INSTITUTO DE PESQUISAS ENERGÉTICAS E NUCLEARES
Autarquia Associada à Universidade de São Paulo

**Planta experimental para monitoração e diagnóstico de falhas
utilizando inteligência artificial**

DAVI ALMEIDA MORAES

**Tese apresentada como parte dos
requisitos para obtenção do Grau de
Doutor em Ciências na Área
de Tecnologia Nuclear - Reatores**

**Orientadora:
Profa. Dra. Iraci Martinez Pereira**

**São Paulo
2019**

INSTITUTO DE PESQUISAS ENERGÉTICAS E NUCLEARES
Autarquia Associada à Universidade de São Paulo

**Planta experimental para monitoração e diagnóstico de falhas
utilizando inteligência artificial**

Versão Corrigida

Versão Original disponível no IPEN

DAVI ALMEIDA MORAES

**Tese apresentada como parte dos
requisitos para obtenção do Grau de
Doutor em Ciências na Área
de Tecnologia Nuclear - Reatores**

**Orientadora:
Profa. Dra. Iraci Martinez Pereira**

**São Paulo
2019**

Autorizo a reprodução e divulgação total ou parcial deste trabalho,
para fins de estudo e pesquisa, desde que citada a fonte

Como citar:

MORAES, D. A. ***Planta experimental para monitoração e diagnóstico de falhas utilizando inteligência artificial***. 2019. 162 p. Tese (Doutorado em Tecnologia Nuclear), Instituto de Pesquisas Energéticas e Nucleares, IPEN-CNEN/SP, São Paulo.
Disponível em: (data de consulta no formato: dd/mm/aaaa)

Ficha catalográfica elaborada pelo Sistema de geração automática da Biblioteca IPEN/USP,
com os dados fornecidos pelo(a) autor(a)

Moraes, Davi Almeida

Planta experimental para monitoração e diagnóstico de falhas utilizando inteligência artificial / Davi Almeida Moraes; orientadora Iraci Martinez Pereira. -- São Paulo, 2019.

162 p.

Tese (Doutorado) - Programa de Pós-Graduação em Tecnologia Nuclear (Reatores) -- Instituto de Pesquisas Energéticas e Nucleares, São Paulo, 2019.

1. GMDH. 2. redes neurais. 3. inteligência artificial. 4. planta experimental. 5. digital twin. I. Pereira, Iraci Martinez, orient. II. Título.

FOLHA DE APROVAÇÃO

Autor: Davi Almeida Moraes

Título: Planta experimental para monitoração e diagnóstico de falhas utilizando inteligência artificial

Tese apresentada ao Programa de Pós-Graduação
em Tecnologia Nuclear da Universidade São Paulo
para obtenção do título de Doutor em Ciências.

Data: 08 / 11 / 2019

Banca Examinadora

Profa. Dra.: Iraci Martinez Pereira

Instituição: IPEN / USP

Julgamento: Aprovado

Prof. Dr.: Antônio Teixeira e Silva

Instituição: IPEN / USP

Julgamento: Aprovado

Prof. Dr.: Roberto Navarro de Mesquita

Instituição: IPEN / USP

Julgamento: Aprovado

Prof. Dr.: Paulo Marcos de Aguiar

Instituição: IFSP / Campus São Paulo

Julgamento: Aprovado

Profa. Dra.: Elaine Inacio Bueno

Instituição: IFSP / Campus São Paulo

Julgamento: Aprovado

a minha esposa, Keila e a minha filha Rafaela
minhas pérolas, minha vida !

AGRADECIMENTOS

Primeiramente a Deus pela vida, oportunidade, criatividade, coragem e força para não desistir nunca !

A Professora Dra. Iraci Martinez Pereira pela confiança na realização desse trabalho, paciência e excepcional apoio durante todo tempo.

A minha esposa Keila que me inspira, sempre me apoiou e incentivou, durante todo desenvolvimento deste trabalho.

A minha filha Rafaela, um presente de Deus para o nosso lar que abrilhanta minha vida.

A todos os amigos que me apoiaram, incentivaram e entenderam a minha ausência em nossos encontros.

A empresa DK8 Tecnologia Educacional que apoiou o desenvolvimento do trabalho com espaço físico, componentes e equipamentos para o desenvolvimento da Planta Experimental.

A todos os colaboradores da empresa DK8 que de uma forma direta e/ou indireta auxiliaram durante o desenvolvimento do trabalho.

Ao meu pai José Francisco de Moraes *“in memoriam”* e minha mãe Aparecida Almeida de Moraes *“in memoriam”*, que mesmo durante poucos anos que passamos juntos nessa vida, deixaram valores profundos sobre ética, valorização das oportunidades e incentivo aos estudos.

RESUMO

MORAES, Davi A. ***Planta Experimental para Monitoração e Diagnóstico de Falhas Utilizando Inteligência Artificial***. 2019. 164 p. Tese (Doutorado em Tecnologia Nuclear) – Instituto de Pesquisas Energéticas e Nucleares – IPEN-CNEN/SP. São Paulo.

Neste trabalho foi desenvolvida uma planta experimental inspirada em um reator nuclear de potência do tipo PWR e posterior aplicação de Inteligência Artificial na Monitoração e Diagnóstico de Falhas, por meio dos métodos GMDH (*Group Method of Data Handling*) e RNA (Redes Neurais Artificiais). Com a planta experimental, tornou-se possível aplicar conceitos inovadores de modelagem de sistemas (*Digital Twin*) *on line* para a monitoração e diagnóstico de falhas individuais e/ou combinadas. Conclui-se que, embora ambos os sistemas de monitoração apresentaram resultados satisfatórios, o GMDH demonstrou um melhor desempenho em relação às Redes Neurais, pois além de apresentar valores de desvios médios menores do que o modelo utilizando Redes Neurais, foi possível realizar a monitoração de todas as variáveis, enquanto que utilizando Redes Neurais não foi possível monitorar as variáveis de potência do aquecedor, nível, e potência e vazões das bombas. A inserção de falhas em uma ou mais variáveis de temperatura, repercutiu na estimativa da rede para as demais variáveis, porém não impediu que o Sistema de Monitoração identificasse a falha. Para determinar o comportamento do Sistema de Monitoração com falhas múltiplas, foram aplicadas falhas simultâneas nos sensores de temperatura.

Palavras-chave: GMDH; redes neurais; inteligência artificial; planta experimental; digital twin.

ABSTRACT

MORAES, Davi A. ***Experimental Plant for Monitoring and Fault Diagnostic Using Artificial Intelligence***. 2019. 164 p. Tese (Doutorado em Tecnologia Nuclear) – Instituto de Pesquisas Energéticas e Nucleares – IPEN-CNEN/SP. São Paulo.

In this work we developed an experimental plant inspired by a PWR-type nuclear power reactor and applied later Artificial Intelligence in the Monitoring and Fault Diagnosis of Faults, through the Group Method of Data Handling (GMDH) and ANN (Artificial Neural Networks). Through the experimental plant, it became possible to apply innovative concepts of on-line system modeling (Digital Twin) for monitoring and diagnosing individual and / or combined faults. It is concluded that although both monitoring systems presented satisfactory results, GMDH showed a better performance compared to Neural Networks, because besides presenting smaller average deviation values than the model using Neural Networks, it was possible to perform the monitoring of all variables, while using Neural Networks, it was not possible to monitor the variables of heater power, level, and pump power and flow rates. The insertion of faults in one or more temperature variables interfered in the network estimation for the other variables, but did not prevent the Monitoring System from identifying the fault. To determine the behavior of the multiple fault monitoring system, simultaneous faults were applied to temperature sensors.

Key words: GMDH; neural networks; artificial intelligence; experimental plants; digital twin.

LISTA DE TABELAS

Tabela 1 - Revoluções Industriais [1]	17
Tabela 2 - Sensores e atuadores da Planta Experimental (Tag / Func. / Caract. Téc. / Faixa Oper.)	34
Tabela 3 - Resultado geral dos desvios médios das temperaturas (°C)	76
Tabela 4 - Resultado geral dos desvios médios das temperaturas (%)	76
Tabela 5 - Desvios médios das temperaturas com falha em TE-01 (°C)	88
Tabela 6 - Desvios médios das temperaturas com falha em TE-01 (%)	88
Tabela 7 - Desvios médios das temperaturas com falha em TE-02 (°C)	92
Tabela 8 - Desvios médios das temperaturas com falha em TE-02 (%)	92
Tabela 9 - Desvios médios das temperaturas com falha em TE-03 (°C)	96
Tabela 10 - Desvios médios das temperaturas com falha em TE-03 (%)	96
Tabela 11 - Desvios médios das temperaturas com falha em TE-04 (°C)	100
Tabela 12 - Desvios médios das temperaturas com falha em TE-04 (%)	100
Tabela 13 - Desvios médios das temperaturas com falha em TE-05 (°C)	104
Tabela 14 - Desvios médios das temperaturas com falha em TE-05 (%)	104
Tabela 15 - Desvios médios das temperaturas com falha em TE-06 (°C)	108
Tabela 16 - Desvios médios das temperaturas com falha em TE-06 (%)	108
Tabela 17 - Desvios médios gerais das temperaturas (inserção de falha) (°C) ..	109
Tabela 18 - Desvios médios gerais das temperaturas (inserção de falha) (%) ...	109
Tabela 19 - Desvios médios das temperaturas com falha em TE-01 e TE-02 (°C) - 809s a 829s	116
Tabela 20 - Desvios médios das temperaturas com falha em TE-01 e TE-02 (%) - 809s a 829s	116
Tabela 21 - Desvios médios das temperaturas com falha em TE-01 e TE-02 (°C) - 1415s a 1436s	120
Tabela 22 - Desvios médios das temperaturas com falha em TE-01 e TE-02 (°C) - 1415s a 1436s	120
Tabela 23 - Desvios médios das temperaturas com falhas em TE-01 e TE-05 (°C) - 1126 a 1149s	125
Tabela 24 - Desvios médios das temperaturas com falhas em TE-01 e TE-05 (%) - 1126 a 1149s	125

Tabela 25 - Desvios médios das temperaturas com falha em TE-01 e TE-05 (°C) - 1721s a 1745s	129
Tabela 26 - Desvios médios das temperaturas com falhas em TE-01 e TE-05 (%) - 1721s a 1745s	129
Tabela 27 - Desvios médios gerais das temperaturas com falhas múltiplas (°C)	130
Tabela 28 - Desvios médios percentuais das temperaturas com falhas múltiplas (%)	131
Tabela 29 - Resultado geral GMDH - Desvios médios das temperaturas (°C) ...	152
Tabela 30 - Resultado geral GMDH - Desvios médios das temperaturas (%)	152
Tabela 31 - Desvios médios GMDH para as variáveis: AQ-01, B-01, B-02, B-03, FT-01, FT-02 e PT-01.	153
Tabela 32 - Percentual dos desvios médios GMDH para as variáveis: AQ-01, B- 01, B-02, B-03, FT-01, FT-02 e PT-01.....	153
Tabela 33 - Comparativo entre o GMDH e a RNA (média total).....	154
Tabela 34 - Comparativo entre o GMDH e a RNA (média total)	154
Tabela 35 - Comparativo entre o GMDH e a RNA (estado estacionário).....	155
Tabela 36 - Comparativo entre o GMDH e a RNA (estado estacionário).....	155

LISTA DE FIGURAS

Figura 1 - Banner principal do evento - AIEA (10 a 12/junho/2019).....	18
Figura 2 - Representação esquemática do funcionamento do Reator tipo PWR [19].....	25
Figura 3 - Planta experimental desenvolvida para monitoração e diagnóstico de falhas	26
Figura 4 - Tanque TQ-01	27
Figura 5 - Tanque TQ-02	27
Figura 6 - Tanque TQ-03	28
Figura 7 - Instrumentação do tanque TQ-01	29
Figura 8 - Instrumentação do tanque TQ-02	29
Figura 9 - Instrumentação do tanque TQ-03	30
Figura 10 - Sensores de vazão FT-01 e FT02.....	30
Figura 11- Válvulas para geração de falhas mecânicas	31
Figura 12 - Fluxograma de engenharia da Planta Experimental.....	32
Figura 13 - Módulo para geração de falhas elétricas	33
Figura 14 - Controlador Lógico Programável (CLP)	35
Figura 15 - Tela principal do software supervisor (SCADA).....	36
Figura 16 - Rede com propagação para frente de uma camada	39
Figura 17 - Redes do tipo MLP (múltiplas camadas com propagação para frente)	39
Figura 18 - Redes recorrentes	40
Figura 19 - Arquitetura de uma rede neural do tipo MLP	41
Figura 20 - Curva RMIN calculado a cada geração.....	49
Figura 21 - Estrutura do modelo auto organizável GMDH com m entradas e k gerações	50
Figura 22 - Treinamento GMDH / Redes Neurais	51
Figura 23 - Aquisição de dados da planta (normalizados).....	52
Figura 24 - Monitoração GMDH / Redes Neurais	53
Figura 25 - Software supervisor (SCADA) desenvolvido para a Planta Experimental	54
Figura 26 - Interface desenvolvida no <i>Simulink</i> para a monitoração de TE-01	55

Figura 27 - Interface desenvolvida no Simulink para a monitoração das temperaturas	56
Figura 28 - Desempenho da RNA para a variável de temperatura TE-01	58
Figura 29 - Regressão linear da RNA para a variável de temperatura TE-01	59
Figura 30 - Monitoração da temperatura TE-01	60
Figura 31 - Desempenho da RNA para a variável de temperatura TE-02	61
Figura 32 - Regressão linear da RNA para a variável de temperatura TE-02	62
Figura 33 - Monitoração da temperatura TE-02	63
Figura 34 - Desempenho da RNA para a variável de temperatura TE-03	64
Figura 35 - Regressão linear da RNA para a variável de temperatura TE-03	65
Figura 36 - Monitoração da temperatura TE-03	66
Figura 37 - Desempenho da RNA para a variável de temperatura TE-04	67
Figura 38 - Regressão linear da RNA para a variável de temperatura TE-04	68
Figura 39 - Monitoração da temperatura TE-04	69
Figura 40 - Desempenho da RNA para a variável de temperatura TE-05	70
Figura 41 - Regressão linear da RNA para a variável de temperatura TE-05	71
Figura 42 - Monitoração da temperatura TE-05	72
Figura 43 - Desempenho da RNA para a variável de temperatura TE-06	73
Figura 44 - Regressão linear da RNA para a variável de temperatura TE-06	74
Figura 45 - Monitoração da temperatura TE-06	75
Figura 46 - Desempenho da RNA para a variável de pressão PT-01	77
Figura 47 - Regressão linear da RNA para a variável de pressão PT-01	78
Figura 48 - Desempenho da RNA para a variável de vazão FT-01	79
Figura 49 - Regressão linear da RNA para a variável de vazão FT-01	80
Figura 50 - Desempenho da RNA para a variável de vazão FT-02	81
Figura 51 - Regressão linear da RNA para a variável de vazão FT-02	82
Figura 52 - Monitoração de todas as temperaturas com a inserção de falha	84
Figura 53 - Monitoração da temperatura TE-01 com inserção de falha	85
Figura 54 - Monitoração da temperatura TE-02 com falha em TE-01	86
Figura 55 - Monitoração da temperatura TE-03 com falha em TE-01	86
Figura 56 - Monitoração da temperatura TE-04 com falha em TE-01	87
Figura 57 - Monitoração da temperatura TE-05 com falha em TE-01	87
Figura 58 - Monitoração da temperatura TE-06 com falha em TE-01	88
Figura 59 - Monitoração da temperatura TE-02 com inserção de falha	89

Figura 60 - Monitoração da temperatura TE-01 com falha em TE-02.....	90
Figura 61 - Monitoração da temperatura TE-03 com falha em TE-02.....	90
Figura 62 - Monitoração da temperatura TE-04 com falha em TE-02.....	91
Figura 63 - Monitoração da temperatura TE-05 com falha em TE-02.....	91
Figura 64 - Monitoração da temperatura TE-06 com falha em TE-02.....	92
Figura 65 - Monitoração da temperatura TE-03 com inserção de falha	93
Figura 66 - Monitoração da temperatura TE-01 com falha em TE-03.....	94
Figura 67 - Monitoração da temperatura TE-02 com falha em TE-03.....	94
Figura 68 - Monitoração da temperatura TE-04 com falha em TE-03.....	95
Figura 69 - Monitoração da temperatura TE-05 com falha em TE-03.....	95
Figura 70 - Monitoração da temperatura TE-06 com falha em TE-03.....	96
Figura 71 - Monitoração da temperatura TE-04 com inserção de falha	97
Figura 72 - Monitoração da temperatura TE-01 com falha em TE-04.....	98
Figura 73 - Monitoração da temperatura TE-02 com falha em TE-04.....	98
Figura 74 - Monitoração da temperatura TE-03 com falha em TE-04.....	99
Figura 75 - Monitoração da temperatura TE-05 com falha em TE-04.....	99
Figura 76 - Monitoração da temperatura TE-06 com falha em TE-04.....	100
Figura 77 - Monitoração da temperatura TE-05 com inserção de falha	101
Figura 78 - Monitoração da temperatura TE-01 com falha em TE-05.....	102
Figura 79 - Monitoração da temperatura TE-02 com falha em TE-05.....	102
Figura 80 - Monitoração da temperatura TE-03 com falha em TE-05.....	103
Figura 81 - Monitoração da temperatura TE-04 com falha em TE-05.....	103
Figura 82 - Monitoração da temperatura TE-06 com falha em TE-05.....	104
Figura 83 - Monitoração da temperatura TE-06 com inserção de falha	105
Figura 84 - Monitoração da temperatura TE-01 com falha em TE-06.....	106
Figura 85 - Monitoração da temperatura TE-02 com falha em TE-06.....	106
Figura 86 - Monitoração da temperatura TE-03 com falha em TE-06.....	107
Figura 87 - Monitoração da temperatura TE-04 com falha em TE-06.....	107
Figura 88 - Monitoração da temperatura TE-05 com falha em TE-06.....	108
Figura 89 - Monitoração de todas as temperaturas com inserção de falhas múltiplas.....	111
Figura 90 - Monitoração TE-01 com inserção de falhas múltiplas	112
Figura 91 - Monitoração TE-02 com inserção de falhas múltiplas	112
Figura 92 - Monitoração TE-01: falha em TE-01 e TE-02 (809 a 829s)	113

Figura 93 - Monitoração TE-02: falha em TE-01 e TE-02 (809 a 829s)	113
Figura 94 - Monitoração TE-03: falha em TE-01 e TE-02 (809 a 829s)	114
Figura 95 - Monitoração TE-04: falha em TE-01 e TE-02 (809 a 829s)	114
Figura 96 - Monitoração TE-05: falha em TE-01 e TE-02 (809 a 829s)	115
Figura 97 - Monitoração TE-06: falha em TE-01 e TE-02 (809 a 829s)	115
Figura 98 - Monitoração TE-01: falha em TE-01 e TE-02 (1415 a 1436s)	117
Figura 99 - Monitoração TE-02: falha em TE-01 e TE-02 (1415 a 1436s)	117
Figura 100 - Monitoração TE-03: falha em TE-01 e TE-02 (1415 a 1436s)	118
Figura 101 - Monitoração TE-04: falha em TE-01 e TE-02 (1415 a 1436s)	118
Figura 102 - Monitoração TE-05: falha em TE-01 e TE-02 (1415 a 1436s)	119
Figura 103 – Monitoração TE-06: falha em TE-01 e TE-02 (1415 a 1436s)	119
Figura 104 - Monitoração de TE-01 com inserção de falhas múltiplas	121
Figura 105 - Monitoração de TE-05 com inserção de falhas múltiplas	122
Figura 106 - Monitoração TE-01: falha em TE-01 e TE-05 (1126 a 1149s)	122
Figura 107 - Monitoração TE-02: falha em TE-01 e TE-05 (1126 a 1149s)	123
Figura 108 - Monitoração TE-03: falha em TE-01 e TE-05 (1126 a 1149s)	123
Figura 109 - Monitoração TE-04: falha em TE-01 e TE-05 (1126 a 1149s)	124
Figura 110 - Monitoração TE-05: falha em TE-01 e TE-05 (1126 a 1149s)	124
Figura 111 - Monitoração TE-06: falha em TE-01 e TE-05 (1126 a 1149s)	125
Figura 112 - Monitoração TE-01: falha em TE-01 e TE-05 (1721s a 1745s)	126
Figura 113 - Monitoração TE-02: falha em TE-01 e TE-05 (1721s a 1745s)	126
Figura 114 - Monitoração TE-03: falha em TE-01 e TE-05 (1721s a 1745s)	127
Figura 115 - Monitoração TE-04: falha em TE-01 e TE-05 (1721s a 1745s)	127
Figura 116 - Monitoração TE-05: falha em TE-01 e TE-05 (1721s a 1745s)	128
Figura 117 - Monitoração TE-06: falha em TE-01 e TE-05 (1721s a 1745s)	128
Figura 118 - Desempenho GMDH para o aquecimento AQ-01	132
Figura 119 - Monitoração GMDH para o aquecimento AQ-01	133
Figura 120 - Desempenho GMDH para a potência da bomba B-01	134
Figura 121 - Monitoração GMDH para a potência da bomba B-01	134
Figura 122 - Desempenho GMDH para a potência da bomba B-02	135
Figura 123 - Monitoração GMDH para a potência da bomba B-02	136
Figura 124 - Desempenho GMDH para a potência da bomba B-03	137
Figura 125 - Monitoração GMDH para a potência da bomba B-03	137
Figura 126 - Desempenho GMDH para a vazão FT-01	138

