveis de entrada são a Frequência do inversor (f_1) e o Ângulo da VC (ϕ_{VRP}), como saída têm-se a Pressão (PT), a Vazão (Q) e a Potência ativa (W) do CMB. Estas variáveis foram selecionadas devido as correlações que formam; a pressão possui uma correlação direta com a frequência do inversor e o ângulo da VC; a vazão possui relação direta com a frequência e inversa com o ângulo da VC; a potência possui correlação direta com o a frequência do inversor e correlação direta e não-linear com o ângulo da VC. A Tabela 4.4 resume as variáveis modeladas, o intervalo global e o intervalo de variação utilizado nos experimentos para o desenvolvimento do banco de dados para treinamento e validação do modelo.

Segundo Ljung (2017) a escolha da frequência “ideal” de amostragem pode ser definida como, aproximadamente, 10 vezes a largura de banda do sistema (ou a largura de banda de interesse), o que resultará em aproximadamente 5-8 amostras no tempo de subida da reposta ao degrau do sistema. Assim, para evitar o efeito *aliasing*, utilizou-se uma frequência de amostragem igual a 20 Hz. Além disso, é preferível uma amostragem considerada rápida a uma amostragem considerada lenta (Ljung e Glad, 1994).

Tabela 4.4 – Descrição das variáveis utilizadas nos ensaios.

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

*Os valores foram escolhidos aleatoriamente dentro deste intervalo.

O treinamento dos modelos Neural e Neuro-Fuzzy ocorre de forma semelhante e envolve a utilização do algoritmo de treinamento *Backpropagation* em um processos iterativo para redução do erro final. Na Figura 4.14 é ilustrada a arquitetura inicial da RNA desenvolvida neste trabalho. Ela é organizada em três camadas: i) entrada; ii) intermediária; iii) saída. A camada de entrada é responsável por receber os sinais de entrada. Na camada

intermediária é realizado o processamento, ou seja, os pesos (W) são ajustados para reduzir o erro e atender a saída, também é considerada de extratora de regras. Por fim, na camada de saída ocorre a conclusão do resultado final e a realimentação do sinal a entrada, em um processo iterativo, para reduzir o erro (e). O truncamento dá-se através do número de iterações ou o erro final (e_F) admissível. O número de camadas intermediárias e de neurônios por camada pode ser definido através de uma tentativa inicial, aumentando o número de ambos até que os resultados sejam satisfatórios.

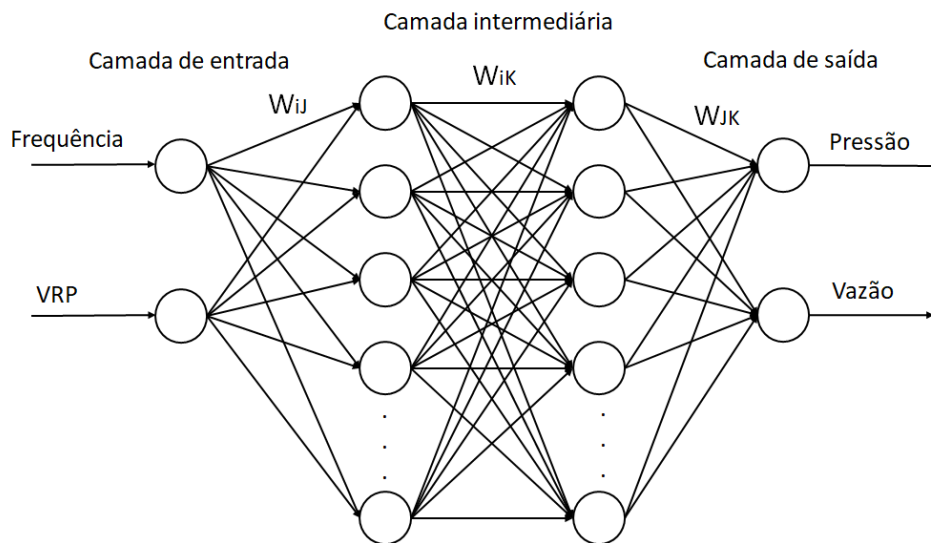


Figura 4.14 – Arquitetura MIMO da Rede Neural.

Na Figura 4.15 é ilustrada a arquitetura inicial do sistema Neuro-Fuzzy desenvolvido neste trabalho. O algoritmo do ANFIS é composto por cinco camadas que fazem parte do processo de treinamento. A primeira camada calcula o grau de pertinência (w_1 e w_2) com que as entradas (x_1 e x_2) satisfazem os valores ou termos linguísticos associados a estes nós. Na segunda camada cada nó corresponde a uma regra e calcula com que grau ($A_{i,j}$) o consequente da regra está sendo atendido, ou seja, são as implicações das premissas. A terceira camada é responsável por realizar a normalização do vetor (\bar{w}_1 e \bar{w}_2). Na quarta camada as saídas dos neurônios (Pressão e Vazão) são calculadas pelo produto dos valores dos consequentes da regra – como na Equação (3.9). Na última camada é calculada a respectiva saída – como na Equação (3.12). O *backpropagation* é utilizado juntamente com a retropropagação do erro quadrático para o treinamento.

Um importante aspecto é a escolha da MF, que podem ser triangulares ou gaussianas, entre outras. Neste trabalho, por se tratar de um sistema não-linear, resolveu-se adotar MF

gaussianas, por representar melhor não-linearidades e com o objetivo de reduzir o número de neurônios da camada intermediária.

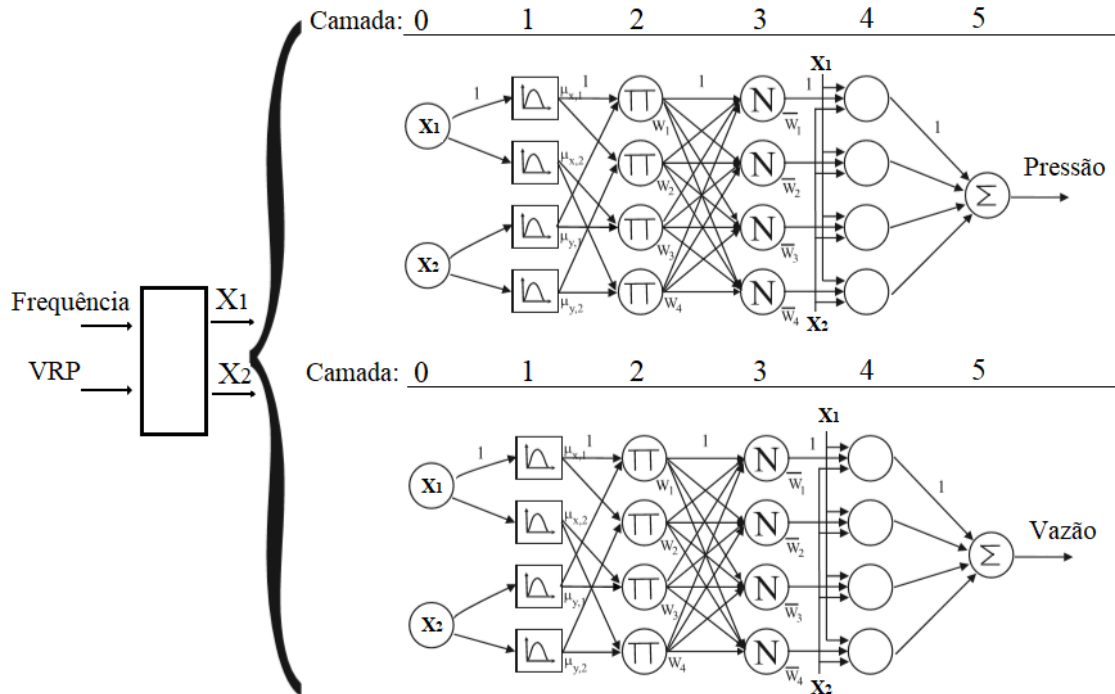


Figura 4.15 – Arquitetura MIMO do sistema Neuro-Fuzzy.

A metodologia utilizada para a identificação do sistema pode ser descrita na forma de fluxograma, como ilustrado na Figura 4.16. O projeto do experimento define as variáveis de interesse do sistema e como elas são manipuladas para produzir as paridades de dados necessárias para o treinamento; seguida da coleta dos dados para o desenvolvimento do banco de dados. A determinação da estrutura está relacionada à estrutura e ordem do modelo, o que é determinado através do conhecimento preliminar sobre o sistema e, geralmente, através de um estudo paramétrico. A validação ocorre a partir da simulação e comparação do modelo com dados experimentais de validação, no que se chama de validação cruzada. O método de estimação trata dos indicadores utilizados para determinar o desempenho quantitativo do modelo. Quanto menor o erro, dado pela Equação (3.3), mais próximo do desejado se torna o modelo computacional; além disso, as Equações (3.4), (3.5) e (3.6) são utilizadas para analisar o erro relativo do modelo. É dada uma atenção especial em relação a Equação (3.6), onde é verificado o ajuste percentual que o modelo tem em relação aos dados experimentais.

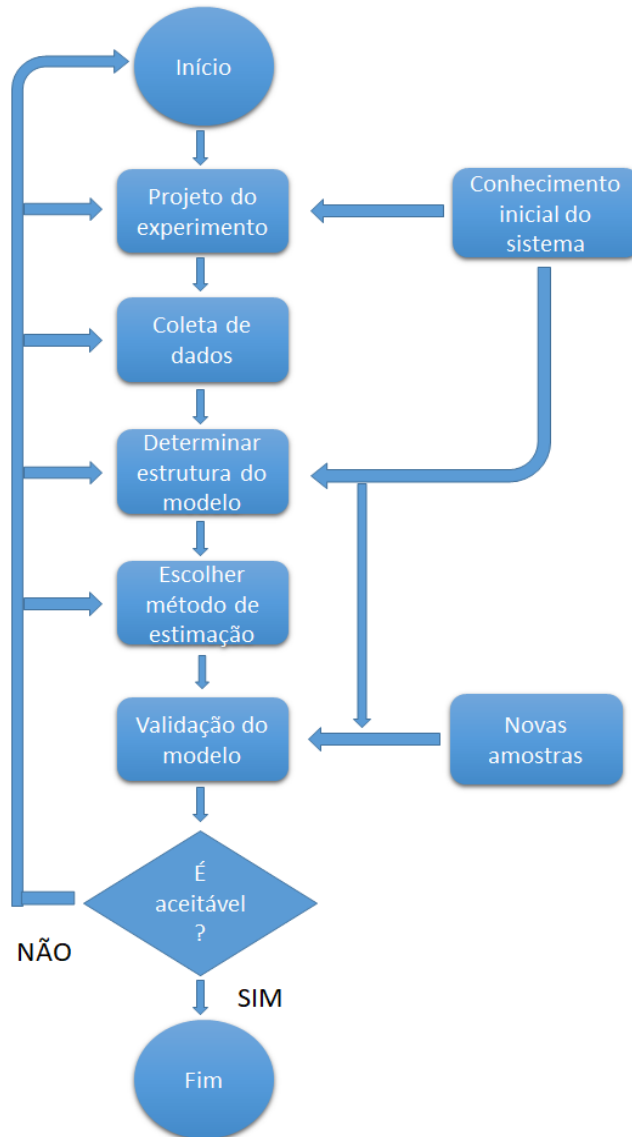


Figura 4.16 – Fluxograma metodológico para modelagem computacional de sistemas.

