

**UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO
EM ENGENHARIA MECÂNICA**

**Diagnóstico de Falhas em Componentes de Turbinas a Gás Utilizando Redes Neurais
Artificiais**

José Biruel Junior

Itajubá, abril de 2016

**UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA MECÂNICA**

José Biruel Junior

**Diagnóstico de Falhas em Componentes de Turbinas a Gás Utilizando Redes Neurais
Artificiais**

**Tese submetida ao Programa de Pós-
Graduação em Engenharia Mecânica como
parte dos requisitos para obtenção do Título
de Doutor em Ciências em Engenharia
Mecânica.**

Área de Concentração: Conversão de Energia

Orientador: Dr. Marco Antonio R. Nascimento

**Abril de 2016
Itajubá**

**UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA MECÂNICA**

José Biruel Junior

**Diagnóstico de Falhas em Componentes de Turbinas a Gás Utilizando Redes Neurais
Artificiais**

Tese aprovada por banca examinadora em 22 de
abril de 2016, conferindo ao autor o título de ***Doutor em
Ciências em Engenharia Mecânica.***

Banca Examinadora:

Prof. Dr. Marco Antonio Rosa do Nascimento (Orientador)

Profa. Dra. Lucilene de Oliveira Rodrigues (UNIFEI)

Prof. Dr. Carlos Henrique Valério de Moraes (UNIFEI)

Dr. Marcelo Assato (IAE)

Dr. Sandro Barros Ferreira (GT2)

Itajubá
2016

AGRADECIMENTOS

Agradeço à PETROBRAS pelo incentivo e apoio à capacitação de seus empregados, que no âmbito de seu Programa de Desenvolvimento de Recursos Humanos, aprovou e suportou a realização deste trabalho, confiante no retorno deste investimento, refletido no aumento de produtividade da Companhia.

Igualmente, agradeço aos gerentes do Centro de Pesquisas da PETROBRAS (CENPES), Paulo Roberto Barreiros Neves e Fernando Vieira Castellões, que me confiaram esta missão, aprovaram o aporte de recursos e, principalmente, concederam a utilização de parte de meu horário de trabalho para a realização do doutorado. Também agradeço o consultor Bruno de Queiroz Lima pelo auxílio na obtenção dos dados da campanha operacional da termelétrica em estudo.

Em especial, agradeço meu amigo e orientador Professor Dr. Marco Antônio Nascimento pelos ensinamentos técnicos, pela orientação pedagógica, pelos contatos estabelecidos com fabricantes e universidades e, principalmente, pela confiança em meu trabalho nestes anos de caminhada.

Agradeço aos Professores Dr. Yiguand Li e Dr. Pericles Pilidis pelo direcionamento dos estudos iniciais deste trabalho e pela presteza durante o período que passei na Universidade de Cranfield na Inglaterra. Ainda, agradeço aos membros da banca examinadora pelas inúmeras contribuições durante o exame de qualificação, que tornaram possível a defesa desta Tese.

Vou ser sempre grato à amiga Cristina Santos Amorim pelo grande auxílio com as referências bibliográficas e com a formatação final da Tese.

Destaco a importância do apoio, companheirismo, perseverança e paciência de minha esposa Fernanda, fundamentais para o sucesso deste trabalho. Da mesma forma, sou grato aos meus filhos caninos Rebeca e Nietzsche e minha gata Cutting, sempre presentes nos momentos mais difíceis, assim como, aos meus pais José (In memoriam) e Santina.

Por fim, agradeço a Deus por colocar tanta gente competente em meio caminho.

RESUMO

A geração de energia termelétrica no Brasil vem crescendo nas últimas duas décadas, visto que a maior parte dos recursos hídricos, destinados para geração hidrelétrica, já foram explorados. De maneira a manter a energia elétrica a preços razoáveis, inúmeras iniciativas foram tomadas, incluindo a redução de custos de operação e manutenção de usinas termelétricas. Nesse contexto, as técnicas de diagnóstico de falhas em componentes de turbinas a gás podem melhorar a qualidade da manutenção, reduzindo o tempo da turbina parada e, desta forma, aumentando a disponibilidade da usina, enquanto maximiza o lucro operacional, mantendo a eficiência da turbina a gás em níveis adequados. Nesta Tese, uma técnica de diagnóstico de falhas baseada em redes neurais artificiais foi desenvolvida para avaliar as condições de saúde operacional de uma turbina a gás industrial de eixo simples ALSTOM GT11N2. Primeiramente, um modelo da turbina a gás foi elaborado utilizando o software PYTHIA 2.8, onde dados de uma turbina real foram utilizados no processo de convergência do modelo. Em seguida, foram aplicados diferentes níveis de degradação nos parâmetros independentes dos componentes do modelo da turbina a gás para gerar as amostras de treinamento e validação das redes neurais artificiais. Então, uma estrutura hierarquizada de três níveis foi estabelecida compreendendo as funções de detecção, isolamento e quantificação de falhas, sendo representadas por arquiteturas específicas de redes neurais, que são treinadas para tratar medições sem e com ruído. No primeiro caso, as redes neurais individuais apresentaram excelente desempenho, enquanto no último foi alcançado bom resultado, a menos de poucos problemas com a rede de isolamento de falhas. No entanto, toda a estrutura do sistema hierárquico de diagnóstico apresentou, respectivamente, bom e aceitável desempenho quando analisando esses dois casos. Além do esforço mencionado, também é objeto desta Tese a investigação das técnicas de filtragem de sinais de sensores de medição, de forma a promover a suavização e remoção de ruídos dos sinais oriundos dos instrumentos de medição, resultando em parâmetros dependentes adequados para serem submetidos à análise de diagnóstico pela técnica proposta. Finalmente, a metodologia completa é aplicada a uma campanha operacional da turbina a gás para verificação de sua efetividade.

Palavras Chaves: Análise do Caminho do Gás, Redes Neurais Artificiais, Sistema Hierárquico de Diagnóstico, Monitoramento da Saúde Operacional de Turbinas a Gás, Turbinas a Gás Industriais

ABSTRACT

Thermoelectricity generation in Brazil has been on the increase over the last two decades, since most of the hydraulic resources that are used to drive the hydropower plants have already been deployed. In order to keep electrical energy at reasonable prices, several initiatives have been taken which include a reduction in operating and maintenance costs of thermoelectric facilities. In this context, engine component fault diagnostic techniques are intended to enhance maintenance quality, reducing engine downtime, and thereby increasing plant availability, whilst maximizing operational profit by keeping engine efficiency at a standard level. In this Thesis, an artificial neural network based fault diagnostic technique has been developed to assess the health condition of a single shaft heavy duty engine ALSTOM GT11N2. Firstly, an engine model is carried out using PYTHIA 2.8, where actual engine data is used in the matching process. Secondly, component parameters degradations are applied to the model to generate neural network training and validation samples. Thus, a three level hierarchical structure is established comprising fault detection, isolation, and quantification functions, each represented by specific neural network architecture, which are trained to tackle both measurement data without and with noise. In the former case, the individual networks have presented excellent performance, while in the latter good performance has been achieved, despite a few problems with the fault isolation network. Nonetheless, the whole hierarchical neural network has presented, respectively, good and acceptable performance when analyzing these two cases. Furthermore, this Thesis also aim to investigate the measurements signal filtering techniques, in order to promote data smoothing and noise removal, yielding suitable dependent parameters to be used in the herein stated diagnostic technique. Finally, the thorough methodology is implemented over a gas turbine engine operational campaign in order to attest its effectivity.

Keywords: Gas Path Analysis, Artificial Neural Network, Hierarchical Diagnostic System, Gas Turbine Engine Health Monitoring, Heavy Duty Gas Turbine Engine

SUMÁRIO

1 INTRODUÇÃO	18
1.1 Motivação	18
1.2 Um Breve Histórico dos Sistemas de Diagnóstico de Falha em Turbinas a Gás Industriais.....	20
1.3 Objetivos	22
1.4 Estrutura da Tese	24
2 REVISÃO DA LITERATURA	26
2.1 Introdução	26
2.2 Sistemas de Diagnóstico de Falhas em Turbinas a Gás	26
2.2.1 Tipos de Falhas em Componentes da Turbina a Gás	27
2.2.2 Sistemas de Diagnóstico de Falhas	30
2.2.3 Análise das Medições.....	33
2.2.4 Processamento de Sinal.....	35
2.2.5 Revisão Bibliográfica das Aplicações de Diagnóstico de Falhas	37
2.3 Redes Neurais Artificiais	40
2.3.1 Tipos e Arquiteturas de RNA.....	41
2.3.2 Métodos de Treinamento de RNA	45
2.3.3 Revisão Bibliográfica da Aplicação de RNA para Diagnóstico de Falhas em Turbinas a Gás.....	49
2.4 Comentários	52
3 METODOLOGIA DO SISTEMA HIERÁRQUICO DE DIAGNÓSTICO.....	55
3.1 Introdução	55
3.2 Parâmetros do Sistema Hierárquico de Diagnóstico.....	56
3.2.1 Tratamento de Sinais de Sensores de Medição	57
3.3 Arquitetura do Sistema Hierárquico de Diagnóstico	59
3.4 Arquitetura das Redes Neurais Individuais	60
3.4.1 Arquitetura da RNA para Detecção de Degradação.....	60
3.4.2 Arquitetura da RNA para Isolamento de Falhas	61
3.4.3 Arquitetura da RNA para Quantificação de Falhas.....	62
3.5 Métodos de Validação de RNA	64
3.5.1 Método de Validação da RNA de Detecção de Degradação.....	65
3.5.2 Método de Validação da RNA de Isolamento de Falhas	65

3.5.3 Método de Validação da RNA de Quantificação de Falhas.....	66
3.5.4 Método do Sistema Hierárquico de Diagnóstico.....	68
3.6 Modelo de Diagnóstico de Falhas.....	69
3.7 Comentários.....	70
4 MODELO DA TURBINA A GÁS.....	72
4.1 Introdução	72
4.2 Turbina ALSTOM GT11N2	73
4.3 Simulação da Turbina Utilizando PYTHIA.....	76
4.4 Modelo Termodinâmico Turbina a Gás	78
4.5 Mapa dos Principais Componente da Turbina a Gás	81
5 APLICAÇÃO DO SISTEMA HIERÁRQUICO DE DIAGNÓSTICO	85
5.1 Introdução	85
5.2 Amostras de Treinamento e Validação das RNA	86
5.3 Validação do Sistema Hierárquico de Diagnóstico	92
5.3.1 Caso Teste Utilizando Simulações sem Ruído de Medição	93
5.3.2 Caso Teste Utilizando Simulações com Ruído de Medição	101
5.4 Monitoramento da Campanha de Operação.....	106
5.4.1 Correção dos Parâmetros Dependentes pela Temperatura Ambiente	106
5.4.2 Aplicação de Filtros nos Parâmetros Dependentes	111
5.4.3 Diagnóstico de Falhas dos Componentes da Turbina a Gás	123
6 CONCLUSÕES E COMENTÁRIOS	133
6.1 Trabalhos Futuros	137
REFERENCIAS BIBLIOGRAFICAS	139
APÊNDICES	143
Apêndice A – Código de Simulação no TURBOMATCH.....	144
Apêndice B – Código de Treinamento e Validação das RNA.....	149
Apêndice C – Comportamento dos Parâmetros Dependentes (Degradação Combinada) ..	157
Apêndice D – Arquiteturas das Redes Neurais Artificiais.....	162

LISTA DE FIGURAS

Figura 1.1 - Confiabilidade e Disponibilidade de Sistemas de Turbinas a Gás (Adaptado de SINGH, 1999).....	21
Figura 2.1 - Compressor Danificado por Surto na Turbina a Gás (Adaptado de LIMA & CRUXEN, 2015)	29
Figura 2.2 - Erro de Medição (adaptado de LI, 2011).....	35
Figura 2.3 - Representação do Processo de Diagnóstico de Turbina a Gás (Adaptado de GANGULI, 2013).....	35
Figura 2.4 - Diagrama Esquemático de um Neurônio (BEALE; HAGAN; DEMUTH, 2011).....	40
Figura 2.5 - Funções de Transferência: (a) Degrau, (b) Linear, (c) Sigmoid. (BEALE; HAGAN; DEMUTH, 2011)	41
Figura 2.6 - Modelo Esquemático de uma RNA com Múltiplas Camadas (BEALE; HAGAN; DEMUTH, 2011).....	42
Figura 2.7 - Modelo Esquemático de um Perceptron de Simples Camada (BEALE; HAGAN; DEMUTH, 2011).....	43
Figura 2.8 - Representação Esquemática de uma RNA Feed-Forward (BEALE; HAGAN; DEMUTH, 2011).....	43
Figura 2.9 - Representação Esquemática de uma RNA Probabilística (BEALE; HAGAN; DEMUTH, 2011).....	44
Figura 2.10 - Representação Esquemática de uma RNA de duas camadas (GUPTA; JIN; HOMMA., 2003).....	46
Figura 3.1 - Modelo Esquemático Simplificado da Turbina	56
Figura 3.2 - Ruído: (a) Representação Estatística; (b) Método da Estimativa	58
Figura 3.3 - Arquitetura do Sistema hierárquico de Diagnóstico	60
Figura 3.4 - Algoritmo de Diagnóstico de Falhas	70
Figura 4.1 - Secção Horizontal GT11N2 (ALSTOM,2007).....	74
Figura 4.2 - Representação Esquemática da GT11N2 (ALSTON, 2010)	74
Figura 4.3 - Diagrama Básico de Processamento do TURBOMATCH (CRANFIELD UNIVERSITY, 1999).....	77
Figura 4.4 - Estrutura do Modelo da Turbina.....	78
Figura 4.5 - Representação Esquemática do Modelo da Turbina a Gás.....	79
Figura 4.6 - Diagrama T-S (Temperatura x Entropia) do Ponto de Referência Operacional do Modelo da Turbina	79
Figura 4.7 - Mapa de Desempenho do Compressor (Fluxo de Massa x Razão de Pressão)	82

Figura 4.8 - Mapa de Desempenho do Compressor (Razão de Pressão x Eficiência)	83
Figura 4.9 - Mapa de Desempenho da Turbina (Função Trabalho x Fluxo de Massa)	84
Figura 4.10 - Mapa de Desempenho da Turbina (Função Trabalho x Eficiência)	84
Figura 5.1 - Comportamento da Temperatura de Saída do Compressor sob Degradação do Compressor	87
Figura 5.2 - Comportamento da Temperatura de Saída da Turbina sob Degradação do Compressor	87
Figura 5.3 - Comportamento da Pressão de Saída do Compressor sob Degradação do Compressor	88
Figura 5.4 - Comportamento da Potência de Eixo sob Degradação do Compressor	89
Figura 5.5 - Comportamento da Temperatura de Saída do Compressor sob Degradação da Turbina	89
Figura 5.6 - Comportamento da Temperatura de Saída da Turbina sob Degradação da Turbina	90
Figura 5.7 - Comportamento da Pressão de Saída do Compressor sob Degradação da Turbina	91
Figura 5.8 - Comportamento da Potência de Eixo sob Degradação da Turbina	91
Figura 5.9 – Temperatura de Saída do Compressor <i>versus</i> Temperatura Ambiente	107
Figura 5.10 – Temperatura de Saída da Turbina <i>versus</i> Temperatura Ambiente	108
Figura 5.11 - Pressão de Saída do Compressor <i>versus</i> Temperatura Ambiente	108
Figura 5.12 – Potência de Eixo <i>versus</i> Temperatura Ambiente	109
Figura 5.13 – Variação da Temperatura Ambiente Durante Campanha Operacional 2012 ...	110
Figura 5.14 – Temperatura de Saída do Compressor: Valores Medidos e Corrigidos pela Temperatura Ambiente	110
Figura 5.15 – Temperatura de Saída da Turbina: Valores Medidos e Corrigidos pela Temperatura Ambiente	111
Figura 5.16 – Potência de Eixo: Valores Medidos e Corrigidos pela Temperatura Ambiente	111
Figura 5.17 – Filtros: Média Móvel e Média Móvel Ponderada Exponencial (T_3)	114
Figura 5.18 - Filtros: Média Móvel e Média Móvel Ponderada Exponencial (T_6)	114
Figura 5.19 - Filtros: Média Móvel e Média Móvel Ponderada Exponencial (P_3)	115
Figura 5.20 - Filtros: Média Móvel e Média Móvel Ponderada Exponencial (POT)	115
Figura 5.21 – Filtro: Mediana Ponderada Centrada (T_3)	116
Figura 5.22 – Filtro: Mediana Ponderada Centrada (T_6)	116