Figura 127 - Monitoração GMDH para a vazão FT-01	139
Figura 128 - Desempenho GMDH para a vazão FT-02.....	140
Figura 129 - Monitoração do GMDH para a vazão FT-02	140
Figura 130 - Desempenho GMDH para a pressão PT-01	141
Figura 131 - Monitoração GMDH para a pressão PT-01	142
Figura 132 - Desempenho GMDH para a temperatura TE-01	143
Figura 133 - Monitoração GMDH para a temperatura TE-01.....	143
Figura 134 - Desempenho GMDH para a temperatura TE-02	144
Figura 135 - Monitoração GMDH para a temperatura TE-02.....	145
Figura 136 - Desempenho GMDH para a temperatura TE-03	146
Figura 137 - Monitoração GMDH para a temperatura TE-03.....	146
Figura 138 - Desempenho GMDH para a temperatura TE-04	147
Figura 139 - Monitoração GMDH para a temperatura TE-04.....	148
Figura 140 - Desempenho GMDH para a temperatura TE-05	149
Figura 141 - Monitoração GMDH para a temperatura TE-05.....	149
Figura 142 - Desempenho GMDH para a temperatura TE-06	150
Figura 143 - Monitoração GMDH para a temperatura TE-06.....	151

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Objetivo	20
2	REVISÃO DA LITERATURA.....	21
3	PLANTA EXPERIMENTAL PARA MONITORAÇÃO E DIAGNÓSTICO DE FALHAS.....	25
3.1	Sistema para Aquisição de Dados	35
4	FUNDAMENTOS TEÓRICOS	37
4.1	Redes Neurais Artificiais	37
4.1.1	Redes Neurais do tipo Multilayer Perceptron (MLP)	41
4.1.2	Algoritmo de Retropropagação	42
4.2	GMDH (<i>Group Method of Data Handling</i>).....	45
4.2.1	Descrição da metodologia GMDH	46
5	METODOLOGIA	51
5.1	Operação da Planta Experimental	53
5.2	Monitoração da Planta Experimental	55
6	RESULTADOS.....	57
6.1	Monitoração em Regime Normal de Funcionamento (RNA).....	57
6.1.1	Resultado da Rede Neural para a Temperatura TE-01.....	58
6.1.2	Resultado da Rede Neural para a Temperatura TE-02.....	61
6.1.3	Resultado da Rede Neural para a Temperatura TE-03.....	64
6.1.4	Resultado da Rede Neural para a Temperatura TE-04.....	67
6.1.5	Resultado da Rede Neural para a Temperatura TE-05.....	70
6.1.6	Resultado da Rede Neural para a Temperatura TE-06.....	73
6.1.7	Análise dos Resultados dos Desvios Médios para as Temperaturas	76
6.1.8	Resultado da Rede Neural para a Pressão PT-01	77
6.1.9	Resultado da Rede Neural para a Vazão FT-01	79
6.1.10	Resultado da Rede Neural para a Vazão FT-02	81
6.2	Monitoração do Funcionamento com Inserção de Falha (RNA)	83
6.2.1	Monitoração da RNA para Inserção de Falha em TE-01	85
6.2.2	Monitoração da RNA para Inserção de Falha em TE-02	89
6.2.3	Monitoração da RNA para Inserção de Falha em TE-03	93

6.2.4	Monitoração da RNA para Inserção de Falha em TE-04	97
6.2.5	Monitoração da RNA para Inserção de Falha em TE-05	101
6.2.6	Monitoração da RNA para Inserção de Falha em TE-06	105
6.2.7	Análise dos Desvios Médios para Falhas Individuais.....	109
6.3	Monitoração com Inserção de Falhas Múltiplas (RNA)	110
6.3.1	Monitoração da RNA para Falhas Múltiplas em TE01 e TE02	112
6.3.2	Monitoração da RNA para Falhas Múltiplas em TE01 e TE05	121
6.3.3	Análise Geral dos Desvios Médios para a inserção de Falhas Múltiplas....	130
6.4	Monitoração Utilizando GMDH	132
6.4.1	Resultado GMDH para a AQ-01	132
6.4.2	Resultado GMDH para a Bomba B-01	133
6.4.3	Resultado GMDH para a Bomba B-02.....	135
6.4.4	Resultado GMDH para a Bomba B-03.....	136
6.4.5	Resultado GMDH para a Vazão FT-01	138
6.4.6	Resultado GMDH para a Vazão FT-02.....	139
6.4.7	Resultado GMDH para a Pressão PT-01	141
6.4.8	Resultado GMDH para a Temperatura TE-01.....	142
6.4.9	Resultado GMDH para a Temperatura TE-02.....	144
6.4.10	Resultado GMDH para a Temperatura TE-03.....	145
6.4.11	Resultado GMDH para a Temperatura TE-04.....	147
6.4.12	Resultado GMDH para a Temperatura TE-05.....	148
6.4.13	Resultado GMDH para a Temperatura TE-06.....	150
6.4.14	Análise dos Resultados dos Desvios Médios para as Temperaturas	152
6.4.15	Análise dos Resultados dos Desvios Médios para as demais Variáveis ..	153
6.5	Comparação GMDH com RNA	154
7	CONCLUSÕES	156
8	TRABALHOS FUTUROS	158
	REFERÊNCIAS BIBLIOGRÁFICAS.....	159

1 INTRODUÇÃO

Com a ascensão da industrialização orientada para exportação (IOE), aplicada principalmente por países do leste asiático, a indústria dos países desenvolvidos sofreu um processo de desindustrialização. Segundo o serviço de pesquisa do parlamento europeu (EPRS), a Europa perdeu um terço de sua base industrial nos últimos 40 anos [1].

Na busca da recuperação do valor agregado na indústria global, foi apresentado em 2011 na Alemanha, através da Feira de Hannover o termo Indústria 4.0, como parte da estratégia do governo alemão para o desenvolvimento de alta tecnologia para o âmbito industrial do país. Iniciado em 2006, o projeto *High Tech Strategy*, reuniu os principais desenvolvedores de inovação e tecnologia do país para alavancar e difundir novas tecnologias em âmbito nacional, dando origem ao *High Tech Strategy 2020 - Action Plan* (2010) [2].

Seguindo os dados do Parlamento Europeu, a indústria 4.0 possui um potencial de ganhos de eficiência na ordem de 6% a 8%, influenciando assim, a economia mundial de modo geral. Desse modo, diversos países com grande relevância mundial, no que cerne ao desenvolvimento tecnológico, iniciaram ações que abrangem a ampliação e aplicação desse tema. A exemplo: Estados Unidos, França, China e a própria União Europeia (UE).

Também conhecido como a quarta revolução industrial, a indústria 4.0 é marcada pela fusão dos mundos físicos e virtuais, onde a fusão de ambos ocorre através da internet. “Em resumo, tudo dentro e ao redor de uma planta de manufatura (fornecedores, distribuidores, unidades fabris e até o produto), são conectados digitalmente, proporcionando uma cadeia de valor altamente integrada” [1].

Data-se a primeira revolução industrial em 1748, posteriormente a segunda inicia-se no final do século 19 e a terceira revolução industrial, a partir de 1970.

A Tabela 1 demonstra os períodos das 4 revoluções e indica as principais tecnologias e capacidades relacionadas a cada uma.

Tabela 1 - Revoluções Industriais [1]

Revolução Industrial	Período	Tecnologias e Capacidades
Primeira	1748 - meados do Século 19	Uso da energia a vapor e utilização de máquinas.
Segunda	Final do Século 19 - 1970	Produção em massa com base na divisão do trabalho (linha de montagem) e introdução da energia elétrica.
Terceira	1970 - Hoje	Eletrônica e tecnologia da informação impulsionam novos níveis de automação de tarefas complexas
Quarta	Hoje - Futuro	A tecnologia do sensor, a interconectividade e a análise de dados permitem a personalização em massa, a integração de cadeias de valor e maior eficiência

Fonte: EPRS | European Parliamentary Research Service Industry, 2015.

Entre muitos componentes da indústria 4.0, destacam-se como chave quatro deles: Sistemas Cyber-Físicos (*Cyber-Physical System* - CPS), Internet das Coisas (*Internet of Things* - IoT), Internet dos Serviços (*Internet of Services* - IoS) e Fábrica Inteligente (*Smart Factories*). Todavia, além desses quatro, existem também os seguintes componentes: *Smart Products*, M2M (*Machine to Machine*), *Big Data* e *Cloud*, segundo Hermann, Pentek e Otto [3].

O conceito de fábrica inteligente conta com a integração dos diversos componentes para que ocorra a simulação e testes do processo em questão, antes mesmo de sua concepção, ou mesmo para que ocorra mudança e/ou expansão deste. Para que isso se torne possível, obtém-se o *Digital Twin* (Gêmeo Digital) do processo. Esse Gêmeo Digital é uma reprodução do processo de forma digital, em outras palavras, um “modelo equivalente digital” desse processo [4].

Para construção do *Digital Twin* é necessário ter uma base de dados com todo histórico de funcionamento do processo em suas mais diversas condições de funcionamento. Quanto maior e mais completa for a base de dados, maior será o realismo do processo virtual, frente ao funcionamento do processo real. Desse modo é possível obter uma simulação mais próximo possível de como será o comportamento do processo físico.

Inicialmente o conceito da indústria 4.0 surgiu com toda sua estratégia em resposta ao segmento industrial, porém, sua aplicabilidade pode ocorrer em processos de todo e qualquer segmento. Em nosso caso, daremos enfoque à aplicabilidade ao setor de energia nuclear.

Mais de 250 líderes da indústria nuclear, reguladores, pesquisadores, representantes do governo e provedores de tecnologia emitiram um “*Call to Action*” (chamado para ação) para acelerar soluções inovadoras para sustentar e avançar a atual frota operacional de NPPs (*Nuclear Power Plants* - Usinas Nucleares) em todo o mundo. Pode-se observar o banner principal do evento na Figura 1. O “*Call to Action*” enfatiza as quatro inovações identificadas pelos participantes do Fórum Global de Inovação para o Futuro da Energia Nuclear durante três dias, de 10 a 12/Junho de 2019 [5][6].

Figura 1 - Banner principal do evento - AIEA (10 a 12/junho/2019)

Fonte: Current and Future Nuclear Energy Leaders '*Call to Action*' for Innovation, 2019.

O objetivo principal do evento foi enfrentar os desafios mais urgentes do setor nuclear e examinar as barreiras e oportunidades para implantar soluções tecnológicas e de processos inovadoras para manter ou até melhorar a segurança nuclear e reduzir custos. Para isso, os participantes destacaram 28 inovações em

vários aspectos da operação da atual frota de centrais nucleares, encimadas pelas quatro seguintes:

Gêmeo Digital (*Digital Twin*): Recriação virtual de um processo em um modelo baseado em computador para melhorar o desempenho de reatores nucleares de potência, bem como, reduzir custos;

Fabricação Avançada (*Advanced Manufacturing*): Inclusão de impressão 3D para enfrentar os desafios da cadeia de suprimentos;

Aprendizado de Máquina (*Machine Learning*): Disponibiliza melhor uso de “*big data*” já disponível no setor de energia nuclear para otimizar a manutenção;

Uso de estruturas mais inovadoras (*Using more innovative framework*): Disponibiliza a troca de informações para compartilhar dados sobre pesquisa e desenvolvimento, operações e manutenção.

O “*Call to Action*” forma a base do desenvolvimento de itens a serem implementados nos reatores nucleares de potência. [5][6]

Em relação ao termo *Digital Twin*, embora seja recente, o modelamento de sistemas de processo já vem sendo realizado há alguns anos. Foram desenvolvidos trabalhos para monitoração e detecção de falhas utilizando técnicas de inteligência artificial: Redes Neurais (Bueno, E.), GMDH (Martinez, I.), Colônias de Formiga (Santos, G.) pelo grupo de monitoração e diagnóstico do CEN (Centro de Engenharia Nuclear) do IPEN (Instituto de Pesquisas Energéticas e Nucleares). [7][8][10]

Nestes trabalhos, foram desenvolvidos sistemas de monitoração e diagnóstico aplicados ao reator de pesquisa do IPEN, IEA-R1. Inicialmente utilizou-se o modelo teórico do reator e posteriormente, foi aplicado aos seus dados de operação.

Esses sistemas foram utilizados para monitorar o reator em situações normais de operação e em situações de falhas. Porém, para a análise de operação de um reator nuclear, mesmo tratando-se de um reator de pesquisa, existem normas e procedimentos de segurança que devem ser obedecidos durante sua operação. Qualquer ação diferente do procedimento estabelecido nas normas de operação, deve ser submetida à aprovação de um comitê de segurança.

Desse modo, optou-se por utilizar a aplicação de falhas sintéticas aos dados do reator. Torna-se impossível a monitoração *on line* para se obter os resultados de operação em condições de funcionamento com a inserção de falhas.

Para preencher essa lacuna, seria necessário o desenvolvimento de uma planta experimental que permitisse a monitoração, diagnóstico e inserção de falhas *on line*.

1.1 Objetivo

O trabalho tem como objetivo o desenvolvimento de uma planta experimental para a monitoração e diagnóstico de falhas simples e múltiplas, de forma *on line*, utilizando inteligência artificial através das técnicas de Redes Neurais Artificiais e GMDH.

Este trabalho é inédito, pois, por meio da planta experimental, além da análise *on line* do funcionamento do processo em regime normal de operação, será possível a monitoração e diagnóstico de falhas *on line* em diversas partes da planta durante o seu funcionamento, utilizando técnicas de inteligência artificial. Em trabalhos anteriores não foi possível a monitoração em tempo real e as falhas eram inseridas de forma sintética com análise *off-line*.

Outro ponto importante é que, por meio das falhas geradas em uma ou mais variáveis, será possível realizar a análise comportamental das demais variáveis, uma vez que o sistema de monitoração toma como referência todas as variáveis para o cálculo ou estimativa do valor de saída.

Além da concepção da Planta Experimental ter sido inspirada em um reator nuclear, o projeto como um todo disponibiliza um sistema de instrumentação com redundância de sensores, um módulo para inserção de falhas elétricas, um sistema para inserção de falhas mecânicas, dois sistemas de aquisição de dados que operam em paralelo e um sistema de monitoração *on line* que utiliza técnicas de inteligência artificial, o que faz desse projeto uma Planta Experimental inédita.

Da forma como foi projetada, a planta pode gerar uma base de dados para outras análises e também permite ser modificada facilmente para adaptar-se a novas pesquisas.

2 REVISÃO DA LITERATURA

A bibliografia revisada apresenta trabalhos que abrangem a área de inovação tecnológica para processos em diversos segmentos, com enfoque na monitoração e diagnóstico de falhas utilizando inteligência artificial, possibilitando assim, o estabelecimento de um estudo sobre o estado da arte referente ao emprego de GMDH e RNA.

A Agência Internacional de Energia Atômica (AIEA) realizou o fórum global que ocorreu de 10 a 12 de Junho de 2019 em Gyeongju, na República da Coreia [6]. Esse evento reuniu mais de 250 líderes da indústria nuclear, reguladores, pesquisadores, representantes do governo e provedores de tecnologia. O objetivo principal foi destacar as inovações necessárias para tornar a atual frota de usinas nucleares mais sustentável com foco nas novas tecnologias. Como assunto foco, foram citados: gêmeo digital, fabricação avançada, aprendizado de máquina e a utilização de estruturas mais inovadoras.

Davies [1] explanou a visão do parlamento europeu, *European Parliamentary Research Service* (EPRS) em 2015, sobre a situação da indústria nas últimas décadas, com enfoque na quarta revolução industrial. Foram apresentados os desafios para a absorção das novas tecnologias e as políticas a serem adotadas pela União Europeia para implementação e desenvolvimento das tecnologias atuais.

Em 2006, Sharma [2] apresentou a organização dos fatos, desde o início do projeto *High Tech Strategy*, até o seu lançamento na feira de Hannover em 2011, destacando o *Action Plan* com agenda para o desenvolvimento de novas tecnologias até 2020. Foram destacados as seguintes áreas, como campos de pesquisa e desenvolvimento de tecnologia: clima, energia, saúde, nutrição, mobilidade, segurança e comunicação.

Em 2015, Herman et al. [3] propuseram uma definição para a indústria 4.0 citando os componentes: Sistemas Cyber-Físicos (*Cyber-Physical System* - CPS), Internet das Coisas (*Internet of Things* - IoT), Internet dos Serviços (*Internet of Services* - IoS) e Fábrica Inteligente (*Smart Factories*), *Smart Products*, M2M

(*Machine to Machine*), *Big Data* e *Cloud*. Sendo o destaque para os quatro primeiros componentes, com critério sobre o número de artigos encontrados. Também identificam seis princípios para sua implementação, são eles: interoperabilidade, virtualização, descentralização, capacidade em tempo real, orientação a serviços e modularidade.

Em 2006, Gonçalves [7] desenvolveu um sistema de Monitoração e Diagnóstico de Falhas utilizando a metodologia GMDH aplicado ao reator IEA-1. O sistema foi responsável pela monitoração das variáveis de operação, comparando os valores calculados pelo modelo GMDH com os valores medidos. A metodologia foi aplicada inicialmente em um modelo teórico do reator e, posteriormente em uma base de dados experimentais contendo informações referentes a uma semana típica de operação deste. O diagnóstico de falhas foi desenvolvido através da inserção de falhas sintéticas a uma base de dados, onde foram simuladas falhas nos sensores de temperatura, sendo implementado pela Lógica Nebulosa.

Em 2011, Bueno [8] apresentou uma metodologia para a monitoração e detecção de falhas utilizando os algoritmos GMDH e RNA de forma combinada, aplicados ao reator de pesquisa do IPEN, IEA-R1. Inicialmente a metodologia foi implementada utilizando dados de um modelo teórico, posteriormente, foram utilizados dados referentes a uma semana típica de operação do reator. Uma vez que foi construída uma base de dados, foi possível a inserção de falhas de forma sintética.

No livro *GMDH-Methodology and Implementation in Matlab*, Imperial College Press, 2016 [9], o editor Godfrey Onwubolu convidou vários pesquisadores, internacionalmente reconhecidos especialistas na área de GMDH que contribuíram com seus trabalhos. No livro tem-se várias versões de algoritmos empregados, de simples camadas a sistemas híbridos, que combinam principalmente GMDH e Redes Neurais Artificiais.

Em 2011, Gu e Yang [11] propuseram uma nova abordagem para detecção de falhas robustas e isolamento para uma classe de sistemas incertos. Foi proposto um banco de dados para todas as possibilidades de detecção de falhas e isolamento. Baseado na análise dos dados, um banco residual foi definido e correlacionado. Foi desenvolvido um esquema adaptativo para estimar parâmetros desconhecidos para atuadores fechados, nos quais a posição de bloqueio é desconhecida.

Em 2011, Feital et al. compararam os resultados de três diferentes métodos de detecção e isolamento de falhas (FDI) para sistemas dinâmicos. Estas técnicas foram propostas na literatura, a saber: *Dynamic Principal Component Analysis* (DPCA), *Canonical Variable Analysis* (CVA) e *Subspace Model Identification* (SMI). O objetivo deste estudo foi o contraste do desempenho de cada FDI. As informações utilizadas, dados reais, provenientes de uma torre de destilação identificaram o modelo SMI como o mais sensível para a detecção de falhas. Por sua vez, o método DPCA conseguiu oferecer um panorama correto, pois utilizou as variáveis reais de reconstrução e de contribuição do evento de falha. O CVA utilizou apenas as variáveis de reconstrução e obteve resultados satisfatórios. Concluíram que os métodos de detecção de falhas e isolamento DPCA , CVA e SMI , possuem pontos fortes e fracos que se complementam [12].