4.3 PROJETO DO CONTROLADOR

O método de treinamento adotado no algoritmo do ANFIS é o supervisionado; assim, a elaboração desse controlador envolve o desenvolvimento de um banco de dados robusto, com a paridade de dados do sistema controlado por um controlador pré-existente (primário). Um controlador primário pode ser baseado em qualquer técnica de controle, normalmente, são controladores mais simples, convencionais e que em geral, não possuem bom desempenho, como os ajustáveis, compensadores, PID. Neste trabalho é proposto a utilização de um controlador primário heurístico (Fuzzy Mandani) para controlar o sistema e construir a paridade de dados. Este mesmo controlador primário é utilizado na análise

comparativa na seção de resultados. A escolha dessa técnica de controle foi motivada devido ao seu uso recente no trabalho de Moreira *et al.* (2019a), Moreira *et al.* (2019b) e Flores *et al.* (2019). Na seção 5.2.1 é realizada uma análise do uso do controlador primário PD e porquê seu uso foi descartado.

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

O banco de dados é formado pela paridade de dados de duas variáveis de entrada (Erro e Variação do erro) e uma variável de saída (Variação de frequência) – como ilustrado na Figura 4.17. A planta é representada por um sistema caixa preta e sua dinâmica é alterada pelo ângulo de abertura da VC.

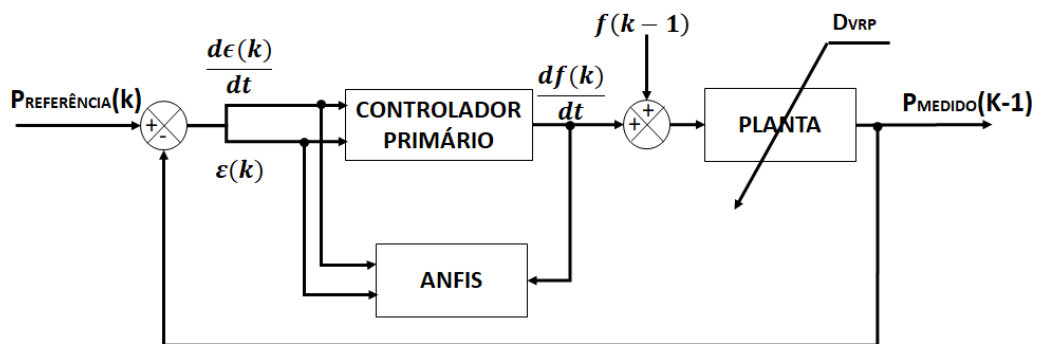


Figura 4.17 – Estrutura de treinamento do controlador ANFIS.

Para a aquisição dos dados de treinamento foi utilizada uma frequência de amostragem igual a 100 amostras/s, estimando um valor médio a cada 10 amostras para reduzir as variabilidades durante a aquisição dos dados. Ao total foram utilizados 5900 conjuntos de dados para o treinamento do controlador Neuro-Fuzzy (NF). Estes dados também foram utilizados para o treinamento do controlador Neural. A Tabela 4.5 contém o formato dos dados adquiridos, usados para o treinamento dos controladores.

Tabela 4.5 – Formato do conjunto de dados.

Instante de amostragem	Erro	Varição do erro	Varição da frequência	Estimação
k-1
k	e(k)	e(k)-e(k-1)	f(k)-f(k-1)	Estimação do valor médio do e, de e df a cada 10 amostras
k+1	e(k+1)	e(k+1)-e(k)	f(k+1)-f(k)	
k+2	e(k+2)	e(k+2)-e(k+1)	f(k+2)-f(k+1)	
...	
k+9	e(k+9)	e(k+9)-e(k+8)	f(k+9)-f(k+8)	
k+10

A estrutura do algoritmo do ANFIS utilizado neste trabalho é ilustrada na Figura 4.18. O processo de treinamento é o mesmo exemplificado na Figura 4.15. A primeira camada calcula o grau de pertinência (w_1 e w_2) com que as entradas (Erro: x_1 e Variação do erro: x_2) satisfazem os valores ou termos linguísticos associados a estes nós. Na segunda camada, cada nó corresponde a uma regra e calcula com que grau ($A_{i,j}$) o consequente da regra está sendo atendido, ou seja, são as implicações das premissas. A terceira camada é responsável por realizar a normalização do vetor (\bar{w}_1 e \bar{w}_2). Na quarta camada as saídas dos neurônios são calculadas através do produto dos consequentes da regra. Na última camada é calculada a respectiva saída (Delta de frequência: Y_1).

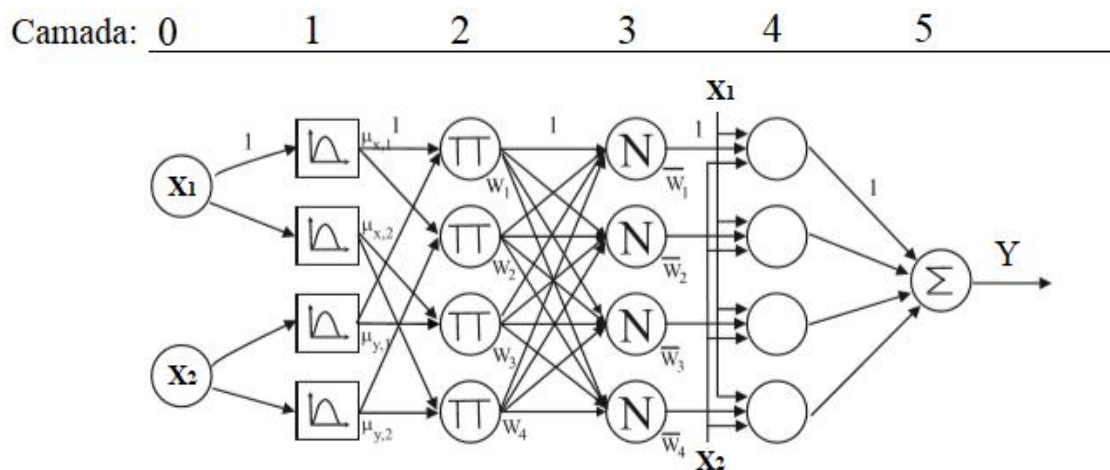


Figura 4.18 – Estrutura do algoritmo de treinamento do ANFIS.

A Figura 4.19 ilustra a estrutura do sistema de controle em malha fechada para o controlador NF. As variáveis de entrada são o Erro e a Variação do Erro, enquanto que a variável de saída é o Delta de frequência.

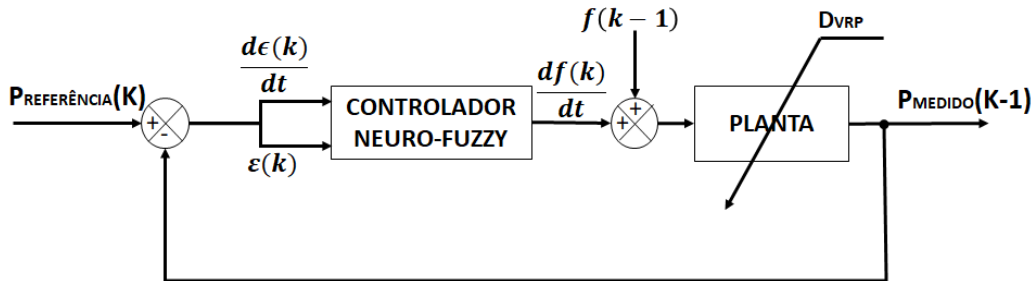


Figura 4.19 – Sistema de controle em malha fechada.

O controlador primário, utilizado para gerar a paridade de dados de treinamento do controlador Neuro-Fuzzy, têm suas funções de pertinência e superfície de controle ilustradas na Figura 4.20 e sua base de regras na Tabela 4.6. A motivação para a escolha das MF gaussianas é atribuída a suas melhores características em representar conjuntos de dados não-lineares.

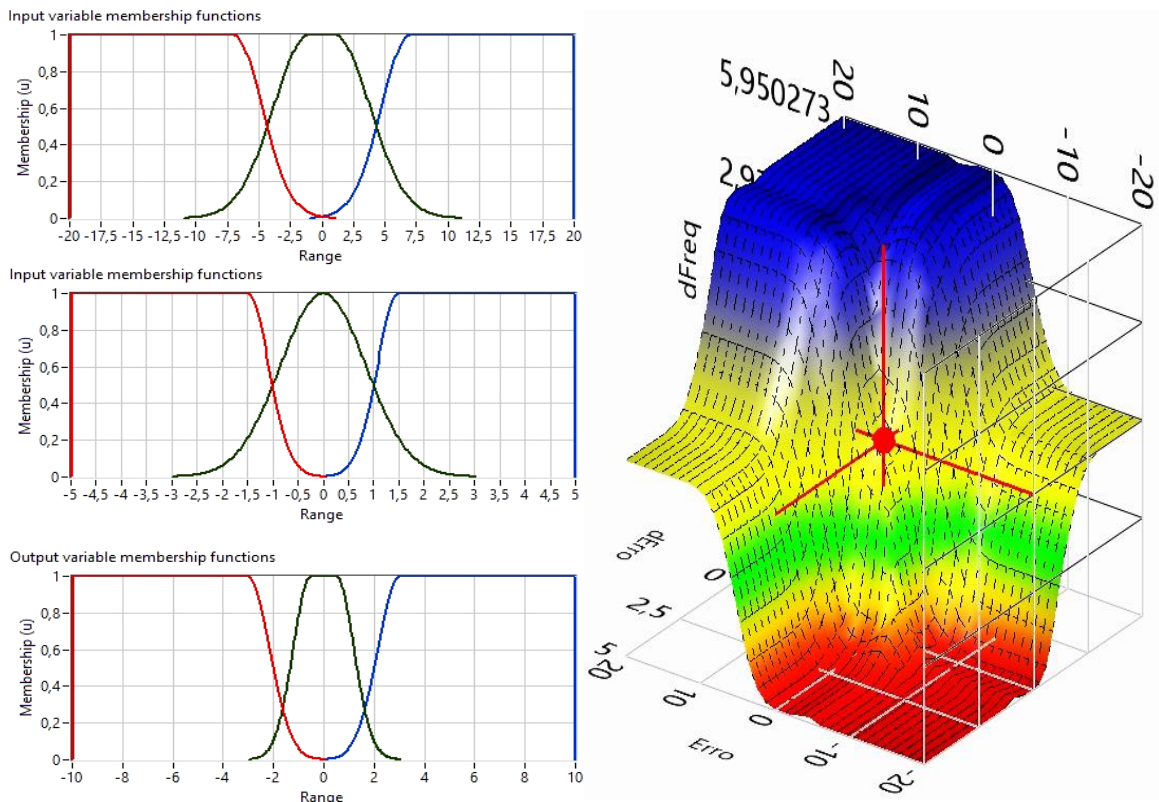


Figura 4.20 – Controlador intermediário Fuzzy – Mandani (Moreira, 2019a).