Figura 5.23 – Filtro: Mediana Ponderada Centrada (P_3)	117
Figura 5.24 – Filtro: Mediana Ponderada Centrada (POT)	117
Figura 5.25 - Filtros: Mediana Ponderada Centrada e Híbrido Racional-Mediana (T_3)	118
Figura 5.26 - Filtros: Mediana Ponderada Centrada e Híbrido Racional-Mediana (T_6)	118
Figura 5.27 - Filtros: Mediana Ponderada Centrada e Híbrido Racional-Mediana (P_3).....	119
Figura 5.28 - Filtros: Mediana Ponderada Centrada e Híbrido Racional-Mediana (POT)....	119
Figura 5.29 - Filtros: Mediana Ponderada Centrada e Híbrido Linear Finito-Mediana (T_3)..	120
Figura 5.30 - Filtros: Mediana Ponderada Centrada e Híbrido Linear Finito-Mediana (T_6)..	120
Figura 5.31 - Filtros: Mediana Ponderada Centrada e Híbrido Linear Finito-Mediana (P_3)..	121
Figura 5.32 - Filtros: Mediana Ponderada Centrada e Híbrido Linear Finito-Mediana (POT)	121
Figura 5.33 –Desvio no Coeficiente de Vazão do Compressor (RNA sem Ruído e Medição sem Filtro)	124
Figura 5.34 – Desvios no Coeficiente de Vazão do Compressor (RNA sem Ruído e Medição com Filtro).....	124
Figura 5.35 – Desvios no Coeficiente de Vazão do Compressor (RNA com Ruído e Medição sem Filtro)	125
Figura 5.36 – Desvios no Coeficiente de Vazão do Compressor (RNA com Ruído e Medição com Filtro).....	125
Figura 5.37 – Desvio na Eficiência do Compressor (RNA sem Ruído e Medição sem Filtro)	126
Figura 5.38 – Desvio na Eficiência do Compressor (RNA sem Ruído e Medição com Filtro)	126
Figura 5.39 – Desvio na Eficiência do Compressor (RNA com Ruído e Medição sem Filtro)	127
Figura 5.40 – Desvio na Eficiência do Compressor (RNA com Ruído e Medição com Filtro)	127
Figura 5.41 – Desvio no Coeficiente de Vazão da Turbina (RNA sem Ruído e Medição sem Filtro).....	128
Figura 5.42 – Desvio no Coeficiente de Vazão da Turbina (RNA sem Ruído e Medição com Filtro).....	128
Figura 5.43 – Desvio no Coeficiente de Vazão da Turbina (RNA com Ruído e Medição sem Filtro).....	129
Figura 5.44 – Desvio no Coeficiente de Vazão da Turbina (RNA com Ruído e Medição com Filtro).....	129

Figura 5.45 – Desvio na Eficiência da Turbina (RNA sem Ruído e Medição sem Filtro).....	130
Figura 5.46 – Desvio na Eficiência da Turbina (RNA sem Ruído e Medição com Filtro)	130
Figura 5.47 – Desvio na Eficiência da Turbina (RNA com Ruído e Medição sem Filtro)	131
Figura 5.48 – Desvio na Eficiência da Turbina (RNA com Ruído e Medição com Filtro)....	131

LISTA DE TABELAS

Tabela 3.1- Desvio Padrão das Medições.....	59
Tabela 3.2- Matriz de Confusão para Avaliar a Qualidade da RNA de Isolamento de Falhas	66
Tabela 4.1- Principais Características da ALSTOM GT11N2 (ALSTOM, 2010).....	73
Tabela 4.2 – Resultados da Modelagem do Ponto de referência operacional	78
Tabela 4.3 - Valores das Propriedades Termodinâmicas nas Estações do Modelo.....	81
Tabela 4.4 - Razão de Pressão Máxima dos Mapas de Compressores (Adaptado de LI, 2011)	82
Tabela 4.5 - Máxima Razão de Salto Entálpico dos Mapas de Turbinas (Adaptado de LI, 2011).....	83
Tabela 5.1 - Avaliação da RNA de Detecção de Degradação	94
Tabela 5.2 – Matriz de Confusão do Processo de Treinamento da RNA de Isolamento de Falhas.....	95
Tabela 5.3 – Matriz de Confusão do Processo de Validação da RNA de Isolamento de Falhas	95
Tabela 5.4 - EQM do Processo de Treinamento da RNA de Quantificação de Falhas no Compressor.....	97
Tabela 5.5 - EQM do Processo de Validação da RNA de Quantificação de Falhas no Compressor.....	97
Tabela 5.6 - EQM do Processo de Treinamento da RNA de Quantificação de Falhas na Turbina	99
Tabela 5.7 - EQM do Processo de Validação da RNA de Quantificação de Falhas na Turbina	99
Tabela 5.8 - Erros das Estimativas dos Parâmetros dos Componentes	100
Tabela 5.9 - Estimativa de Erro da Sistema Hierárquico de Diagnóstico	100
Tabela 5.10 - Avaliação da RNA de Detecção de Degradação (Simulação com Ruído).....	102
Tabela 5.11 - Avaliação do Processo de Treinamento da RNA de Isolamento de Falhas (Simulação com Ruído).....	102
Tabela 5.12 - Validação da RNA de Isolamento de Falhas (Simulação com Ruído).....	103
Tabela 5.13 - EQM do Treinamento da RNA de Quantificação de Falhas no Compressor (Simulação com Ruído).....	103
Tabela 5.14 - EQM da Validação da RNA de Quantificação de Falhas no Compressor (Simulação com Ruído).....	104

Tabela 5.15 - EQM do Treinamento da RNA de Quantificação de Falhas na Turbina (Simulação com Ruído).....	104
Tabela 5.16 - EQM do Processo de Validação da RNA de Quantificação de Falhas na Turbina	105
Tabela 5.17 - Erros das Estimativas dos Parâmetros dos Componentes (Simulação com Ruído).....	105
Tabela 5.18 - Estimativa de Erro da Sistema Hierárquico de Diagnóstico (Simulação com Ruído).....	106
Tabela 5.19 – Filtros Utilizados para Suavização dos Sinais de Medição	113
Tabela 5.20 - Comparação Entre as Técnicas de Suavização de Dados.....	122

SIMBOLOGIA

a	Vetor de Saída das Redes Neurais Artificiais
ACM	Matriz de Coeficiente de Adaptação (<i>Adaptation Coefficient Matrix</i>)
AGPA	Análise do Caminho do Gás Adaptativa (<i>Adaptive Gas Path Analysis</i>)
AI	Inteligência Artificial (<i>Artificial Intelligence</i>)
b	Vetor Tendência das Redes Neurais Artificiais
CMD	Centro de Monitoramento e Diagnóstico
CWM	Filtro Mediana Ponderada Centrada (<i>Center Weighted Median</i>)
CV	Coeficiente de Vazão
EQM	Erro Médio Quadrático
f	Função de Transferência das Redes Neurais Artificiais
FCM	Matriz de Coeficiente de Falhas (<i>Fault Coefficient Matrix</i>)
FHFM	Filtro Híbrido Linear Finito-Mediana
FHRM	Filtro Híbrido Racional-Mediana
FIR	Filtro de Resposta ao Impulso Finito (<i>Finite Impulse Response</i>)
FMP	Filtro Mediana Ponderada Centrada
GPA	Análise do Caminho do Gás (<i>Gas Path Analysis</i>)
H_4	Entalpia de Entrada da Turbina
H_6	Entalpia de Saída da Turbina
ICM	Matriz de Coeficiente de Influência (<i>Influence Coefficient Matrix</i>)
i_d	Vetor de Entrada da RNA de Detecção de Degradação
i_i	Vetor de Entrada da RNA de Isolamento de Falhas
i_{qc}	Vetor de Entrada da RNA de Quantificação de Falhas do Compressor
i_{qt}	Vetor de Entrada da RNA de Quantificação de Falhas da Turbina
i_{qct}	Vetor de Entrada da RNA de Quantificação de Falhas Combinada

IGV	Pás Direcionadoras de Entrada (<i>Inlet Guide Vanes</i>)
IIR	Filtro de Resposta ao Impulso Infinito (<i>Infinite Impulse Response</i>)
ISA	Atmosfera Padrão Internacional (<i>International Standard Atmosphere</i>)
KF	Filtros de Kalman (<i>Kalman Filter</i>)
LGPA	Análise do Caminho do Gás Linear (<i>Linear Gas Path Analysis</i>)
NLGPA	Análise do Caminho do Gás Não Linear (<i>Non Linear Gas Path Analysis</i>)
N_C	Número Total de Amostras com Falha no Compressor
N_C^C	Número de Amostras com Falha no Compressor Isoladas Corretamente
N_{CT}	Número Total de Amostras com Falha Combinada
N_{CT}^{CT}	Número de Amostras com Falha Combinada Isoladas Corretamente
N_S	Número Total de Estimativas da RNA de Detecção de Degradação
N_R	Número de Amostras Detectadas com Sucesso pela RNA de Detecção
N_T	Número Total de Amostras com Falha na Turbina
N_T^T	Número de Amostras com Falha na Turbina Isoladas Corretamente
P_{Amb}	Pressão Ambiente
P_{3c}	Medição de Pressão na Saída do Compressor Saudável
POT	Potência de Eixo
POT_d	Medição de Potência de Eixo da Turbina Degradada
POT_c	Medição de Potência de Eixo da Turbina Saudável
P_2	Pressão de Entrada do Compressor
P_3	Pressão de Saída do Compressor
P_{3d}	Medição de Pressão na Saída do Compressor Degradado
P_R	Elemento do Vetor de Entrada das Redes Neurais Artificiais
RNA	Redes Neurais Artificiais
SMST	Sistema de Monitoramento da Saúde da Turbina a Gás

T_{Amb}	Temperatura Ambiente
T^{AI}	Taxa de Acertos no Isolamento de Falhas
T_2	Temperatura de Entrada do Compressor
T_3	Temperatura de Saída do Compressor
T_{3c}	Medição de Temperatura na Saída do Compressor Saudável
T_{3d}	Medição de Temperatura na Saída do Compressor Degradado
T_4	Temperatura de Entrada da Turbina
T_5	Temperatura de Saída da Turbina
T_{5c}	Medição de Temperatura na Saída da Turbina Saudável
T_{5d}	Medição de Temperatura na Saída da Turbina Degradada
t_d	Vetor Alvo da RNA de Detecção de Degradação
t_i	Vetor Alvo da RNA de Isolamento de Falhas
t_{qc}	Vetor Alvo da RNA de Quantificação de Falhas no Compressor
t_{qt}	Vetor Alvo da RNA de Quantificação de Falhas na Turbina
t_{qct}	Vetor Alvo da RNA de Quantificação de Falhas Combinadas
$W_{1,R}$	Peso Atribuído ao Vetor de Entrada das Redes Neurais Artificiais
WLS	Mínimos Quadrados Ponderados (<i>Weighted Least Square</i>)
ΔT_3	Desvio de Medição na Temperatura de Saída do Compressor
ΔT_5	Desvio de Medição na Temperatura de Saída da Turbina
ΔP_3	Desvio de Medição na Pressão de Saída do Compressor
ΔPOT	Desvio de Medição na Potência de Eixo
$\Delta \Gamma_c$	Desvio no Coeficiente de Vazão do Compressor
$\Delta \eta_c$	Desvio na Eficiência do Compressor
$\Delta \Gamma_T$	Desvio no Coeficiente de Vazão da Turbina
$\Delta \eta_T$	Desvio na Eficiência da Turbina

ε_{ij}^{CFD}	EQM da Estimativa da RNA de Quantificação de Falhas no Compressor
ε^{DD}	Erro da Estimativa da RNA de Detecção de Degradação
ε_{ij}^{TFQ}	EQM da Estimativa da RNA de Quantificação de Falhas na Turbina
η_C	Eficiência Isentrópica do Compressor
η_T	Eficiência Isentrópica da Turbina
σ_k^{CTQ}	Desvio Padrão dos Erros do Sistema Hierárquico de Diagnóstico
μ_k^{CTQ}	Média dos Erros do Sistema Hierárquico de Diagnóstico

1 INTRODUÇÃO

1.1 Motivação

No ano de 2010, ocorreu um aumento de 10% na geração de energia elétrica no Brasil em relação ao ano anterior, alcançando a produção de 507,2 TWh de energia elétrica, com 74% advindo de hidrelétricas. A capacidade de geração de eletricidade instalada total brasileira alcançou 113 GW, sendo esse montante dividido em 71,2% de hidrelétricas, 26,2% de termelétricas, 1,8% de termonuclear e 0,8% de eólicas (EMPRESA DE PESQUISA ENERGÉTICA, 2011).

A geração de energia elétrica de base hídrica é dependente das estações do ano. Durante o período seco, o nível da água nos reservatórios cai, chegando perto do volume morto (mínimo nível operacional seguro). De forma a evitar problemas operacionais nas instalações e falta de energia na rede, o Sistema Integrado Nacional (SIN) intensifica os despachos de termelétricas nestas ocasiões.

Os impactos da sazonalidade dos fenômenos climáticos não são novidade e vêm afetando os padrões operacionais das hidrelétricas desde sua ativação. Entretanto, somente após o início dos anos 2000 que o consumo de energia passou a exceder os níveis de segurança dos reservatórios das hidrelétricas, levando à construção de diversas termelétricas, que, a princípio, foram utilizadas para complementar a oferta de energia elétrica na rede para atendimento da demanda durante o período seco.

Neste contexto, a Petróleo Brasileiro S.A (PETROBRAS) teve um papel vital, sendo responsável pela liderança na implantação de usinas termelétricas a gás natural no Brasil. Originalmente, estas instalações pertenciam às parcerias internacionais com a participação da PETROBRAS, que com o tempo comprou a participação dos demais acionistas, tornando-se a única proprietária dos ativos. Atualmente, a PETROBRAS possui uma capacidade instalada de geração termelétrica de 5,5 GW, sendo em grande parte composta de usinas de ciclo combinado e cogeração movidas a gás natural. Ainda, outros projetos estão em fase de implantação para aumentar esse número nos próximos anos (PETROBRAS, 2016).

A Usina Termelétrica Governador Leonel Brizola, usina com maior capacidade de geração do portfólio de usinas da PETROBRAS, possui uma capacidade instalada de geração de energia

de 1000 MW e capacidade de produção de vapor de alta pressão de 400 ton/h. Esta usina de geração em ciclo combinado com cogeração, movida a gás natural, compreende 6 turbinas a gás industriais ALSTOM GT11N2, 6 caldeiras de recuperação de calor, 3 turbinas a vapor e uma tubulação de exportação de vapor de alta pressão, divididos em 3 conjuntos (PETROBRAS, 2016).