Em 2009, Zhenhai e Imad [13] consideraram um modelo baseado na detecção e isolamento de falhas e isolamento do problema de sistemas dinâmicos lineares invariantes no tempo, sujeitos a falhas e distúrbios. Estudaram o estado que cancela o sistema dinâmico e define um sinal vetor do sistema que é sensível somente às falhas e distúrbios. Foi desenvolvido então, um filtro de isolamento e um sistema estável de detecção de falhas tal que a *H-norm* da função de matriz de transferência da perturbação fosse minimizada (para a detecção das falhas). A solução encontrada foi propor uma forma de desigualdades matriciais lineares, onde utilizaram técnicas de espaço-estado, bem como, evidenciaram o problema usando técnicas de fatoração da matriz. Um exemplo numérico ilustrou a eficiência da detecção de falhas e filtro de isolamento.

Em 2013, Youssef et al. [14] realizaram uma pesquisa com um sensor de detecção e isolamento de falhas (FDI) e estudo das evidências no controle tolerante de falhas (FTC) de uma fase (*PWM - Pulse Width Modulation*) com retificador para aplicação na tração ferroviária elétrica. Consideraram para este estudo dados de frequentes falhas sensoriais e falhas na tensão CC. Os resultados do estudo experimental mostraram a efetividade dos métodos de detecção de falhas FDI e FTC e com bom desempenho de retificação da falha após a reconfiguração.

Em 2010, Cho et al. [15] propuseram o uso de Redes Neurais dinâmicas na detecção e no isolamento de falhas em processos industriais. A metodologia proposta consistiu em utilizar dois modelos neurais distintos: um para simular o

comportamento normal do sistema, e outro para as diversas condições de falha. Os resultados obtidos neste trabalho demonstraram a viabilidade de utilização da metodologia proposta na detecção e no isolamento de falhas em motores de indução.

Em 2008, Pierri et al. [16] propuseram um esquema para diagnóstico de falhas do sensor nos reatores químicos em batelada. O esquema foi baseado em dois bancos de dados para a finalidade de gerar um conjunto residual sensível da ocorrência das falhas. Como resultado, as estimativas fornecidas pelos dados e pelas medidas do sensor foram processadas para prover informações sobre o sensor defeituoso, bem como as medidas de sensores sem defeito. A fim de testar a eficácia da abordagem proposta, um estudo de caso de simulação foi desenvolvido.

Em 2014, Vanini et al. [17] desenvolveram um esquema de isolamento e detecção de falhas para o motor a jato de uma aeronave. O sistema FDI proposto baseia-se no modelo de abordagem múltipla e utiliza redes neurais dinâmicas (DNNs) para alcançar este objetivo. Para este fim, vários DNNs foram construídos para aprender a dinâmica não linear do motor a jato de aeronaves. Cada DNN corresponde a um modo de funcionamento específico do motor em condição de funcionamento normal ou em sua condição de falha. Os resultados da simulação demonstram e ilustram a eficácia da estratégia proposta baseada na dinâmica da rede neural.

Em 2014, Kamal et al. [18] pesquisaram o uso da função de base radial no modo independente como o modelo de sistema de detecção de falhas. Verificou-se que o resíduo é sensível à falha. As redes neurais têm sido utilizadas com sucesso para modelar sistemas dinâmicos não lineares, no entanto, quando um modelo de rede neural estático é usado para a detecção de falha do sistema e o erro de previsão do modelo é utilizado como o resíduo, o mesmo é insensível à falha se a rede neural usada se encontra no modo dependente.

Como pode ser observado na bibliografia revisada, as técnicas de Inteligência Artificial vêm sendo bastante empregadas na área de Monitoração, Diagnóstico e Detecção de Falhas com o propósito de tornar os processos mais eficazes.

3 PLANTA EXPERIMENTAL PARA MONITORAÇÃO E DIAGNÓSTICO DE FALHAS

O desenvolvimento da planta experimental para monitoração e diagnóstico de falhas, foi inspirado em um reator nuclear do tipo PWR (*Pressurized Water Reactor*), reator a água pressurizada, pelo fato de operar com água sob alta pressão.

Esse reator nuclear representa a maioria das usinas de energia nuclear existentes no mundo. Trata-se de um reator composto basicamente por três circuitos, sendo eles: um vaso de pressão (localizado no circuito primário), um gerador de vapor (circuito secundário) e um circuito terciário que permite o resfriamento no circuito secundário. Pode-se observar a representação esquemática desse funcionamento na Figura 2.

Figura 2 - Representação esquemática do funcionamento do Reator tipo PWR [19]

Fonte: U.S. NRC (United States Nuclear Regulatory Commission), 2018.

O funcionamento de um reator PWR baseia-se no aquecimento de água no interior do vaso de pressão, através do elemento de combustível (material nuclear). O elemento combustível acomoda as varetas de combustível que contêm urânio, que é o combustível nuclear. A circulação dessa água é utilizada para gerar

o aquecimento de outra corrente de água que circula no interior do gerador de vapor. Esse vapor é responsável pela movimentação de uma turbina ligada a um gerador de energia elétrica.

É importante salientar que existe uma independência entre o circuito primário e o circuito secundário. O principal objetivo dessa independência é evitar que, caso ocorra algum dano em uma ou mais varetas no interior do vaso de pressão, o material radioativo passe para o circuito secundário. Existe um circuito terciário que é responsável pelo resfriamento da água resultante do vapor (condensação), logo após que a água sai da turbina. [20][21]

Para a construção dessa planta, não foi levado em conta a proporcionalidade mecânica entre os componentes e sistemas, a precisão dos fenômenos físicos nem a dinâmica exata do reator (Figura 3).

Figura 3 - Planta experimental desenvolvida para monitoração e diagnóstico de falhas

Fonte: autor da tese.

As dimensões da planta são: 1295 mm de largura x 620 mm de profundidade x 1410 mm de altura. O Tanque 1 (TQ-01), que pode ser visto na Figura 4, simboliza o vaso de pressão do reator PWR. O aquecimento da água do circuito primário é feito através de um aquecedor elétrico (AQ-01). A água escoa no circuito primário pela ação das bombas B-01 e B-02 que atuam em conjunto. O sistema de controle de potência da resistência elétrica ocorre por meio de um controlador que utiliza um circuito PWM (*Pulse Width Modulation*) [22].

Figura 4 - Tanque TQ-01

Fonte: autor da tese.

O Tanque 2 (TQ-02) simboliza o gerador de vapor do reator. Nesse tanque ocorre a troca de calor da água do circuito primário para o secundário (Figura 5).

Figura 5 - Tanque TQ-02

Fonte: autor da tese.

Dando continuidade na analogia da planta com o reator, o circuito secundário é representado pelo escoamento da água no tanque TQ-03, através da ação da bomba B-03. O resfriamento da água do circuito primário ocorre através da circulação de água no tanque TQ-03 (Figura 6).

O resfriamento do fluido contido no interior do tanque TQ-03 ocorre por meio de um ciclo de refrigeração e pode ser observado através da Figura 6.

Figura 6 - Tanque TQ-03

Fonte: autor da tese.

A planta experimental possui instrumentação para medição das variáveis de pressão, nível, temperatura e vazão, incluindo a indicação de nível máximo e mínimo nos tanques 1 e 2. No tanque TQ-01 se encontram instalados quatro sensores de temperatura, são eles: TE-01, TE-02, TE-03 e TE-04 (Figura 07) e um sensor pressão PT-01 localizado atrás do tanque TQ-01 (Figura 07). A medição da pressão no interior do tanque TQ-01, ocorre por meio de um tubo conectado a conexão instalada na parte superior do tanque TQ-01. Essa medição de pressão é utilizada para informação de nível.

Para garantir a condição de operação entre os níveis máximo e mínimo, existem chaves de nível que disponibilizam sinal digital para o dispositivo de controle. São elas: LSL-01 e LSH-01, como pode ser observado na Figura 7.

Figura 7 - Instrumentação do tanque TQ-01

Fonte: autor da tese.

No tanque TQ-02 se encontra instalado o sensor de temperatura TE-05. Para garantir a condição de operação entre os níveis máximo e mínimo, existem duas chaves de nível que disponibilizam sinal digital para o dispositivo de controle. São elas: LSL-02 e LSH-02 (Figura 8).

Figura 8 - Instrumentação do tanque TQ-02

Fonte: autor da tese.

A medição da temperatura do fluido do tanque TQ-03 é disponibilizada por meio do sensor de temperatura TE-06. Esse sensor pode ser observado na Figura 9.

Figura 9 - Instrumentação do tanque TQ-03

Fonte: autor da tese.

Para a medição da variável de vazão no circuito primário, existe o medidor de vazão FT-01 que se encontra instalado entre a saída da bomba B-01 e a entrada do tanque TQ-02. No circuito secundário, existe o medidor de vazão FT-02 que se encontra instalado entre a saída do tanque TQ-02 e a entrada do tanque TQ-03 (Figura 10).

Figura 10 - Sensores de vazão FT-01 e FT02

Fonte: autor da tese.

A planta possui um conjunto de válvulas XV-01, XV-02 e XV-03 que foram instaladas para possibilitar a inserção de falhas mecânicas no sistema. Essas válvulas disponibilizam a abertura e fechamento digital e podem ser observadas através da Figura 11.

Figura 11- Válvulas para geração de falhas mecânicas

Fonte: autor da tese.

Este conjunto de válvulas foi utilizado em testes preliminares, porém, devido ao escoamento de água ocorrer em um período de tempo muito curto (da ordem de 5 minutos), os estudos foram redirecionados para análise de falhas nos sensores de temperatura, vazão e pressão.

Para representação do circuito, é possível observar o fluxograma de engenharia com todo detalhamento do processo através da Figura 12.

Figura 12 - Fluxograma de engenharia da Planta Experimental

Fonte: autor da tese.

Para geração das falhas elétricas, foi desenvolvido um módulo com chaves do tipo On/Off que permitem cortar o sinal dos sensores de temperatura, vazão e pressão presentes na planta, conforme pode ser observado na Figura 13 a seguir.

Figura 13 - Módulo para geração de falhas elétricas

Fonte: autor da tese.

O módulo para geração das falhas se localiza fisicamente ao lado esquerdo da planta, próximo ao dispositivo de controle microprocessado. Para o acionamento das falhas, basta comutar a chave referente ao sensor desejado para que o sinal seja interrompido. Desse modo o sinal do sensor que se encontra conectado na entrada do dispositivo de controle microprocessado é interrompido.

É isso o que ocorre quando existe um rompimento do fio dos sensores em processos desse tipo. Esse tipo de falha também ocorre quando um sensor é danificado e o sinal de seu circuito eletrônico interno é interrompido.

É possível a geração das falhas nos sensores de temperatura TE-01, TE-02, TE-03, TE-04, TE-05 e TE-06. Para a vazão, nos sensores FT-01 e FT-02 e para a variável de pressão no sensor PT-01 (Figura 13).

Durante o desenvolvimento e utilização da planta experimental, foram realizados testes de sensores e atuadores de diferentes fabricantes e tecnologias. Observou-se que os testes de componentes oriundos de fabricantes distintos, não modificou ou influenciou nos resultados das aquisições de dados e atuação sobre o processo. O critério de seleção dos componentes da planta, privilegiou

componentes de empresas que investem em desenvolvimento e pesquisa para alta tecnologia de acordo com padrões internacionais.

Na Tabela 2, tem-se o detalhamento técnico geral dos sensores e atuadores da planta, com os seus respectivos Tags, funções, características técnicas e faixa operacional. Para esse detalhamento técnico, foram consideradas características técnicas que atendem a todos os experimentos realizados na planta.

Tabela 2 - Sensores e atuadores da Planta Experimental (Tag / Func. / Caract. Téc. / Faixa Oper.)

TAG	Função	Características Técnicas / Faixa Operacional
LSH-01	Chave de Nível Alto	Sensor capacitivo M18 24 Vcc
LSL-01	Chave de Nível Baixo	Sensor capacitivo M18 24 Vcc
LSH-02	Chave de Nível Alto	Sensor capacitivo M18 24 Vcc
LSL-02	Chave de Nível Baixo	Sensor capacitivo M18 24 Vcc
TE-01	Sensor de Temperatura 01	Termopar Tipo K - 0 a 100°C (4 a 20 mA)
TE-02	Sensor de Temperatura 02	Termopar Tipo K - 0 a 100°C (4 a 20 mA)
TE-03	Sensor de Temperatura 03	Termopar Tipo K - 0 a 100°C (4 a 20 mA)
TE-04	Sensor de Temperatura 04	Termopar Tipo K - 0 a 100°C (4 a 20 mA)
TE-05	Sensor de Temperatura 05	Pt100 - 0 a 100°C (4 a 20 mA)
TE-06	Sensor de Temperatura 06	Termopar Tipo K - 0 a 100°C (4 a 20 mA)
AQ-01	Resistência 01	220 VAC, máx.10A
CJ-01	Controlador de Potência	220 VAC, máx. 20A - 0 a 100% (0 a 10 Vcc)
B-01	Bomba 01	30 Vcc, máx. 10A - 0 a 100% (0 a 10 Vcc)
B-02	Bomba 02	30 Vcc, máx. 10A - 0 a 100% (0 a 10 Vcc)
B-03	Bomba 03	30 Vcc, máx. 10A - 0 a 100% (0 a 10 Vcc)
XV-01	Válvula 01	24 Vcc / 2A
XV-02	Válvula 02	24 Vcc / 2A
XV-03	Válvula 03	24 Vcc / 2A
FT-01	Sensor de Vazão 01	0 a 5 l/min (4 a 20 mA / 1 a 5Vcc)
FT-02	Sensor de Vazão 02	0 a 5 l/min (4 a 20 mA / 1 a 5 Vcc)
PT-01	Sensor de Pressão 01	-100 a 80 kPa - 0 a 100% (4 a 20 mA / 1 a 5 Vcc)

Fonte: autor da tese.

A simbologia apresentada no fluxograma de engenharia (Figura 12) com o detalhamento dos principais componentes na Tabela 2, seguem a normalização ANSI/ISA-S5.1 [23]

3.1 Sistema para Aquisição de Dados

Inicialmente os dados são coletados através de um dispositivo de controle microprocessado, que nesse trabalho foi um controlador lógico programável, como pode ser observado na Figura 14. Durante o desenvolvimento e utilização da planta para testes e aquisições de dados, foram utilizados diversos fabricantes de controlador lógico programável. Independente da alternância de fabricante, não houve influência na aquisição de dados dos resultados obtidos. A configuração mínima do número de pontos de entradas e saídas para atender a aplicação da planta foi de: 7 entradas digitais, 3 saídas digitais, 9 entradas analógicas e 4 saídas analógicas.

A comunicação para aquisição dos dados ocorre através da conectividade e interação entre os seguintes *softwares*: *Software* Supervisório SCADA (*Supervisory Control and Data Acquisition*) [25][26] e o *software* Matlab do fabricante MathWorks [24].

Figura 14 - Controlador Lógico Programável (CLP)

Fonte: autor da tese.

Os dados são obtidos por meio da comunicação entre o dispositivo de controle microprocessado e o *software* supervisório. A informação é enviada e/ou recebida pelo *software* supervisório SCADA, *Software* para Supervisão, Controle e Aquisição de Dados ou apenas *Software* Supervisório [25][26].

Foi desenvolvida uma interface que permite a visualização e atuação sobre o processo. Para melhor compreensão do funcionamento de todo processo, os *displays* responsáveis em informar os valores de todos os sensores da planta experimental, foram posicionados próximos aos respectivos instrumentos de

leitura, juntamente com seu Tag de indicação. Para os atuadores, foram disponibilizados controles deslizantes através de *sliders* que permitem a alteração dos valores em tempo real. A faixa operacional de cada sensor e/ou atuador foi mantida nessa interface, seguindo os dados da Tabela 2.

O posicionamento físico dos *displays* e *sliders* seguiram a mesma lógica do posicionamento do fluxograma de engenharia. Desse modo, facilita-se a interpretação do fluxograma em comparação ao *software* supervisório (SCADA) e em comparação ao posicionamento físico de todos os componentes existentes na planta experimental (Figura 15).

O *software* supervisório conecta-se diretamente com o dispositivo de controle microprocessado através de interface de comunicação específica, disponibilizando assim, uma interface em tempo real com o processo.

Figura 15 - Tela principal do software supervisório (SCADA)

Fonte: autor da tese.

Inicialmente os dados foram armazenados na base de dados do *software* supervisório (SCADA). Por meio dessa base de dados foi possível realizar a monitoração do sistema utilizando o *software* Matlab. Posteriormente foi implementado o padrão de comunicação OPC (*Open Platform Communications*) [27] para monitoração da planta em tempo real.

4 FUNDAMENTOS TEÓRICOS

A planta experimental foi desenvolvida para a monitoração e diagnóstico de falhas utilizando inteligência artificial.

Dentro do campo da ciência computacional, foi aplicada inteligência computacional, atualmente também chamada de inteligência artificial. Dentre as técnicas de inteligência artificial existentes, foram aplicadas nesse trabalho: Redes Neurais Artificiais e GMDH (*Group Method of Data Handling*). Ambas serão descritas a seguir.

4.1 Redes Neurais Artificiais

Os avanços em neurofisiologia têm desvendado vários mecanismos sobre o fluxo e o processamento de informações que ocorrem no cérebro humano. Alguns destes mecanismos foram modelados matematicamente permitindo a elaboração de algoritmos computacionais que simulam, ainda que de modo simplificado, a mais básica das estruturas cerebrais: o neurônio.

A capacidade de implementar computacionalmente versões simplificadas de neurônios biológicos deu origem a uma subespecialidade da inteligência artificial, conhecida como Redes Neurais Artificiais (RNAs), que podem ser definidas como sistemas paralelos compostos por unidades de processamento simples, dispostas em camadas e altamente interligadas, inspiradas no cérebro humano [28] [29].

O aprendizado de uma RNA é realizado a partir de um algoritmo, conhecido como algoritmo de aprendizagem, onde os pesos sinápticos são atualizados com o propósito de se alcançar o objetivo desejado. Dentre as principais características das RNAs, destacam-se:

- Aprendizado: a rede é treinada a partir de exemplos;

- Não-linearidade: um neurônio artificial pode ser linear ou não linear. Esta é uma propriedade importante, pois existe um grande número de aplicações que apresentam um comportamento não linear;
- Capacidade de Adaptação: a RNA possui uma capacidade de generalização do conhecimento adquirido a partir da existência de informações (dados) completas ou imprecisas;
- Tolerância a Falhas: uma RNA apresenta como atributo fundamental sua tolerância a falhas. Esta propriedade está relacionada ao processamento paralelo e distribuído da rede, a exemplo do que ocorre no cérebro humano;
- Imunidade a Ruídos: em algumas aplicações existe a possibilidade dos dados de entrada apresentarem ruídos, de modo que uma RNA consegue separar o ruído da informação relevante, sendo utilizada até mesmo como filtro de dados em algumas aplicações.

As formas em que os neurônios das RNAs estão organizados estão intimamente ligadas ao algoritmo de aprendizado utilizado no treinamento das redes. Geralmente, podemos identificar três tipos de arquiteturas de RNAs [28]:

- Redes com propagação para frente de uma camada: são compostas por uma camada de entrada e outra de saída, como mostra a Figura 16;
- Redes com propagação para frente de múltiplas camadas: são compostas por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, como mostra a Figura 17;
- Redes Recorrentes: contêm realimentação das saídas para as entradas, sendo suas saídas determinadas pelas entradas atuais e pelas saídas anteriores, como pode ser visto na Figura 18.

Figura 16 - Rede com propagação para frente de uma camada

Fonte: autor da tese.

O principal objetivo do treinamento de uma RNA é fazer com que a aplicação de um conjunto de entradas produza um conjunto de saídas desejadas, ou no mínimo, um conjunto de saídas consistentes. Cada conjunto de entrada ou saída pode ser descrito por um vetor.

Figura 17 - Redes do tipo MLP (múltiplas camadas com propagação para frente)

Fonte: autor da tese.

Figura 18 - Redes recorrentes

Fonte: autor da tese.

O treinamento é realizado pela aplicação sequencial dos vetores de entradas, enquanto os pesos da rede são ajustados de acordo com um procedimento de treinamento pré-determinado.

Durante o treinamento, os pesos da rede convergem gradualmente para determinados valores, de tal forma que a aplicação dos vetores de entrada produzam as saídas necessárias.

Os procedimentos de treinamento das RNAs podem ser classificados em duas classes: supervisionado e não supervisionado.

O treinamento supervisionado necessita de um vetor de entrada e um vetor de saída, conhecido como vetor alvo. Esses dois vetores são então utilizados para o treinamento da RNA.

O procedimento do treinamento funciona da seguinte maneira: o vetor de entrada é aplicado, a saída de rede é calculada e comparada com o correspondente vetor alvo.