Tabela 4.6 – Conjunto de regras para o controlador primário Fuzzy.

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

4.4 ANÁLISE HIDROENERGÉTICA

As análises hidroenergéticas são medidas de eficiência e eficácia utilizadas para fins comparativos entre as atividades desenvolvidas. “A eficiência mede até que ponto os recursos disponíveis são utilizados de modo otimizado para a produção do serviço, a eficácia mede até que ponto os objetivos de gestão, definidos específica e realisticamente, foram cumpridos” (Alegre, 1998). Os dois indicadores de desempenho mais usuais em sistemas de bombeamento são o da: energia fornecida ao fluido pelo rotor da bomba – Equação (4.1) – e o da razão de energia gasta por volume bombeado (CE) – Equação (4.2) – este índice é utilizado, geralmente, para medir comparar a eficiência energética de um mesmo sistema de bombeamento sob diferentes condições de operação.

- Rendimento do conjunto motobomba (η), em decimais:

$$\eta = \frac{\gamma * H_{man} * Q}{P} \quad (4.1)$$

- Consumo específico de energia (CE), em kWh/m³:

$$CE = \frac{P'}{V} \quad (4.2)$$

Em que: γ é o peso específico do fluido, H_{man} é a altura manométrica em mca, Q é a vazão volumétrica em $[\text{m}^3/\text{s}]$, P a potência em $[\text{W}]$, P' a energia consumida em $[\text{kWh}]$ e V é o volume bombeado em $[\text{m}^3]$.

CAPITULO V

5 RESULTADOS

Este capítulo está seccionado em três partes. A primeira é referente à identificação do sistema e à caracterização do rendimento global do CMB. A segunda seção contém os resultados e a análise do desempenho do controlador Neuro-Fuzzy. Na última seção é analisado, através dos indicadores hidroenergéticos, os ganhos energéticos por meio da implementação da curva de demanda horária de água para os controladores Fuzzy e NF.

5.1 IDENTIFICAÇÃO DO SISTEMA

Esta seção apresenta os resultados da modelagem computacional do sistema de bombeamento de água. Foram desenvolvidos três modelos que abrangem a:

- I) Análise da vazão e pressão com $VC=30^\circ$ (demanda fixa) - (1 entrada – 2 saídas);
- II) Análise da vazão e pressão com VC variável (demanda variável) - (2 entrada – 2 saídas);
- III) Caracterização da eficiência energética do sistema com VC variável (demanda variável) - (2 entrada – 2 saídas).

Para melhor exposição estes resultados estão seccionados em três partes, como ilustrado na Figura 4.13. A primeira parte descreve os procedimentos experimentais e os resultados obtidos no desenvolvimento do banco de dados para treinamento e validação. A segunda parte discute as etapas analisa as etapas de treinamento e validação dos modelos. Na última seção os modelos obtidos são analisados e discutidos para alguns cenários de operação.

5.1.1 Desenvolvimento do banco de dados

O procedimento experimental para o desenvolvimento do banco de dados de treinamento e validação dos modelos (1 entrada – 2 saídas), consistiu da variação, conforme a Tabela 4.4, da frequência do conversor do CMB com a observação das variáveis de saída, pressão e vazão. Inicialmente, foram inseridos degraus crescentes de frequência até o limite da variável; posteriormente foram inseridos degraus decrescentes. O ângulo da VC foi mantido constante em 30° . Os dados experimentais para o treinamento são ilustrados na Figura 5.1, com um total de 5700 pares sequenciais. Para validação foram utilizados 3120 novos pares sequenciais.

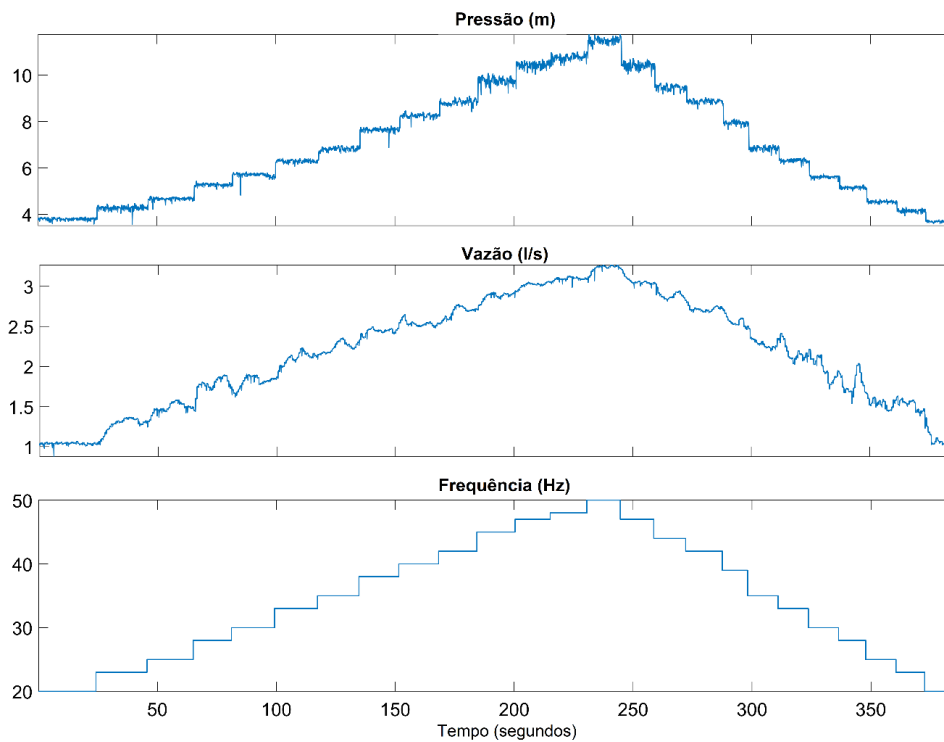


Figura 5.1 – Relação dos dados de treinamento do modelo SIMO.

Há certas complexidades no modelo MIMO, ocasionadas devido ao número de variáveis e as não-linearidades da variação de demanda. A variação do ângulo da VC tem como objetivo alterar a demanda do sistema, o que resulta no deslocamento vertical da curva da tubulação e adiciona uma variável e não-linearidades severas ao modelo, principalmente, devido às características hidráulicas e mecânicas da válvula. O procedimento experimental realizado neste ensaio é semelhante ao anterior, variando a frequência em degraus crescentes

até o limite da variável, seguida da variação gradual do ângulo da VC conforme a Tabela 4.4. A Figura 5.2 ilustra a relação entre as variáveis de saída e entrada dos dados de treinamento com 61850 pares sequenciais. Para a validação foram utilizados 19700 pares sequenciais.




Figura 5.2 – Relação dos dados de treinamento do modelo MIMO.

Apesar de ser possível utilizar filtros no pós processamento dos dados para reduzir o ruído, preferiu-se não utilizá-los aqui com o objetivo de verificar o potencial de modelagem das Redes Neurais e Neuro-Fuzzy utilizando dados ruidosos.

5.1.2 Treinamento

Encontrar a configuração ideal da Rede Neural e do Neuro-Fuzzy é um exercício paramétrico. Foi realizado um processo interativo de treinamento para encontrar a

configuração estrutural (número de camadas e neurônios) com o maior percentual de ajuste. Na Figura 5.3 é ilustrada a superfície gerada variando-se o número de neurônios por camadas para o modelo MIMO (2 entradas – 2 saídas). A análise gráfica da Figura 5.3 mostra que o modelo Neural obteve melhores resultados com um número baixo de neurônios na primeira camada e elevados na segunda. Os resultados do modelo Neuro-Fuzzy não apresentam tendência comum nas duas saídas analisadas. Observando a resposta do modelo para a pressão, prefere-se um elevado número de MF para o ângulo da VC. Para a vazão prefere-se um baixo número de MF para o ângulo. Em geral, os modelos apresentam ajustes superiores a 96%, sendo excelentes valores para as simulações e desenvolvimento de algoritmos de controle.

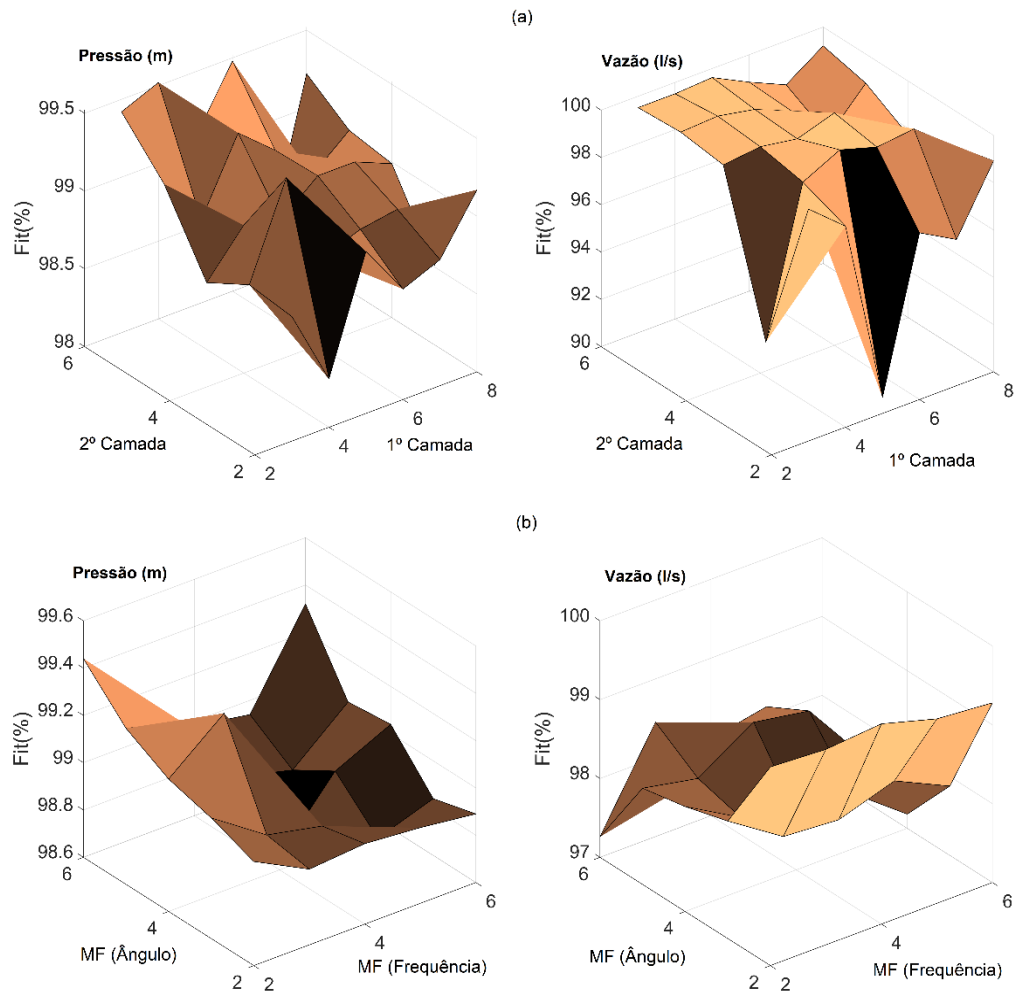


Figura 5.3 – Gráfico de convergência do modelo MIMO Neural (a) e Neuro-Fuzzy (b).