A necessidade de redução de custos levou a implantação de um projeto de otimização de todo o parque termelétrico da PETROBRAS, com iniciativas em diversas áreas, onde manutenção baseada na condição operacional apresenta uma real oportunidade de redução de custo. Para tanto, a PETROBRAS implantou um centro de monitoramento e diagnóstico (CMD), que atua de forma remota, tratando variáveis operacionais de forma contínua e integrada em uma sala de controle capaz de gerar diagnósticos preditivos de 17 usinas termelétricas. O CMD realiza o acompanhamento de desempenho da condição mecânica de 63 turbinas a gás, 13 turbinas a vapor, 11 compressores de gás natural, 131 geradores e 59 motores de combustão interna (LIMA; GUEDES; D'OLIVEIRA, 2015).

O sistema de monitoramento do CMD utiliza técnicas de análise de vibração, análise de óleo de mancais e acompanhamento da tendência dos parâmetros de desempenho dos equipamentos para realização da análise de diagnóstico.

Do ponto de vista da contribuição para a PETROBRAS, esta Tese tem o objetivo de otimizar o trabalho realizado no CMD, provendo uma ferramenta automatizada de diagnóstico de falhas.

A realização deste doutorado na Universidade Federal de Itajubá (UNIFEI) foi aprovada pelo Programa de Desenvolvimento de Recursos Humanos da PETROBRAS, com a finalidade de desenvolver competências técnicas que a empresa julga essenciais para o seu negócio. Para tanto, o doutorando complementou sua formação técnica na Universidade de Cranfield, na Inglaterra, onde cursou as disciplinas do curso de especialização em turbina a gás e recebeu orientação dos Professores Dr. Yiguang Li e Dr. Pericles Pilidis. Neste período, com duração de 13 meses, foi possível aprofundar os conhecimentos em análise de desempenho de turbinas a gás e iniciar o desenvolvimento desta Tese.

Sob a supervisão do Professor Dr. Yiguang Li, a turbina a gás foi modelada utilizando primeiramente o software TURBOMATCH (PALMER, 1999, apud NKOI; PILIDIS; NIKOLAIDIS, 2013) e, num segundo momento, o software PYTHIA 2.8 (ESCHER, 1995),

ambos de propriedade da própria universidade. Além disso, foi desenvolvida e validada a metodologia do sistema hierárquico de diagnóstico para detecção, isolamento e quantificação de falhas em turbinas a gás.

A experiência obtida na Universidade de Cranfield foi muito proveitosa para esta Tese, pois possibilitou um contato muito intenso com as principais linhas de pesquisas no campo de turbinas a gás, bem como a identificação de suas lacunas e potenciais pontos de melhoria. Outro ponto de destaque, foi o contato prático com o equipamento, seja por meio de realização de ensaios operacionais na turbina a gás AVON da universidade ou pelas visitas à fábrica de turbinas a gás da Rolls Royce em Derby, na Inglaterra.

1.2 Um Breve Histórico dos Sistemas de Diagnóstico de Falha em Turbinas a Gás Industriais

O uso de turbinas a gás em aplicações industriais, como acionadores primários de máquinas rotativas ou geração de energia, vem crescendo na última década. Estas turbinas podem ser aero derivadas ou turbinas industriais (*heavy duty*). A turbina a gás aero derivada consiste em uma adaptação da turbina a gás aeronáutica, onde normalmente o bocal convergente é substituído por uma turbina de potência, permitindo a produção de potência útil de eixo. A turbina a gás industrial (*heavy duty*) consiste de uma turbina a gás projetada para tal aplicação. A vida útil de uma turbina a gás industrial, sem necessidade de uma manutenção completa, é aproximadamente 100.000 horas, enquanto uma turbina a gás aeronáutica deve ser inspecionada mais frequentemente. Ainda, limitações de aplicações industriais em relação ao peso e tamanho são bem menos restritas que aquelas para aplicações aeronáuticas. Finalmente, aplicações industriais requerem potência de eixo, enquanto aeronaves requerem empuxo, que resultam em diferentes tratamentos na análise de desempenho (SARAVANAMUTTO *et al.*, 2001).

Os sistemas de monitoramento da saúde da turbina a gás (SMST), que foram primeiramente desenvolvidos para aplicações aeronáuticas, estão sendo aplicados com sucesso em aplicações industriais. A abordagem intrínseca para aumento da disponibilidade do sistema e redução dos custos de manutenção é estudada desde o nascimento da indústria de turbinas a gás, contudo sua implementação prática somente foi possível devido aos desenvolvimentos nas tecnologias de aquisição e tratamento de dados (URBAN, 1975).

Uma instalação de turbina a gás compreende equipamentos acessórios, como sistemas de condicionamento de combustível e de lubrificação; equipamentos mecânicos rotativos, como as caixas de engrenagens, volante de inércia e eixos, e componentes do caminho termodinâmico do gás, como o compressor, a turbinas e o combustor (URBAN, 1975). Mesmo que a confiabilidade dos componentes do caminho do gás seja consideravelmente maior do que as dos demais sistemas, seus longos tempos de manutenção ou substituição (*downtime*) implicam em uma redução de disponibilidade, o que pode ser constatado na Figura 1.1 (SINGH, 1999).

A Figura 1.1 apresenta uma comparação entre a confiabilidade e a disponibilidade dos sistemas de controle e de combustível, e dos componentes do caminho do gás de uma turbina a gás. Enquanto os sistemas de controle ou de combustível são mais susceptíveis à falha, ou seja, possuem baixa confiabilidade, eles apresentam baixo tempo de inatividade. Por outro lado, os componentes do caminho do gás, como o compressor e a turbina, possuem alta confiabilidade, mas, em caso de falha, apresentam longo tempo de indisponibilidade (SINGH, 1999).




Figura 1.1 - Confiabilidade e Disponibilidade de Sistemas de Turbinas a Gás (Adaptado de SINGH, 1999)

Além disso, o SMST também é utilizado nos procedimentos de recuperação de desempenho, como na limpeza de compressores, onde por meio do SMST é possível realizar uma avaliação econômica da intervenção com o objetivo de maximizar as receitas e minimizar os custos de manutenção. Os principais benefícios da aplicação das técnicas de diagnóstico do caminho do gás são: aumento da vida do equipamento, redução de estoque de peças de reposição,

melhoria na qualidade do gerenciamento da manutenção, otimização da manutenção completa (*overhaul*) da turbina a gás, identificação do ponto de equilíbrio de custo para a intervenção na turbina, melhoria e otimização da instrumentação e maximização da disponibilidade da usina de potência.

No CMD da PETROBRAS são utilizados sistemas que geram alertas automáticos a partir da comparação dos valores dos parâmetros operacionais com limites de alerta e alarme. Com base em cálculos do balanço de energia é realizada a investigação das eficiências mecânicas, térmicas e elétricas dos equipamentos, possibilitando inferir sobre a degradação de eficiência do compressor de uma turbina a gás, a definição de pontos ótimos de operação e a estimativa de desempenho esperado (LIMA; GUEDES; D'OLIVEIRA, 2015).

Em resumo, a utilização de sistemas de diagnóstico de falhas em turbinas a gás industriais passou a ser indispensável. As técnicas que foram desenvolvidas para aplicações em turbinas a gás aeronáuticas são adequadas para aplicações industriais e podem ser implementadas na prática devido ao constante desenvolvimento das tecnologias de aquisição e processamento de dados. Os benefícios da aplicação de técnicas de diagnóstico do caminho do gás estão relacionados com uma variedade de aspectos, como avaliação econômica, identificação de riscos e otimização da produção e manutenção.

1.3 Objetivos

O objetivo desta Tese é prover uma ferramenta para diagnóstico de falhas, baseada em técnicas de redes neurais artificiais, capaz de executar a análise de falhas de componentes de uma turbina a gás industrial de eixo simples, aqui representada pela turbina a gás ASLTOM GT11N2. Para tanto, o trabalho apresenta os seguintes objetivos específicos:

- i. Construir um modelo termodinâmico da turbina a gás, utilizando o software PYTHIA 2.8, para representar o ponto de referência operacional da turbina a gás ALSTOM GT11N2.
- ii. Simular o modelo com desvios nos parâmetros independentes (eficiência e coeficiente de vazão do compressor e da turbina), para gerar amostras de parâmetros dependentes sem ruído (temperatura e pressão na saída do compressor, temperatura na saída da turbina e potência de eixo) da turbina a gás degradada.

- iii. Simular os ruídos das amostras de parâmetros dependentes com base nos desvios padrões típicos das respectivas medições, utilizando as ferramentas estatísticas do Microsoft Excel.
- iv. Estabelecer as arquiteturas das redes neurais artificiais individuais utilizando o software MATLAB, para executar a detecção, o isolamento e a quantificação de falhas nos componentes da turbina a gás.
- v. Estabelecer a estrutura do sistema hierárquico de diagnóstico de falhas, utilizando as redes neurais individuais;
- vi. Treinar e validar as redes neurais artificiais individuais e o sistema hierárquico de diagnóstico, utilizando os parâmetros dependentes como vetor de entrada e os parâmetros independentes como vetor alvo, considerando duas configurações, a saber: amostras sem ruído de medição e com ruído de medição.
- vii. Definir os fatores de correção dos parâmetros dependentes pela temperatura ambiente, utilizando os dados da campanha operacional da turbina a gás ALSTOM GT11N2, obtidos por meio do software PI (OSISOFT, 2013)
- viii. Submeter os dados da campanha operacional aos filtros para redução de ruído e eliminação de pontos espúrios e, a partir dos resultados, definir qual filtro é mais adequado para a ferramenta de diagnóstico de falhas proposta.
- ix. Submeter os dados da campanha operacional, corrigidos pela temperatura ambiente, à estrutura hierárquica de diagnóstico para determinar o desempenho de cada configuração proposta.

Os métodos de diagnóstico de falhas a partir da análise dos parâmetros de medição podem ser divididos em duas linhas de pesquisas principais, a saber: métodos baseados em modelos analíticos (BOUGET & LEONARD, 2010; DOEL, 1994; KURZ & BRUN, 2009; LI, 2010; LIPOWSKY *et al.*, 2009; NAEEM; SINGH; PROBERT, 1998; RAHME & MESKIN, 2015; SIMON & ARMSTRONG, 2013; VODOPIANOV, 2004) e métodos baseados em técnicas de inteligência artificial (FAST & PALME, 2010; FAST; ASSADI; DE, 2009; PALME; FAST; THERN, 2011; OGAJI & SINGH, 2003; SINA & KHOROSANI, 2015; SHIVAKUMAR; PAI; RAO, 2011). Uma análise detalhada destes trabalhos, apresentada no Capítulo 2, revela que os métodos baseados em inteligência artificial utilizados para detecção, isolamento e

quantificação de falhas são validados contra dados de simulação do modelo da turbina a gás degradada, sem levar em conta os ruídos e pontos espúrios presentes em sinais de medições reais.

Desta forma, a determinação de um sistema capaz tratar os sinais de medições reais, com a finalidade de aplicar a técnica proposta em um ambiente industrial, constitui a principal contribuição desta Tese para o desenvolvimento da linha de pesquisa de aplicação de técnicas de inteligência artificial para diagnóstico de falhas em turbinas a gás. Para tanto, o trabalho apresenta as seguintes contribuições específicas:

- i. Determinação de amostras de treinamento e validação das RNA com ruído de medição a partir dos valores simulados sem ruído e dos ruídos probabilísticos baseados nos desvios padrões típicos das respectivas medições, para estabelecer o sistema hierárquico de diagnóstico com ruído, capaz de tratar diretamente os sinais de medição
- ii. Determinação de um filtro de tratamento de sinais de medição, bem como dos ajustes de seus parâmetros internos, para pré-processar os sinais de medição, para que sejam utilizados no sistema hierárquico de diagnóstico sem ruído.
- iii. Comparação do desempenho do sistema hierárquico de diagnóstico com ruído, tratando dados brutos de medição, com o desempenho do sistema hierárquico de diagnóstico sem ruído, tratando dados pré-processados, para determinar a melhor estratégia para aplicação industrial da ferramenta de diagnóstico de falhas.

1.4 Estrutura da Tese

O corpo principal desta Tese é dividido em seis capítulos: Introdução, Revisão da Literatura, Metodologia de Redes Neurais Artificiais, Modelo da Turbina a Gás, Aplicação do Sistema Hierárquico de Diagnóstico e Conclusões e Comentários. Além disso, os materiais de suporte utilizados para a realização desta Tese podem ser encontrados nos apêndices.

O Capítulo 1, Introdução, apresenta a motivação da Tese no tocante as iniciativas da PETROBRAS para otimização de suas usinas de geração termelétrica, uma breve descrição da importância do monitoramento das condições de saúde do equipamento no ambiente industrial, bem como, os objetivos e as contribuições da Tese.

O Capítulo 2, Revisão da Literatura, pavimenta o caminho para o desenvolvimento da Tese, traçando um esboço do que foi publicado em relação às técnicas de diagnóstico de falhas em componentes de turbinas a gás e aplicações de redes neurais artificiais no monitoramento das condições de saúde de turbinas a gás. Ainda, este capítulo apresenta uma revisão da teoria de redes neurais, enfatizando os tipos utilizados na metodologia deste trabalho e descrevendo seus métodos de treinamento. Finalmente, é apresentada uma breve revisão dos tipos de filtros que serão investigados no tratamento dos dados medidos.

O Capítulo 3, Metodologia de Redes Neurais Artificiais, apresenta os passos tomados para a execução da análise de diagnóstico utilizando redes neurais artificiais. Em seguida, é descrito a arquitetura do sistema hierárquico de diagnóstico, bem como o detalhamento de cada um de seus elementos. Então, são analisados os métodos adequados para validação das redes neurais artificiais. Finalmente, é apresentado o algoritmo implementado em MATLAB para execução da análise.

O Capítulo 4, Modelo da Turbina a Gás, apresenta breves descrições da turbina a gás industrial ALSTOM GT11N2 e do software TURBOMATCH. Em seguida, detalha a modelagem termodinâmica da turbina a gás, dispondo os resultados em um diagrama T-S (temperatura – entropia). Por fim, apresenta os mapas característicos dos principais componentes do equipamento.

O Capítulo 5, Aplicação do Sistema Hierárquico de Diagnóstico, detalha a utilização da metodologia demonstrada para avaliar as condições de saúde dos componentes do caminho do gás de uma turbina a gás industrial ALSTOM GT11N2. Primeiramente, são apresentados os resultados da avaliação dos processos de treinamento e generalização das RNA. Em seguida, é apresentado a aplicação da metodologia para monitorar as condições dos componentes do equipamento durante uma campanha operacional, contemplando a definição dos fatores de correção pela temperatura ambiente e do filtro de ruídos mais adequado para a referida aplicação.

O Capítulo 6, Conclusões e Comentários, aborda os principais pontos do trabalho, discutindo as contribuições e indicando as possibilidades de desenvolvimentos futuros no campo do diagnóstico de falhas em componentes de turbinas a gás.

2 REVISÃO DA LITERATURA

2.1 Introdução

Neste capítulo, será realizada uma revisão das técnicas de diagnóstico de falhas em turbinas a gás, da teoria de redes neurais artificiais e das técnicas de filtro de dados, pavimentando o caminho para o desenvolvimento da metodologia.