O erro encontrado é então realimentado através da rede e os pesos são atualizados de acordo com um algoritmo determinado a fim de minimizar este erro.

Este processo de treinamento é repetido até que o erro para os vetores de treinamento alcance valores pré-determinados.

O treinamento não supervisionado, por sua vez, não requer vetor alvo para as saídas e, obviamente, não faz comparações para determinar a resposta ideal. O conjunto de treinamento modifica os pesos da rede de forma a produzir saídas que sejam consistentes.

O processo de treinamento extrai as propriedades estatísticas do conjunto de treinamento e agrupa os vetores similares em classes, onde a aplicação de um vetor de uma determinada classe à entrada da rede produzirá um vetor de saída específico.

4.1.1 Redes Neurais do tipo Multilayer Perceptron (MLP)

As redes do tipo MLP são redes de multicamadas, formadas por uma camada de entrada, uma ou várias camadas escondidas (ocultas), e uma camada de saída. Devido ao uso de uma ou mais camadas intermediárias, pode-se trabalhar com dados que não são linearmente separáveis [28].

A Figura 19 mostra a arquitetura de uma rede neural do tipo MLP, composta por uma unidade de entrada, duas camadas ocultas e uma camada de saída.

Figura 19 - Arquitetura de uma rede neural do tipo MLP

Fonte: autor da tese.

A escolha de estrutura deste tipo de rede consiste em estipular o número de neurônios em cada camada e as funções de ativação que serão utilizadas para cada uma das camadas.

O número de neurônios da camada de entrada deve ser adequado ao vetor de entrada que se pretende utilizar. Da mesma forma, o número de neurônios na camada de saída deve ser adequado à resposta desejada para o problema.

O número de neurônios da camada oculta é determinado de forma empírica, através da observação do erro da rede quando é aplicado o conjunto de dados de treinamento.

Uma forma prática consiste em iniciar os testes com um número pequeno de neurônios, aumentando-o a cada teste. No processo de aprendizado, em geral utiliza-se a técnica do gradiente descendente, através do algoritmo de retropropagação, que será explicado no próximo tópico.

4.1.2 Algoritmo de Retropropagação

O algoritmo escolhido para o treinamento das Redes Neurais neste trabalho foi o de retropropagação. Este algoritmo foi escolhido por apresentar resultados satisfatórios para a aplicação proposta.

O algoritmo de retropropagação é um algoritmo supervisionado que utiliza pares (entrada/saída desejada) para, por meio de um mecanismo de correção, ajustar os pesos da rede.

O treinamento ocorre em duas fases distintas conhecidas como “*forward*” e “*backward*”. Na fase *forward*, a rede é utilizada para definir a saída da rede para um dado padrão de entrada, e na fase *backward*, a diferença entre a saída desejada e a saída fornecida é utilizada pela rede para atualizar os pesos de suas conexões [28].

A implantação computacional do algoritmo de retropropagação apresenta os seguintes passos:

Passo 1: Inicialização de todos os pesos e parâmetros;

Passo 2: Fase *forward*, consiste em:

- Calcular todas as entradas e saídas para todas as camadas da rede;
- Calcular o erro de saída da rede.

Passo 3: Fase *backward*, consiste em:

- Efetuar o cálculo das atualizações dos pesos entre as camadas da rede, iniciando a partir da última camada, até chegar à camada de entrada.

O algoritmo de retropropagação consiste na utilização dos pesos, considerando a propagação do erro da saída da rede para a sua entrada. Este algoritmo é também conhecido como regra delta generalizada.

Embora o erro total E seja definido pela soma dos erros dos neurônios de saída para todos os padrões, será considerado sem perda de generalidade, que a minimização do erro para cada padrão individualmente levará à minimização do erro total para todos os padrões. Portanto, o erro passa a ser definido conforme a equação (1) [28] [29].

$$E(w) = \frac{1}{2} \times \sum_{k=1}^k (Yd(k) - Y(k))^2 \quad (1)$$

Onde E , representa a medida do erro cometido pela rede para cada padrão individualmente, ou seja, o quanto as saídas geradas pela rede $Y(k)$ diferem das saídas desejadas $Yd(k)$, sendo k o número de unidades de saída da rede.

Como na regra delta a variação dos pesos é definida de acordo com o gradiente descendente, partindo-se da equação (2), é calculada matematicamente a equação (3) para a regra delta generalizada:

$$W(t+1) = W(t) - \eta \times \frac{\partial E}{\partial W} \quad (2)$$

$$W(t+1) = W(t) - \eta \times \delta_j \times X_i \quad (3)$$

Para um neurônio de saída, a variável δ_j (erro) é calculada conforme a equação (4):

$$\delta_j = (Yd_j - Y_j) \times f'(u_j) \quad (4)$$

$$u_j = \sum_{i=1}^m x_i \cdot w_{ij}$$

Para os demais neurônios, diferentes dos de saída, a variável δ_j (erro) é calculada conforme a equação (5):

$$\delta_j = f'(u_j) \cdot \sum_l \delta_l \cdot W_{jl} \quad (5)$$

Onde:

$W(t+1)$: peso atualizado / $W(t)$: peso antigo

$f'(\)$: a derivada da função de ativação do neurônio

Y_{dj} : saída desejada pela rede / Y_j : saída fornecida pela rede

$\frac{\partial E}{\partial W}$: gradiente

η : taxa de aprendizado

x_i : entrada do neurônio

O termo δj corresponde à derivada da função de erro com relação aos pesos, sendo responsável pela propagação do erro da saída da rede para as suas camadas intermediárias, através de um cálculo recursivo.

4.2 GMDH (*Group Method of Data Handling*)

O método GMDH (*Group Method of Data Handling*) é composto por um algoritmo proposto por Ivakhnenko. Consiste em um método algébrico para estimar estados de um sistema, saídas de controladores e funções de atuadores [30].

A metodologia pode ser considerada como um algoritmo auto organizável de propagação indutiva para a solução de problemas práticos mais complexos, possibilitando a obtenção de um modelo matemático do processo a partir de observações de amostras de dados, que será utilizado na identificação e no reconhecimento de padrões, ou até mesmo para descrever o próprio processo.

O método GMDH soluciona o problema multidimensional de otimização do modelo pelo procedimento de escolha e seleção de modelos escolhidos a partir de um conjunto de modelos candidatos de acordo com um critério dado. A maioria dos algoritmos GMDH usa funções de referência polinomiais.

Uma conexão genérica entre variáveis de entrada e de saída pode ser expressa pela série funcional de Volterra, discreta análoga do polinômio de Kolmogorov-Gabor [32]:

$$y = a + \sum_{i=1}^m b_i x_i + \sum_{i=1}^m \sum_{j=1}^m c_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m d_{ijk} x_i x_j x_k + \dots \quad (6)$$

Onde:

$\{x_1, x_2, x_3 \dots\} \rightarrow$ variáveis de entrada

$\{a, b, c, \dots\} \rightarrow$ coeficientes do polinômio

As componentes da matriz de entrada podem ser variáveis independentes, formas funcionais ou termos de diferenças finitas, além disso, podem-se utilizar outras funções de referência não lineares. O método permite ainda, encontrar simultaneamente a estrutura do modelo e a dependência da saída do sistema modelado em função dos valores de entrada mais significativos do sistema.

A teoria GMDH soluciona problemas em várias áreas dentre as quais se podem destacar [32]:

- estimativa de processos e eventos a curto e longo prazo;

- aproximação de processos multivariados;
- "clusterização" de amostras de dados;
- reconhecimento de padrões no caso de variáveis contínuas e discretas;
- diagnóstico através de algoritmos probabilísticos de escolha e seleção;
- suporte na decisão após um cenário de regras do tipo "se-então".

Aksenova e Yurachkovsky [31] obtiveram as bases teóricas da efetividade do GMDH como método adequado e robusto de construção de modelos para estimativa. A modelagem auto-organizável é baseada em redes de aprendizado estatísticas, que capturam relações complexas não lineares em uma forma de execução rápida e compacta.

Essas redes subdividem o problema em partes menores de fácil manuseio e aplicam técnicas de regressão avançadas para resolver cada um desses problemas simples.

4.2.1 Descrição da metodologia GMDH

Em geral, os dados disponíveis são as variáveis de entrada e de saída de um sistema, representadas pela matriz de variáveis de entrada $X = (x_{ij})$, e pelo vetor da variável de saída $Y = (y_i)$, $i = 1, 2, \dots, n$ e $j = 1, 2, \dots, m$ onde n é o número total de observações e m é o número total de variáveis.

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & \dots & x_{1m} \\ x_{21} & x_{22} & \dots & \dots & x_{2m} \\ \dots & \dots & \dots & x_{ij} & \dots \\ \dots & \dots & \dots & \dots & \dots \\ x_{n1} & x_{n2} & \dots & \dots & x_{nm} \end{bmatrix} \quad Y = \begin{bmatrix} y_1 \\ y_2 \\ \dots \\ y_i \\ \dots \\ y_n \end{bmatrix} \quad (7)$$

O algoritmo GMDH é executado de acordo com os seguintes passos:

1º Passo) O primeiro passo consiste em construir um novo conjunto de variáveis Z . Para tanto, inicialmente deve-se dividir as observações em dois subconjuntos

distintos. O primeiro subconjunto será utilizado para ajuste ($i = 1$ até nt) e o segundo para verificação ($i = nt+1$ até n).

$$X = \begin{bmatrix} X_{11} & X_{12} & \cdots & \cdots & X_{1m} \\ X_{21} & X_{22} & \cdots & \cdots & X_{2m} \\ \cdots & \cdots & \cdots & X_{ij} & \cdots \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ X_{nt1} & X_{nt2} & \cdots & X_{ntj} & \cdots \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ X_{n1} & X_{n2} & \cdots & \cdots & X_{nm} \end{bmatrix} \quad Y = \begin{bmatrix} y_1 \\ y_2 \\ \cdots \\ y_{nt} \\ \cdots \\ y_n \end{bmatrix} \quad (8)$$

A seguir tomam-se as variáveis independentes do subconjunto de ajuste, duas de cada vez para todas as combinações possíveis e calculam-se os coeficientes da seguinte regressão polinomial, onde p e q são as colunas da matriz X :

$$y_i = a_{pq} + b_{pq} x_{ip} + c_{pq} x_{iq} + d_{pq} x_{ip}^2 + e_{pq} x_{iq}^2 + f_{pq} x_{ip} x_{iq} \quad \begin{cases} p = 1, 2 \dots m, p \neq q, \\ q = 1, 2 \dots m, q > p, \\ i = 1, 2 \dots nt \end{cases} \quad (9)$$

Para cada combinação das variáveis independentes (colunas de X) há um conjunto de coeficientes da regressão, resultando na matriz de coeficientes C . Como se tem $m(m-1)/2$ diferentes combinações das variáveis de entrada, resultam $m(m-1)/2$ linhas da matriz de coeficientes C .

$$C = (a_{pq}, b_{pq}, c_{pq}, d_{pq}, e_{pq}, f_{pq}) \quad \begin{cases} p = 1, 2 \dots m, p \neq q, \\ q = 1, 2 \dots m, p > q \end{cases} \quad (10)$$

Para cada conjunto de coeficientes C_{pq} , avalia-se o polinômio para todos os n pontos de dados para calcular uma nova estimativa de y , chamada z_{pq} :

$$z_{i,pq} = a_{pq} + b_{pq} x_{ip} + c_{pq} x_{iq} + d_{pq} x_{ip}^2 + e_{pq} x_{iq}^2 + f_{pq} x_{ip} x_{iq} \quad (11)$$

Esses novos valores são armazenados na primeira coluna de uma matriz Z . Repete-se esta avaliação para todos os conjuntos de coeficientes e para todos os n dados, gerando uma nova matriz Z chamada nova geração de variáveis.

$$Z = (z_{ij}) \quad \begin{cases} i = 1, 2, \dots, n, \\ j = 1, 2, \dots, m(m-1)/2 \end{cases} \quad \text{onde cada } j \text{ corresponde a um par } p, q \quad (12)$$

$$Z = \begin{bmatrix} z_{11} & z_{12} & \dots & \dots & z_{1, m(m-1)/2} \\ z_{21} & z_{22} & \dots & \dots & \dots \\ \dots & \dots & \dots & z_{ij} & \dots \\ \dots & \dots & \dots & \dots & \dots \\ z_{n1} & z_{n2} & \dots & \dots & z_{n, m(m-1)/2} \end{bmatrix} \quad (13)$$

Podem-se interpretar estas variáveis (matriz Z) como novas variáveis que têm melhor poder de estimativa do que aquelas da geração original (matriz X).

2º Passo) O próximo passo é comparar cada coluna de Z com a variável dependente Y. Isto é, para cada coluna j de Z calcula-se o desvio médio quadrático r_j para i variando de $nt+1$ até n, ou seja, utilizando o subconjunto de verificação:

$$r_j^2 = \frac{\sum_{i=nt+1}^n (y_i - z_{ij})^2}{\sum_{i=nt+1}^n y_i^2} \quad j=1, 2, \dots, m(m-1)/2 \quad (14)$$

Ordena-se as colunas de Z em ordem crescente de r_j e então seleciona-se aquelas colunas de Z que satisfaçam um critério selecionado anteriormente (por exemplo $r_j < R$, onde R é um valor residual mínimo). Pode-se notar que o número de variáveis salvas, digamos m_1 , pode ser igual, menor ou maior do que o número original m.

3º Passo) Esta nova matriz Z irá substituir a matriz original X. Estas novas variáveis são combinadas exatamente como se fez anteriormente. Ou seja, calculam-se todas as equações de regressão quadráticas de y em função destas novas variáveis (duas a duas).

Isso irá fornecer um novo conjunto de $m_1(m_1-1)/2$ equações de regressão para estimar y a partir das novas variáveis. Agora são selecionadas as melhores das novas estimativas, gerando novas variáveis independentes a partir das equações selecionadas para substituir as anteriores, e combinar todos os pares destas novas variáveis.

4º Passo) No passo anterior encontra-se o menor r_j e chama-se de RMIN. Se o valor de RMIN é menor que o valor de RMIN da geração prévia, repete-se os passos 1, 2 e 3. Se o valor de RMIN é maior que o valor precedente, assume-se que a "curva RMIN" atingiu seu mínimo, o processo é interrompido e usam-se os resultados da geração anterior, como pode ser visto na Figura 20.

Figura 20 - Curva RMIN calculado a cada geração

Fonte: GONÇALVES, I. M. P., 2006.

A primeira coluna da matriz Z conterá os valores de y_i do polinômio de Ivakhnenko avaliados para os n pontos de dados originais. Em outras palavras, a primeira coluna de Z é a estimativa da variável dependente.

Para encontrar os coeficientes a , b_i , C_{ij} , $d_{ijk}, \dots$ no polinômio de Ivakhnenko, deve-se salvar todos os conjuntos de coeficientes de todas as gerações que foram computados a cada iteração e sistematicamente avaliar esta árvore de quadráticos até chegar em um polinômio de alta ordem nas variáveis originais $x_1, x_2, \dots, x_m$.

De um ponto de vista computacional, desde que se tenham todos os polinômios de regressão quadráticos armazenados no computador, é possível computar a estimativa da saída y a partir destes quadráticos.

Na Figura 21 tem-se uma ilustração mostrando que os valores estimados são propagados sucessivamente para gerações superiores do algoritmo, melhorando a cada estágio sucessivo. Cada estágio de aproximação z_{ipq} é formado

a partir de pares dos sinais de entrada (desta geração), e novos valores da variável estimada são propagados para a próxima geração.

A iteração continua até que o desvio médio quadrático entre os valores estimados e medidos para determinada variável de saída seja menor do que um valor desejado, ou quando um número máximo de gerações previamente definido seja atingido.

Figura 21 - Estrutura do modelo auto organizável GMDH com m entradas e k gerações

Fonte: GONÇALVES, I. M. P., 2006.

O que se tem é uma estimativa de y como uma forma quadrática de duas variáveis, as quais são por sua vez uma combinação quadrática de duas outras variáveis, e assim sucessivamente para todas as combinações possíveis.

Em outras palavras, se forem feitas as substituições algébricas necessárias, o polinômio resultante teria a forma mostrada na equação a seguir, conhecida como o polinômio de Ivakhnenko [30].

$$y = a + \sum_{i=1}^m b_i x_i + \sum_{i=1}^m \sum_{j=1}^m c_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m d_{ijk} x_i x_j x_k + \dots \quad (15)$$

5 METODOLOGIA

Inicialmente é realizada a aquisição dos dados para treinamento do GMDH e das Redes Neurais. Para isso, os sensores e atuadores da planta experimental enviam e recebem informações do sistema de controle microprocessado, que nesse caso foi utilizado um controlador lógico programável (CLP) instalado no painel elétrico da planta.

Após a aquisição dos dados ocorre o treinamento do GMDH e das Redes Neurais. Depois de finalizado o treinamento, inicia-se a etapa de monitoração do sistema para ambas as técnicas de inteligência artificial (GMDH e RNA).

Nos diagramas em bloco da Figura 22 e Figura 24 é possível verificar como ocorreu a etapa de treinamento e monitoração para ambas as técnicas de inteligência artificial. O CLP realiza a troca de informações com o processo e com o *software* supervisor SCADA, que troca informações com o *software* Matlab (Figura 23).

Figura 22 - Treinamento GMDH / Redes Neurais

Fonte: autor da tese.

Existem duas bases de dados, sendo que uma é gerada diretamente através do SCADA e outra é gerada através do *software* Matlab. Observa-se na Figura 23 a seguir a aquisição de dados típicos normalizados da planta.

Figura 23 - Aquisição de dados da planta (normalizados)

Fonte: autor da tese.

Após ser realizada a aquisição de dados, ocorre a monitoração do funcionamento da planta. Nesse caso, temos o *Digital Twin* da planta e assim que o processo entra em funcionamento, o sistema de monitoração é iniciado. Em tempo real, obtém-se uma nova aquisição de dados do funcionamento do processo e ocorre a comparação dos dados do funcionamento pelos quais o GMDH e a RNA foram treinados (Figura 24).

Figura 24 - Monitoração GMDH / Redes Neurais

Fonte: autor da tese.

Uma vez finalizada a monitoração, é possível realizar uma análise para o diagnóstico de possíveis falhas durante o funcionamento do processo comparando os valores calculados pelas Redes Neurais e GMHD com os valores lidos dos sensores.

5.1 Operação da Planta Experimental

Finalizado o projeto, após a realização de todos os testes da planta experimental foi possível a aquisição, monitoração, análise dos dados e o diagnóstico das falhas. Para iniciar operação da planta se faz necessário ajustar o nível de fluido e a temperatura no interior dos tanques.

As condições iniciais estabelecidas para o nível dos tanques foram: TQ-01 com 6 litros de fluido, TQ-02 com 2 litros e TQ-03 com 2 litros de fluido.

Para ocorrer a troca de calor entre os fluidos do circuito primário e secundário no tanque TQ-02, deve-se estabelecer as temperaturas iniciais no tanque TQ-01 (temperatura alta) e no tanque TQ-03 (temperatura baixa). Determinou-se experimentalmente que, para os valores iniciais de 40°C em TQ-01

e 3°C em TQ-03, é possível obter um transiente de aproximadamente 10 minutos, até atingir o regime de estado estacionário.

As condições de operação estabelecidas foram:

- Funcionamento normal de operação;
- Funcionamento com inserção de falhas simples;
- Funcionamento com inserção de falhas múltiplas.

O tempo estabelecido para o funcionamento do sistema foi de 40 minutos. As aquisições e monitoração dos dados também ocorreram durante esse tempo.

Uma vez definida a condição de operação da planta experimental, pode-se iniciar o seu funcionamento. Para isso, a temperatura no circuito primário deve estar em torno de 40°C. Esse valor pode ser conferido através do valor informado pelos sensores TE-01 a TE-04, instalados em TQ-01 (tanque da esquerda, Figura 24).

Em TQ-03, o valor de temperatura deve estar em torno de 3°C, nesse caso, a temperatura pode ser conferida através do sensor TE-06 (tanque localizado na direita da Figura 25).

Figura 25 - Software supervisorio (SCADA) desenvolvido para a Planta Experimental

Fonte: autor da tese.

Uma vez que as temperaturas se encontram ajustadas, devem ser ligadas as bombas B-01 e B-02 com valores de potência de 70% e 20%, respectivamente, e B-03 com potência de 100%. Desse modo, ocorre a circulação do fluido aquecido entre os tanques TQ-01 e TQ-02 (circuito primário) e a circulação do fluido resfriado em TQ-03 (circuito secundário).