5.1.3 Resposta do modelo SIMO (1 Input – 2 Output)

Modelos paramétricos possuem relevância crucial na identificação de sistemas lineares, sendo preferíveis por sua fácil obtenção. Na Tabela 5.1 é possível observar que nem todos os modelos apresentaram ajustes satisfatórios, como o de Espaço de Estados ($n_a=3$, $n_b=4$ e $n_c=3$) e o ARX ($n_a=[4\ 6]$; $n_b=[4\ 6]$ e $n_k=0$), principalmente para simular as pressões de serviço. O não-*overfit* é uma característica bastante comum em modelos paramétricos, ocorrendo quando o modelo não consegue manter ajustes satisfatórios quando testado com novos dados. O modelo ARMAX ($n_a=[6\ 6]$; $n_b=[6\ 6]$; $n_c=3$ e $n_k=1$) e a Função de Transferência ($n_b=3$; $n_f=3$ e $n_k=0$) apresentaram bom ajuste e baixo RMSE. Há forma de elevar o desempenho desses modelos; a mais trivial é aumentar as suas ordens, o que ocasiona também o aumento do custo computacional. Desta forma, limitou-se a ordem do modelo atribuindo uma função custo proposta por Ljung e Glad (1996).

A Função de Transferência, modelo que apresentou o maior ajuste, é exposta nas Equações (5.1) e (5.2), sendo a resposta da pressão e vazão, respectivamente.

$$G(s) = \frac{0.4443s^2 + 0.0003168s + 8.402e^{-5}}{s^3 + 1.284s^2 + 0.0003167s + 8.402e^{-5}} \quad (5.1)$$

$$G(s) = \frac{0.02368s^2 + 0.0004096s + 3.021e^{-5}}{s^3 + 0.5191s^2 + 0.005583s + 5.328e^{-5}} \quad (5.2)$$

Por outro lado, os modelos inteligentes apresentaram ajustes superiores a 99% com dados de validação. A Figura 5.4 ilustra as respostas dos modelos inteligentes testados com dados de treinamento e de validação para o ANFIS (com 5 MF gaussianas) e para a Neural (com 8 e 5 neurônios na primeira e segunda camada, respectivamente). De modo geral, o custo computacional do ANFIS é maior; desta forma, é conveniente reduzir o número de neurônios da camada intermediária para valores inferiores aos encontrados nos modelos desenvolvidos por RNA, mantendo resultados, muitas vezes, superiores.

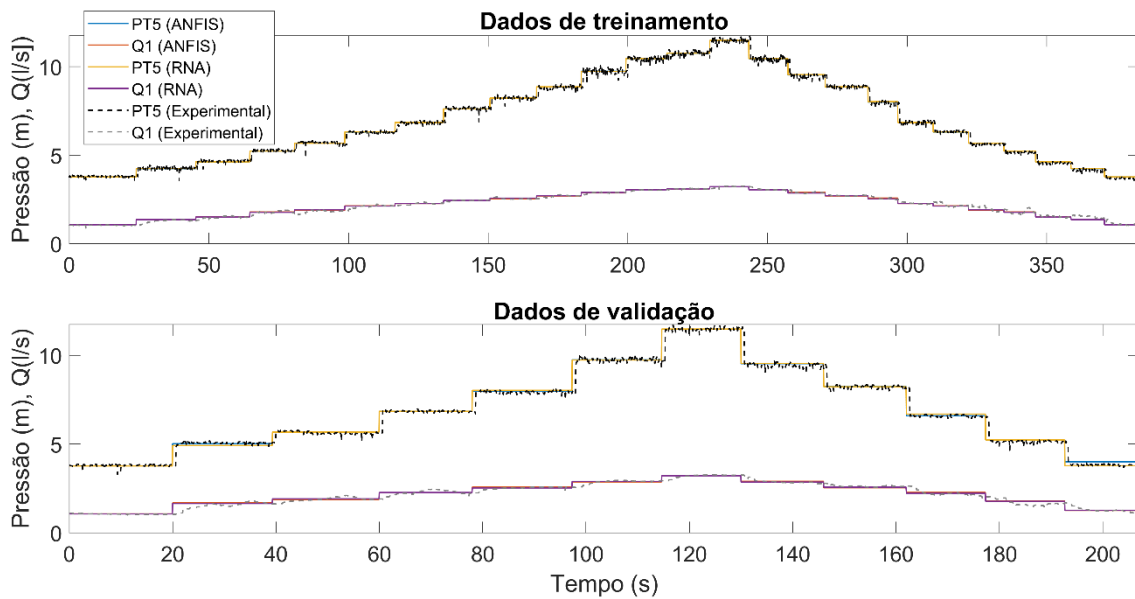


Figura 5.4 – Resposta dos modelos inteligentes com dados de treinamento e validação.

A Tabela 5.1 resume os resultados dos indicadores de performance dos modelos, sendo as saídas Pressão e Vazão (Q). É notável os ajustes superiores dos modelos inteligentes. Entretanto, a predição não é um ponto positivo destes modelos, indicado pelo menor FPE apresentado pelos modelos paramétricos. Desta forma, é possível afirmar que os modelos paramétricos apresentaram melhores resultados quando aplicados na predição do comportamento linear de sistemas de bombeamento. Os inteligentes são recomendados para simulações de sistemas de bombeamento. Entretanto, em situações práticas, com a alta complexidade, não-linearidades e multivariáveis, pertencentes à muitos sistemas industriais, os modelos inteligentes apresentarão superioridade, frente aos paramétricos em qualquer situação, como predição, simulação e análise, como será visto na próxima seção.

Tabela 5.1 – Dados de performance dos modelos computacionais testados com dados de validação.

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

5.1.4 Resposta do modelo MIMO (2 Input – 2 Output)

Apesar dos modelos paramétricos apresentarem boas vantagens na modelagem de sistemas lineares, estes possuem limitações para a modelagem de sistemas não-lineares. Foi observado um problema de não-overfit quando os modelos são testados com dados de validação, não conseguindo obter valores razoáveis de ajustes. Apesar do modelo ARX ($n_a=3$; $n_b=[3 \ 3]$ e $n_k=[0 \ 0]$) e TF ($n_b=[3 \ 3; 3 \ 3]$; $n_f=[3 \ 3; 3 \ 3]$ e $n_k=[0 \ 0; 0 \ 0]$) apresentarem dinâmica de comportamento próxima à resposta do sistema real, estes modelos foram descartados quando seu uso visar à simulação. Entretanto, como é observado na Tabela 5.2, o seu uso pode se justificar para predição, por apresentar baixo FPE. Os modelos ARMAX ($n_a=4$; $n_b=[4 \ 4]$; $n_c=2$ e $n_k=[1 \ 1]$) e SS ($n_a=[3 \ 0; 0 \ 3]$; $n_b=[4 \ 4; 4 \ 4]$; $n_c=[3; 3]$ e $n_k=[0 \ 0; 0 \ 0]$) não apresentaram desempenho suficiente para serem utilizados para simulação ou predição. Devido as não-linearidades inseridas pela VC, nenhum modelo paramétrico apresentou ajuste suficiente para justificar sua aplicação em simulação.

Para a representação de sistemas não-lineares, as técnicas inteligentes têm sido utilizadas com sucesso em muitas aplicações, como discutido na seção 2.4. Como alternativa às deficiências dos modelos paramétricos em modelar sistemas com não-linearidades, é proposto a utilização de métodos mais robustos para identificar o sistema com estas

condições. A Figura 5.5 ilustra a resposta dos modelos inteligentes com dados de treinamento e validação. O ANFIS (com 3 MF gaussianas) e a RNA (com 8 e 5 neurônios na primeira e segunda camada, respectivamente). É possível notar o excelente ajuste das respostas, não havendo problemas relacionados ao *overfit*.




Figura 5.5 – Resposta dos modelos inteligentes com dados de treinamento e validação.

A Tabela 5.2 apresenta a comparação dos dados de performance dos modelos obtidos para o caso. É notável a superioridade dos modelos inteligentes em qualquer indicador de desempenho, principalmente no ajuste e no RMSE. Estes resultados demonstram que a utilização dos modelos baseados em inteligência artificial visam suprimir as deficiências encontradas nos modelos tradicionais de identificação de sistemas, quando o objetivo é a simulação e predição de sistemas dinâmicos multivariáveis e não-lineares de bombeamento com demanda variável de água.

Tabela 5.2 – Dados de performance dos modelos testados com dados de validação.

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

5.1.5 Caracterização do rendimento do CMB

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

Em sistemas de bombeamento é possível relacionar a altura manométrica, vazão e a potência ativa do CMB, através da Equação (4.1), para obter o rendimento do CMB. Foi investigada a possibilidade de obter a curva de rendimento com demanda fixa, variando-se a rotação do CMB; e com demanda variável mantendo-se fixa a rotação do CMB. Sendo possível obter modelos matemáticos para cada caso.

A análise polinomial da frequência sob o rendimento expõe as características do regime de operação do sistema de bombeamento. A Figura 5.6 ilustra as curvas de rendimento para três condições de demanda de água - VC com ângulo de 30°, 40° e 50° -, com a variação da frequência. É possível observar que os modelos polinomiais obtidos apresentam variância (R^2) superior a 0,97. A análise da Figura 5.6 mostra que, nestes casos,

os pontos de máxima eficiência estão em baixas frequências de operação. Por fim, é observável que ao mudar qualquer parâmetro do sistema, um novo modelo polinomial é exigido.