Desenvolvimentos relativamente recentes na ciência da computação e instrumentação tornaram a implementação de sistemas de diagnóstico de falhas em componentes de turbinas a gás um campo fértil para pesquisa e desenvolvimento. O comportamento dos componentes do caminho do gás pode ser adversamente afetado por diversas falhas, implicando perda de desempenho e aumento de risco operacional. Por essa razão, diversas técnicas vêm sendo desenvolvidas para tratar os problemas, com diversos níveis de detecção de falhas, que incluem as técnicas baseadas em inteligência artificial, como redes neurais artificiais (RNA).

A rede neural artificial consiste em uma técnica matemática para tratar problemas complexos, onde a relação entre entradas e saídas do sistema não pode ser facilmente representada por uma expressão algébrica, condição encontrada nos problemas de diagnóstico de falha em componentes de turbinas a gás. As RNA são criadas por meio de unidades de processamento elementares interconectadas, chamadas de neurônios, nas quais os sinais são modificados para resultar nas saídas desejadas. A velocidade de processamento de uma RNA, quando não são necessários cálculos iterativos, é maior que em programas de simulação tradicional.

Na primeira seção deste capítulo, sistemas de diagnóstico de falhas em turbinas a gás são discutidos, enfatizando a natureza das falhas e as técnicas de diagnósticos desenvolvidas. Na segunda seção, é apresentada uma breve discussão da teoria de RNA e realizada uma análise de sua aplicação em problemas de diagnóstico de falhas de turbinas a gás.

2.2 Sistemas de Diagnóstico de Falhas em Turbinas a Gás

O diagnóstico de falhas em turbinas a gás vem sendo uma questão importante desde que as turbinas a gás passaram a motorizar as aeronaves, no entanto sua implementação prática somente foi possível nas últimas décadas devido aos desenvolvimentos em aquisição e processamento de dados (URBAN, 1975). As falhas mais comuns relacionadas aos

componentes do caminho do gás são: sujidade (*fouling*), *tip clearance*, corrosão, erosão e danos por objetos, que podem ser avaliados com o emprego do método de diagnóstico adequado.

Os métodos de diagnóstico de falhas podem ser classificados em duas categorias: convencionais e não convencionais (OGAJI, 2003). Os primeiros compreendem inspeção visual, árvore de falhas, matriz de falhas, análise de vibração e GPA. Os últimos compreendem métodos baseados em inteligência artificial, tais como lógica difusa, algoritmo genético e redes neurais artificiais.

Atualmente, o GPA representa o conjunto de técnicas mais comum aplicado para avaliar a saúde dos componentes do caminho do gás. As técnicas de GPA incluem GPA linear, GPA não linear, algoritmo de mínimos quadrados ponderado, filtro de Kalman e adaptações destes métodos utilizando técnicas de inteligência artificial. Embora estes métodos tenham sido demonstrados como adequados para a aplicação a que se destinam, eles dependem fortemente da qualidade das medições (LI & SINGH, 2005). Logo, o conjunto de dados medidos deve ser tratado antes de sua utilização. A seguir, as falhas em componentes de turbina a gás, os métodos de diagnóstico e a análise de dados são discutidos em detalhes.

2.2.1 Tipos de Falhas em Componentes da Turbina a Gás

Uma instalação completa de turbina a gás industrial compreende, além da turbina a gás, o sistema de controle, sistema elétrico e sistemas auxiliares, como os de lubrificação, resfriamento externo e condicionamento de combustível. Todos esses elementos possuem efeitos similares na saúde da instalação, visto que o mau funcionamento de um deles pode degradar ou interromper a operação do equipamento. No entanto, a maioria dos sistemas pode ser monitorada por práticas de operação e manutenção bem conhecidas, enquanto o monitoramento de falhas nos componentes da turbina a gás requer técnicas mais complexas.

Os principais componentes da turbina a gás, também conhecidos como componentes do caminho do gás, são o compressor, a turbina e o combustor. Este último não será tratado nesta seção, dado que sua eficiência não apresenta alterações significativas ao longo do tempo, condição necessária para aplicação das técnicas de detecção de falhas do caminho do gás. De acordo com Ogaji (2003), as falhas mais frequentes que implicam em redução na eficiência dos componentes do caminho do gás são:

- **Sujidade:** esta falha é caracterizada pelo acúmulo de depósitos de material estranho ou doméstico na superfície das pás, logo alterando suas características aerodinâmicas, sendo considerada a principal causa de deterioração da eficiência da turbina a gás. Um compressor sujo resulta na redução do seu fluxo de massa e na sua pressão de saída, levando a um aumento no *heat rate* da turbina a gás. Por outro lado, sujeira ou desgaste de selos leva a uma redução na eficiência da turbina e um aumento na temperatura de exausto. Na maioria dos casos, a sujidade pode ser prevenida com lavagens periódicas da turbina a gás.
- **Tip Clearance:** esta falha é caracterizada pelo aumento na folga entre as pontas das pás e a carcaça do compressor, que pode ser atribuída a um desgaste na selagem ou a uma pá danificada, levando à redução na eficiência e no coeficiente de vazão do compressor. Quando comparada à falha do tipo sujidade, este tipo de falha possui maior influência sobre a redução de eficiência do compressor.
- **Erosão:** esta falha é causada pelo impacto de partículas nas pás, resultando na deterioração de sua superfície e, por conseguinte, alteração no seu perfil aerodinâmico. Pás de compressor erodidas levam a uma redução em sua razão de pressão e no fluxo de massa. Por outro lado, pás de turbinas ou bocais erodidos resultam em um aumento no coeficiente de vazão e em uma redução da eficiência da turbina.
- **Corrosão:** esta falha é causada pela reação entre o material das pás e os contaminantes. A seção quente da turbina a gás é mais susceptível à corrosão pela presença de sódio, vanádio e chumbo, sendo que pás de turbinas corroídas levam à redução no desempenho esperado da turbina a gás.
- **Danos por Objeto:** esta falha pode ser causada tanto por objetos externos que são carregados para o interior da turbina a gás pelo ar, como por partículas internas que se destacam de seus locais de origem e são carregadas pelo fluido de trabalho através dos componentes do caminho do gás. O efeito do dano causado pelo choque de objetos nos componentes do caminho do gás pode ser comparado com o efeito da sujidade no desempenho da turbina a gás.

Lima e Cruxen (2015) apresentam a falha no compressor de uma turbina a gás GE6FA ocorrida devido à ocorrência de surto no equipamento. A Figura 2.1 mostra a condição do equipamento após a falha, sendo (a) e (b) as IGV (*Inlet Guide Vanes*) e (c) as pás do rotor do

compressor. No momento da falha, a máquina apresentava 25.172 horas de operação, com as manutenções em dia, e o comportamento do equipamento estava estável. Foi apurado pela equipe de manutenção que a causa raiz desta falha foi a ocorrência de surto, ou fluxo reverso de ar no compressor durante a operação da turbina a gás, inutilizando todo o equipamento à montante da câmara de combustão. As possíveis condições identificadas para a ocorrência de surto foram mudança de temperatura externa, obstrução parcial da entrada de ar, impregnação das palhetas (sujeidade) e mau acabamento do perfil de bordo de ataque dos aerofólios (erosão).



(a)



(b)



(c)

Figura 2.1 - Compressor Danificado por Surto na Turbina a Gás (Adaptado de LIMA & CRUXEN, 2015)

As características das falhas nos componentes do caminho do gás supracitadas indicam que existe uma relação entre as alterações nos parâmetros independentes, ou seja, nas condições de saúde dos componentes, e os parâmetros dependentes, como aqueles relacionados com o desempenho da máquina. Além disso, os diferentes tipos de falhas nos componentes do caminho do gás afetam os parâmetros de desempenho de diferentes maneiras.

2.2.2 Sistemas de Diagnóstico de Falhas

Fica claro, portanto, que as falhas são permanentes ou reparáveis, podendo levar a redução do desempenho ou, ainda pior, das margens de segurança operacionais da turbina a gás. Por esta razão, é vital que as falhas possam ser identificadas precocemente pelos métodos de diagnóstico.

Esta seção apresenta uma revisão das técnicas de monitoramento da saúde de turbinas a gás até então desenvolvidas, destacando seus pontos fortes e fracos. De acordo com Ogaji (2003), a aplicação de cada técnica depende de diversos fatores, tais como: custos de aquisição do sistema de monitoramento, potencial de economia de custos na manutenção e operação da turbina a gás, da natureza da operação e da confiabilidade do sistema de monitoramento. Independente da preocupação com custos, os sistemas de monitoramento da saúde de turbinas a gás devem ser considerados, visto que apresentam inúmeros benefícios, tais como: prevenção de falha catastrófica, redução de tempo indisponível (*downtime*) e melhoria na segurança operacional.

As técnicas convencionais, já aplicadas na indústria, incluem inspeção visual, árvore de falhas, matriz de falhas, análise de vibração e GPA. O conjunto de técnicas que utilizam GPA continua como objeto de pesquisa e desenvolvimento no campo da inteligência artificial, como por exemplo, em sistemas especialistas, lógica difusa, algoritmo genético e redes neurais artificiais. Ogaji (2003) e Ganguli (2013) apresentam uma revisão completa destas técnicas, que são discutidas a seguir.

A Inspeção Visual, como o nome sugere, compreende o conjunto de técnicas de monitoramento de saúde que requer um técnico bem treinado para visualmente identificar potenciais problemas. Embora esta técnica pareça superficial e não confiável, ela é frequentemente utilizada na indústria com bons resultados. Boroscopia é a técnica mais importante de inspeção visual porque permite a inspeção dos componentes internos da turbina a gás sem a necessidade de abertura da máquina.

A Árvore de Falhas é a técnica que utiliza mapeamento do padrão de falhas para avaliar a saúde da turbina. Os mapas são construídos com base na combinação entre as experiências da equipe da termelétrica com o conhecimento da equipe do fabricante de turbinas a gás. Uma vez obtidos os mapas, eles podem ser facilmente aplicados durante a campanha de operação.

Entretanto, esta técnica pode somente identificar falhas simples, não podendo distinguir entre falha no componente ou falha no sensor e apresenta apenas resultados qualitativos.

A Matriz de Falhas é muito similar à técnica previamente mencionada, onde o mapa de falhas é transformado em uma matriz. Isto confere somente uma indicação qualitativa do problema, podendo apenas identificar falhas simples.

O Monitoramento da Vibração compreende um conjunto de técnicas bem estabelecidas utilizadas para monitorar a saúde de todos os tipos de equipamentos rotativos. Este monitoramento pode ser realizado por meio de análise espectral, que utiliza um banco de dados de assinaturas de espectros de falhas como padrão de comparação para detecção de falhas. Outras análises comumente utilizadas são análise de proximidade, análise orbital, formato de onda temporal e análise de fase.

A Análise do Caminho do Gás (GPA) consiste em sistemas de monitoramento da saúde de turbinas que utilizam as propriedades termodinâmicas do caminho do gás para estimar o nível de degradação dos componentes. As técnicas que vem sendo desenvolvidas para realizar a análise do caminho do gás são capazes de identificar e isolar múltiplas falhas e produzem resultados quantitativos, mas dependem da qualidade dos dados medidos. Erros tendência de sensores e ruídos de medição podem levar a resultados inconsistentes, visto que seus efeitos nos dados medidos podem ultrapassar os efeitos da degradação dos componentes. As técnicas de GPA incluem: GPA linear, GPA não linear, Algoritmo de Mínimos Quadrados Ponderados, Filtros de Kalman e técnicas de inteligência artificial.

A técnica de Análise do Caminho do Gás Linear (LGPA – *Linear Gas Path Analysis*) foi o primeiro sistema de GPA desenvolvido, relacionando desvios nos parâmetros medidos com desvios nas características dos componentes através de uma matriz de coeficiente de falhas (FCM – *Fault Coefficient Matrix*), que é a inversa da matriz de coeficiente de influência (ICM – *Influence Coefficient Matrix*). A ICM representa a taxa de alteração de cada parâmetro de medição em relação a uma alteração percentual unitária nas características dos componentes, que é dada numericamente pela expansão em série de Taylor. As deficiências desta técnica são: (i) a taxa real de degradação do componente pode não ser linear; (ii) é somente confiável quando aplicável em pequenos desvios; (iii) requer um grande número de sensores e (iv) defeitos em sensores não podem ser detectados.

A técnica de Análise do Caminho do Gás Não Linear (NLGPA – *Non Linear Gas Path Analysis*) é uma adaptação da técnica apresentada anteriormente, num esforço para superar alguns de seus pontos fracos. NLGPA consiste na aplicação recursiva do LGPA para estabelecer a função que relaciona o parâmetro medido e a degradação do componente em um domínio estendido, utilizando o método de Newton Raphson. Esta técnica não considera problemas em sensores e apresenta problemas de convergência para grandes desvios nas características dos componentes degradados.

A técnica dos Mínimos Quadrados Ponderados (WLS – *Weighted Least Square*) utiliza um tratamento probabilístico para representar o comportamento não linear da degradação dos componentes. A função não linear que correlaciona os desvios nos parâmetros de medida com os desvios nas características dos componentes é substituída por uma função linear multiplicada pela degradação probabilística do componente, representado por uma curva Gaussiana.

Os Filtros de Kalman (KF – *Kalman Filter*) é uma técnica que estima a saúde dos componentes da turbina a gás por meio de uma base de dados cumulativa no tempo. KF é uma adaptação da técnica dos Mínimos Quadrados Ponderados, onde o vetor de estado pode mudar para cada passo de tempo da simulação. Esta técnica assume sistema linear, onde o ruído e o estado inicial são representados por curvas Gaussianas.

As Técnicas de Inteligência Artificial (AI – *Artificial Intelligence*), tais como Sistema Especialista, Lógica Difusa, Algoritmo Genético e Redes Neurais Artificiais estão sendo aplicadas como técnicas de monitoramento da saúde de turbinas. Uma breve explanação sobre estas técnicas é apresentada nos próximos parágrafos.

O Sistema Especialista utiliza relações heurísticas para representar a razoabilidade humana. Sua aplicação é adequada para processos onde a relação entre entradas e saídas do sistema podem, pelo menos, ser qualificadas por especialistas. Portanto, de forma a aplicar o Sistema Especialista, as seguintes condições devem ser atendidas: delimitação do escopo do problema endereçado, descrição dos possíveis sintomas do problema, codificação do modelo de razoabilidade, validação das regras. A aplicação sinérgica desta técnica juntamente com outras ferramentas de GPA pode prover uma melhor interpretação dos resultados.

A Lógica Difusa é adequada para tratar situações de imprecisão, onde os conjuntos *booleanos* são substituídos por conjuntos difusos, que são caracterizados por uma função de pertinência,

i.e., pelo grau de verdade do elemento. Esta técnica apresenta grande potencial para aplicação como ferramenta de GPA, visto que a devida modelagem das funções de pertinência auxiliaria no isolamento das falhas entre componentes do caminho do gás ou na definição de falhas em sensores de medição.

Os Algoritmos Genéticos consistem em um algoritmo de procura do ponto ótimo que seguem o conceito da teoria de seleção natural de Darwin. A procura é realizada por meio dos estágios: avaliação, seleção, cruzamento e mutação. Em cada iteração do algoritmo, os melhores são escolhidos para sobreviver (seleção), então novos são gerados através de combinação dos sobreviventes (cruzamento) ou através de alterações aleatórias (mutação). Este algoritmo provê uma ferramenta poderosa para determinação do ótimo global e representa uma potencial aplicação para diagnóstico de falhas por meio da determinação direta dos desvios nos parâmetros dependentes do modelo, sem a necessidade da utilização da FCM.