Para o ajuste da potência das bombas B-01, B-02 e B-03, são utilizados os “*sliders*” referente a cada uma das bombas, através da interface gráfica especialmente desenvolvida.

Finalizado o ajuste da potência das bombas, observa-se que a vazão no circuito primário fica em torno de 3,0 l/min. No circuito secundário a vazão fica em torno de 2,7 l/min.

5.2 Monitoração da Planta Experimental

Antes de realizar a monitoração, foi desenvolvido um modelo do sistema usando redes neurais. Para comunicação do SCADA com o *software* Matlab, foi utilizada a ferramenta *Simulink*, disponível no *software* Matlab.

Na Figura 26 é possível observar a interface desenvolvida na ferramenta *Simulink*, para a monitoração da temperatura,

com a aplicação do modelo obtido utilizando RNA. O procedimento foi o mesmo para as demais variáveis.

Figura 26 - Interface desenvolvida no *Simulink* para a monitoração de TE-01

Fonte: autor da tese.

Para facilitar a análise e compreensão do sistema, foram mantidos os nomes dos TAGs utilizados no fluxograma de engenharia para as variáveis internas no *software*. Esse padrão seguiu para as variáveis no *software* Matlab, incluindo sua declaração na ferramenta do *Simulink*, bem como, para o *software* de supervisão de processo (SCADA).

Na Figura 27 é possível observar uma aplicação especialmente desenvolvida para aquisição das variáveis de temperatura TE-01, TE-02, TE-03, TE-04, TE-05 e TE-06.

Figura 27 - Interface desenvolvida no Simulink para a monitoração das temperaturas

Fonte: autor da tese.

Como exemplo de utilização das funções de Redes Neurais Artificiais, está demonstrado através da Figura 27 a captura e monitoração dos dados utilizando os modelos desenvolvidos de redes neurais para as variáveis de temperatura. Também foram realizadas as aquisições e posteriormente a monitoração das demais variáveis.

A mesma base de dados utilizada para o treinamento das Redes Neurais foi utilizada para o desenvolvimento dos cálculos polinomiais da metodologia GMDH. Foi feito um modelo (*Digital Twin*) da planta usando GMDH.

Foi desenvolvido um programa que permitiu a monitoração dos dados aplicando a metodologia GMDH utilizando o *software* Matlab .

6 RESULTADOS

Para análise dos dados, foram definidas condições de funcionamento da Planta Experimental. As condições foram definidas como regime normal de funcionamento e a condição de funcionamento com inserção de falhas (simples e múltiplas).

Através do regime normal de funcionamento torna-se possível a análise comportamental das variáveis, bem como a dinâmica de funcionamento do processo. Essa análise é fundamental, pois é a partir dela que se torna possível a comparação dos resultados quando são inseridas as falhas.

6.1 Monitoração em Regime Normal de Funcionamento (RNA)

Conforme já foi apresentado anteriormente, foram realizadas aquisições das variáveis de nível, pressão, temperatura, vazão, potência do aquecedor e velocidade do motor das bombas. Para análise dos dados em regime normal de funcionamento do sistema, foram utilizadas as seguintes variáveis: TE-01, TE-02, TE-03, TE-04, TE-05, TE-06, FT-01, FT-02, AQ-01, B-01, B-02 e B-03.

Como já detalhado anteriormente, foram treinadas redes neurais para cada uma das variáveis da planta.

Para o treinamento das redes neurais foram utilizados seguintes parâmetros: 01 camada de entrada, 01 camada oculta com 10 neurônios e uma camada de saída. Foram realizados treinamentos com mais de 10 neurônios, porém, não houve melhora no resultado. O algoritmo de treinamento foi o Levenberg-Marquardt. Os dados foram divididos em treinamento (70%), validação (15%) e teste (15%).

A seguir são mostrados os resultados do treinamento das redes neurais. Para as variáveis AQ-01, B-01 e B-03 não houve resultados, pois os valores resultantes das respectivas aquisições foram constantes (a rede não converge).

6.1.1 Resultado da Rede Neural para a Temperatura TE-01

Desempenho TE-01

É possível mensurar o desempenho do resultado do treinamento da rede neural por meio da função “*plotperform(tr)*” do *software* Matlab, conforme pode ser observado na Figura 28 demonstrada a seguir.

Figura 28 - Desempenho da RNA para a variável de temperatura TE-01

Fonte: autor da tese.

Pode-se observar na Figura 28 que no *epoch* (iteração) 32 foi obtido o melhor resultado do treinamento da rede neural para a temperatura TE-01, com o MSE (erro médio quadrático) de 0,0048232.

Também podemos observar que na análise são levados em conta o treinamento, validação e testes da rede.

Regressão Linear TE-01

Utilizando a função de “*plotregression*” do *software* Matlab, torna-se possível a análise do treinamento, validação, teste e um gráfico geral com os três conjuntos de dados, conforme pode ser observado na Figura 29.

Figura 29 - Regressão linear da RNA para a variável de temperatura TE-01

Fonte: autor da tese.

Como pode ser observado na Figura 29, o treinamento da rede possui $R=0,99967$, validação $R=0,99976$, teste $R=0,99962$ e a somatória de todos os dados com $R=0,99968$.

Monitoração da Temperatura TE-01

Para todos os casos, a monitoração ocorre considerando a comparação de dados entre o valor lido diretamente de cada sensor de temperatura e o valor estimado pela rede neural.

A seguir é apresentado o resultado da variável de TE-01 após análise durante 2400 segundos (Figura 30).

Figura 30 - Monitoração da temperatura TE-01

Fonte: autor da tese.

Observando a Figura 30, percebe-se que o sistema se encontra em regime de transiente e alcança o estado estacionário próximo a 1000 segundos de análise. Para esse caso, seguem os valores do desvio médio total e o valor desvio médio em regime normal de funcionamento, considerando apenas o estado estacionário:

- Desvio médio total: 0,33 °C;
- Desvio médio estado estacionário: 0,16 °C.

6.1.2 Resultado da Rede Neural para a Temperatura TE-02

Desempenho TE-02

É possível mensurar o desempenho do resultado do treinamento da rede neural por meio da função “*plotperform(tr)*” do *software* Matlab, conforme pode ser observado na Figura 31 demonstrada a seguir.

Figura 31 - Desempenho da RNA para a variável de temperatura TE-02

Fonte: autor da tese.

Pode-se observar no Figura 31 que no *epoch* 68 foi obtido o melhor resultado do treinamento da rede neural para a temperatura TE-02, com o MSE (erro médio quadrático) de 0,0045152.

Também podemos observar que na análise são levados em conta o treinamento, validação e testes da rede.

Regressão Linear TE-02

Utilizando a função de “*plotregression*” do *software* Matlab, torna-se possível a análise do treinamento, validação, teste e um gráfico geral com os três conjuntos de dados, conforme pode ser observado nos gráficos presentes na Figura 32 demonstrada a seguir.

Figura 32 - Regressão linear da RNA para a variável de temperatura TE-02

Fonte: autor da tese.

Como pode ser observado na Figura 32, o treinamento da rede possui $R=0,99965$, validação $R=0,99964$, teste $R=0,99962$ e a somatória de todos os dados com $R=0,99965$.

Monitoração da Temperatura TE-02

Para todos os casos, a monitoração ocorre considerando a comparação de dados entre o valor lido diretamente de cada sensor de temperatura e o valor estimado pela rede neural.

A seguir é apresentado o resultado da variável de TE-02 após análise durante 2400 segundos (Figura 33).

Figura 33 - Monitoração da temperatura TE-02

Fonte: autor da tese.

Observando a Figura 33, percebe-se que o sistema encontra-se em regime de transiente e alcança o estado estacionário próximo a 1000 segundos.

Para esse caso, seguem os valores do desvio médio total e o valor desvio médio em regime normal de funcionamento, considerando apenas o estado estacionário:

- Desvio médio total: 0,15 °C;
- Desvio médio estado estacionário: 0,12 °C.

6.1.3 Resultado da Rede Neural para a Temperatura TE-03

Desempenho TE-03

Antes da monitoração da variável TE-03 é possível mensurar o desempenho do resultado do treinamento da rede neural através da função “*plotperform(tr)*” do *software* Matlab, conforme pode ser observado na Figura 34 demonstrada a seguir.

Figura 34 - Desempenho da RNA para a variável de temperatura TE-03

Fonte: autor da tese.

Pode-se observar na Figura 34 que no *epoch* 10 foi obtido o melhor resultado do treinamento da rede neural para a temperatura TE-03, com o MSE (erro médio quadrático) de 0,0060331.

Também podemos observar que na análise são levados em conta o treinamento, validação e testes da rede.

Regressão Linear TE-03

Utilizando a função de “*plotregression*” do *software* Matlab, torna-se possível a análise do treinamento, validação, teste e um gráfico geral com os três conjuntos de dados, conforme pode ser observado nos gráficos da Figura 35 demonstrada a seguir.

Figura 35 - Regressão linear da RNA para a variável de temperatura TE-03

Fonte: autor da tese.

Como pode ser observado na Figura 35, o treinamento da rede possui $R=0,99951$, validação $R=0,9994$, teste $R=0,99944$ e a somatória de todos os dados com $R=0,99948$.

Monitoração da Temperatura TE-03

Para todos os casos, a monitoração ocorre considerando a comparação de dados entre o valor lido diretamente de cada sensor de temperatura e o valor estimado pela rede neural.

Na Figura 36 a seguir é apresentado o resultado da variável de TE-03 após análise durante 2400 segundos.

Figura 36 - Monitoração da temperatura TE-03

Fonte: autor da tese.

Observando a Figura 36, percebe-se que o sistema encontra-se em regime de transiente alcança o estado estacionário próximo a 1000 segundos de análise.

Para esse caso, seguem os valores do desvio médio total e o valor desvio médio em regime normal de funcionamento, considerando apenas o estado estacionário:

- Desvio médio total: 0,27 °C;
- Desvio médio estado estacionário: 0,23 °C.

6.1.4 Resultado da Rede Neural para a Temperatura TE-04

Desempenho TE-04

É possível mensurar o desempenho do resultado do treinamento da rede neural através da função “*plotperform(tr)*” do *software* Matlab, conforme pode ser observado na Figura 37 a seguir.

Figura 37 - Desempenho da RNA para a variável de temperatura TE-04

Fonte: autor da tese.

Pode-se observar na Figura 37 que no *epoch* 6 foi obtido o melhor resultado do treinamento da rede neural para a temperatura TE-04, com o MSE (erro médio quadrático) de 0,0081119.

Também podemos observar que na análise são levados em conta o treinamento, validação e testes da rede.

Regressão Linear TE-04

Utilizando a função de “*plotregression*” do *software* Matlab, torna-se possível a análise do treinamento, validação, teste e um gráfico geral com os três conjuntos de dados, conforme pode ser observado nos gráficos da Figura 38 demonstrada a seguir.

Figura 38 - Regressão linear da RNA para a variável de temperatura TE-04

Fonte: autor da tese.

Como pode ser observado na Figura 38, o treinamento da rede possui $R=0,99912$, validação $R=0,99927$, teste $R=0,99925$ e a somatória de todos os dados com $R=0,99916$.

Monitoração da Temperatura TE-04

Para todos os casos, a monitoração ocorre considerando a comparação de dados entre o valor lido diretamente de cada sensor de temperatura e o valor estimado pela rede neural.

A seguir é apresentado o resultado da variável de TE-04 após análise durante 2400 segundos (Figura 39).

Figura 39 - Monitoração da temperatura TE-04

Fonte: autor da tese.

Observando a Figura 39, percebe-se que o sistema se encontra em regime de transiente alcança o estado estacionário próximo a 1000 segundos de análise.

Para esse caso, seguem os valores do desvio médio total e o valor desvio médio em regime normal de funcionamento, considerando apenas o estado estacionário:

- Desvio médio total: 0,18 °C;
- Desvio médio estado estacionário: 0,14 °C.

6.1.5 Resultado da Rede Neural para a Temperatura TE-05

Desempenho TE-05

É possível mensurar o desempenho do resultado do treinamento da rede neural através da função “*plotperform(tr)*” do *software* Matlab, conforme pode ser observado na Figura 40 demonstrada a seguir.

Figura 40 - Desempenho da RNA para a variável de temperatura TE-05

Fonte: autor da tese.

Pode-se observar na Figura 40 que no *epoch* 20 foi obtido o melhor resultado do treinamento da rede neural para a temperatura TE-05, com o MSE (erro médio quadrático) de 0,0086886.

Também podemos observar que na análise são levados em conta o treinamento, validação e testes da rede.

Regressão Linear TE-05

Utilizando a função de “*plotregression*” do *software* Matlab, torna-se possível a análise do treinamento, validação, teste e um gráfico geral com os três conjuntos de dados, conforme pode ser observado nos gráficos da Figura 41.

Figura 41 - Regressão linear da RNA para a variável de temperatura TE-05

Fonte: autor da tese.

Como pode ser observado na Figura 41, o treinamento da rede possui $R=0,99499$, validação $R=0,99505$, teste $R=0,99423$ e a somatória de todos os dados com $R=0,99487$.

Monitoração da Temperatura TE-05

Para todos os casos, a monitoração ocorre considerando a comparação de dados entre o valor lido diretamente de cada sensor de temperatura e o valor estimado pela rede neural.

A seguir é apresentado o resultado da variável de TE-05 após análise durante 2400 segundos (Figura 42).

Figura 42 - Monitoração da temperatura TE-05

Fonte: autor da tese.

Observando a Figura 42, percebe-se que o sistema encontra-se em regime de transiente alcança o estado estacionário próximo a 600 segundos de análise.

Para esse caso, seguem os valores do desvio médio total e o valor desvio médio em regime normal de funcionamento, considerando apenas o estado estacionário:

- Desvio médio total: 0,25 °C;
- Desvio médio estado estacionário: 0,27 °C.

6.1.6 Resultado da Rede Neural para a Temperatura TE-06

Desempenho TE-06

É possível mensurar o desempenho do resultado do treinamento de cada rede neural através da função “*plotperform(tr)*” do *software* Matlab, conforme pode ser observado na Figura 43 demonstrada a seguir.

Figura 43 - Desempenho da RNA para a variável de temperatura TE-06

Fonte: autor da tese.

Pode-se observar no Figura 43 que no epoch 34 foi obtido o melhor resultado do treinamento da rede neural para a temperatura TE-06, com o MSE (erro médio quadrático) de 0,013328.

Também podemos observar que na análise são levados em conta o treinamento, validação e testes da rede.

Regressão Linear TE-06

Utilizando a função de “*plotregression*” do *software* Matlab, torna-se possível a análise do treinamento, validação, teste e um gráfico geral com os três conjuntos de dados, conforme podemos observar nos gráficos da Figura 44 demonstrada a seguir.

Figura 44 - Regressão linear da RNA para a variável de temperatura TE-06

Fonte: autor da tese.

Como pode ser observado na Figura 44, o treinamento da rede possui $R=0,99946$, validação $R=0,99938$, teste $R=0,99938$ e a somatória de todos os dados com $R=0,99943$.

Monitoração da Temperatura TE-06

Para todos os casos, a monitoração ocorre considerando a comparação de dados entre o valor lido diretamente de cada sensor de temperatura e o valor estimado pela rede neural.

Na Figura 45 a seguir é apresentado o resultado da variável de TE-06 após análise durante 2400 segundos.

Figura 45 - Monitoração da temperatura TE-06

Fonte: autor da tese.

Observando o Figura 45, percebe-se que o sistema encontra-se em regime de transiente alcança o estado estacionário próximo a 1000 segundos de análise.

Para esse caso, seguem os valores do desvio médio total e o valor desvio médio em regime normal de funcionamento, considerando apenas o estado estacionário:

- Desvio médio total: 0,43 °C;
- Desvio médio estado estacionário: 0,52 °C.

6.1.7 Análise dos Resultados dos Desvios Médios para as Temperaturas

Através da Tabela 3, pode-se observar os desvios médios calculados entre o valor lido e o valor estimado pela rede neural para todas as temperaturas em regime normal de funcionamento.

Tabela 3 - Resultado geral dos desvios médios das temperaturas (°C)

	Desvio TE-01 (°C)	Desvio TE-02 (°C)	Desvio TE-03 (°C)	Desvio TE-04 (°C)	Desvio TE-05 (°C)	Desvio TE-06 (°C)
Desvio Médio Total	0,33	0,15	0,27	0,18	0,25	0,43
Desvio Méd. (estacionário)	0,16	0,12	0,23	0,14	0,27	0,52

Fonte: autor da tese.

Na Tabela 4, pode-se observar os correspondentes desvios médios percentuais para cada uma das temperaturas.

Tabela 4 - Resultado geral dos desvios médios das temperaturas (%)

	Desvio TE-01 (%)	Desvio TE-02 (%)	Desvio TE-03 (%)	Desvio TE-04 (%)	Desvio TE-05 (%)	Desvio TE-06 (%)
Desvio Médio Total	1,14	0,53	0,95	0,64	0,95	1,93
Desvio Méd. (estacionário)	0,59	0,42	0,85	0,49	1,05	2,17

Fonte: autor da tese.

6.1.8 Resultado da Rede Neural para a Pressão PT-01

Desempenho PT-01

É possível mensurar o desempenho do resultado do treinamento de cada rede neural através da função “*plotperform(tr)*” do *software* Matlab, conforme pode ser observado na Figura 46 a seguir.

Figura 46 - Desempenho da RNA para a variável de pressão PT-01

Fonte: autor da tese.

Pode-se observar no Figura 46 que no *epoch* 36 foi obtido o melhor resultado do treinamento da rede neural para a pressão PT-01, com o MSE (erro médio quadrático) de 1,2376. Também podemos observar que na análise são levados em conta o treinamento, validação e testes da rede. Para este caso não é possível fazer a monitoração devido ao alto valor do erro quadrático médio (mse).

Regressão Linear PT-01

Utilizando a função de “*plotregression*” do *software* Matlab, torna-se possível a análise do treinamento, validação, teste e um gráfico geral com os três conjuntos de dados, conforme pode ser observado na Figura 47 demonstrada a seguir.

Figura 47 - Regressão linear da RNA para a variável de pressão PT-01

Fonte: autor da tese.

Como pode ser observado na Figura 47, o treinamento da rede possui $R=0,97689$, validação $R=0,97101$, teste $R=0,97231$ e a somatória de todos os dados com $R=0,97532$.

6.1.9 Resultado da Rede Neural para a Vazão FT-01

Desempenho FT-01

É possível mensurar o desempenho do resultado do treinamento de cada rede neural através da função “*plotperform(tr)*” do software Matlab (Figura 48).

Figura 48 - Desempenho da RNA para a variável de vazão FT-01

Fonte: autor da tese.

Pode-se observar no Figura 48 que no *epoch* 13 foi obtido o melhor resultado do treinamento da rede neural para a vazão FT-01, com o MSE (erro médio quadrático) de 0,002221. Também podemos observar que na análise são levados em conta o treinamento, validação e testes da rede. Para este caso, embora o desempenho do treinamento tenha sido satisfatório, não foi possível realizar a monitoração. Através dos gráficos de regressão linear (Figura 49), pode-se observar que os valores estimados não se ajustaram aos valores previstos.

Regressão Linear FT-01

Utilizando a função de “*plotregression*” do *software* Matlab, torna-se possível a análise do treinamento, validação, teste e um gráfico geral com os três conjuntos de dados, conforme pode ser observado na Figura 49.

Figura 49 - Regressão linear da RNA para a variável de vazão FT-01

Fonte: autor da tese.

Como pode ser observado na Figura 49, o treinamento da rede possui $R=0,29031$, validação $R=0,20845$, teste $R=0,25862$ e a somatória de todos os dados com $R=0,27266$.

6.1.10 Resultado da Rede Neural para a Vazão FT-02

Desempenho FT-02

É possível mensurar o desempenho do resultado do treinamento de cada rede neural através da função “*plotperform(tr)*” do software Matlab (Figura 50).

Figura 50 - Desempenho da RNA para a variável de vazão FT-02

Fonte: autor da tese.

Pode-se observar na Figura 50 que no *epoch* 19 foi obtido o melhor resultado do treinamento da rede neural para a vazão FT-02, com o MSE de 0,00049618. Para este caso, embora o desempenho do treinamento tenha sido satisfatório, não foi possível realizar a monitoração. Através dos gráficos de regressão linear (Figura 51), pode-se observar que a maior parte dos dados

concentram-se em uma região específica do gráfico, portanto, esse ajuste não representa a variação dos dados em sua totalidade.

Regressão Linear FT-02

Utilizando a função de “*plotregression*” do software Matlab, torna-se possível a análise do treinamento, validação, teste (Figura 51).

Figura 51 - Regressão linear da RNA para a variável de vazão FT-02

Fonte: autor da tese.