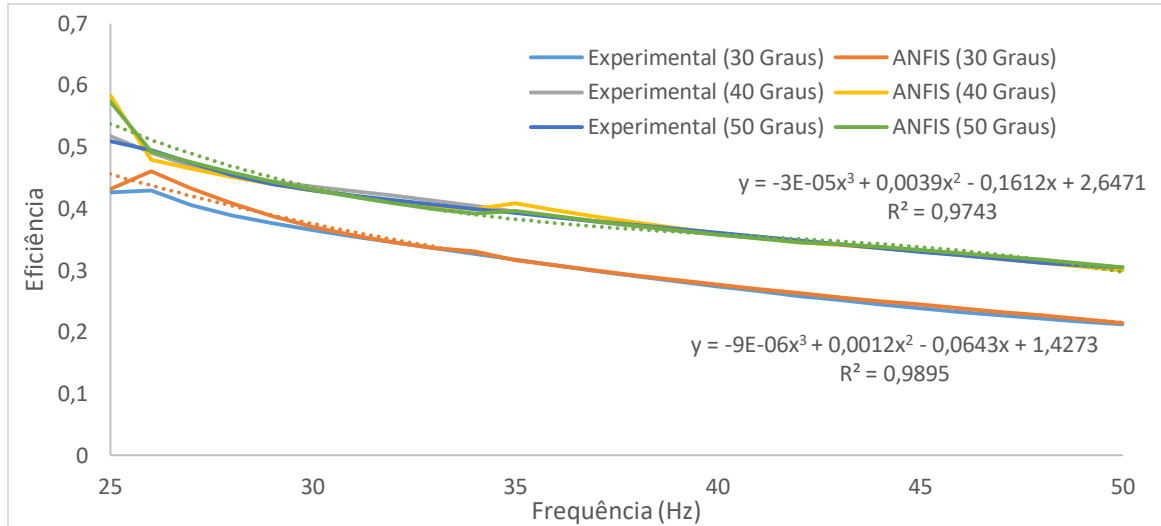


Figura 5.6 – Influência da frequência no rendimento do CMB.

Sistemas de abastecimento de água operam sob demanda variável, surge, diante disso, a necessidade em controlar o acionamento ou a rotação dos CMBs. Como forma de avaliar o rendimento em uma condição real de operação, foi realizado um estudo em que a abertura da VC era controlada de forma a simular a variação de demanda com pressão constante em 10 m. A Figura 5.7 apresenta o rendimento do CMB com a variação de demanda. Novamente, é ressaltado o ótimo ajuste fornecido pelos modelos polinomiais locais. É possível observar que a condição de máxima eficiência do sistema ocorre com demandas médias de água.

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




Figura 5.7 – Influência da demanda no rendimento do CMB.

A Figura 5.8 ilustra a superfície do modelo global do rendimento do sistema de bombeamento, obtida com o ANFIS. É possível observar a inter-relação das variáveis de importância do sistema (variáveis de entrada: VC e Frequência; variáveis de saída: Eficiência). É mostrado graficamente que o rendimento máximo do sistema ocorre em baixas rotações e com demandas médias de água. Há ainda regiões onde a eficiência do sistema apresenta máximos locais, como quando opera com altas demandas e baixas rotações. Em geral, o sistema pode operar, em algumas regiões, com eficiência 305% superior com relação à operação com demandas máximas; por exemplo, em sua frequência nominal, com 50 Hz, a variação de demanda pode proporcionar um ganho de 112% no rendimento. A análise gráfica da Figura 5.8 permite a melhor interpretação das condições de operação do sistema de bombeamento, mostrando que é conveniente manter um determinado número de CMBs, em arranjo série/paralelo, operando com capacidades médias de vazão. Essa estratégia deve resultar em economia de energia elétrica.




Figura 5.8 – Superfície da caracterização da eficiência do sistema de bombeamento.

5.1.6 Análise dos modelos

Elementos gráficos permitem uma grande interpretação de sistemas dinâmicos. Em hidráulica, variáveis como pressão, vazão e demanda são constantemente avaliadas para o suprimento de energia ou controle de processos. Na Figura 5.9 é ilustrada a superfície de comportamento do sistema de bombeamento obtida com a utilização da técnica NF, descrito na seção 5.1.4. É ilustrado a inter-relação das variáveis de entrada e saída. Através desta superfície é possível analisar o comportamento gráfico do sistema mediante a mudança de cenário e determinar limites seguros de operação. O desenvolvimento de modelos computacionais tem por finalidade a análise e simulação com o objetivo de desenvolver estratégias e algoritmos de controle que resultem na maior eficiência operacional, reduzindo consideravelmente o consumo energético do sistema de bombeamento. Além disso, o desenvolvimento de um modelo que relacione os parâmetros de operação à eficiência energética do sistema resulta em uma ferramenta eficaz para a análise energética.




Figura 5.9 – Superfície de comportamento do sistema de abastecimento Neuro-Fuzzy.

5.2 ANÁLISE DO CONTROLADOR

Esta seção contém os resultados dos ensaios experimentais realizados com o controlador Neuro-Fuzzy. O controlador é analisado em regime transiente, permanente e com relação aos distúrbios inseridos no sistema através da VC, comparando-o com os controladores Neural (RNA) e Heurístico (Fuzzy). Para avaliar e comparar o desempenho dos controladores foram realizados ensaios experimentais na bancada instrumentada (Figura 4.1). Os ensaios consistiram em:

- Respostas ao degrau com ângulo de abertura da VC em 30° e 40°;
- Variação do valor de referência do sistema com ângulo de abertura da VC em 40°;

- Variação contínua da VC de 30° à 70° e de volta à 30° com valor de referência em 10 m;
- Variação pausada da VC de 30° à 70° com valor de referência em 10 m;
- Ação do controlador.

5.2.1 Dados de treinamento

Inicialmente, o controlador proporcional-derivativo (PD; $K_P=0,5$ e $K_D=1$) foi cotado para a posição de controlador primário. Entretanto, ensaios realizados com ele, demonstraram que a qualidade dos dados de treinamento eram inviáveis, devido a presença de elevados picos, pouca estabilidade em situações de variação de demanda e mudança de valor de referência, como ilustrado na Figura 5.10; assim, o seu uso foi descartado.




Figura 5.10 – Dados de treinamento do controlador primário PD.

A soma das respostas do controlador primário (Fuzzy) representam os dados de treinamento utilizados para o desenvolvimento dos controladores Neuro-Fuzzy (NFC) e Neural (NC) - como ilustrado na Figura 5.11. Os critérios utilizados para definir os procedimentos experimentais para o desenvolvimento do banco de dados foram as simplicidades, representadas pelas respostas degrau e variação do valor de referência, e as condições de operação do sistema de bombeamento de água, representadas pela variação de demanda e pressões de serviço.




Figura 5.11 – Dados de treinamento do controlador primário Fuzzy.

A Figura 5.12 ilustra a superfície de resposta do controlador Neuro-Fuzzy (NFC); comparando com a Figura 4.20, que representa a superfície de resposta do controlador Fuzzy, as superfícies não apresentam nenhuma relação de semelhança, mesmo assim, ambas deverão controlar o sistema de bombeamento, em menor ou maior desempenho.




Figura 5.12 – Superfície de resposta do controlador NF.

5.2.2 Resposta ao degrau

A resposta ao degrau é um método bastante comum para analisar o desempenho de controladores quando aplicados em sistemas que partem do repouso. A Figura 5.13 ilustra a resposta ao degrau com os controladores NF, Fuzzy e Neural. A partir de uma análise comparativa, é observado que o Fuzzy apresenta a maior velocidade e o controlador Neural apresenta o menor valor de máxima ultrapassagem. Tendo o NFC características híbridas, ele apresenta velocidade intermediária e alguma ultrapassagem. Analisando o tempo de acomodação e a sua estabilidade (erro de regime permanente) do NFC é notável que os seus resultados são superiores.




Figura 5.13 – Resposta ao Degrau 10 m.

A Tabela 5.3 resume o desempenho do controlador em relação à análise transiente e permanente para um degrau de 10 m. Em sistemas de abastecimento, o erro de regime permanente se sobrepõe, em importância, ao tempo de subida. Desta forma, pode-se considerar os resultados obtidos pelo NFC superiores aos demais.

Tabela 5.3 – Análise do desempenho dos controladores.

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

Fuzzy	4,4	9,3	-	5.7
-------	-----	-----	---	-----

Uma análise semelhante foi realizada em relação à anterior. Desta vez, assumiu-se um degrau de 15 m para verificar a influência da mudança de valor de referência. A Figura 5.14 mostra a resposta dos controladores; ambos os controladores apresentam ultrapassagem, entretanto o NF apresenta o melhor desempenho em relação ao erro de regime permanente e ao tempo de acomodação.




Figura 5.14 – Resposta ao Degrau 15 mca.

5.2.3 Variação do valor de referência do sistema

Com o objetivo de demonstrar a efetividade do controlador em diferentes valores de referência, a Figura 5.15 apresenta o resultado da operação dos controladores com a mudança progressiva dos valores de pressão do sistema com VC em demanda média (40°). É possível observar que devido à mudança repetitiva do valor de referência, nenhum controlador atinge um baixo erro de regime permanente, quando comparados ao degrau da Figura 5.13. Avaliando graficamente o tempo de subida e a estabilidade, os controladores NF e Neural apresentam resultados semelhantes, entre si, e superiores ao controlador Fuzzy.




Figura 5.15 – Variação do valor de referência com VC em 40°.

5.2.4 Variação contínua da VC

Um sistema de controle é considerado robusto quando ele é capaz de manter a estabilidade do sistema quando sujeito a distúrbios na planta. Sistemas de abastecimento possuem, na prática, demanda variável; assim, faz-se necessário a análise dos controladores diante de situações que mudem as características dinâmicas do sistema. A VC tem por objetivo deslocar a curva da tubulação verticalmente e induzir o controlador a encontrar um novo ponto de equilíbrio, através do controle da velocidade de rotação do CMB. A Figura 5.16 ilustra a resposta do sistema com um valor de referência de 10 m, controlado quando a demanda do sistema é alterada através do ângulo da VC. É possível verificar que o controlador NF é o único que mantém boa estabilidade (erro < 8%), adaptando-se às mudanças do sistema com baixo erro, mesmo sob condições críticas de variação dinâmica.

É realizado um outro ensaio configurando um novo valor de referência de 15 m, como ilustrado na Figura 5.17. Ambos os controladores apresentam ultrapassagens não nulas; entretanto, o NF apresenta o melhor desempenho em relação ao erro de regime permanente, ao tempo de acomodação e à variação de demanda.




Figura 5.16 – Degrau em 10 m com variação contínua da VC.




Figura 5.17 – Degrau em 15 m com variação contínua da VC.