Rede Neural Artificial consiste em uma aproximação numérica de uma função, onde a relação lógica e numérica entre as entradas e saídas é desconhecida. Sua estrutura é baseada no modelo básico de aprendizagem humana. Esta técnica pode facilmente ser aplicada aos problemas não lineares sem barrar nas limitações dos modelos analíticos, que são essenciais para GPA. Este assunto será discutido em detalhes nas próximas seções, dados que esta técnica foi escolhida para ser utilizada nesta Tese.

2.2.3 Análise das Medições

As técnicas de diagnóstico de falhas mencionadas na seção anterior dependem da qualidade das medições. Uma vez que o conjunto dos desvios nas medições dos parâmetros é a fonte de informação para qualquer técnica de diagnóstico de falhas, os erros de medição considerados não devem ser maiores que uma fração de seus desvios devido à degradação dos componentes da turbina a gás.

Entretanto, cada medição contém erros que podem estar relacionados com a incerteza do instrumento ou variações nas condições do ambiente. Logo, deve ser definida uma variação aceitável no valor da medição sobre o valor real da grandeza para que se possa utilizá-la (LI, 2011).

Os erros de medição podem ser divididos em dois tipos: constante (sistemático) e variável (aleatório). Os erros constantes, também conhecidos como erro de tendência ou *bias*, são erros sistemáticos que permanecem constantes sobre um período específico de tempo. Não existe um método estatístico adequado para determinar este tipo de erro a partir dos dados medidos, visto que isto dependeria do valor real da grandeza medida, que é desconhecido. Os limites desse tipo de erro são normalmente definidos por uma análise de engenharia da instrumentação. Não obstante, esse tipo de erro não apresenta forte influência nas condições em que se baseiam os sistemas de monitoramento, dado que ambas as medições da turbina a gás degradada e da turbina a gás saudável são tomadas pelo mesmo conjunto de instrumentos. O procedimento para calcular o vetor de desvio nos parâmetros dependentes, que é realizado através de uma operação de subtração, elimina os erros constantes (URBAN, 1975).

O erro variável, também conhecido como ruído, é aleatoriamente distribuído ao redor de um valor central. Este efeito, chamado de incerteza de medida, é dado pelo desvio padrão dos erros variáveis das amostras (LI, 2011).

A representação gráfica destes dois tipos de erros em medições é apresentada na Figura 2.2. A diferença entre o valor real da grandeza e o valor medido é resultado da soma do erro de tendência (*bias*) com o ruído, onde o erro de tendência representa a distância entre o valor real da grandeza e a média dos valores medidos e o ruído representa a dispersão, dada a incerteza na medição.

Em uma turbina a gás degradada, os desvios nos parâmetros de desempenho podem ser causados por falhas nos sensores ou degradação de componentes, que possuem aproximadamente a mesma magnitude. Por esta razão, os dados brutos medidos devem ser tratados antes de serem utilizados como dados de entrada das técnicas de diagnóstico de falhas. Os dois métodos mais comuns aplicados para redução da influência de ruídos são os métodos da média móvel e da média exponencial. O primeiro é executado através de um simples cálculo das médias dos dados das últimas medições, enquanto o último utiliza uma média exponencial para otimizar o processo. Além disso, redes neurais auto associativas estão sendo utilizadas na validação de dados de entrada (LI, 2011). Esses filtros de dados serão tratados em detalhes em uma seção posterior, visto que serão utilizados como ferramenta desta Tese.

Além disso, existem incertezas associadas aos resultados do modelo da turbina a gás utilizados para gerar os valores base dos parâmetros dependentes. Por exemplo, de acordo com Lou; Fabian; Key (2014), o valor absoluto e a incerteza na eficiência isentrópica de um compressor varia significativamente com o modelo adotado para caracterização termodinâmica do fluido de trabalho (calores específicos a pressão constante e volume constante), seja o modelo de gás perfeito, gás ideal ou gás real.




Figura 2.2 - Erro de Medição (adaptado de LI, 2011)

2.2.4 Processamento de Sinal

Os sinais oriundos dos instrumentos de medições devem ser submetidos a um processo de tratamento e suavização antes de serem utilizados pelas técnicas de monitoramento e diagnóstico falhas de turbinas a gás. Ganguli (2013) propõe uma representação esquemática do processo de diagnóstico, apresentada na Figura 2.3, onde é possível observar que a chave para o sistema de diagnóstico está na função de filtro ou suavização de sinal.




Figura 2.3 - Representação do Processo de Diagnóstico de Turbina a Gás (Adaptado de GANGULI, 2013)

Os métodos tradicionais para suavização de sinais utilizados na indústria de turbinas a gás são a média móvel e a média exponencial (LI, 2011; GANGULI, 2013). O método de tratamento de sinal pela média móvel é um caso especial dos filtros de resposta ao impulso finito (FIR – *finite impulse response*) e o método de tratamento de sinal pela média exponencial é um caso especial dos filtros de resposta ao impulso infinito (IIR – *infinite impulse response*).

No entanto, tanto os filtros FIR como os IIR são filtros lineares para remoção de ruído que opacam as bordas no sinal. Em muitos casos, a presença de bordas indica a ocorrência de uma falha abrupta ou então da resolução de um problema que vinha se intensificando ao longo do tempo. Desta forma, os filtros aplicados ao monitoramento da saúde de turbinas a gás devem remover ruído de grande amplitude ao mesmo tempo em que preservam as bordas nos desvios das medições (GANGULI, 2013). Entre as alternativas apresentadas às restrições supracitadas, os filtros medianas, da classe dos filtros não lineares, são úteis para remover ruído enquanto preservam detalhes finos no sinal.

De acordo com Ganguli (2013), o filtro mediana ponderada centrada (CWM – *center weighted median*) pode ser empregado para melhorar a visualização e remover ruído das medições do caminho do gás, pois quando aplicado retém as tendências de mudança e outras características do sinal, enquanto remove o ruído.

Considerando o comprimento da janela igual a $2K-1$, o CWM pode ser definido pela Equação 2.01 (GANGULI, 2013):

$$y = \text{median} (x_{-k}, \dots, x_{-1}, 2K - 1 * x_0, x_1, \dots, x_k) \quad (2.01)$$

Ganguli (2013) sugere estabelecer um comprimento de janela do filtro de 5, resultando em $K=2$. Como isso, o CWM passa a ser definido pela Equação 2.02:

$$y = \text{median} (x_{-k}, \dots, x_{-1}, 3 * x_0, x_1, \dots, x_k) \quad (2.02)$$

Ganguli (2013) apresenta outros filtros adequados à aplicação nos processos de diagnóstico de falhas em turbinas a gás, como por exemplo, a aplicação do filtro médio com o filtro racional. O filtro racional não é adequado para remoção de pontos espúrios, mas remove ruído gaussiano, preserva as bordas e a saúde do sinal, enquanto o filtro médio remove pontos espúrios. A investigação das técnicas de filtragem e suavização de sinal busca identificar a técnica mais adequada para tratamento dos sinais de instrumentos com ruído, visando o processamento posterior pelo sistema hierárquico de diagnóstico.

2.2.5 Revisão Bibliográfica das Aplicações de Diagnóstico de Falhas

Rahme e Meskin (2015) propõem um método para diagnóstico de falhas em sensores de turbinas a gás industrial que utiliza o modo de deslizamento adaptativo. Este método é robusto para tratar incertezas paramétricas e perturbações, além de garantir a convergência do modelo. O método consiste em um modelo dinâmico da turbina a gás, desenvolvido em MATLAB, que possui em sua formulação fatores de degradação das eficiências e dos coeficientes de vazão do compressor e da turbina. O modelo é dividido no vetor de estado de variáveis não mensuráveis e de variáveis mensuráveis, sendo que as falhas são representadas neste último.

Simon e Armstrong (2013) propõem um método de estimativa de desempenho e diagnóstico de falhas de turbinas a gás, baseado em KF, para aplicação *on-line* em aviões nas situações onde o número de sensores de medição é menor que o número de parâmetros que representam a saúde do equipamento, caracterizando um sistema indeterminado. Nesta condição, a identificação da degradação dos parâmetros independentes a partir de desvios nos parâmetros dependentes é prejudicada, dado que as causas dos desvios, identificadas pela resolução do sistema indeterminado, são distribuídas entre os parâmetros independentes, ou seja, entre os parâmetros que representam a saúde do equipamento, dificultando a identificação do componente degradado. No método proposto, um modelo de redução de ordem de variáveis de estado é aplicado para determinação do vetor de parâmetros ajustados, que representa a combinação linear de todos os parâmetros de saúde do equipamento na ordem compatível com o número de medições disponíveis. Ao contrário dos métodos de diagnóstico de falhas pela análise direta dos desvios nos parâmetros de medição, que exigem a implementação de um modelo da linha de base de desempenho do equipamento *on-board*, este método propõe o monitoramento do vetor de parâmetros ajustados produzidos pelos KF, requerendo apenas o arquivo de valores passados destes parâmetros para realização do diagnóstico.

Li (2010) desenvolveu uma nova técnica para executar o diagnóstico de falhas em componentes de turbinas a gás por meio da estimativa de parâmetros de desempenho da turbina a gás degradada e da medição de dados de parâmetros de saúde da turbina a gás. Este método é chamado de Análise do Caminho do Gás Adaptativa (AGPA – *Adaptive Gas Path Analysis*). Um conjunto de medições dos parâmetros da turbina a gás, incluindo dados de pressão e temperatura do caminho do gás, rotação, fluxo de combustível, etc., é comparado com valores simulados ou medidos para o equipamento novo, sem deterioração dos

componentes, indicando os desvios dos parâmetros de desempenho, que podem então ser utilizados para avaliar os parâmetros de saúde da turbina a gás. O conjunto dos parâmetros de desempenho da turbina a gás compreende o fluxo de massa, a eficiência isentrópica do compressor e sua razão de pressão, a temperatura de entrada na turbina, a eficiência isentrópica da turbina, etc., enquanto o conjunto dos parâmetros de saúde da turbina a gás compreende os índices de eficiência e coeficiente de vazão do compressor e da turbina. O método AGPA é dividido em duas fases. Primeiramente, os desvios dos parâmetros de desempenho da turbina são calculados de forma similar aos utilizados no GPA tradicional, onde uma matriz de coeficientes de influência é utilizada para representar a relação entre os parâmetros dependentes e independentes. A inversa desta matriz, aqui chamada de matriz de coeficiente de adaptação (ACM – *adaptation coefficient matrix*), é utilizada para estimar os parâmetros de desempenho da turbina a gás a partir dos dados medidos. De maneira a aumentar a precisão desta estimativa, é aplicado o método de Newton-Raphson, transformando a aproximação linear em não linear. Em seguida, os parâmetros de saúde dos componentes da turbina são obtidos por meio da plotagem dos mapas da turbina saudável e degradada, que são baseados nos parâmetros de desempenho estimados, e então, calcula-se o fator de escala da degradação. De maneira geral, a vantagem deste método sobre o GPA tradicional está no fato dele permitir uma avaliação prévia dos desvios nos parâmetros de desempenho da turbina a gás.

Lipowsky *et al.* (2019) desenvolveram uma técnica alternativa de detecção de degradação e desempenho para tratar eventos de falha simples. Tanto as mudanças incrementais ou abruptas nas características dos componentes levam a modificação dos parâmetros de desempenho da turbina a gás. A técnica proposta combina a Teoria de Bayes com modelagem linear dinâmica para gerar o modelo da turbina a gás saudável, que é mantido constante durante todo processo de monitoramento e análise, e um modelo da turbina a gás com falha, que é gerado antes de cada medição. Ambos os modelos consistem de funções de densidade de probabilidade sendo usadas para ajustar os dados reais. A detecção de falhas é então realizada por meio da comparação do desempenho de ajuste dos dois modelos.

Bouget e Leonard (2010) apresentam um sistema de monitoramento de desempenho da turbina a gás baseado em KF, que utiliza técnicas de tratamento residual para melhorar a capacidade de detecção de falha isolada. Enquanto KF busca degradação gradual por meio de um esquema de equiparação de covariâncias, o sistema de tratamento residual utiliza o teste de razão de probabilidade generalizado para melhorar a detecção de falhas abruptas.

Kurz e Brun (2009) estudaram a influência da degradação de componentes múltiplos nos parâmetros de desempenho da turbina a gás. A análise foi realizada pela implementação individual de falhas nos componentes do modelo da turbina a gás e observando seus efeitos nos parâmetros de desempenho. Este artigo também inclui um resumo das causas de degradação de turbinas a gás.

Vodopianov (2004) apresenta uma adaptação probabilística do GPA. A técnica compreende uma matriz de coeficiente de falhas, onde cada elemento é dado por uma função densidade de probabilidade. Segundo o autor, esta técnica supera a falta de precisão dos métodos lineares e a complexidade dos métodos não lineares.

Naeem; Singh; Probert (1998) avaliaram as consequências da deterioração dos componentes da turbina a gás sobre a efetividade operacional e consumo de combustível, para aeronaves militares operando sob determinado perfil de missão. Neste estudo, um parâmetro único, definido como Índice de Deterioração, foi utilizado para descrever as reduções de eficiência e coeficiente de vazão dos componentes da turbina a gás. A combinação de degradação nos componentes foi implantada no modelo computacional PYTHIA para simulação dos resultados.

Doel (1994) descreve a ferramenta de análise do caminho do gás denominada GE TEMPER (*Turbine Engine Module Performance Estimation Routine*), utilizada para detecção de degradação em componentes de turbinas a gás aeronáuticas, seja durante o uso comercial ou enquanto na bancada de testes de aceitação pós-manutenção. A utilização desta ferramenta permite otimizar a manutenção, definindo sua frequência e escopo. Neste modelo, a degradação dos componentes é identificada por meio de desvios no desempenho da turbina a gás em relação ao esperado para o equipamento novo ou após manutenção, calculados a partir de dados de sensores de medição. Assim, para avaliar corretamente o desempenho dos componentes, os erros nos sensores de medição devem ser considerados. Para tanto, a ferramenta utiliza a análise dos mínimos quadrados ponderada para diferenciar a natureza dos desvios nos parâmetros de medição entre erros de instrumentos e queda de desempenho dos componentes da turbina a gás. Esta análise utiliza a Teoria de Bayes, caracterizada por uma matriz que reflete os efeitos das variáveis de estado sobre as medições, uma matriz de covariância do vetor de estado, que reflete a variação esperada das variáveis de estado, e uma matriz de covariância do vetor de medições, que reflete a magnitude esperada dos erros nos sensores de medição.

2.3 Redes Neurais Artificiais

O conceito de Redes Neurais Artificiais foi primeiramente introduzido por McCulloch e Pitts (1943) em uma tentativa de reproduzir o processamento de sinais do cérebro humano. Embora os modelos desenvolvidos até agora estejam longe de constituir uma representação completa da estrutura biológica real, eles são capazes de realizar cálculos complexos baseados nos princípios da neurociência, tais como unidades processadoras numerosas e altamente conectadas, conexões adaptáveis e processamento paralelo (CARLING, 1992).

As redes neurais artificiais vêm sendo aplicada no reconhecimento de padrões, processamento de imagens, modelagem empírica, otimização, sistemas de controle e processamento de dados (HOU, 2007). Independente da complexidade da aplicação, a RNA é baseada em um modelo simplificado de neurônio, formado por uma matriz de pesos e tendências em conexão com uma função de transferência, como apresentado na Figura 2.4.