Como pode ser observado na Figura 51, o treinamento da rede possui $R=0,96367$, validação $R=0,96778$, teste $R=0,97005$ e a somatória de todos os dados com $R=0,96491$.

6.2 Monitoração do Funcionamento com Inserção de Falha (RNA)

Conforme já foi apresentado anteriormente, foram realizadas aquisições das variáveis de nível, pressão, temperatura, vazão, aquecimento e velocidade do motor das bombas.

Para análise dos dados em regime normal de funcionamento do sistema, foram utilizadas as seguintes variáveis: TE-01, TE-02, TE-03, TE-04, TE-05, TE-06, FT-01, FT-02, AQ-01, B-01, B-02 e B-03 e as análises de dados foram realizadas levando em conta o regime transiente e estacionário.

Para a análise com inserção das falhas, aguardou-se o período transiente do sistema. Uma vez que foi finalizado esse período, foram inseridas as falhas para cada uma das variáveis de temperatura. Foram utilizadas as seguintes variáveis: TE-01, TE-02, TE-03, TE-04, TE-05 e TE-06.

Pode-se observar na Figura 52 a monitoração de todas as temperaturas para uma visão geral do sistema de aquisição de dados.

Figura 52 - Monitoração de todas as temperaturas com a inserção de falha

Fonte: autor da tese.

6.2.1 Monitoração da RNA para Inserção de Falha em TE-01

Através da inserção de falha na temperatura TE-01, obtém-se o resultado mostrado na Figura 53, demonstrada a seguir.

Figura 53 - Monitoração da temperatura TE-01 com inserção de falha

Fonte: autor da tese.

É inserida uma falha durante 20 segundos entre os tempos 713s e 733s. Após ser finalizada a inserção da falha, observa-se um pico de aproximadamente 05 segundos. Esse pico deve-se ao tempo de atualização de leitura do sistema de controle microprocessado.

Durante o intervalo da falha, foi calculado o desvio entre o valor lido e o valor estimado pela rede neural, como pode se observar na Tabela 5 e Tabela 6.

Como a rede neural utiliza o valor da temperatura TE-01 para calcular as demais temperaturas, observa-se também desvios nas demais temperaturas durante esse intervalo da falha de TE-01 como pode ser observado da Figura 54 até a Figura 58.

Figura 54 - Monitoração da temperatura TE-02 com falha em TE-01

Fonte: autor da tese.

Figura 55 - Monitoração da temperatura TE-03 com falha em TE-01

Fonte: autor da tese.

Figura 56 - Monitoração da temperatura TE-04 com falha em TE-01

Fonte: autor da tese.

Figura 57 - Monitoração da temperatura TE-05 com falha em TE-01

Fonte: autor da tese.

Figura 58 - Monitoração da temperatura TE-06 com falha em TE-01

Fonte: autor da tese.

Na Tabela 5 pode-se observar os desvios médios calculados para as temperaturas: TE-02, TE-03, TE-04, TE-05 e TE-06.

Tabela 5 - Desvios médios das temperaturas com falha em TE-01 (°C)

Falhas Aplicadas	Desvio TE-01 (°C)	Desvio TE-02 (°C)	Desvio TE-03 (°C)	Desvio TE-04 (°C)	Desvio TE-05 (°C)	Desvio TE-06 (°C)
TE-01	24,94	3,79	0,32	2,47	2,84	3,33

Fonte: autor da tese.

Na Tabela 6 é possível observar também os correspondentes desvios médios percentuais para cada uma das temperaturas.

Tabela 6 - Desvios médios das temperaturas com falha em TE-01 (%)

Falhas Aplicadas	Desvio TE-01 (%)	Desvio TE-02 (%)	Desvio TE-03 (%)	Desvio TE-04 (%)	Desvio TE-05 (%)	Desvio TE-06 (%)
TE-01	Falha	14,64	1,27	9,77	11,83	15,07

Fonte: autor da tese.

6.2.2 Monitoração da RNA para Inserção de Falha em TE-02

Através da inserção de falha na temperatura TE-02, obtém-se o resultado mostrado na Figura 59 demonstrada a seguir.

Figura 59 - Monitoração da temperatura TE-02 com inserção de falha

Fonte: autor da tese.

É inserida uma falha durante 21 segundos entre os tempos 1011s e 1032s. Durante esse intervalo, foi calculado o desvio entre o valor lido e o valor estimado pela rede neural, como pode se observar na Tabela 7 e Tabela 8.

Como a rede neural utiliza o valor da temperatura TE-02 para calcular as demais temperaturas, observa-se também desvios nas demais temperaturas durante esse intervalo da falha de TE-02 como pode ser observado da Figura 60 até a Figura 64.

Figura 60 - Monitoração da temperatura TE-01 com falha em TE-02

Fonte: autor da tese.

Figura 61 - Monitoração da temperatura TE-03 com falha em TE-02

Figura 62 - Monitoração da temperatura TE-04 com falha em TE-02

Fonte: autor da tese.

Figura 63 - Monitoração da temperatura TE-05 com falha em TE-02

Fonte: autor da tese.

Figura 64 - Monitoração da temperatura TE-06 com falha em TE-02

Fonte: autor da tese.

Na Tabela 7 observa-se os desvios médios calculados para as temperaturas: TE-01, TE-03, TE-04, TE-05 e TE-06.

Tabela 7 - Desvios médios das temperaturas com falha em TE-02 (°C)

Falhas Aplicadas	Desvio TE-01 (°C)	Desvio TE-02 (°C)	Desvio TE-03 (°C)	Desvio TE-04 (°C)	Desvio TE-05 (°C)	Desvio TE-06 (°C)
TE-02	0,34	24,83	2,91	1,92	0,88	1,61

Fonte: autor da tese.

Na Tabela 8 é possível observar os valores correspondentes dos desvios médios percentuais para cada uma das temperaturas.

Tabela 8 - Desvios médios das temperaturas com falha em TE-02 (%)

Falhas Aplicadas	Desvio TE-01 (%)	Desvio TE-02 (%)	Desvio TE-03 (%)	Desvio TE-04 (%)	Desvio TE-05 (%)	Desvio TE-06 (%)
TE-02	1,32	Falha	11,42	7,53	3,62	7,20

Fonte: autor da tese.

6.2.3 Monitoração da RNA para Inserção de Falha em TE-03

Através da inserção de falha na temperatura TE-03, obtém-se o resultado mostrado na Figura 65 demonstrada a seguir.

Figura 65 - Monitoração da temperatura TE-03 com inserção de falha

Fonte: autor da tese.

É inserida uma falha durante 21 segundos entre os tempos 1317s e 1338s. Durante esse intervalo, foi calculado o desvio entre o valor lido e o valor estimado pela rede neural, como pode se observar na Tabela 9 e Tabela 10.

Como a rede neural utiliza o valor da temperatura TE-03 para calcular as demais temperaturas, observa-se também desvios nas demais temperaturas durante esse intervalo da falha de TE-03 como pode ser observado da Figura 66 até a Figura 70.

Figura 66 - Monitoração da temperatura TE-01 com falha em TE-03

Fonte: autor da tese.

Figura 67 - Monitoração da temperatura TE-02 com falha em TE-03

Fonte: autor da tese.

Figura 68 - Monitoração da temperatura TE-04 com falha em TE-03

Fonte: autor da tese.

Figura 69 - Monitoração da temperatura TE-05 com falha em TE-03

Fonte: autor da tese.

Figura 70 - Monitoração da temperatura TE-06 com falha em TE-03

Fonte: autor da tese.

Na Tabela 9 observa-se os desvios médios calculados para as temperaturas: TE-01, TE-02, TE-04, TE-05 e TE-06.

Tabela 9 - Desvios médios das temperaturas com falha em TE-03 (°C)

Falhas Aplicadas	Desvio TE-01 (°C)	Desvio TE-02 (°C)	Desvio TE-03 (°C)	Desvio TE-04 (°C)	Desvio TE-05 (°C)	Desvio TE-06 (°C)
TE-03	1,19	4,29	28,86	1,09	4,04	2,93

Fonte: autor da tese.

Na Tabela 10 é possível observar os correspondentes desvios médios percentuais para cada uma das temperaturas.

Tabela 10 - Desvios médios das temperaturas com falha em TE-03 (%)

Falhas Aplicadas	Desvio TE-01 (%)	Desvio TE-02 (%)	Desvio TE-03 (%)	Desvio TE-04 (%)	Desvio TE-05 (%)	Desvio TE-06 (%)
TE-03	4,66	16,68	Falha	4,23	16,63	13,15

Fonte: autor da tese.

6.2.4 Monitoração da RNA para Inserção de Falha em TE-04

Através da inserção de falha na temperatura TE-04, obtém-se o resultado mostrado na Figura 71, demonstrado a seguir.

Figura 71 - Monitoração da temperatura TE-04 com inserção de falha

Fonte: autor da tese.

É inserida uma falha durante 23 segundos entre os tempos 1628s e 1651s. Durante esse intervalo, foi calculado o desvio entre o valor lido e o valor estimado pela rede neural, como pode se observar na Tabela 11 e Tabela 12.

Como a rede neural utiliza o valor da temperatura TE-04 para calcular as demais temperaturas, observa-se também desvios nas demais temperaturas durante esse intervalo da falha de TE-04 como pode ser observado da Figura 72 até a Figura 76.

Figura 72 - Monitoração da temperatura TE-01 com falha em TE-04

Fonte: autor da tese.

Figura 73 - Monitoração da temperatura TE-02 com falha em TE-04

Fonte: autor da tese.

Figura 74 - Monitoração da temperatura TE-03 com falha em TE-04

Fonte: autor da tese.

Figura 75 - Monitoração da temperatura TE-05 com falha em TE-04

Fonte: autor da tese.

Figura 76 - Monitoração da temperatura TE-06 com falha em TE-04

Fonte: autor da tese.

Na Tabela 11 observa-se os desvios médios calculados para as temperaturas: TE-01, TE-02, TE-03, TE-05 e TE-06.

Tabela 11 - Desvios médios das temperaturas com falha em TE-04 (°C)

Falhas Aplicadas	Desvio TE-01 (°C)	Desvio TE-02 (°C)	Desvio TE-03 (°C)	Desvio TE-04 (°C)	Desvio TE-05 (°C)	Desvio TE-06 (°C)
TE-04	2,17	6,08	3,94	27,12	0,14	0,63

Fonte: autor da tese.

Na Tabela 12 é possível observar os correspondentes desvios médios percentuais para cada uma das temperaturas.

Tabela 12 - Desvios médios das temperaturas com falha em TE-04 (%)

Falhas Aplicadas	Desvio TE-01 (%)	Desvio TE-02 (%)	Desvio TE-03 (%)	Desvio TE-04 (%)	Desvio TE-05 (%)	Desvio TE-06 (%)
TE-04	8,45	23,50	15,35	Falha	0,59	2,75

Fonte: autor da tese.

6.2.5 Monitoração da RNA para Inserção de Falha em TE-05

Através da inserção de falha na temperatura TE-05, obtém-se o resultado mostrado na a Figura 77, demonstrada a seguir.

Figura 77 - Monitoração da temperatura TE-05 com inserção de falha

Fonte: autor da tese.

É inserida uma falha durante 21 segundos entre os tempos 1885s e 1906s. Durante esse intervalo, foi calculado o desvio entre o valor lido e o valor estimado pela rede neural, como pode se observar na Tabela 13 e Figura 77.

Como a rede neural utiliza o valor da temperatura TE-05 para calcular as demais temperaturas, observa-se também desvios nas demais temperaturas durante esse intervalo da falha de TE-05 como pode ser observado da Figura 78 até a Figura 82.

Figura 78 - Monitoração da temperatura TE-01 com falha em TE-05

Fonte: autor da tese.

Figura 79 - Monitoração da temperatura TE-02 com falha em TE-05

Fonte: autor da tese.

Figura 80 - Monitoração da temperatura TE-03 com falha em TE-05

Fonte: autor da tese.

Figura 81 - Monitoração da temperatura TE-04 com falha em TE-05

Fonte: autor da tese.

Figura 82 - Monitoração da temperatura TE-06 com falha em TE-05

Fonte: autor da tese.

Na Tabela 13 observa-se os desvios médios calculados para as temperaturas: TE-01, TE-02, TE-03, TE-04 e TE-06.

Tabela 13 - Desvios médios das temperaturas com falha em TE-05 (°C)

Falhas Aplicadas	Desvio TE-01 (°C)	Desvio TE-02 (°C)	Desvio TE-03 (°C)	Desvio TE-04 (°C)	Desvio TE-05 (°C)	Desvio TE-06 (°C)
TE-05	3,34	6,14	17,56	16,62	24,98	5,80

Fonte: autor da tese.

Na Tabela 14 é possível observar os correspondentes desvios médios percentuais para cada uma das temperaturas.

Tabela 14 - Desvios médios das temperaturas com falha em TE-05 (%)

Falhas Aplicadas	Desvio TE-01 (%)	Desvio TE-02 (%)	Desvio TE-03 (%)	Desvio TE-04 (%)	Desvio TE-05 (%)	Desvio TE-06 (%)
TE-05	16,80	23,53	68,45	49,03	Falha	25,49

Fonte: autor da tese.

6.2.6 Monitoração da RNA para Inserção de Falha em TE-06

Através da inserção de falha na temperatura TE-06, obtém-se o resultado mostrado na Figura 83, demonstrada a seguir.

Figura 83 - Monitoração da temperatura TE-06 com inserção de falha

Fonte: autor da tese.

É inserida uma falha durante 21 segundos entre os tempos 2113s e 2034s. Durante esse intervalo, foi calculado o desvio entre o valor lido e o valor estimado pela rede neural, como pode se observar na Tabela 15 e Tabela 16.

Como a rede neural utiliza o valor da temperatura TE-06 para calcular as demais temperaturas, observa-se também desvios nas demais temperaturas durante esse intervalo da falha de TE-06 como pode ser observado da Figura 84 até a Figura 88.

Figura 84 - Monitoração da temperatura TE-01 com falha em TE-06

Fonte: autor da tese.

Figura 85 - Monitoração da temperatura TE-02 com falha em TE-06

Fonte: autor da tese.

Figura 86 - Monitoração da temperatura TE-03 com falha em TE-06

Fonte: autor da tese.

Figura 87 - Monitoração da temperatura TE-04 com falha em TE-06

Fonte: autor da tese.

Figura 88 - Monitoração da temperatura TE-05 com falha em TE-06

Fonte: autor da tese.

Na Tabela 15 pode-se observar os desvios médios calculados para as temperaturas: TE-01, TE-02, TE-03, TE-04 e TE-05.

Tabela 15 - Desvios médios das temperaturas com falha em TE-06 (°C)

Falhas Aplicadas	Desvio TE-01 (°C)	Desvio TE-02 (°C)	Desvio TE-03 (°C)	Desvio TE-04 (°C)	Desvio TE-05 (°C)	Desvio TE-06 (°C)
TE-06	1,46	2,65	7,67	7,48	1,80	24,52

Fonte: autor da tese.

Na Tabela 16 é possível observar os correspondentes desvios médios percentuais para cada uma das temperaturas.

Tabela 16 - Desvios médios das temperaturas com falha em TE-06 (%)

Falhas Aplicadas	Desvio TE-01 (%)	Desvio TE-02 (%)	Desvio TE-03 (%)	Desvio TE-04 (%)	Desvio TE-05 (%)	Desvio TE-06 (%)
TE-06	5,66	10,21	29,69	29,00	7,28	Falha

Fonte: autor da tese.

6.2.7 Análise dos Desvios Médios para Falhas Individuais

Pode-se observar uma síntese dos desvios médios monitorados para todas as temperaturas com as inserções de falhas individuais nas Tabelas 17 e 18.

Tabela 17 - Desvios médios gerais das temperaturas (inserção de falha) (°C)

Falhas Aplicadas	Desvio TE-01 (°C)	Desvio TE-02 (°C)	Desvio TE-03 (°C)	Desvio TE-04 (°C)	Desvio TE-05 (°C)	Desvio TE-06 (°C)
TE-01	24,94	3,79	0,32	2,47	2,84	3,33
TE-02	0,34	24,83	2,91	1,92	0,88	1,61
TE-03	1,19	4,29	28,86	1,09	4,04	2,93
TE-04	2,17	6,08	3,94	27,12	0,14	0,63
TE-05	3,34	6,14	17,56	16,62	24,98	5,80
TE-06	1,46	2,65	7,67	7,48	1,80	24,52

Fonte: autor da tese.

Tabela 18 - Desvios médios gerais das temperaturas (inserção de falha) (%)

Falhas Aplicadas	Desvio TE-01 (%)	Desvio TE-02 (%)	Desvio TE-03 (%)	Desvio TE-04 (%)	Desvio TE-05 (%)	Desvio TE-06 (%)
TE-01	Falha	14,64	1,27	9,77	11,83	15,07
TE-02	1,32	Falha	11,42	7,53	3,62	7,20
TE-03	4,66	16,68	Falha	4,23	16,63	13,15
TE-04	8,45	23,50	13,35	Falha	0,59	2,75
TE-05	16,80	23,53	68,45	49,03	Falha	25,49
TE-06	5,66	10,21	29,69	29,00	7,28	Falha

Fonte: autor da tese.

6.3 Monitoração com Inserção de Falhas Múltiplas (RNA)

Para esse caso, foram inseridas falhas em dois sensores simultaneamente. As variáveis selecionadas foram as temperaturas TE-01, TE-02 e TE-05.

A sequência para a inserção das falhas múltiplas ocorreu para falhas em TE-01+TE-02 e TE-01+TE-05. O critério para a escolha dessas combinações dos sensores de temperatura foi de utilizar dois sensores instalados no mesmo tanque, nesse caso, TE-01 e TE-02 (TQ-01) e utilizar sensores instalados em tanques diferentes, nesse caso, TE-01 (TQ-01) e TE-05 (TQ-02).

Para cada um dos casos ocorreram duas inserções de falhas em quatro momentos diferentes.

Pode-se observar através da Figura 89 a monitoração de todas as temperaturas com as respectivas inserções das falhas, para uma visão geral do sistema de aquisição de dados.

Figura 89 - Monitoração de todas as temperaturas com inserção de falhas múltiplas

Fonte: autor da tese.

6.3.1 Monitoração da RNA para Falhas Múltiplas em TE01 e TE02

Foram inseridas falhas simultâneas em TE-01 e TE-02, durante 20 segundos entre o intervalo de tempo de 809s a 829s e durante 21 segundos durante o intervalo de tempo de 1415s a 1436s, como pode ser observado através da Figura 90 para TE-01 e através da Figura 91 para TE-02.

Figura 90 - Monitoração TE-01 com inserção de falhas múltiplas

Fonte: autor da tese.

Figura 91 - Monitoração TE-02 com inserção de falhas múltiplas

Fonte: autor da tese.

Observa-se também desvios nas demais temperaturas durante esses intervalos de tempos inseridos nas falhas múltiplas. Para os intervalos de tempo de 809s a 829s, temos da Figura 92 até a Figura 97.

Durante esse intervalo, foram calculados os desvios entre os valores lidos e os valores estimados pela rede neural, como pode se observar na Tabela 19 e Tabela 20.

Figura 92 - Monitoração TE-01: falha em TE-01 e TE-02 (809 a 829s)

Fonte: autor da tese.

Figura 93 - Monitoração TE-02: falha em TE-01 e TE-02 (809 a 829s)

Fonte: autor da tese.

Figura 94 - Monitoração TE-03: falha em TE-01 e TE-02 (809 a 829s)

Fonte: autor da tese.

Figura 95 - Monitoração TE-04: falha em TE-01 e TE-02 (809 a 829s)

Fonte: autor da tese.

Figura 96 - Monitoração TE-05: falha em TE-01 e TE-02 (809 a 829s)

Fonte: autor da tese.

Figura 97 - Monitoração TE-06: falha em TE-01 e TE-02 (809 a 829s)

Fonte: autor da tese.

Na Tabela 19 é possível observar os desvios médios calculados para as temperaturas com a inserção das falhas múltiplas. Nesse caso, através das temperaturas TE-01 e TE-02, considerando o intervalo de tempo de 809 a 829s.

Tabela 19 - Desvios médios das temperaturas com falha em TE-01 e TE-02 (°C) - 809s a 829s

Falhas Aplicadas	Desvio TE-01 (°C)	Desvio TE-02 (°C)	Desvio TE-03 (°C)	Desvio TE-04 (°C)	Desvio TE-05 (°C)	Desvio TE-06 (°C)
TE-01 e TE-02	27,11	27,26	0,66	3,23	6,31	5,07

Fonte: autor da tese.

Como pode ser observado na Tabela 20, observa-se os correspondentes desvios médios percentuais para cada uma das temperaturas.