5.2.5 Variação pausada da VC

Apesar das mudanças bruscas na variação serem possíveis, como na seção 5.2.4, o mais comum é que a variação ocorra de forma suave ao longo do dia. Analisando o desempenho do controlador ao variar pausadamente a demanda - uma condição mais branda que a observada nas Figura 5.16 e Figura 5.17 - é possível observar que o controlador NF mantém a pressão de serviço com baixo percentual de erro (erro < 3.3%), contra 9,8% do

controlador Neural e 2,1% do Fuzzy, como ilustra-se na Figura 5.18. Para sistemas de abastecimento o erro de regime permanente não é um fator extremamente crítico, principalmente em situações de variação de demanda. Dessa forma, são toleráveis erros da ordem de 2 a 5%. A Figura 5.18 também ilustra a potência ativa do CMB, sendo estável e apresentando ausência de pico para o caso do controlador NF - aspecto importante para a proteção dos equipamentos eletromecânicos e eletrônicos. Entretanto, a presença de um elevado pico (até 179% maior que o controlador NF) na potência, para o controlador Fuzzy, mostra certa instabilidade nas características transientes do sistema.




Figura 5.18 – Degrau em 10 m com variabilidade pausada da VC.

5.2.6 Ação de controle

A última análise realizada com relação ao desempenho do controlador é referente à ação de controle. A ação de controle, ou, o delta de frequência (positivo ou negativo) é o sinal de atuação do controlador para aumentar ou diminuir a velocidade do CMB. Em regime permanente o delta de frequência deverá ser, idealmente, zero ou muito próximo de zero; em regiões onde há transiente, este sinal apresentará variabilidade. A Figura 5.19 apresenta um ensaio experimental realizado com cada um dos três controladores visando manter o valor de referência do sistema nos valores estabelecidos na Figura 5.19a. A Figura 5.19b mostra a ação de controle dos três controladores, nas regiões marcadas em preto, é possível ver que a ação de controle dos controladores Neural e NF é, aproximadamente, constante e diferente de zero, o que é conivente, já que estas regiões apresentam transitórios. Na marcação em

verde, é possível observar que os valores de atuação do controlador NF é zero ou muito próximo de zero, o que é resultado de uma região de intensa estabilidade e baixo erro de regime permanente.




Figura 5.19 – Ação de controle.

5.3 ANÁLISE HIDROENERGÉTICA

Para avaliar a eficiência energética do sistema, controlado e não controlado, foi simulado o perfil de consumo proposto por Gomes *et al.* (2012), mostrado na Figura 2.3, o qual indica o consumo de água médio horário. A variação de consumo provoca flutuações significantes na pressão da rede. Assim, o controlador deve manter a pressão de serviço em valores de referência estabelecidos, objetivando reduzir o gasto energético do sistema. O consumo normalizado de água para o caso analisado foi de 0.765 l/s ($k=1$).

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

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

A Figura 5.20 ilustra o rendimento do CMB para cada período para cada uma das quatro situações de operação. Para este cálculo usou-se a Equação (4.1). Pode-se observar que durante os horários de baixa demanda o rendimento do sistema controlado é superior frente aos outros modos de operação. Entretanto, este rendimento é inferior nos horários de máxima demanda. O aumento do rendimento durante a mínima demanda citado anteriormente, deve-se ao fato do controlador manter a pressão em 10 m. Em contrapartida, nos outros dois casos o CMB opera sempre em velocidade nominal, independente da demanda, aumentando as perdas por vazamento ao longo da rede de distribuição, principalmente nos horários de mínima demanda. Para o controlador Fuzzy, houve um acréscimo médio no rendimento de 9,16%. Para o controlador NF o acréscimo foi de 9,59%, resultado da menor ação de controle, refletindo na maior estabilidade e eficiência energética. Por outro lado, quando o sistema opera com o CMB em velocidade nominal e a demanda é controlada por registro manual, há uma queda da pressão no usuário final, devido ao excesso de perda de carga causada pelo registro, consequentemente impactando negativamente no rendimento global do sistema.




Figura 5.20 – Rendimento do CMB.

Na Figura 5.21 ilustra-se o resultado da avaliação do consumo específico de energia (CE), na qual se evidencia que a atuação do controlador Fuzzy e NF produzem um CE menor ou igual quando comparado com as outras duas metodologias experimentadas. No período avaliado das 9:00 às 14:59, observasse a igualdade do CE nos quatro métodos adotados; isso

porquê, em todos os casos, o sistema opera com velocidade nominal, devido à alta demanda. Além disso, é possível constatar uma redução máxima de 383% às 00:00, ao comparar o sistema operando com o controlador de pressão Fuzzy ao sistema não controlado. Quando comparado o controlador NF, ao sistema não controlado, o resultado é ainda melhor de até 392% para o período de 00:00 até 02:59 h, mostrando que o controlador NF pode reduzir em, aproximadamente, 4 vezes o consumo energético do sistema.




Figura 5.21 – Coeficiente de consumo específico de energia (CE).

Investigou-se, também, o comportamento da pressão na saída do sistema ao longo das 24h para cada um dos quatro casos de operação propostos neste artigo, cujo resultados são apresentados na Figura 5.22. Para o controlador NF a pressão média foi de 10,3 m, já para o Fuzzy a pressão média foi de 10,7 m, erro de 3% e 7%, respectivamente. Constatou-se, também, que o sistema sem o controlador produz as maiores pressões durante os períodos de menores demandas. Isto pode ocasionar o rompimento de dutos, aumento dos vazamentos e redução da eficiência operacional.




Figura 5.22 – Pressões médias do sistema com demanda variável.

CAPITULO VI

6 CONCLUSÕES

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

Em alternativa aos modelos paramétricos, que apresentam deficiências em modelar sistemas multivariáveis e não-lineares, este trabalho propôs a utilização da técnica NF para a identificação do sistema de abastecimento de água com demanda variável. Para analisar estas técnicas foram realizadas análises comparativas. A primeira tratou da identificação do sistema com demanda fixa ($VC=30^\circ$). Nesta análise, os modelos paramétricos mostraram boa capacidade de predição; entretanto, com resultados inferiores para simulação (baixo ajuste e alto RMSE), quando comparado ao modelo Neuro-Fuzzy. A segunda análise consistiu da identificação do sistema com demanda variável, o que acrescentou não-linearidades ao sistema. Nesse caso, somente os modelos Neural e NF apresentaram resultados satisfatórios. Apesar de ser possível melhorar a performance dos modelos paramétricos aumentando as suas respectivas ordens, uma desvantagem é observada; o aumento do custo computacional. É possível concluir que as técnicas inteligentes apresentam superioridade para a identificação de sistemas não-lineares e multivariáveis de bombeamento, frente aos modelos paramétricos, apontado através dos dados de validação e dos indicadores de performance. A análise dos modelos inteligentes mostrou que o Neuro-Fuzzy apresenta similaridades na predição (FPE) em relação às redes neurais, podendo-se utilizar qualquer uma para esta aplicação.

A técnica NF foi utilizada para caracterizar o rendimento global do sistema de bombeamento, suprimindo as deficiências dos modelos polinomiais; estes apresentam a vantagem da fácil obtenção; entretanto, a desvantagem de construir uma quantidade elevada

de equações para determinar o comportamento global do sistema, o que é inviável. A análise do modelo permitiu observar que as regiões de máximo rendimento ocorrem quando o sistema opera com vazões médias. Assim, é possível idealizar um projeto com um maior número de CMBs operando em arranjos série/paralelo para suprir a pressurização da água. Entretanto, esta estratégia exige um maior investimento inicial na aquisição dos equipamentos eletromecânicos, sendo necessária uma análise financeira. Este procedimento pode estendido à outros sistemas hidráulicos/pneumáticos com demanda variável.

A técnica Neuro-Fuzzy foi aplicada no controle do sistema de bombeamento para regularizar as pressões e elevar a eficiência energética do sistema. O controlador NF e Neural foram desenvolvidos utilizando dados de treinamento obtidos de um controlador Fuzzy. A comparação entre os três controladores mostrou que o controlador NF apresentou desempenho superior, aos demais, em todos os cinco testes para avaliação da resposta em regime transiente, permanente e em relação aos distúrbios inseridos pela VC. Como forma de avaliar o desempenho do controlador NF, controlando o sistema submetido à demanda variável, foi proposta a implementação da curva de consumo horário de água. Os resultados da análise hidroenergética mostraram que houve uma redução significativa do consumo energético com a implementação de automação nos sistemas de abastecimento. O controlador NF proporcionou um aumento de 4,7% do rendimento do CMB, quando comparado ao controlador Fuzzy; e de 9,59% comparado ao controle manual ou quando o sistema não é controlado. Houve também uma redução significativa do CE, sendo o controlador NF superior ao Fuzzy. Essas melhorias são consequência de uma menor ação de controle e maior performance em manter as pressões nos valores de referência.

Os controladores obtidos por modelagem computacional, como o NF e o Neural, baseiam-se no comportamento dos dados obtidos com o controlador primário, captando as tendências que esse apresenta. Desta forma, mesmo que os dados sejam imprecisos, ruidosos ou não reflitam o controle estável do sistema, os derivados desses terão a capacidade de controlar o sistema com maior robustez e desempenho. Permite-se concluir que uma das grandes vantagens desse tipo de controle, é que controladores mais eficientes podem ser desenvolvidos a partir de controladores não tão eficientes. Outra vantagem observada e analisada reside na menor ação de controle realizada pelos controladores NF e Neural; resultando na maior estabilidade do sistema e no menor desgaste dos equipamentos eletromecânicos e elétricos. Conclui-se que a aplicação da técnica Neuro-Fuzzy fornece bons

resultados na identificação e controle de sistemas de bombeamento com demanda variável, fornecendo resultados superiores aos modelos Fuzzy e Neural.

6.1 SUGESTÕES PARA TRABALHOS FUTUROS

Este trabalho apresentou avanços significativos no controle de sistemas de abastecimento de água com demanda variável; entretanto, a necessidade por sistemas mais eficientes e inteligentes força o contínuo movimento da pesquisa científica. Como trabalhos futuros recomenda-se:

- Implementar características adaptativas do controlador NF, retroalimentando o banco de dados de treinamento com dados provenientes dele próprio;
- Aperfeiçoar o sistema experimental de bombeamento implementando uma válvula eletrônica para alterar o arranjo série/paralelo de forma automática ou implementar novas zonas de abastecimento com cotas piezométricas diferentes;
- Simular em ambiente virtualizado, como o EPANET.