Figura 2.4 - Diagrama Esquemático de um Neurônio (BEALE; HAGAN; DEMUTH, 2011)

As funções de transferência são importantes para RNA porque modelam seus propósitos. As funções de transferência aplicadas mais frequentemente em RNA são *Degrau*, *Linear* e *Sigmoid*. A função de transferência *Degrau* é utilizada em RNA com propósito de decisão de classificação. Esta função retorna um conjunto binário de soluções, que são úteis para caracterização de regiões do domínio linearmente divididas. A função de transferência *Linear* é utilizada em RNA com propósito de aproximação de funções complexas. A função de transferência *Sigmoid* é frequentemente usada nas primeiras camadas de RNA para modular a entrada ponderada dentro de um intervalo limitado. A representação gráfica destas funções é apresentada na Figura 2.5.




Figura 2.5 - Funções de Transferência: (a) Degrau, (b) Linear, (c) Sigmoid. (BEALE; HAGAN; DEMUTH, 2011)

Em princípio, a aplicação de RNA para solucionar problemas complexos é extremamente atrativa, contudo na prática existem muitas questões que devem ser previamente endereçadas para uma correta implementação. Primeiramente, a arquitetura de uma RNA compreende diversas características, que levam em conta os números de camadas, conexões, neurônios e o tipo de função de transferência.

Ainda, uma RNA pode ser atualizada ou treinada por processos síncronos ou assíncronos, determinísticos ou estocásticos. Também, uma infinita combinação de RNA pode ser utilizada para resolução de um problema específico. Estas questões são interconectadas e devem ser respondidas durante o processo de criação da RNA (HERTZ; KROGH; PALMER, 1991).

2.3.1 Tipos e Arquiteturas de RNA

A combinação de neurônios, número de camadas e funções de transferência define a arquitetura de uma RNA. A configuração ótima de uma RNA para uma aplicação específica pode apenas ser definida por tentativa e erro, onde a convergência é alcançada pelo aumento incremental do número de neurônios (PALME; FAST; THERN, 2011; FAST; ASSADI; DE, 2009).

Uma representação genérica de uma RNA com múltiplas camadas é apresentada na Figura 2.6. Cada camada compreende uma matriz de pesos, operadores de multiplicação e somatório, tendência e funções de transferência. O sinal de entrada é processado em todas as camadas, resultando o vetor de saída. Foi demonstrado que uma RNA com camadas escondidas com o número suficiente de neurônios pode ser utilizada como uma boa representação de qualquer função contínua (PALME; FAST; THERN, 2011; FAST; ASSADI; DE, 2009).




Figura 2.6 - Modelo Esquemático de uma RNA com Múltiplas Camadas (BEALE; HAGAN; DEMUTH, 2011)

Os vetores de entrada podem ser concorrentes ou sequenciais, sendo o primeiro relacionado àquelas situações onde a sequência no tempo não é importante, enquanto o último é relacionado àquelas situações onde a ordem das informações é importante. Estes dois tipos de vetores de entrada determinam quando a RNA é considerada estática ou dinâmica.

Não obstante o alto grau de liberdade possível no projeto de uma RNA, alguns modelos bem estabelecidos foram desenvolvidos. Cada um foi criado para tratar necessidades de aplicações específicas, mas podem também ser úteis para outras situações. Neste trabalho, foram utilizados três importantes tipos de RNA: *perceptron*, rede neural probabilística e rede neural *feed-forward*.

2.3.1.1 Perceptron

O *Perceptron* consiste de um neurônio, onde é adotada a função de transferência do tipo *Degrau*, que tem a habilidade de classificar vetores de entrada pela divisão do domínio em duas regiões distintas. O *perceptron* pode ser entendido como um separador ponderado pelos pesos de ajuste. A Figura 2.7 apresenta um modelo esquemático de um *perceptron* de simples camada.

Cada neurônio do *perceptron* resulta em “1” quando a entrada da função de transferência é igual ou maior que zero ou “0” quando a entrada da função de transferência é menor que zero. A entrada de cada função de transferência é dada pelo produto interno do vetor de entrada com o respectivo vetor de pesos mais a tendência. Logo, o processo de treinamento do *perceptron* consiste em encontrar o melhor conjunto de pesos e tendências que produzem a mínima diferença entre a saída real e a desejada.




Figura 2.7 - Modelo Esquemático de um Perceptron de Simples Camada (BEALE; HAGAN; DEMUTH, 2011)

Embora o *perceptron* possa sempre encontrar uma solução para problemas envolvendo vetores linearmente independentes, ele possui muitas limitações. O conjunto de saída binária do *perceptron* não permite sua aplicação para problemas de aproximação de função. Ainda, esta rede pode somente ser utilizada para classificar domínios separados linearmente.

2.3.1.2 Rede Neural de Duas Camadas *Feed-Forward*

A rede neural artificial *Feed-Forward* é uma classificação generalizada que compreende as redes sem ciclo de retroalimentação (OGAJI, 2003). A RNA de duas camadas *feed-forward* apresentada na Figura 2.8 é adequada para aplicações de aproximação de funções. A primeira camada utiliza uma função de transferência *sigmoid* para limitar o intervalo do vetor de entrada ponderado, enquanto a segunda camada é utilizada para realizar a aproximação da função. Foi provado que este tipo de rede neural é capaz de produzir uma aproximação razoável de qualquer função (OGAJI, 2003).





Figura 2.8 - Representação Esquemática de uma RNA Feed-Forward (BEALE; HAGAN; DEMUTH, 2011)

As RNA de múltiplas camadas não podem ser utilizadas fora do intervalo das amostras de treinamento. Além disso, a complexidade do processo de treinamento aumenta com o crescimento da rede. Logo, o número de camadas escondidas e o número de neurônios da cada camada devem ser selecionados cuidadosamente (OGAJI, 2003).

2.3.1.3 Rede Neural Probabilística

As redes neurais artificiais probabilísticas são adequadas para aplicações de classificação de padrões. Na primeira camada, a distância entre o vetor de entrada e o padrão de treinamento é calculado, resultando em um vetor que mostra o quão longe o vetor de entrada está da amostra de treinamento. Na segunda camada, a contribuição de cada classe de entrada é somada, resultando em um vetor de probabilidades. Finalmente, a função de transferência promove a competição entre as probabilidades, selecionando a maior e atribuindo o valor “1” para esta classe. O modelo esquemático de uma RNA probabilística é apresentado na Figura 2.9.

A aplicação de RNA probabilística a um considerado conjunto de dados de entrada garante excelente comportamento de generalização. Seu treinamento é menos complexo que o algoritmo de retroalimentação. Contudo, esta RNA pode ser lenta, visto que uma nova rodada de cálculos é realizada cada vez que a rede for utilizada (OGAJI, 2003).



Onde:

R = número de elementos no vetor de entrada

Q = número de pares entrada/alvo = número de neurônios na camada 1

K = número de classes dos dados de entrada = número de neurônios na camada 2

Figura 2.9 - Representação Esquemática de uma RNA Probabilística (BEALE; HAGAN; DEMUTH, 2011)

2.3.2 Métodos de Treinamento de RNA

Uma vez que a arquitetura da RNA é estabelecida, o processo de treinamento deve ser definido. Este processo depende da aplicação, de tipo e arquitetura da RNA e da fonte das amostras de treinamento.

O processo de treinamento pode ser realizado de forma incremental ou em batelada. No primeiro, os parâmetros ajustáveis são atualizados cada vez que uma nova entrada é apresentada para a RNA, enquanto, no segundo, estes parâmetros são atualizados quando todo conjunto de entrada é apresentado. O estilo de treinamento é indiferente considerando aplicações de RNA estáticas, mas pode produzir resultados diferentes quando utilizados no treinamento de RNA dinâmicas.

Adicionalmente, o treinamento pode ser realizado com ou sem supervisão. O treinamento supervisionado é realizado com base em um conjunto de exemplos, que compreendem o vetor de entrada e o respectivo alvo desejado. Por outro lado, no treinamento não supervisionado, os parâmetros ajustáveis são atualizados com base somente no vetor de entrada. Este processo de treinamento é adequado para operações de agrupamento, onde o vetor de entrada é categorizado em um número de classes finito.

Muitos algoritmos de treinamento foram desenvolvidos para melhorar o desempenho de RNA. De acordo com Beale; Hagan; Demuth. (2011), os algoritmos de treinamento mais importantes são: *Levenberg-Marquardt*, *Bayesian Regularization*, *BFGS Quase-Newton*, *Resilient Back Propagation*, *Scaled Conjugate Gradient*, *Conjugate Gradient with Powell / Beale Restarts*, *Fletcher-Powell Conjugate Gradient*, *Polak-Ribiere Conjugate Gradient* e *One Step Secant*. Não faz parte do escopo desta Tese discutir sobre os métodos de treinamento citados. Com o propósito de ilustração, o método de Retroalimentação é discutido a seguir.

Considerando a RNA de múltiplas camadas apresentada na Figura 2.6, onde cada camada somente pode enviar saídas para a camada acima e receber entrada da camada abaixo, a regra de retroalimentação é executada em dois passes: o passe para frente e o passe para trás.

No passe para frente, o vetor de entrada flui em direção às camadas produzindo os resultados de saída para cada unidade, culminando na produção da saída da RNA, que é comparada com o alvo desejado para encontrar o erro da iteração.

No passe para trás, o processo é reverso; o erro calculado flui da camada de saída para a camada de entrada modificando os pesos e tendências de cada unidade. O erro total da RNA é minimizado usando o método de gradiente descendente, que altera os pesos proporcionalmente ao montante do erro total (CARLING, 1992).

Gupta; Jin; Homma (2003) apresentam um algoritmo detalhado de retroalimentação usando o método de gradiente descendente para executar a atualização dos pesos de uma rede de duas camadas simples com três neurônios. Uma breve explicação deste algoritmo é apresentada a seguir.

Considerando a RNA apresentada na Figura 2.10, a primeira camada consiste de dois neurônios; neurônio (1, 1) e neurônio (1, 2), e a segunda camada consiste de um neurônio; neurônio (2, 1).




Figura 2.10 - Representação Esquemática de uma RNA de duas camadas (GUPTA; JIN; HOMMA., 2003)

As expressões dos vetores relacionados a esta RNA são apresentadas nas Equações 2.03, 2.04, 2.05, 2.06 e 2.07 (GUPTA; JIN; HOMMA, 2003).

Para a primeira camada:

$$\text{vetor de entrada aumentado: } p_a \triangleq [p_0, p_1, \dots, p_n]^T, p_0 = 1 \quad (2.03)$$

vetor de pesos aumentado: $w_{a1}^{(1)} \triangleq \left[w_{10}^{(1)}, w_{11}^{(1)}, \dots, w_{1n}^{(1)} \right]^T$ (2.04)

vetor de pesos aumentado: $w_{a2}^{(1)} \triangleq \left[w_{20}^{(1)}, w_{21}^{(1)}, \dots, w_{2n}^{(1)} \right]^T$ (2.05)

Para segunda camada:

vetor de entrada aumentado: $a_a^{(1)} \triangleq \left[a_0^{(1)}, a_1^{(1)}, a_2^{(1)} \right]^T, a_0^{(1)} = 1$ (2.06)

vetor de pesos aumentado: $w_{a1}^{(2)} \triangleq \left[w_{10}^{(2)}, w_{11}^{(2)}, w_{12}^{(2)} \right]^T$ (2.07)

Baseado nas definições acima, as saídas de cada neurônio são dadas pelas Equações 2.08, 2.09, 2.10, 2.11 e 2.12 (GUPTA; JIN; HOMMA, 2003).

$$n_1^{(1)} = \left(w_{a1}^{(1)} \right)^T p_a \quad (2.08)$$

$$n_2^{(1)} = \left(w_{a2}^{(1)} \right)^T p_a \quad (2.09)$$

$$n_1^{(2)} = \left(w_{a1}^{(2)} \right)^T a_a^{(1)} \quad (2.10)$$

$$a_a^{(1)} = \left[a_0^{(1)}, \sigma(n_1^{(1)}), \sigma(n_2^{(1)}) \right]^T \quad (2.11)$$

$$a_a^{(2)} = a = \sigma(n_1^{(2)}) \quad (2.12)$$

Uma vez que a RNA tenha sido estabelecida, considerando $t(k)$ o alvo desejado, o erro quadrático instantâneo é dado pela Equação 2.13 (GUPTA; JIN; HOMMA, 2003).

$$e^2(t) = \left[t(t) - a_a^{(2)} \right]^2 = \left\{ t(t) - \sigma[n_1^{(2)}(t)] \right\}^2 \quad (2.13)$$

As derivadas parciais dos erros quadráticos associados com cada neurônio são dadas pelas Equações 2.14, 2.15 e 2.16 (GUPTA; JIN; HOMMA, 2003).

$$\delta_1^{(1)} \triangleq -\frac{1}{2} \frac{\partial e^2}{\partial n_1^{(1)}} \quad (2.14)$$

$$\delta_2^{(1)} \triangleq -\frac{1}{2} \frac{\partial e^2}{\partial n_2^{(1)}} \quad (2.15)$$

$$\delta_1^{(2)} \triangleq -\frac{1}{2} \frac{\partial e^2}{\partial n_1^{(2)}} \quad (2.16)$$

Combinando as Equações 2.12, 2.13 e 2.14 com a Equação 2.11 e aplicando algumas operações algébricas, resulta nas Equações 2.17, 2.18 e 2.19 (GUPTA; JIN; HOMMA, 2003).

$$\delta_1^{(2)} = e_1^{(2)} \sigma'(n_1^{(2)}) \quad (2.17)$$

$$\delta_1^{(1)} = \delta_1^{(2)} w_{11}^{(2)} \sigma'(n_1^{(1)}) \quad (2.18)$$

$$\delta_2^{(1)} = \delta_1^{(2)} w_{12}^{(2)} \sigma'(n_2^{(1)}) \quad (2.19)$$

Uma vez obtidos as derivadas para cada neurônio, é possível calcular o gradiente do erro relacionado a cada vetor de peso, conforme apresentado nas Equações 2.20, 2.21 e 2.22 (GUPTA; JIN; HOMMA, 2003).

$$\nabla_{w_{a1}^{(2)}}(e^2) = -2\delta_1^{(2)} a_a^{(1)} \quad (2.20)$$

$$\nabla_{w_{a1}^{(1)}}(e^2) = -2\delta_1^{(1)} p_a \quad (2.21)$$

$$\nabla_{w_{a2}^{(1)}}(e^2) = -2\delta_2^{(1)} p_a \quad (2.22)$$

Finalmente, aplicando o método descendente com gradiente instantâneo, os vetores de pesos atualizados para cada neurônio são dados pela Equações 2.23, 2.24 e 2.25 (GUPTA; JIN; HOMMA, 2003).

$$w_{a1}^{(1)}(t+1) = w_{a1}^{(1)}(t) - \mu \nabla_{w_{a1}^{(1)}}(e^2(t)) \quad (2.23)$$

$$w_{a2}^{(1)}(t+1) = w_{a2}^{(1)}(t) - \mu \nabla_{w_{a2}^{(1)}}(e^2(t)) \quad (2.24)$$

$$w_{a1}^{(2)}(t+1) = w_{a1}^{(2)}(t) - \mu \nabla_{w_{a1}^{(2)}}(e^2(t)) \quad (2.25)$$

onde, μ é a taxa de aprendizagem do parâmetro.