Tabela 20 - Desvios médios das temperaturas com falha em TE-01 e TE-02 (%) - 809s a 829s

Falhas Aplicadas	Desvio TE-01 (%)	Desvio TE-02 (%)	Desvio TE-03 (%)	Desvio TE-04 (%)	Desvio TE-05 (%)	Desvio TE-06 (%)
TE-01 e TE-02	Falha	Falha	2,65	12,91	26,89	24,27

Fonte: autor da tese.

Pode-se observar por meio da Figura 98 o comportamento de TE-01 durante o intervalo de tempo de 1415 a 1436s. O comportamento das demais variáveis através podem ser observados por meio da Figura 99 até a Figura 103.

Durante esse intervalo, foi calculado o desvio entre o valor lido e o valor estimado pela rede neural.

Figura 98 - Monitoração TE-01: falha em TE-01 e TE-02 (1415 a 1436s)

Fonte: autor da tese.

Figura 99 - Monitoração TE-02: falha em TE-01 e TE-02 (1415 a 1436s)

Fonte: autor da tese.

Figura 100 - Monitoração TE-03: falha em TE-01 e TE-02 (1415 a 1436s)

Fonte: autor da tese.

Figura 101 - Monitoração TE-04: falha em TE-01 e TE-02 (1415 a 1436s)

Fonte: autor da tese.

Figura 102 - Monitoração TE-05: falha em TE-01 e TE-02 (1415 a 1436s)

Fonte: autor da tese.

Figura 103 – Monitoração TE-06: falha em TE-01 e TE-02 (1415 a 1436s)

Fonte: autor da tese.

Na Tabela 21 é possível observar os desvios médios calculados para as temperaturas com a inserção das falhas múltiplas. Nesse caso, através das temperaturas TE-01 e TE-02, considerando o intervalo de tempo de 1415 a 1436s.

Tabela 21 - Desvios médios das temperaturas com falha em TE-01 e TE-02 (°C) - 1415s a 1436s

Falhas Aplicadas	Desvio TE-01 (°C)	Desvio TE-02 (°C)	Desvio TE-03 (°C)	Desvio TE-04 (°C)	Desvio TE-05 (°C)	Desvio TE-06 (°C)
TE-01 e TE-02	26,89	26,98	0,39	2,94	6,57	5,59

Fonte: autor da tese.

Como pode ser observado na Tabela 22, tem-se os correspondentes desvios médios percentuais para cada uma das temperaturas.

Tabela 22 - Desvios médios das temperaturas com falha em TE-01 e TE-02 (°C) - 1415s a 1436s

Falhas Aplicadas	Desvio TE-01 (%)	Desvio TE-02 (%)	Desvio TE-03 (%)	Desvio TE-04 (%)	Desvio TE-05 (%)	Desvio TE-06 (%)
TE-01 e TE-02	Falha	Falha	1,58	12,04	28,43	22,04

Fonte: autor da tese.

6.3.2 Monitoração da RNA para Falhas Múltiplas em TE01 e TE05

Foram inseridas falhas simultâneas em TE-01 e TE-05, durante 21 segundos entre os tempos 1126s e 1149s e entre os tempos 1721s e 1745s. Observa-se através da Figura 104, o comportamento de TE-01 durante o intervalo de tempo de 1126s a 1149s.

Figura 104 - Monitoração de TE-01 com inserção de falhas múltiplas

Fonte: autor da tese.

Através da Figura 105, observa-se o comportamento de TE-05 durante o intervalo de tempo de 1126s a 1149s.

Figura 105 - Monitoração de TE-05 com inserção de falhas múltiplas

Fonte: autor da tese.

Observa-se também desvios nas demais temperaturas durante esses intervalos de tempos inseridos nas falhas múltiplas. Para os intervalos de tempo de 1126s a 1149s, temos as Figuras 106 até a Figura 111.

Figura 106 - Monitoração TE-01: falha em TE-01 e TE-05 (1126 a 1149s)

Fonte: autor da tese.

Figura 107 - Monitoração TE-02: falha em TE-01 e TE-05 (1126 a 1149s)

Fonte: autor da tese.

Figura 108 - Monitoração TE-03: falha em TE-01 e TE-05 (1126 a 1149s)

Fonte: autor da tese.

Figura 109 - Monitoração TE-04: falha em TE-01 e TE-05 (1126 a 1149s)

Fonte: autor da tese.

Figura 110 - Monitoração TE-05: falha em TE-01 e TE-05 (1126 a 1149s)

Fonte: autor da tese.

Figura 111 - Monitoração TE-06: falha em TE-01 e TE-05 (1126 a 1149s)

Fonte: autor da tese.

Na Tabela 23 temos os desvios médios calculados para as temperaturas com a inserção das falhas múltiplas. Nesse caso, através das temperaturas TE-01 e TE-05, considerando o intervalo de tempo de 1126 a 1149s.

Tabela 23 - Desvios médios das temperaturas com falhas em TE-01 e TE-05 (°C) - 1126 a 1149s

Falhas Aplicadas	Desvio TE-01 (°C)	Desvio TE-02 (°C)	Desvio TE-03 (°C)	Desvio TE-04 (°C)	Desvio TE-05 (°C)	Desvio TE-06 (°C)
TE-01 e TE-05	29,90	5,46	8,20	9,35	27,34	0,61

Fonte: autor da tese.

Como pode ser observado na Tabela 24 temos os correspondentes desvios médios percentuais para cada uma das temperaturas.

Tabela 24 - Desvios médios das temperaturas com falhas em TE-01 e TE-05 (%) - 1126 a 1149s

Falhas Aplicadas	Desvio TE-01 (%)	Desvio TE-02 (%)	Desvio TE-03 (%)	Desvio TE-04 (%)	Desvio TE-05 (%)	Desvio TE-06 (%)
TE-01 e TE-05	Falha	22,36	33,46	38,08	Falha	2,94

Fonte: autor da tese.

Podemos observar através da Figura 112 o comportamento de TE-01 durante o intervalo de tempo de 1721s a 1745s. Durante esse intervalo, foi calculado o desvio entre o valor lido e o valor estimado pela rede neural, como pode se observar na Tabela 25 e Tabela 26.

Observa-se também, desvios nas demais temperaturas durante esses intervalos de tempos inseridos nas falhas múltiplas. Para os intervalos de tempo de 1721s a 1745s, temos as Figuras 113 até a Figura 117.

Figura 112 - Monitoração TE-01: falha em TE-01 e TE-05 (1721s a 1745s)

Fonte: autor da tese.

Figura 113 - Monitoração TE-02: falha em TE-01 e TE-05 (1721s a 1745s)

Fonte: autor da tese.

Figura 114 - Monitoração TE-03: falha em TE-01 e TE-05 (1721s a 1745s)

Fonte: autor da tese.

Figura 115 - Monitoração TE-04: falha em TE-01 e TE-05 (1721s a 1745s)

Fonte: autor da tese.

Figura 116 - Monitoração TE-05: falha em TE-01 e TE-05 (1721s a 1745s)

Fonte: autor da tese.

Figura 117 - Monitoração TE-06: falha em TE-01 e TE-05 (1721s a 1745s)

Fonte: autor da tese.

Na Tabela 25 temos os desvios médios calculados para as temperaturas com a inserção das falhas múltiplas. Nesse caso, através das temperaturas TE-01 e TE-05, considerando o intervalo de tempo de 1721 a 1745s.

Tabela 25 - Desvios médios das temperaturas com falha em TE-01 e TE-05 (°C) - 1721s a 1745s

Falhas Aplicadas	Desvio TE-01 (°C)	Desvio TE-02 (°C)	Desvio TE-03 (°C)	Desvio TE-04 (°C)	Desvio TE-05 (°C)	Desvio TE-06 (°C)
TE-01 e TE-05	29,63	5,23	8,70	8,89	27,77	0,91

Fonte: autor da tese.

Como pode ser observado na Tabela 26 temos os correspondentes desvios médios percentuais para cada uma das temperaturas.

Tabela 26 - Desvios médios das temperaturas com falhas em TE-01 e TE-05 (%) - 1721s a 1745s

Falhas Aplicadas	Desvio TE-01 (%)	Desvio TE-02 (%)	Desvio TE-03 (%)	Desvio TE-04 (%)	Desvio TE-05 (%)	Desvio TE-06 (%)
TE-01 e TE-05	Falha	21,98	36,25	34,64	Falha	4,38

Fonte: autor da tese.

6.3.3 Análise Geral dos Desvios Médios para a inserção de Falhas Múltiplas

Pode-se observar os desvios médios monitorados para todas as temperaturas em regime de funcionamento com inserção de falhas múltiplas, através da Tabela 27.

Falhas Aplicadas	Desvio TE-01 (°C)	Desvio TE-02 (°C)	Desvio TE-03 (°C)	Desvio TE-04 (°C)	Desvio TE-05 (°C)	Desvio TE-06 (°C)
TE-01 e TE-02 (809 a 829s)	27,11	27,26	0,66	3,23	6,31	5,07
TE-01 e TE-02 (1415 a 1436s)	26,89	26,98	0,39	2,94	6,57	5,59
TE-01 e TE-05 (1126 a 1149s)	29,90	5,46	8,20	9,35	27,34	0,61
TE-01 e TE-05 (1721 a 1745s)	29,63	5,23	8,70	8,89	27,77	0,91

Fonte: autor da tese.

Observa-se também na Tabela 27 que as falhas foram inseridas de forma intercalada em relação ao tempo. Primeiramente em TE-01 e TE-02 (tempo 803 a 829s) e posteriormente segue: TE-01 e TE-05 (tempo 1126 a 1149s), TE-01 e TE-02 (tempo 1415 a 1436s), TE-01 e TE-05 (tempo 1721 a 1745s).

Para todos os casos da Tabela 27, foram gerados os resultados percentuais dos respectivos desvios médios para as falhas múltiplas, que podem ser observados através da Tabela 28.

Tabela 28 - Desvios médios percentuais das temperaturas com falhas múltiplas (%)

Falhas Aplicadas	Desvio TE-01 (%)	Desvio TE-02 (%)	Desvio TE-03 (%)	Desvio TE-04 (%)	Desvio TE-05 (%)	Desvio TE-06 (%)
TE-01 e TE-02 (809 a 829s)	Falha	Falha	2,65	12,91	26,89	24,27
TE-01 e TE-02 (1415 a 1436s)	Falha	Falha	1,58	12,04	28,43	22,04
TE-01 e TE-05 (1126 a 1149s)	Falha	22,36	33,46	38,08	Falha	2,94
TE-01 e TE-05 (1721 a 1745s)	Falha	21,98	36,25	34,64	Falha	4,38

Fonte: autor da tese.

6.4 Monitoração Utilizando GMDH

Conforme já foi apresentado anteriormente, foram realizadas aquisições das variáveis de nível, pressão, temperatura, vazão, aquecimento e velocidade do motor das bombas. As seguintes variáveis foram consideradas para análise: TE-01, TE-02, TE-03, TE-04, TE-05, TE-06, FT-01, FT-02, AQ-01, B-01, B-02 e B-03.

Da mesma forma que foi feito para as Redes Neurais, para cada variável foi feito um modelo GMDH utilizando as demais variáveis como variáveis de entrada do modelo polinomial.

6.4.1 Resultado GMDH para a AQ-01

Desempenho AQ-01

Após a implementação da metodologia GMDH, foi determinado o RMIN (resíduo mínimo) (Equação 14), bem como sua camada correspondente, conforme pode ser observado na Figura 118.

Figura 118 - Desempenho GMDH para o aquecimento AQ-01

Fonte: autor da tese.

No Figura 118 observa-se a relação entre o resíduo calculado e as camadas. Nesse caso, o resíduo mínimo é de $3,2166 \cdot 10^{-7}$. Esse valor foi encontrado na camada 1.

Monitoração do Aquecedor AQ-01

Na Figura 119 é apresentado o resultado da variável AQ-01 após a análise durante 2400 segundos.

Para todos os casos, a monitoração ocorreu considerando a comparação dos valores lidos do processo e os valores calculados através do método GMDH.

Figura 119 - Monitoração GMDH para o aquecimento AQ-01

Fonte: autor da tese.

Observando a Figura 119, pode-se perceber que os valores encontram-se sobrepostos, ou seja, o valor lido é muito próximo ao valor calculado pelo método GMDH.

- Desvio médio total de AQ-01: 9,6498e-08;
- Desvio médio de estado estacionário de AQ-01: 1,2866e-07.

6.4.2 Resultado GMDH para a Bomba B-01

Desempenho B-01.

Após a implementação da metodologia GMDH, foi determinado o RMIN (resíduo mínimo), bem como sua camada correspondente, conforme pode ser observado na Figura 120.

Figura 120 - Desempenho GMDH para a potência da bomba B-01

Fonte: autor da tese.

Observa-se a relação entre o resíduo calculado e as camadas através da Figura 120. Nesse caso, o resíduo mínimo é de $4,6820 \cdot 10^{-7}$. Esse valor foi encontrado na camada 1.

Monitoração da Bomba B-01.

Através da Figura 121 é apresentado o resultado da variável B-01 após a análise durante 2400 segundos.

Figura 121 - Monitoração GMDH para a potência da bomba B-01

Fonte: autor da tese.

Observando a Figura 121 pode-se perceber que os valores encontram-se sobrepostos, ou seja, o valor lido é muito próximo ao valor calculado pelo método GMDH.

- Desvio médio total de B-01: $3,277e-07$;
- Desvio médio de estado estacionário de B-01: $4,3699e-07$.

6.4.3 Resultado GMDH para a Bomba B-02

Desempenho B-02

Após a implementação da metodologia GMDH, foi determinado o RMIN (resíduo mínimo), bem como sua camada correspondente, conforme pode ser observado na Figura 122.

Figura 122 - Desempenho GMDH para a potência da bomba B-02

Fonte: autor da tese.

Na Figura 122, observa-se a relação entre o resíduo calculado e as camadas. Nesse caso, o resíduo mínimo é de 0,0797. Esse valor foi encontrado na camada 10.

Monitoração da Bomba B-02

Através da Figura 123, pode-se observar o resultado da monitoração da variável B-02 após a análise durante 2400 segundos.

Figura 123 - Monitoração GMDH para a potência da bomba B-02

Fonte: autor da tese.

Observando a Figura 123 pode-se perceber os seguintes valores calculados pelo método GMDH:

- Desvio médio total de B-02: 0,0133;
- Desvio médio de estado estacionário de B-02: 0,0178.

6.4.4 Resultado GMDH para a Bomba B-03

Desempenho B-03

Após a implementação da metodologia GMDH, foi determinado o RMIN (resíduo mínimo), bem como sua camada correspondente, conforme pode ser observado na Figura 124.

Figura 124 - Desempenho GMDH para a potência da bomba B-03

Fonte: autor da tese.

Na Figura 124 observa-se a relação entre o resíduo calculado e as camadas. Nesse caso, o resíduo mínimo é de $4,4505 \cdot 10^{-7}$. Esse valor foi encontrado na camada 1.

Monitoração da Bomba B-03

Através da Figura 125 é apresentado o resultado da variável B-03 após a análise durante 2400 segundos.

Figura 125 - Monitoração GMDH para a potência da bomba B-03

Fonte: autor da tese.

Observando a Figura 125, pode-se perceber que os valores encontram-se sobrepostos, ou seja, o valor lido é muito próximo ao valor calculado pelo método GMDH.

- Desvio médio total de B-03: $2,9670e-07$.
- Desvio médio de estado estacionário de B-03: $3,9560e-07$.

6.4.5 Resultado GMDH para a Vazão FT-01

Desempenho FT-01

Após a implementação da metodologia GMDH, foi determinado o RMIN (resíduo mínimo), bem como sua camada correspondente, conforme pode ser observado na Figura 126.

Figura 126 - Desempenho GMDH para a vazão FT-01

Fonte: autor da tese.

Observa-se a relação entre o resíduo calculado e as camadas. Nesse caso, o resíduo mínimo é de 0,0143 (Figura 126). Esse valor foi encontrado na camada 3.

Monitoração da Vazão FT-01

Através da Figura 127 é possível observar o resultado da variável FT-01 após a análise durante 2400 segundos.

Figura 127 - Monitoração GMDH para a vazão FT-01

Fonte: autor da tese.

Seguem os valores de desvio médio total e desvio médio de estado estacionário:

- Desvio médio total de FT-01: 0,0042;
- Desvio médio de estado estacionário de FT-01: 0,0055.

6.4.6 Resultado GMDH para a Vazão FT-02

Desempenho FT-02

Após a implementação da metodologia GMDH, foi determinado o RMIN (resíduo mínimo), bem como sua camada correspondente, conforme pode ser observado na Figura 128.

Figura 128 - Desempenho GMDH para a vazão FT-02.

Fonte: autor da tese.

Observa-se a relação entre o resíduo calculado e as camadas. Nesse caso, o resíduo mínimo é de 0,0104 (Figura 128). Esse valor foi encontrado na camada 10.

Monitoração da Vazão FT-02

Através da Figura 129 é possível observar resultado da variável FT-02 após a análise durante 2400 segundos.

Figura 129 - Monitoração do GMDH para a vazão FT-02

Fonte: autor da tese.

Seguem os valores de desvio médio total e desvio médio de estado estacionário:

- Desvio médio total de FT-02: 0,0181;
- Desvio médio de estado estacionário de FT-02: 0,0241.

6.4.7 Resultado GMDH para a Pressão PT-01

Desempenho PT-01

Após a implementação da metodologia GMDH, foi determinado o RMIN (resíduo mínimo), bem como sua camada correspondente, conforme pode ser observado na Figura 130.

Figura 130 - Desempenho GMDH para a pressão PT-01

Fonte: autor da tese.

Observa-se a relação entre o resíduo calculado e as camadas. Nesse caso, o resíduo mínimo é de 0,0336 (Figura 130). Esse valor foi encontrado na camada 7.

Monitoração de Nível PT-01

Através da Figura 131, pode-se observar o resultado da variável PT-01 após a análise durante 2400 segundos.

Figura 131 - Monitoração GMDH para a pressão PT-01

Fonte: autor da tese.

Seguem os valores de desvio médio total e desvio médio de estado estacionário:

- Desvio médio total de PT-01: 0,0679;
- Desvio médio de estado estacionário de PT-01: 0,0905.

6.4.8 Resultado GMDH para a Temperatura TE-01

Desempenho TE-01

Após a implementação da metodologia do GMDH, foi determinado o RMIN (resíduo mínimo), bem como sua camada correspondente, conforme pode ser observado na Figura 132.

Figura 132 - Desempenho GMDH para a temperatura TE-01

Fonte: autor da tese.

Observa-se a relação entre o resíduo calculado e as camadas. Nesse caso, o resíduo mínimo é de 0,0035 (Figura 132). Esse valor foi encontrado na camada 8.

Monitoração da Temperatura TE-01

Através da Figura 133 é apresentado o resultado da monitoração da variável TE-01 após a análise durante 2400 segundos.

Figura 133 - Monitoração GMDH para a temperatura TE-01

Fonte: autor da tese.

Seguem os valores de desvio médio total e desvio médio de estado estacionário para esse caso:

- Desvio médio total de TE-01: 0,0056;
- Desvio médio de estado estacionário de TE-01: 0,0028.

6.4.9 Resultado GMDH para a Temperatura TE-02

Desempenho TE-02

Após a implementação da metodologia do GMDH, foi determinado o RMIN (resíduo mínimo), bem como sua camada correspondente, conforme pode ser observado na Figura 134.

Figura 134 - Desempenho GMDH para a temperatura TE-02

Fonte: autor da tese.

Observa-se a relação entre o resíduo calculado e as camadas (Figura 134). Nesse caso, o resíduo mínimo é de 0,00354. Esse valor foi encontrado na camada 2.

Monitoração da Temperatura TE-02

O resultado da monitoração da variável TE-02 após a análise durante 2400 segundos pode ser observado através da Figura 135.

Figura 135 - Monitoração GMDH para a temperatura TE-02

Fonte: autor da tese.

Seguem os valores de desvio médio total e desvio médio de estado estacionário:

- Desvio médio total de TE-02: 0,0035;
- Desvio médio de estado estacionário de TE-02: 0,0017.

6.4.10 Resultado GMDH para a Temperatura TE-03

Desempenho TE-03

Após a implementação da metodologia GMDH, foi determinado o RMIN (resíduo mínimo), bem como sua camada correspondente, conforme pode ser observado na Figura 136.

Figura 136 - Desempenho GMDH para a temperatura TE-03

Fonte: autor da tese.

Observa-se a relação entre o resíduo calculado e as camadas (Figura 136). Nesse caso, o resíduo mínimo é de 0,0041. Esse valor foi encontrado na camada 3.