7 REFERÊNCIAS

- Aguirre, L. A., 2004. *Introdução a identificação de sistemas*. 1 ed. Belo Horizonte – MG, Editora UFMG.
- Alegre, H., Hirner, W., Baptista, J. M., Parena, R, 2004. *Indicadores de desempenho para serviços de abastecimento de água*. Série Guias Técnicos, LNEC e IRAR.
- Amirkhani, S., Nasirivatan, S., Kasaeian, A. B., Hajinezhad, A., 2015. “ANN and ANFIS models to predict the performance of solar chimney power plants”, *Journal of the Renewable Energy*. <http://dx.doi.org/10.1016/j.renene.2015.04.072>. ISBN: 0960-1481/© 2015 Elsevier Ltd.
- Andrade Filho, L.S., 2009. *Bombas e Estações Elevatórias*. In: H. Gomes, *Sistemas de Bombeamento e Eficiência Energética* (pp. 45-112). João Pessoa - PB: Editora Universitária - UFPB.
- Andrade, L. H. S., Agulhari, C. M., Goedtel, A., 2015. “Controle PI-Neural aplicado a um sistema de vazão”. *XII Simpósio Brasileiro de Automação Inteligente*, Natal-RN, Brasil.
- ANEEL. Agência Nacional de Energia Elétrica – ANEEL. **BIG – Banco de Informações de Geração, 2019**. Disponível em: <www.aneel.gov.br> Acesso em: 27 de nov. 2019.
- Anjana, G., Kumar, M., Amrutur, B., 2017. “Comparison of Different Controllers for Equitable Water Supply in Water Networks”, *Computing and Control for the Water Industry*.

- Azar, A. T., 2010. *Fuzzy Systems*. ISBN: 978-953-7619-92-3.
- Babunski, D., ZaeV, E., Tuneski, A., Bozovic, D., 2018. “Optimization methods for water supply SCADA system”, *In 2018 7th Mediterranean Conference on Embedded Computing (MECO)*, pages 1–4, June 2018.
- Barros, E. G. F., Salvino, L. R., Bezerra, S. T. M., Salvino, M. M., Gomes, H. P., 2017. “Intelligent system for control of water distribution networks”, *Water science & technology: water supply*, p. 1-12. doi.org/10.2166/ws.2017.188.
- Bittencourt, M. C., 2007. *Identificação de sistemas dinâmicos lineares – métodos paramétricos e não paramétricos*. Projeto de Graduação, Universidade de Brasília, Brasília, DF, Brasil.
- Brion, L. M., Mays, L. W., 1991. “Methodology for Optimal Operation of Pumping Stations in Water Distribution Systems”, *Journal of Hydraulic Engineering*, 117(11), 1551–1569. doi:10.1061/(asce)0733-9429(1991)117:11(1551).
- Brogan, A., Gopalakrishnan, V., Sturtevant, K., Valigosky, Z., Kissock, K., 2016. “Improving Variable-Speed Pumping Control to Maximize Savings”, *ASHRAE Transactions*, volume 122, n. 2.
- Carvalho, A. P. L. F., 2019. *Redes Neurais Artificiais*. Disponível em: <https://sites.icmc.usp.br/andre/research/neural/>. Acesso em 19 de novembro de 2019.
- Cavallaro, F., 2015. “A Takagi-Sugeno Fuzzy Inference System for Developing a Sustainability Index of Biomass”, *Sustainability*. 7. doi:10.3390/su70912359.
- Camboim, W. L. L., 2012. *Aplicações de técnicas de controle Fuzzy em sistemas de abastecimento de água visando melhoria no rendimento energético e hidráulico*. Tese (Doutorado em Engenharia Mecânica) – Programa de Pós Graduação em Engenharia Mecânica, UFPB, João Pessoa, PB, Brasil.

- Carvalho, P. S. O., 2012. *Controle para bombeamento distribuído com vistas à minimização dos custos energéticos aplicado a sistemas de abastecimento de água*. Tese (Doutorado em Engenharia Mecânica) – Programa de Pós Graduação em Engenharia Mecânica, UFPB, João Pessoa, PB, Brasil.
- Cavalcanti, D. M. J., Villanueva, J. M., Gomes, H. P., 2018. “Modelagem de um sistema de bombeamento para o controle de vazão por conversor de frequência baseado na teoria de identificação de sistemas”. doi:10.20906/CPS/CBA2018-0313.
- Chaya, E. C., Reddy, K., Devaraju, T., 2015. “Implementation of ANFIS control for renewable interfacing inverter in distribution network”, *International Journal of Advanced Technology and Innovative Research*, IJATIR.
- Coura, J. T. N., 2018. *Processamento de valores atípicos em redes elétricas inteligentes baseado em algoritmos Neuro-Fuzzy*. Dissertação de Mestrado, Programa de Pós Graduação em Engenharia Elétrica, Universidade Federal da Paraíba, João Pessoa, PB, Brasil.
- Coutinho, F. A. B., Chigueru, T., Melo, R. O., 2018. “Modelagem de um sistema de bombeamento fotovoltaico utilizando redes neurais artificiais e comparativo com modelagem tradicional”. *VII Congresso Brasileiro de Energia Solar*, Porto Alegre, RS, Brasil.
- Donadel, j., 2012. *Implementação de um sistema de controle heurístico de aceleração e tensão mecânica para ensaios em Shaker eletrodinâmico*. Tese (Doutorado em Engenharia Mecânica) – Programa de Pós Graduação em Engenharia Mecânica, UFRGS, Porto Alegre, RS, Brasil.
- Ferdaus, M. M., Pratama, M., Anavatti, S. G., Garratt, M. A., & Lughofer, E., 2019. “A novel self-adaptive Neuro-Fuzzy controller for micro aerial vehicles”, *Information sciences*. doi:10.1016/j.ins.2019.10.001.

- Feng, H., Yin, C., Ma, W., Yu, H., Cao, D., 2019. "Parameters identification and trajectory control for a hydraulic system", *ISA Transactions*. doi:10.1016/j.isatra.2019.02.022.
- Flores, T. K. S., 2018. *Sistema Fuzzy para controle de pressão aplicado a sistemas de bombeamento série-paralelo visando a eficiência energética*. Monografia (Graduação em Engenharia Elétrica) – Programa de Graduação em Engenharia Elétrica, UFPB, João Pessoa, PB, Brasil.
- Filev, D., 1991. "Fuzzy modeling of complex systems", *International Journal Approximate Reasoning*. 1991, Vol. 5, pp. 281-290.
- Furtado, E. C., Mendes, E. M. A. M., Nepomuceno, E. G., Silva, V. V. R., 2002. "Identificação de sistemas dinâmicos não-lineares contínuos utilizando modelos NARMAX: estudo de caso de um forno a arco elétrico". *XIV Congresso Brasileiro de Automática*, Natal, RN, Brasil, 2 a 5 de Setembro de 2002, pg. 2150 - 2155.
- Galuppini, G., Magni, L., Creaco, E., 2020. "Stability and Robustness of Real-Time Pressure Control in Water Distribution Systems", *Journal of Hydraulic Engineering*, 146(4), 04020023. doi:10.1061/(asce)hy.1943-7900.0001722.
- Gao, W., Moayedi, H., Shahsavari, A., 2019. "The feasibility of genetic programming and ANFIS in prediction energetic performance of a building integrated photovoltaic thermal (BIPVT) system", *International Solar Energy Society*. <https://doi.org/10.1016/j.solener.2019.03.016>. ISBN: 0038-092X/ © 2019 International Solar Energy Society.
- Ghanooni, P., Yazdani, A. M., Mahmoudi, A., Mahmoud. Zadeh, S., Ahmadi, M. M., e Fathi, M., 2020. "Robust precise trajectory tracking of hybrid stepper motor using adaptive critic-based Neuro-Fuzzy controller", *Computers & Electrical Engineering*, 81, 106535. doi:10.1016/j.compeleceng.2019.106535
- Gomes, J.E.C., 2013. *Controle fuzzy Takagi-Sugeno de pêndulo invertido: Projeto e validação em bancada didática*. Trabalho de Graduação em Engenharia de Controle

e Automação, Publicação FT.TG-nº 07, Faculdade de Tecnologia, Universidade de Brasília, Brasília, DF, Brasil, 52p.

Gomes H. P., 2019. *Abastecimento de Água*. João Pessoa, PB, Brasil, LENHS/UFPB.

Gomes, H. P., Carvalho, P. S. O., 2012. *Manual de Sistemas de Bombeamento – Eficiência Energética. Manual do Usuário, PROCEL / SANEAR*. 1 ed, Editora Universitária – UFPB, João Pessoa, PB, Brasil.

Gonçalves, F. V., Costa, L. H., Ramos, H. M., 2011. “ANN for Hybrid Energy System Evaluation: Methodology and WSS Case Study”, *Water Resources Management*, 25(9), 2295–2317. doi:10.1007/s11269-011-9809-y.

Gopal, BT Venu, Shivakumar, E. G., 2019. “Design and simulation of Neuro-Fuzzy controller for indirect vector-controlled induction motor drive”, *Data Analytics and Learning*. Springer, Singapore. p. 155-167.

Ha, D., Zheng, G., Zhou, H., Zeng, C., Zhang, H., 2019. “Estimation of hydraulic parameters from pumping tests in a multi aquifer system”, *Underground Space*. doi:10.1016/j.undsp.2019.03.006.

Haykin, S., 2001. *Neural Networks: a comprehensive foundation*, 2/E. Português: Redes Neurais: princípios e prática 2. Ed. Tradução Paulo Martins Engel. Porto Alegre: Bookman, 2001. ISBN: 9788573077186 (broch.: 2007).

Hyndmana R. J., Koehlerb A. B., 2006. “Another look at measures of forecast accuracy”, *International Journal of Forecasting*. Volume 22, Issue 4, Pages 679-688.

Hopfield, J. J., 1984. *Neurons with graded response have collective computational properties like those of twostate neurons*, Proc. Natl. Acad. Sci. USA, Vol. 81, pp. 3088-3092, May 1984.