2.3.3 Revisão Bibliográfica da Aplicação de RNA para Diagnóstico de Falhas em Turbinas a Gás

As redes neurais artificiais vêm sendo aplicada em diagnóstico de falhas de componentes de turbinas a gás de diferentes maneiras. Fast e Palme (2010) e Fast; Assadi; De (2009) utilizaram RNA, baseada em um conjunto de dados medidos, para estimar os desvios de medições entre a turbina saudável e a turbina degradada; Palme; Fast; Thern (2011) e Ogaji *et al.* (2002) aplicaram RNA para classificação de falha de sensores e recuperação de medições perdidas, e Sina e Khorasani (2015) e Ogaji e Singh (2003) aplicaram RNA para detecção e isolamento de falhas. Uma breve discussão sobre os trabalhos importantes é apresentada a seguir.

Sina e Khorasani (2015) propõem uma metodologia para detecção e isolamento das falhas em turbinas a gás aeronáuticas, utilizando redes neurais artificiais. Neste trabalho são projetadas duas arquiteturas de redes neurais dinâmicas, a saber: modelo neural dinâmico e rede neural de atraso de tempo. A primeira possui grande capacidade de aprender sistemas dinâmicos ou sistemas não lineares complexos, enquanto a segunda tem a capacidade de representar e aprender o mapeamento não linear baseado em dados do passado. A arquitetura do modelo neural dinâmico contempla um módulo inicial de somatório, que promove a soma ponderada dos componentes do vetor de entrada, seguido de um módulo para mapeamento dinâmico entre o neurônio de entrada e de saída, que consiste em um filtro de resposta a impulso infinito, e, por fim, uma função de ativação não linear. Para ajustar os parâmetros da rede, são utilizados somente pares entrada / saída de dados da turbina saudável. O treinamento é realizado pelo método de retroalimentação dinâmico estendido. Por outro lado, a arquitetura da rede neural de atraso de tempo é similar a uma rede multicamadas *perceptron* com algumas modificações para introduzir atrasos nos pesos de entrada da estrutura. Para simular a turbina a gás e gerar os dados para treinamento das RNA, foi utilizado um modelo dinâmico de uma turbina de 2 eixos, desenvolvido no MATLAB Simulink, que foi validado contra os resultados do modelo de um software comercial. Para caracterizar as falhas, foram considerados desvios nas eficiências e nos coeficientes de vazão dos componentes rotativos (compressores e turbina). A detecção de falhas foi primeiramente testada utilizando um banco de 12 estruturas do modelo neural dinâmico, sendo uma estrutura para cada parâmetro dependente monitorado. A comparação entre o valor do parâmetro dependente e da saída da respectiva rede neural resulta em um resíduo, que serve de parâmetro para detectar a falha no

equipamento. Para definir o “gatilho” de detecção de falha, foi utilizado o método de Monte Carlo, variando os valores dos parâmetros de entrada e do nível de ruído, considerando a turbina a gás saudável. O mesmo procedimento foi adotado para testar a rede neural de atraso de tempo. Para isolamento da falha, foram utilizados os resíduos das redes de detecção de falhas, que após um tratamento, serviram de dados de entrada para 12 RNA multicamada *perceptron*, treinadas para classificar as falhas.

Palme; Fast; Thern (2011) apresentam uma metodologia baseada em RNA para sistemas de monitoramento da saúde de sensores, tendo a vantagem de possibilitar a modelagem do comportamento não linear do sensor degradado diretamente pelos dados operacionais sem requerer um modelo de turbina a gás. Outras técnicas existentes para esta aplicação, tal como a análise de componentes principais, mínimos quadrados parciais, e KF requerem um modelo de turbina a gás e, à exceção do último, são baseados em sistemas lineares. A técnica proposta inclui uma RNA para classificação de falhas de sensores e uma RNA para recuperação de medições perdidas. A primeira, que é usada para avaliar a saúde do sensor, compreende uma camada escondida e é treinada por um algoritmo de retroalimentação melhorado chamado de regra do momento. A última, que é usada para gerar os dados corretos de sensores com falhas, compreende uma camada escondida formada por uma função de transferência não linear e uma camada de saída formada por uma função de transferência linear. Esta RNA é treinada por um algoritmo conjugado escalado.

Fast e Palme (2010) apresentam uma ferramenta para o usuário final capaz de realizar diagnóstico online utilizando técnicas de RNA. O sistema é aplicado em uma instalação de ciclo combinado existente, que compreende uma turbina a gás Siemens SGT 800, uma caldeira e uma turbina a vapor. Cada um desses componentes é representado no modelo por meio de uma RNA *perceptron* multicamadas, treinada por amostras extraídas de dados operacionais. A arquitetura da RNA, i.e., o número de neurônios por camada, é selecionada por tentativa e erro e a função de transferência foi escolhida como tangente hiperbólica. De maneira a minimizar o erro da função, um algoritmo de treinamento de retroalimentação baseado no método de gradiente descendente foi aplicado. As amostras de treinamento, que representam os componentes saudáveis, são selecionadas em um intervalo de três meses de operação, onde cada medição é tomada como a média das leituras realizadas em cinco minutos. Antes de sua utilização, o conjunto de dados é filtrado, excluindo pontos espúrios e períodos de operação em regime transiente. Os dados de entrada de cada RNA compreendem as condições ambientais e algumas chaves que são utilizadas para selecionar o modo de

operação, enquanto o conjunto de saída compreende os parâmetros medidos relacionados com o desempenho do sistema. Finalmente, as estimativas e os valores reais destes parâmetros permitem uma avaliação econômica da degradação.

Shivakumar; Pai; Rao (2011) avaliam a influência dos parâmetros operacionais e da composição de combustível no desempenho e emissões de um motor diesel de simples cilindro. Primeiramente, uma sequência de testes experimentais foi realizada para gerar o banco de dados de medições, onde cada conjunto de dados foi medido com o equipamento em condições de estabilidade operacional. Em seguida, as condições operacionais, tais como a carga, razão de compressão, tempo de injeção e composição do combustível foram relacionadas como parâmetros de desempenho e emissões através de uma RNA multicamadas, onde a função de ativação foi ajustada como *sigmoid* e a função da camada de saída como *linear*. Uma técnica de retroalimentação convencional foi aplicada no treinamento da RNA. A precisão estimada da RNA ficou entre 5% e 8%, o que foi considerado bom para a respectiva aplicação.

Fast; Assadi; De (2009) desenvolveram uma aplicação com interface amigável para um sistema de monitoramento de desempenho de turbinas a gás baseado em RNA para demonstrar o potencial prático da RNA para usinas de geração de potência existentes. O trabalho inclui aquisição de dados, treinamento e avaliação de RNA e o projeto de uma interface gráfica. Dados de uma instalação do ciclo combinado existente, que foram medidos a cada minuto no intervalo de uma semana, foram usados como linha de base do sistema. A partir dos dados coletados, somente aqueles para condições de operação em carga total foram escolhidos, resultando em uma amostra de aproximadamente 7500 casos, que foram divididos das seguintes formas: 60% para treinamento da RNA, 15% para validação cruzada da RNA e 25% para teste da RNA. Uma configuração de RNA multicamada *feed-forward* foi aplicada, onde os parâmetros de entrada incluíam umidade relativa, pressão ambiente e temperatura ambiente, enquanto os parâmetros de saída incluíam potência, fluxo de combustível, fluxo de massa de ar, pressão de saída do compressor, temperatura de saída do compressor, temperatura de saída da turbina e emissão de dióxido de carbono. A influência de cada parâmetro de entrada no conjunto de saída foi avaliada através de uma análise de tentativa e erro, que consistiu da exclusão de parâmetros específicos do conjunto de entrada e da medição da precisão da estimativa da RNA. Por meio desta análise, foi possível identificar que a umidade relativa estava redundante para a estimação de parâmetro de desempenho, mesmo

sendo relevante para a decisão do modelo de operação. O treinamento da RNA foi executado por um algoritmo de retroalimentação utilizado comercialmente chamado NeuroSolutions.

Donat *et al.* (2008) apresentaram uma investigação das vantagens da utilização de redução de dados e técnicas de fusão de classificadores para aumentar o desempenho de métodos de diagnóstico de falha baseados em dados. Os seguintes classificadores foram utilizados: máquina de vetor de suporte, redes neurais probabilísticas, *k-nearest neighbour*, análise de componentes principais, modelo de mistura Gaussiana e isolador de falhas simples baseado em princípios físicos. Um mapa auto organizável foi utilizado para visualizar e ajudar no entendimento da natureza do espaço de entrada. Foi demonstrado que as técnicas de redução aumentam a qualidade das ferramentas de diagnóstico e permitem sua implementação em tempo real.

Ogaji e Singh (2003) apresentam uma breve revisão da importância do diagnóstico de falhas em turbinas a gás, destacando os métodos desenvolvidos até agora e introduzindo uma nova técnica baseada em RNA. A nova técnica consiste de uma combinação hierárquica de RNA individuais, que executam a análise de diagnóstico através de um nível crescente de detalhamento de informações. No primeiro nível, o conjunto de dados de medição é submetido a uma rede neural de classificação de padrões que detecta a presença de degradação. No segundo nível, utilizando o mesmo tipo de RNA, verifica-se quando a degradação é oriunda da instrumentação ou dos componentes do caminho do gás. No terceiro nível, o mesmo tipo de RNA foi utilizado para verificar a ocorrência de falha em um simples componente, em dois componentes ou em múltiplos componentes. No último nível, uma rede neural de aproximação de função foi utilizada para avaliar a intensidade das falhas. As classificações de padrões foram realizadas por redes neurais probabilísticas, enquanto as aproximações de funções foram realizadas por redes neurais multicamadas *feed-forward* treinadas por um algoritmo de retroalimentação resiliente. Esta técnica foi aplicada a uma turbina a gás de dois eixos, onde o compressor da turbina, a turbina de potência, o compressor os sensores foram analisados. Os resultados foram satisfatórios, comparados com a estimativa das técnicas de análise do caminho do gás linear e não linear.

2.4 Comentários

Sistemas de diagnóstico de falhas em turbinas a gás são aplicados amplamente nas instalações industriais. Apesar do custo, os benefícios de sua aplicação são relacionados com a

prevenção de falhas catastróficas e redução de tempo de máquina parada, resultando no aumento de disponibilidade e diminuição de riscos operacionais.

Desde a introdução das técnicas de análise do caminho do gás, foram desenvolvidos vários métodos na tentativa de superar os problemas destas técnicas. O comportamento não linear dos parâmetros de desempenho da turbina, que é um dos problemas da utilização de GPA linear, pode ser mais bem representado através do método de diagnóstico GPA não linear. Técnicas baseada na teoria da probabilidade também demonstraram potencial para esta aplicação. Além disso, métodos de inteligência artificial, tais como sistemas especialistas, lógica difusa, algoritmo genético e redes neurais artificiais foram aplicados nos sistemas de diagnóstico de falhas com resultados satisfatórios.

As redes neurais artificiais apresentam um grande potencial para sistemas de monitoramento de condições de saúde de turbinas a gás, dado que podem facilmente tratar problemas não lineares, ruído de medição ou falta de informação, e também, uma vez treinada, é rápida o suficiente para realização de análises em tempo real. Por outro lado, os pontos fracos das RNA são a falta de metodologia para definir a estrutura ótima para tratar um problema específico, a pouca definição de critérios de validação, a falta de metodologia para selecionar o melhor método e o tamanho das amostras de treinamento e o tempo de treinamento relativamente longo (OGAJI & SINGH, 2003).

As redes neurais artificiais foram aplicadas nos sistemas de diagnóstico de falhas através de diversos métodos, que incluem a predição de medição de desempenho, a estimativa de degradação de componentes e sistemas hierárquicos de diagnóstico. A qualidade dos resultados depende fortemente do tamanho do conjunto das amostras de treinamento, da qualidade das medições e do tipo de RNA. A aplicação de redes neurais probabilísticas como classificação de padrão implica em excelentes resultados, enquanto as redes neurais multicamada *feed-forward*, treinadas por algoritmo de retroalimentação, são adequadas para realização de tarefas de aproximação de funções.

Portanto, os trabalhos sobre diagnóstico de falhas encontrados na literatura discutem os modelos de turbina a gás e os vários métodos de diagnóstico, incluindo os métodos baseados em RNA. No entanto, a literatura não apresenta um estudo compreensivo sobre o tratamento de ruídos de medição para aumentar a qualidade dos resultados do diagnóstico, ou seja, não foram encontrados estudos comparativos de filtros de sinais de sensores de medição visando

melhoria dos resultados de sistemas de diagnósticos. Além disso, considerando os métodos baseados em RNA, a literatura não endereça técnicas para gerar amostras de ruído de medição com o propósito de treinamento e validação de RNA. Finalmente, os trabalhos supracitados não apresentam resultados da aplicação dos métodos de diagnóstico em uma campanha operacional completa de uma turbina a gás, assegurando a estabilidade do método, ou seja, se a intensidade da degradação dos componentes aumenta continuamente entre as paradas de manutenção ou entre as lavagens de compressores.

3 METODOLOGIA DO SISTEMA HIERÁRQUICO DE DIAGNÓSTICO

3.1 Introdução

Este capítulo apresenta a metodologia desenvolvida nesta Tese para realizar análise de diagnóstico de falha de uma turbina a gás industrial de eixo simples, que inclui um compressor e uma turbina.

A metodologia compreende a simulação do modelo da turbina, a definição da arquitetura das redes neurais artificiais que compõem o sistema hierárquico de diagnóstico, o método de criação e validação de cada rede neural individual e o estabelecimento da sequência do processo de diagnóstico de falhas. Primeiramente, o software PYTHIA 2.8 foi utilizado para realizar as simulações do modelo da turbina no ponto de referência operacional, considerando o equipamento saudável e degradado. Dada a importância do modelo da turbina a gás, este assunto será abordado separadamente no Capítulo 4. Em seguida, foi estabelecida uma arquitetura adequada para sistema hierárquico de diagnóstico para realização de detecção, isolamento e quantificação de falhas nos componentes da turbina. Então, redes neurais artificiais, com diferentes arquiteturas internas, foram criadas para representar cada função deste sistema de RNA e quatro processos de validação foram desenvolvidos para avaliar a qualidade dos resultados. Finalmente, um fluxograma do algoritmo de programação computacional foi desenvolvido para permitir a implementação da técnica em linguagem MATLAB.

A metodologia proposta utiliza elementos e técnicas encontradas na literatura e descritas no capítulo anterior, com ênfase nas técnicas de diagnóstico de falhas através de sistemas hierárquicos de diagnóstico desenvolvidas por Ogaji e Singh (2003). Entretanto, tais técnicas não apresentam bons resultados quando aplicadas na análise de dados reais das turbinas a gás devido à presença de ruídos e erros de tendência nos sinais dos sensores de medição. De forma a superar este problema, a metodologia proposta nesta Tese compara os resultados de dois métodos de tratamento de sinais dos sensores de medição, a saber: (1) aplicação de filtro sinal previamente à análise pelo sistema hierárquico de diagnóstico, composto por RNA treinadas e validadas por amostras de parâmetros dependentes sem ruído; e (2) análise direta

do sinal pelo sistema hierárquico de diagnóstico, composto por RNA treinadas e validadas por amostras de parâmetros dependentes com ruído.

3.2 Parâmetros do Sistema Hierárquico de Diagnóstico

O modelo da turbina a gás, abordado no Capítulo 4, é representado esquematicamente pela Figura 4.5. No entanto, para fins de demonstração da metodologia de redes neurais, um esquema simplificado do modelo da turbina a gás é apresentado na Figura 3.1.