Monitoração da Temperatura TE-03

A seguir é apresentado o resultado da monitoração da variável TE-03 após a análise durante 2400 segundos (Figura 137).

Figura 137 - Monitoração GMDH para a temperatura TE-03

Fonte: autor da tese.

Seguem os valores de desvio médio total e desvio médio de estado estacionário:

- Desvio médio total de TE-03: 0,0044;
- Desvio médio de estado estacionário de TE-03: 0,0024.

6.4.11 Resultado GMDH para a Temperatura TE-04

Desempenho TE-04

Após a implementação da metodologia GMDH, foi determinado o RMIN (resíduo mínimo), bem como sua camada correspondente, conforme pode ser observado na Figura 138.

Figura 138 - Desempenho GMDH para a temperatura TE-04

Fonte: autor da tese.

Através da Figura 138, observa-se a relação entre o resíduo calculado e as camadas. Nesse caso, o resíduo mínimo é de 0,0047. Esse valor foi encontrado na camada 8.

Monitoração da Temperatura TE-04

O resultado da monitoração da variável TE-04 após a análise durante 2400 segundos é apresentado na Figura 139.

Figura 139 - Monitoração GMDH para a temperatura TE-04

Fonte: autor da tese.

Seguem os valores de desvio médio total e desvio médio de estado estacionário:

- Desvio médio total de TE-04: 0,0031;
- Desvio médio de estado estacionário de TE-04: 0,0017.

6.4.12 Resultado GMDH para a Temperatura TE-05

Desempenho TE-05

Após a implementação da metodologia GMDH, foi determinado o RMIN (resíduo mínimo), bem como sua camada correspondente, conforme pode ser observado na Figura 140.

Figura 140 - Desempenho GMDH para a temperatura TE-05

Fonte: autor da tese.

Pode-se observa-se a relação entre o resíduo calculado e as camadas (Figura 140). Nesse caso, o resíduo mínimo é de 0,0130. Esse valor foi encontrado na camada 3.

Monitoração da Temperatura TE-05

A seguir é apresentado o resultado da monitoração da variável TE-05 após a análise durante 2400 segundos (Figura 141).

Figura 141 - Monitoração GMDH para a temperatura TE-05

Fonte: autor da tese.

Seguem os valores de desvio médio total e desvio médio de estado estacionário:

- Desvio médio total de TE-05: 0,0043;
- Desvio médio de estado estacionário de TE-05: 0,0035.

6.4.13 Resultado GMDH para a Temperatura TE-06

Desempenho TE-06

Após a implementação da metodologia GMDH, foi determinado o RMIN (resíduo mínimo), bem como sua camada correspondente, conforme pode ser observado na Figura 142.

Figura 142 - Desempenho GMDH para a temperatura TE-06

Fonte: autor da tese.

Na Figura 142 observa-se a relação entre o resíduo calculado e as camadas. Nesse caso, o resíduo mínimo é de 0,0157. Esse valor foi encontrado na camada 6.

Monitoração da Temperatura TE-06.

O resultado da monitoração da variável TE-06 pode ser observada através da Figura 143, após a análise durante 2400 segundos.

Figura 143 - Monitoração GMDH para a temperatura TE-06

Fonte: autor da tese.

Seguem os valores de desvio médio total e desvio médio de estado estacionário:

- Desvio médio total de TE-06: 0,0124;
- Desvio médio de estado estacionário de TE-06: 0,0055.

6.4.14 Análise dos Resultados dos Desvios Médios para as Temperaturas

Através da Tabela 29, obtém-se uma síntese com a análise dos desvios médios monitorados para todas as temperaturas em regime normal de funcionamento.

Tabela 29 - Resultado geral GMDH - Desvios médios das temperaturas (°C)

	Desvio TE-01 (°C)	Desvio TE-02 (°C)	Desvio TE-03 (°C)	Desvio TE-04 (°C)	Desvio TE-05 (°C)	Desvio TE-06 (°C)
Desvio Médio Total	0,28	0,18	0,22	0,16	0,22	0,62
Desvio Méd. (estacionário)	0,14	0,09	0,12	0,09	0,18	0,28

Fonte: autor da tese.

Na Tabela 30, é possível observar os correspondentes desvios médios percentuais para cada uma das temperaturas.

Tabela 30 - Resultado geral GMDH - Desvios médios das temperaturas (%)

	Desvio TE-01 (%)	Desvio TE-02 (%)	Desvio TE-03 (%)	Desvio TE-04 (%)	Desvio TE-05 (%)	Desvio TE-06 (%)
Desvio Médio Total	0,98	0,61	0,77	0,54	0,83	2,75
Desvio Méd. (estacionário)	0,53	0,32	0,44	0,31	0,66	1,14

Fonte: autor da tese.

Anteriormente foram mostrados os valores normalizados, nas Tabelas 29 e 30, tem-se os valores em °C.

6.4.15 Análise dos Resultados dos Desvios Médios para as demais Variáveis

Através da Tabela 31, obtém-se uma síntese com a análise dos desvios médios monitorados para as variáveis: AQ-01, B-01, B-02, B-03, FTI-01, FT-02 e PT-01 em regime normal de funcionamento.

Tabela 31 - Desvios médios GMDH para as variáveis: AQ-01, B-01, B-02, B-03, FT-01, FT-02 e PT-01.

	Desvio AQ-01 (%)	Desvio B-01 (%)	Desvio B-02 (%)	Desvio B-03 (%)	Desvio FT-01 (l/min)	Desvio FT-02 (l/min)	Desvio PT-01 (%)
Desvio Médio Total	4,82E-06	3,77E-05	0,67	4,45E-05	0,02	0,09	6,79
Desvio Méd. (estacionário)	6,43E-06	4,37E-05	0,89	5,93E-05	0,03	0,12	9,05

Fonte: autor da tese.

Na Tabela 32, é possível observar os correspondentes desvios médios percentuais para cada uma das temperaturas.

Tabela 32 - Percentual dos desvios médios GMDH para as variáveis: AQ-01, B-01, B-02, B-03, FT-01, FT-02 e PT-01.

	Desvio AQ-01 (%)	Desvio B-01 (%)	Desvio B-02 (%)	Desvio B-03 (%)	Desvio FT-01 (%)	Desvio FT-02 (%)	Desvio PT-01 (%)
Desvio Médio Total	3,22E-05	5,39E-05	3,33	4,45E-05	0,68	0,78	12,13
Desvio Méd. (estacionário)	4,29E-04	6,24E-05	4,45	5,93E-05	0,89	4,48	13,92

Fonte: autor da tese.

6.5 Comparação GMDH com RNA

Através da Tabela 33, é possível observar a comparação do desvio médio total dos valores monitorados para todas as temperaturas em regime normal de funcionamento, utilizando as técnicas de inteligência artificial GMDH e RNA.

Tabela 33 - Comparativo entre o GMDH e a RNA (média total)

Variáveis	RNA Temperatura (°C)	GMDH Temperatura (°C)
TE-01	0,33	0,28
TE-02	0,15	0,18
TE-03	0,27	0,22
TE-04	0,18	0,16
TE-05	0,25	0,22
TE-06	0,43	0,62

Fonte: autor da tese.

Na Tabela 34, observa-se os valores correspondentes desvios médios percentuais para cada uma das temperaturas.

Tabela 34 - Comparativo entre o GMDH e a RNA (média total)

Variáveis	RNA Temperatura (%)	GMDH Temperatura (%)
TE-01	1,14	0,98
TE-02	0,53	0,61
TE-03	0,95	0,77
TE-04	0,64	0,54
TE-05	0,95	0,83
TE-06	1,93	2,75

Fonte: autor da tese.

Através da Tabela 35, pode-se observar a comparação do desvio médio do estado estacionário dos valores monitorados para todas as temperaturas em regime normal de funcionamento, utilizando as técnicas de inteligência artificial GMDH e RNA.

Tabela 35 - Comparativo entre o GMDH e a RNA (estado estacionário)

Variáveis	RNA Temperatura (°C)	GMDH Temperatura (°C)
TE-01	0,16	0,14
TE-02	0,12	0,09
TE-03	0,23	0,12
TE-04	0,14	0,09
TE-05	0,27	0,18
TE-06	0,52	0,28

Fonte: autor da tese.

Na Tabela 36 observa-se os correspondentes desvios médios percentuais para cada uma das temperaturas.

Tabela 36 - Comparativo entre o GMDH e a RNA (estado estacionário)

Variáveis	RNA Temperatura (%)	GMDH Temperatura (%)
TE-01	0,59	0,53
TE-02	0,42	0,32
TE-03	0,85	0,44
TE-04	0,49	0,31
TE-05	1,05	0,66
TE-06	2,17	1,14

Fonte: autor da tese.

7 CONCLUSÕES

O objetivo proposto para esse trabalho foi alcançado, pois ocorreu o desenvolvimento da Planta Experimental que possibilitou realizar a monitoração e diagnóstico de falhas simples e múltiplas de forma *on line*, utilizando inteligência artificial através das técnicas de Redes Neurais e GMDH.

Foi possível aplicar o conceito inovador de modelagem de sistemas (*Digital Twin*), realizar a monitoração e diagnóstico de falhas e proporcionar bancos de dados para futuras análises.

Considerando a condição normal de funcionamento em regime estacionário, utilizando Redes Neurais para as variáveis de temperatura, o sistema apresentou um desvio médio geral de 0,93%, o que corresponde a 0,24°C. Para o GMDH, o desvio médio geral foi de 0,57%, o que corresponde a 0,15°C. Esses valores foram considerados excelentes, uma vez que a precisão dos sensores fornecida pelo fabricante é de 2,2 °C.

Dessa forma conclui-se que, embora ambos os sistemas de monitoração apresentaram resultados satisfatórios, o GMDH demonstrou um melhor desempenho em relação às Redes Neurais Artificiais. Devido a esse fato, optou-se por testes com a inserção de falhas apenas com as RNAs.

Foi possível realizar a monitoração das variáveis AQ-01, B-01, B-02, B-03, FT-01, FT-02 e PT-01 apenas através do método GMDH. Os desvios médios para essas variáveis foram os seguintes: AQ-01=4,29.10⁻⁴ %, B-01=6,24.10⁻⁵ %, B-02=4,45%, B-03=5,93.10⁻⁵ %, FT-01=0,89%, FT-02 = 4,48% e PT-01=13,92 %.

A inserção de falhas em uma ou mais variáveis, repercutiu na estimativa da rede para as demais variáveis, conforme pode ser observado nas Tabelas 17 e 18 para as falhas simples e Tabelas 27 e 28 para as falhas múltiplas.

Analisando as variáveis de temperatura para as falhas simples, obtém-se a média total das variáveis de temperatura do Tanque 01 (TE-01, TE-02, TE-03 e TE-04) de 9,38%. Para o Tanque 02 (TE-05) o valor de 36,66% e para o Tanque 03, o valor de 16,37%.

Em relação às variáveis de temperatura para as falhas múltiplas, para as falhas aplicadas em TE-01+TE-02, obtém-se o valor médio total de 16,35%. Para as falhas aplicadas em TE-01+TE-05, obtém-se o valor médio total de 24,26%.

Após a inserção da falha nos sensores de temperatura, observou-se um pico de aproximadamente 5 segundos para que o sensor retornasse a realizar a leitura da temperatura. Para a análise das falhas, não foi considerado o valor desse pico de leitura, porém, ele interferiu na estimativa da rede.

8 TRABALHOS FUTUROS

Como sugestão de trabalhos futuros para a Planta Experimental, seguem os seguintes tópicos que podem ser implementados:

- Inserção de falhas múltiplas com mais de duas variáveis de temperatura;
- Combinação da inserção de falhas nos sensores de temperatura com sensor de vazão e/ou pressão;
- Combinação da inserção de falhas elétricas (sensores) e mecânicas (válvulas);
- Aplicação de outras técnicas de inteligência artificial, como: colônia de formigas, lógica nebulosa (Fuzzy Logic), entre outras;
- Aplicar modelos de redes neurais e GMDH para outras condições de funcionamento explorando outros valores de vazão e potência do aquecedor;
- No caso das falhas mecânicas, adicionar uma quarta bomba e um novo tanque (TQ-04) para circulação do fluido, após a inserção de falhas no sistema, através das válvulas On/Off.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] DAVIES, R. Industry 4.0: Digitalisation for productivity and growth. **European Parliament**, 2015. Disponível em: < https://www.europarl.europa.eu/thinktank/en/document.html?reference=EPRS_BRI%282015%29568337>. Acesso em: 15 jun. 2019.
- [2] FEDERAL MINISTRY OF EDUCATION AND RESEARCH. **The High-Tech Strategy for Germany**. Bonn, Berlin: Public Relations Division, 2006.
- [3] HERMANN, M; PENTEK, T; OTTO, B. *Design Principles for Industrie 4.0 Scenarios: A Literature Review*. **Research Gate**, 2015. Disponível em: <https://www.researchGate.net/publication/307864150_Design_Principles_for_Industrie_40_Scenarios_A_Literature_Review>. Acesso em: 20 set. 2018.
- [4] UHLEMANN, T. H.J.; LEHMANN, C.; STEINHILPER, R. The Digital Twin: Realizing the Cyber-Physical Production System for Industry 4.0. In: **The 24th CIRP Conference on Life Cycle Engineering**, Mar. 8-10, 2017, Kamakura, Japan. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2212827116313129>> Acesso em: 02 dez. 2018.
- [5] WORD NUCLEAR NEWS. **Call for innovation in nuclear power plant operation**. Researched and written by wnn, 2019. Disponível em: <<https://www.world-nuclear-news.org/Articles/Call-for-innovation-in-nuclear-power-plant-operati>>. Acesso em: 15 jul. 2019.
- [6] FISHER, M. N.; ROUÉ, V. Current and Future Nuclear Energy Leaders 'Call to Action' for Innovation. **International Atomic Energy Agency (IAEA)**, Vienna, 10-12 jun. 2019. Disponível em: <<https://www.iaea.org/newscenter/news/current-and-future-nuclear-energyleaders-call-to-action-for-innovation>>. Acesso em: 15 jul. 2019.

- [7] GONÇALVES, I. M. P. **Monitoração e diagnóstico para detecção de falhas de sensores utilizando a metodologia GMDH**. 2006 Tese (Doutorado) Instituto de Pesquisas Energéticas, São Paulo.
- [8] BUENO, E. I. **Group Method of Data Handling (GMDH) e Redes Neurais na Monitoração e Detecção de Falhas em sensores de centrais nucleares**. 2011 Tese (Doutorado) Instituto de Pesquisas Energéticas, São Paulo.
- [9] ONWUBOLU G. et al.; **GMDH-Methodology and Implementation in Matlab**. Londres: Imperial College Press, 2016.
- [10] SANTOS, G.R. **Algoritmo de colônia de formigas e redes neurais artificiais aplicados na monitoração e detecção de falhas em centrais nucleares**. 2016 Dissertação (Mestrado) Instituto de Pesquisas Energéticas, São Paulo.
- [11] GU Y.; YANG GH. **Observer-based fault detection and isolation for a class of uncertain systems**. In: CHINESE CONTROL AND DECISION CONFERENCE, série de livros: Chinese Control and Decision Conference. v. 1-6 p. 2960-2963, 2011.
- [12] FEITAL, T. S.; KRUGER, U.; PINTO, J. C. et al. In: DE BRITO ALVES, R.M.; DO NASCIMENTO, C.A.O.; BISCAIA, E.C. Comparison between Statistical and Observer-Based Approaches for Fault Detection and Isolation in a Chemical Process. In: 10th International Symposium on Process Systems Engineering, Ago. 16-20, 2009, Salvador, BA. Série de livros: **Computer-Aided Chemical Engineering**, v. 27, p.1257-1262.
- [13] LI, Z.; JAIMOUKHA, I.M. Observer-based fault detection and isolation filter design for linear time-invariant systems. **International Journal of Control**, v. 82, ed. 1, p. 171-182, 2009.
- [14] YOUSSEF, A. B.; EL KHIL, S. K.; SLAMA-BELKHODJA, I. State Observer-Based Sensor Fault Detection and Isolation, and Fault Tolerant Control of a Single-

Phase PWM Rectifier for Electric Railway Traction. **IEEE Transactions on Power Electronics**, v. 28, ed. 12, p. 5842-5853, 2013.

[15] CHO, H. C. et al. Fault detection and isolation of induction motors using recurrent neural networks and dynamic Bayesian modeling. **IEEE Transactions on Control Systems Technology**, v. 18, n. 2, p. 430-437, 2010.

[16] PIERRI F.; PAVIGLIANITI, G.; CACCAVALE, F.; et al. Observer-based sensor fault detection and isolation and isolation for chemical batch reactors. **Engineering Applications of Artificial Intelligence**, v. 21, ed. 8, p.1204-1216, 2008.

[17] SADOUGH VANINI, Z. N.; KHORASANI, K.; MESKIN, N. Fault detection and isolation of a dual spoolgas turbine engine using dynamic neural networks and multiple model approach. **Information Sciences**,v. 259, p.234-251, 2014.

[18] KAMAL, M. M.; YU, D. W.; YU, D. L. Fault detection and isolation for PEM fuel cell stack with independent RBF model. **Engineering Applications of Artificial Intelligence**, v. 28, p.52-63, 2014.

[19] U.S. NRC (United States Nuclear Regulatory Commission). **Pressurized-Water Reactor (PWR)**. Disponível em: <<https://www.nrc.gov/reading-rm/basic-ref/students/multimedia/animated-images-plants-pwr-bwr.html>> Acesso em 28 nov. 2018.

[20] TERREMOTO L. A. A. **Fundamentos de Tecnologia Nuclear Reatores**. Instituto de Pesquisas Energéticas e Nucleares (IPEN/CNEN-SP). São Paulo: Divisão de Ensino - Secretaria de Pós-Graduação Disciplina TNR5764, 2004.

[21] DUDERSTADT, J. J.; HAMILTON, L. J., **Nuclear Reactor Analysis**, New York: Wiley, 1976.

[22] NATIONAL INSTRUMENTS. **What is a Pulse Width Modulation (PWM) Signal and What is it Used For?**. Disponível em: <<https://knowledge.ni.com/KnowledgeArticleDetails?id=kA00Z0000019OkFSAU>>. Acesso em: 8 fev. 2019.

- [23] ISA. **ANSI/ISA-S5.1 - Instrumentation Symbols and Identification**. Research Triangle Park, North Carolina: Instrument Society of America, 1984 (R1992).
- [24] MATHWORKS. **PDF Documentation for MATLAB**. Disponível em: <https://www.mathworks.com/help/pdf_doc/matlab/index.html>. Acesso em: 12 jan. 2016.
- [25] SCADA Supervisory Control and Data Acquisition. **“O que é um sistema SCADA?”** Disponível em: <<http://www.scadabr.com.br/?q=node/1>>. Acesso em: 02 mar. 2014.
- [26] CERN A.D.; CERN W.S. **What is SCADA?**. International Conference on Accelerator and Large Experimental Physics Control Systems, Trieste, Italy 1999. Disponível em: <<http://cds.cern.ch/record/532624/files/mc1i01.pdf>> Acesso em Jan. 2019.
- [27] OPC FOUNDATION. **What is OPC?** Disponível em: <<https://opcfoundation.org/about/what-is-opc>>. Acesso em: 02 dez. 2018.
- [28] BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B. **Redes Neurais Artificiais - Teoria e Aplicações**. 2. ed. Rio de Janeiro: LTC, 2007.
- [29] HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. 2. ed. New Jersey: Prentice Hall, 1999.
- [30] IVAKHNENKO, A. G. Self-teaching Systems of Recognition and Automatic Control. **Tekhnika**, 392, 1969.
- [31] AKSENOVA, T.I.; YURACHKOVSKY, Yu. P. A. Characterisation at Unbiased Structure and Conditions of Their J-Optimality, **Sov. of J. Automation and Information Sciences**, v. 21, n. 4, p. 36-42, 1998.
- [32] FARLOW, S. J. **Self-organizing Methods in Modeling: GMDH-type algorithms**. New York: M. Dekker, 1984.

INSTITUTO DE PESQUISAS ENERGÉTICAS E NUCLEARES
Diretoria de Pesquisa, Desenvolvimento e Ensino
Av. Prof. Lineu Prestes, 2242 – Cidade Universitária CEP: 05508-000
Fone/Fax(0XX11) 3133-8908
SÃO PAULO – São Paulo – Brasil
<http://www.ipen.br>

O IPEN é uma Autarquia vinculada à Secretaria de Desenvolvimento, associada à Universidade de São Paulo e gerida técnica e administrativamente pela Comissão Nacional de Energia Nuclear, órgão do Ministério da Ciência, Tecnologia, Inovações e Comunicações.