- Instituto Trata Brasil (2018). Disponível em: <http://tratabrasil.org.br/>. Acesso em 23 de maio de 2020.
- Jang, J. S. R., 1993. “ANFIS: Adaptive-Network-Based Fuzzy Inference System”, *IEEE Trans. Syst. Man. Cybern.* Vol.23, nº.3, pp.665- 685.
- Kilic, E. D., Melik, K. A., Çalışkan, H., Balkan, T., 2012. “Accurate pressure prediction of a servo-valve controlled hydraulic system”, *Mechatronics.* 22. 997–1014. 10.1016/j.mechatronics.2012.08.001.
- Larsen, T., Arensman, M., Nerup-Jensen, O., 2016. “Including Pressure Measurements in Supervision of Energy Efficiency of Wastewater Pump Systems”, *Journal of Hydraulic Engineering,* 142(2), 04015048. doi:10.1061/(asce)hy.1943-7900.0001072.
- Ljung, L., Glad, T., 1993. *Modeling of dynamic systems*, 1ª ed., Prentice Hall International, United Kingdom, 1994.
- Ljung, L., 2020. “System Identification Toolbox User’s Guide”, Disponível em: <http://www.mathworks.com>. Acesso em 18 de maio de 2020.
- Lima, C. A. M., 2000. *Emprego de teoria de agentes no desenvolvimento de dispositivos Neuro - Computacionais híbridos e aplicação ao controle e identificação de sistemas dinâmicos*. Dissertação de Mestrado, Universidade Estadual de Campinas (Unicamp), SP, Brasil, 280 páginas, Fevereiro, 2000.
- Lopes, A. N. D., 2017. *Seguimento de referências em controle de sistemas não lineares sob restrições via modelagem TAKAGI-SUGENO*. Dissertação de Mestrado, Universidade Federal de São João Del-Rei, São João Del-Rei, MG, Brasil.
- Mahmoud M. S., Mohamed M. A., Mohamed S. E., Sabry F. Saraya, F. F.G., 2016. “An Adaptive Neuro-Fuzzy Sliding Mode Controller for MIMO Systems with

- Disturbance”, *Chinese Journal of Chemical Engineering*, 25(4), 463–476. doi: 10.1016/j.cjche.2016.07.021.
- Mamdani, E. H., 1977. “Application of fuzzy logic to approximate reasoning using linguistic synthesis”, *IEEE Transactions on Computers* C-26(12): 1182–1191.
- McCulloch, W. S., Pitts, W., 1943. “A logical calculus of the ideas immanent in nervous activity”, *Bulletin of Mathematical Biophysics* 5:115–133.
- Meirelles, G., Manzi, D., Brentan, B., Goulart, T., & Luvizotto, E., 2017. “Calibration Model for Water Distribution Network Using Pressures Estimated by Artificial Neural Networks”, *Water Resources Management*, 31(13), 4339–4351. doi:10.1007/s11269-017-1750-2.
- Meunier, S., Heinrich, M., Quéval, L., Cherni, J. A., Vido, L., Darga, A., Marchand, C., 2019. “A validated model of a photovoltaic water pumping system for off-grid rural communities”, *Applied Energy*, 241, 580–591. doi:10.1016/j.apenergy.2019.03.035.
- Mendonça, K. H., 2016. *Sistema de controle fuzzy na operação otimizada de redes setorizadas com bombeamento direto*. Dissertação (Mestrado em Engenharia Mecânica) – Programa de Pós Graduação em Engenharia Mecânica, UFPB, João Pessoa, PB, 2016.
- Mitra, K., Miriyala, S. S., 2019. “Deep learning based system identification of industrial integrated grinding circuits”, *Journal of the Powder Technology*. <https://doi.org/10.1016/j.powtec.2019.10.065>. ISBN: 0032-5910/© 2019 Elsevier B.V.
- Montenegro, L. L. B., 2009. *Eficiência hidráulica e energética da operação do bombeamento para o abastecimento do bairro de mangabeira em João Pessoa*. Dissertação (Mestrado em Engenharia Mecânica) – Programa de Pós Graduação em Engenharia Mecânica, UFPB, João Pessoa, PB, Brasil.

- Mora, M., Vera, J., Rocamora, C., Abadia, R., 2013. “Energy Efficiency and Maintenance Costs of Pumping Systems for Groundwater Extraction”, *Water Resources Management*, 27(12), 4395–4408. doi:10.1007/s11269-013-0423-z.
- Moreira, H. A. M., Gomes, H. P., Villanueva, J. M., 2019a. “Fuzzy – mandani controller for a supply system”. *Anais do 25th ABCM International Congress of Mechanical Engineering* October 20-25, 2019, Uberlândia, MG, Brazil. DOI: <http://dx.doi.org/10.26678/ABCM.COBEM2019.COB2019-0508>.
- Moreira, H. A. M., Gomes, H. P., Villanueva, J. M., 2019b. “Controle inteligente aplicado à um sistema de bombeamento de água”. *14º Simpósio Brasileiro de Automação Inteligente*, 2019, Ouro Preto, MG.
- Moscinski, J., Ogonowski, Z., 1995. *Advanced control with Matlab & Simulink*. 1ª ed., Ellis Horwood, United Kingdom, 1995.
- Moura, G. A., 2016. *Sistemas de controle fuzzy neural e neural adaptativo destinados ao controle de pressão em rede de abastecimento de água*. Tese (Doutorado em Engenharia Mecânica) – Programa de Pós Graduação em Engenharia Mecânica, UFPB, João Pessoa, PB, Brasil.
- Moura, G. de A., Bezerra, S. de T. M., Gomes, H. P., Silva, S. A. da., 2018. “Neural network using the Levenberg–Marquardt algorithm for optimal real-time operation of water distribution systems”, *Urban Water Journal*, 1–8. doi:10.1080/1573062x.2018.1539503.
- Neto, J. T. C., 2017. *Processamento de valores atípicos em redes elétricas inteligentes baseado em algoritmos Neuro-Fuzzy*. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós Graduação em Engenharia Elétrica, UFPB, João Pessoa, PB, Brasil.
- Nise, Norman S., 2002. *Engenharia de sistemas de controle*. 3. ed. Rio de Janeiro: LTC, c2002. 695 p. ISBN 8521613016.

- Nourani, V., Elkiran, G. S. I. Abba., 2018. “Wastewater treatment plant performance analysis using artificial intelligence – an ensemble approach”. *Water Sci Technol* 21 December 2018; 78 (10): 2064–2076. doi: <https://doi.org/10.2166/wst.2018.477>.
- Oliveira, J. E. A., Serni, P. J. A., Ulson, J. A. C., Andreoli, A. L., Aguiar, P. R. A., Goedtel, A., 2010. Modelagem de um motor de indução trifásico acionado com tensões desequilibradas por meio de Redes Neurais Artificiais.
- Oliveira, J. K. C., 2017. *Lógica fuzzy aplicada na otimização operacional de rede setorizada de distribuição de água*. Tese (Doutorado em Engenharia Mecânica) – Programa de Pós Graduação em Engenharia Mecânica, UFPB, João Pessoa, PB, Brasil.
- Ortega, N.R.S., 2001. *Aplicação da Teoria da Lógica Fuzzy a Problemas de Biomedicina*. Tese de doutorado IF-USP. São Paulo, SP, Brasil. 153p.
- Page, P. R., Abu-Mahfouz, A. M., Mothetha, M. L., 2017. “Pressure management of water distribution systems via the remote real-time control of variable speed pumps”, *Journal of Water Resources Planning and Management*, v. 143, n. 8, p. 04017045.
- Prescott, S. L., Ulanicki, B., 2008. “Improved Control of Pressure Reducing Valves in Water Distribution Networks”, *Journal of Hydraulic Engineering*, 134(1), 56–65. doi:10.1061/(asce)0733-9429(2008)134:1(56).
- Rodrigues, G. G., 1996. *Identificação de Sistemas Dinâmicos Não Lineares Utilizando Modelos NARMAX Polinomiais - Aplicação a Sistemas Reais*. Dissertação de Mestrado do PPGEE, Universidade Federal de Minas Gerais, Belo Horizonte, Brasil, junho de 1996.
- Rinas, M., Traenckner, J., Koegst, T., 2018. “Erosion characteristics of raw sewage: investigations for a pumping station in northern Germany under energy efficient pump control”, *Water Sci Technol* 19 December 2018; 78 (9): 1997–2007. doi: <https://doi.org/10.2166/wst.2018.474>.

- Sagayaraj, R., Sthangavel, S., 2014. "Implementation of intelligent control strategies on current ripple reduction and harmonic analysis at the converter side of the industrial inverters and tradeoff analysis", *Journal of Theoretical and Applied Information Technology*, JATIT.
- Salvino, L. R., 2018. *Eficiência energética em sistemas pressurizados de distribuição de água com o uso de Redes Neurais Artificiais*. Tese (Doutorado em Engenharia Mecânica) – Programa de Pós Graduação em Engenharia Mecânica, UFPB, João Pessoa, PB, Brasil.
- Sierra, J. E., Santos, M., 2017. "Modelling engineering systems using analytical and neural techniques", *Hybridization. Journal of the Neuro Computing*. <http://dx.doi.org/10.1016/j.neucom.2016.11.099>. ISBN: 0925-2312/© 2017 Elsevier.
- Signoret, R., Camargo, R., Canno, L., Pires, M., Ribeiro, L., 2016. "Importance of pressure reducing valves (PRVs) in water supply networks", *Journal of Physics: Conference Series*. 738. 012026. 10.1088/1742-6596/738/1/012026.
- Silva, M. J. G., 2016. *Controle adaptativo aplicado a um sistema de bombeamento de água visando a redução das perdas de energia elétrica e água*. Tese (Doutorado em Engenharia Mecânica) – Programa de Pós Graduação em Engenharia Mecânica, UFPB, João Pessoa, PB, Brasil.
- Sivakumar, R. Sahana, C. Savitha, P. A., 2012. "Design of ANFIS based estimation and control for MIMO system", *International Journal of Engineering and Applications*, IJERA, ISSN: 2248-9622.
- Passino, K., Yorkovich S., 1998. *Fuzzy Control*. 1ed, Addison Wesley. New York.
- Pedrycz, W., Gomide, F., 2007. "Fuzzy systems engineering: toward human-centric computing", *New York: Wiley IEEE Press*.

- Takagi T, Sugeno M., 1985. “Fuzzy identifications of systems and its applications to modeling and control”, *IEE Transactions on Systems, MAN and Cybernetics* 15(1):116-132.
- Teklehaimanot, Y. K., Negash, D. S., Workiye, E. A., 2019. “Design of Hybrid Neuro-Fuzzy Controller for Magnetic Levitation Train Systems”. In: *International Conference on Information and Communication Technology for Development for Africa*. Springer, Cham, 2019. p. 119-133.
- Thangaraj, V., Somasundaram, M. S. B., 2018. “NFC-ARP: Neuro-Fuzzy controller for adaptive resource provisioning in virtualized environments”, *Neural Computing and Applications*. doi:10.1007/s00521-018-3528-8.
- Tsutiya, M. T., 2006. *Redução do Custo de Energia Elétrica em Sistemas de Abastecimento de Água*. ABES Associação Brasileira de Engenharia Sanitária e Ambiental. São Paulo, SP, Brasil.
- Villanueva, J. M. M., 2019. Sistemas de inferência Fuzzy. Disponível em: <http://www.cear.ufpb.br/juan/>. Acesso em 21 de maio de 2020.
- Vítor, T. S., 2011. *Projeto de Sistemas de Controle com Modelagem Takagi-Sugeno e Implementação de Controladores Fuzzy com Retroação de Estados*. Dissertação de mestrado, Programa de Pós Graduação em Engenharia Elétrica, Universidade Federal de Itajubá, Itajubá, MG, Brasil.
- Wei, C. C., Hsu, N. S., Huang, C. L., 2013. “Two-Stage Pumping Control Model for Flood Mitigation in Inundated Urban Drainage Basins”, *Water Resources Management*, 28(2), 425–444. doi:10.1007/s11269-013-0491-0.
- Zadeh, L.A., 1965. “Fuzzy Sets”, *Information and Control*, 8, 338-353. [http://dx.doi.org/10.1016/S0019-9958\(65\)90241-X](http://dx.doi.org/10.1016/S0019-9958(65)90241-X).