Figura 3.1 - Modelo Esquemático Simplificado da Turbina

O compressor está localizado entre as estações 2 e 3, o combustor está localizado entre as estações 3 e 4 e a turbina está localizada entre as estações 4 e 6. Logo, a estação 2 representa as condições de entrada do compressor, a estação 3 representa as condições de saída do compressor, a estação 4 representa as condições de entrada da turbina e a estação 6 representa as condições de saída da turbina. É importante notar que as condições de entrada e saída do combustor não podem ser identificadas neste modelo simplificado, dado que no modelo implementado foi considerado extração de ar do compressor com propósito de resfriamento das pás da turbina. As definições a seguir são utilizadas no decorrer da demonstração.

- A Equação 3.01 define o desvio de medição na temperatura de saída do compressor.

$$\Delta T_3 = T_{3d} - T_{3c} \quad (3.01)$$

Onde:

T3d – medição de temperatura na saída do compressor degradado;

T3c – medição de temperatura na saída do compressor saudável;

- A Equação 3.02 define o desvio de medição na pressão de saída do compressor:

$$\Delta P_3 = P_{3d} - P_{3c} \quad (3.02)$$

Onde:

P3d – medição de pressão na saída do compressor degradado;

P3c – medição de pressão na saída do compressor sadio;

- A Equação 3.03 define o desvio de medição na temperatura de saída da turbina:

$$\Delta T_6 = T_{6d} - T_{6c} \quad (3.03)$$

Onde:

T6d – medição de temperatura na saída da turbina degradada;

T6c – medição de temperatura na saída da turbina saudável;

- A Equação 3.04 define o desvio de medição na potência de eixo:

$$\Delta POT = POT_d - POT_c \quad (3.04)$$

Onde:

POTd – medição de potência de eixo turbina degradada;

POTc – medição de potência de eixo da turbina saudável;

Os desvios nos parâmetros independentes da turbina a gás são:

- $\Delta \Gamma_C$ - desvio no coeficiente de vazão do compressor
- $\Delta \eta_C$ - desvio na eficiência do compressor
- $\Delta \Gamma_T$ - desvio no coeficiente de vazão da turbina
- $\Delta \eta_T$ - desvio na eficiência da turbina

3.2.1 Tratamento de Sinais de Sensores de Medição

O erro de medição é definido como a diferença entre o resultado da medição e o valor real da grandeza medida. Este erro pode ser dividido em dois componentes, a saber: ruído, com natureza aleatória, e tendência (*bias*), com natureza constante. Com o propósito de simplificação do modelo e considerando que os elementos dos vetores de entrada da técnica de diagnóstico ora proposta constituem diferenças de medições, o erro de tendência não será considerado neste trabalho.

Neste trabalho serão avaliadas duas abordagens para tratamento do sinal de medição, sendo uma para aplicação prévia ao processo de diagnóstico e outra interna ao processo de diagnóstico. Na primeira alternativa, será aplicado um filtro no sinal de medição com a finalidade de remoção de ruído e pontos espúrios, sendo que a saída desse processo de suavização de sinal alimentará os vetores de entrada das redes neurais treinadas com amostras sem ruído. Na segunda alternativa, serão geradas amostras com ruídos para treinamento das redes neurais, sendo estas utilizadas para processar diretamente os sinais de medição reais, sem a prévia passagem pelos filtros. O erro de medição, quando representado através de uma distribuição normal de média zero, é conhecido como ruído branco. Neste caso, 95% das amostras estão localizadas entre os limites máximos do erro. A Figura 3.2(a) apresenta a representação estatística do ruído, onde o intervalo $[-2\sigma, +2\sigma]$ compreende 95% das amostras. Logo, o desvio padrão da distribuição normal é igual à metade do erro máximo admitido.




Figura 3.2 - Ruído: (a) Representação Estatística; (b) Método da Estimativa

Figura 3.2(b) apresenta o método de estimativa de ruído. Uma vez que a distribuição normal que representa o ruído de uma medição específica é definida, é possível simular o ruído usando a função inversa da distribuição normal acumulada. Este processo é realizado utilizando uma função geradora de número aleatório como entrada da distribuição normal acumulada inversa, resultando no valor do ruído. O ruído calculado é adicionado à medição que foi obtida pela simulação do modelo da turbina degradada, resultando na amostra de treinamento com ruído da RNA. A expressão utilizada para simular o ruído, utilizando o Microsoft Excel, é apresentada na Equação 3.05.

$$M = \tilde{M} + INV.NORM(RAND(), 0, \sigma, 1) \quad (3.05)$$

Onde:

M : medição com ruído

$\tilde{M}$: medição sem ruído (fonte: modelo de simulação)

$INV.NORM()$: distribuição normal acumulada inversa

$RAND()$: número aleatório selecionado no intervalo [0,1]

σ : desvio padrão, que depende do tipo de medição.

O desvio padrão para cada medição é apresentado na Tabela 3.1. Essas expressões representam a metade do erro típico de cada tipo de medição (LI, 2011).

Tabela 3.1- Desvio Padrão das Medições

Medição	Desvio Padrão
Temperatura de Saída do Compressor	$\pm \frac{\sqrt{2.5^2 + (0.0075 \times T)^2}}{2}$
Pressão de Saída do Compressor	$\pm \frac{0.5}{2} \%$
Temperatura de Saída da Turbina	$\pm \frac{\sqrt{2.5^2 + (0.0075 \times T)^2}}{2}$
Potência de Eixo	$\pm \frac{0.1}{2} \%$

Esta técnica é utilizada para gerar ruído de medição para as amostras de treinamento e validação das redes neurais.

3.3 Arquitetura do Sistema Hierárquico de Diagnóstico

A combinação de diferentes tipos de RNA é utilizada para definir a arquitetura do sistema hierárquico de diagnóstico. Tanto a definição da arquitetura do sistema hierárquico de diagnóstico, quanto a escolha de cada rede neural individual foram realizadas de forma a promover uma análise de diagnóstico confiável. No primeiro nível, um *perceptron* de camada única é usado para detectar se a turbina está degradada. No segundo nível, uma rede neural probabilística radial é utilizada para isolar o componente degradado, que pode ser o compressor, a turbina ou ambos. No terceiro nível, redes neurais *feed-forward* com duas camadas, treinadas através de um algoritmo de retroalimentação, são utilizadas para quantificar a degradação dos componentes, i.e., a intensidade dos desvios no coeficiente de vazão e na eficiência de cada caso. A Figura 3.3 apresenta uma representação esquemática do modelo proposto. Na próxima seção, as características de cada RNA serão tratadas em detalhes.




Figura 3.3 - Arquitetura do Sistema hierárquico de Diagnóstico

3.4 Arquitetura das Redes Neurais Individuais

Diversas arquiteturas de redes neurais podem ser encontradas na teoria de redes neurais. Em geral, cada uma delas foi originalmente desenvolvida para uma aplicação específica e então utilizada para solucionar uma família de problemas. Como o desenvolvimento de uma nova arquitetura de RNA não pertence ao escopo desta Tese, as RNA utilizadas neste trabalho foram selecionadas dentre as disponíveis na biblioteca de redes neurais do MATLAB.

3.4.1 Arquitetura da RNA para Detecção de Degradação

O *perceptron* de camada única foi selecionado para executar a detecção de degradação na turbina. Este *perceptron* simples é adequado para aplicações onde um resultado binário é esperado. A função de transferência trabalha como um “gatilho”, onde o limite é dado pelo valor da tendência.

O vetor de entrada do *perceptron* de detecção de degradação compreende o valor absoluto dos desvios das seguintes medições: pressão e temperatura de saída do compressor, temperatura de saída da turbina e potência de eixo, conforme apresentado na Equação 3.06.

$$i_d = \{|\Delta T_3|; |\Delta P_3|; |\Delta T_6|; |\Delta POT|\} \quad (3.06)$$

O vetor alvo compreende um conjunto de resultados binários, onde a turbina degradada recebe o valor “1” e a turbina saudável recebe o valor “0”. A expressão do vetor alvo é apresentada na Equação 3.07.

$$t_d = \begin{cases} 0, & \text{se } \Delta \Gamma_c; \Delta \eta_c; \Delta \Gamma_T \text{ e } \Delta \eta_T = 0 \\ 1, & \text{caso contrário} \end{cases} \quad (3.07)$$

O processo de treinamento deste *perceptron*, usando as funções “*adapt*” ou “*train*” do MATLAB, não atingiu resultados razoáveis, que pode ser explicado pelo fato da amostra de treinamento ter sido formada em grande parte por medições de turbinas a gás degradadas. Por esta razão, depois de ser treinado, a tendência deste *perceptron* foi ajustada manualmente, transformando o processo final de ajuste em um exercício de tentativa e erro. Isso pode se tornar uma importante questão quando da consideração de medições com ruído, dado que o efeito do ruído no vetor de desvios pode ser maior que o efeito da própria degradação.

3.4.2 Arquitetura da RNA para Isolamento de Falhas

As redes neurais artificiais probabilísticas foram selecionadas para executar a tarefa de isolamento de falhas porque são adequadas para problemas de classificação. Três tipos de situações foram identificados como possíveis soluções da RNA, a saber: compressor degradado, turbina degradada e a combinação de compressor e turbina degradados.

O vetor de entrada da rede neural de isolamento de falha compreende os valores dos seguintes desvios de medição: pressão e temperatura de saída do compressor, temperatura de saída da turbina e potência de eixo. Além disso, de forma a melhorar o desempenho da RNA probabilística, o vetor de entrada é inicialmente processado para se situar entre os limites mínimo e máximo [-1, 1]. A expressão para o vetor de entrada é apresentada na Equação 3.08.

$$i_i = \text{mapminmax}\{\Delta T_3; \Delta P_3; \Delta T_6; \Delta POT\} \quad (3.08)$$

O vetor alvo da RNA de isolamento de falhas compreende as três classes mencionadas, onde a degradação do compressor recebe o valor “1”, a degradação da turbina recebe o valor “2” e a degradação combinada recebe o valor “3”. A expressão do vetor alvo é apresentada na Equação 3.09.

$$t_i = \begin{cases} 1, & \text{se } \Delta\Gamma_T \text{ e } \Delta\eta_T = 0 \\ 2, & \text{se } \Delta\Gamma_C \text{ e } \Delta\eta_C = 0 \\ 3, & \text{caso contrário} \end{cases} \quad (3.09)$$

3.4.3 Arquitetura da RNA para Quantificação de Falhas

A rede neural artificial *feed-forward* de duas camadas, com a primeira camada compreendendo uma função de transferência *sigmoid* e a segunda camada compreendendo uma função de transferência linear, é utilizada para quantificar as falhas dos componentes. Esta técnica é aplicada na quantificação de falhas do compressor, de falhas na turbina e de falhas combinadas.

Em todos os três casos, o vetor de entrada da RNA compreende os seguintes desvios de medição: pressão e temperatura de saída do compressor, temperatura de saída da turbina e potência de eixo. Entretanto, todos têm diferentes domínios das amostras de treinamento. O conjunto de amostras de treinamento que compreende o vetor de entrada da RNA de quantificação de falhas do compressor é executado apenas com implantação de degradação no compressor do modelo da turbina a gás. Por outro lado, o conjunto de amostras de treinamento que compreende o vetor de entrada da RNA de quantificação de falhas da turbina é executado apenas com implantação de degradação na turbina do modelo da turbina a gás.

A expressão do vetor de entrada da RNA de quantificação de falhas de compressor é apresentada na Equação 3.10.

$$i_{qc} = \{\Delta T_3; \Delta P_3; \Delta T_6; \Delta POT\}, \quad \text{onde} \begin{cases} 0 \leq \Delta\Gamma_C \leq Limite_S \\ 0 \leq \Delta\eta_C \leq Limite_S \\ \Delta\Gamma_T = 0 \text{ e } \Delta\eta_T = 0 \end{cases} \quad (3.10)$$

A expressão do vetor de entrada da RNA de quantificação de falhas na turbina é apresentada na Equação 3.11.

$$i_{qt} = \{\Delta T_3; \Delta P_3; \Delta T_6; \Delta POT\}, \quad \text{onde} \begin{cases} Limit_I \leq \Delta\Gamma_T \leq Limit_S \\ 0 \leq \Delta\eta_T \leq Limite_S \\ \Delta\Gamma_C = 0 \text{ e } \Delta\eta_C = 0 \end{cases} \quad (3.11)$$

A expressão do vetor de entrada da RNA de quantificação de falhas combinadas é apresentada pela Equação 3.12.

$$i_{qct} = \{\Delta T_3; \Delta P_3; \Delta T_6; \Delta POT\}, \quad \text{onde} \quad \begin{cases} 0 \leq \Delta \Gamma_c \leq Limit_S \\ 0 \leq \Delta \eta_c \leq Limit_S \\ Limit_I \leq \Delta \Gamma_T \leq Limit_S \\ 0 \leq \Delta \eta_T \leq Limit_S \end{cases} \quad (3.12)$$

Normalmente a RNA apresenta um comportamento razoável quando aplicada entre um intervalo bem definido de domínio, que é limitado pelas bordas do conjunto das amostras de treinamento. O chamado “Limit_S” representa a borda superior do conjunto de amostras de treinamento, aqui definido como -5%. Este valor é aplicado para os desvios de coeficiente de vazão e de eficiência do compressor e para os desvios de eficiência da turbina. O chamado “Limit_I” representa a borda inferior do conjunto de amostras de treinamento da turbina degradada, aqui definido como +5%. Este valor positivo representa um aumento no coeficiente de vazão da turbina. A definição dos valores de “Limit_S” e “Limit_I” foi baseada nos valores máximos de desvio no coeficiente de vazão do compressor e na eficiência da turbina adotados por Nozari *et al* (2012).

O vetor alvo da RNA de quantificação de falhas é baseado no nível de degradação de cada componente. A expressão do vetor alvo da RNA de quantificação de falhas do compressor é apresentada na Equação 3.13.

$$t_{qc} = \{\Delta \Gamma_c; \Delta \eta_c\} \quad (3.13)$$

A expressão do vetor alvo da RNA de quantificação de falhas da turbina é apresentada na Equação 3.14.

$$t_{qt} = \{\Delta \Gamma_T; \Delta \eta_T\} \quad (3.14)$$

A expressão do vetor alvo da RNA de quantificação de falhas combinadas é apresentada na Equação 3.15.

$$t_{qct} = \{\Delta \Gamma_c; \Delta \eta_c; \Delta \Gamma_T; \Delta \eta_T\} \quad (3.15)$$

As três RNA de quantificação são treinadas através da função “train” do MATLAB. Os argumentos desta função são a rede neural, o vetor de entrada e o vetor de saída, onde as amostras de treinamento são divididas da seguinte forma: 60% como propósito de treinamento; 20% com o propósito de validação e 20% com o propósito de generalização. O processo de treinamento é realizado no modo batelada, onde todos os dados de entrada do conjunto de amostras de treinamento são aplicados à RNA previamente ao recálculo de seus pesos. O melhor conjunto de pesos e tendências é alcançado pela função de minimização de erro médio quadrático (EMQ). O processo de otimização aplica tanto o gradiente da rede relativa aos pesos e tendências ou o Jacobiano do erro das redes em relação aos pesos e tendências.

Em resumo, os três tipos de RNA utilizados no sistema hierárquico de diagnóstico foram discutidos nesta seção. Foi mostrado que essas redes neurais utilizam diferentes arquiteturas, vetores de entrada e vetores alvos. Na próxima seção, serão apresentados 4 métodos de validação empregados para realizar a verificação de cada RNA utilizada nesta Tese.

3.5 Métodos de Validação de RNA

Em geral, o método de validação da RNA consiste na realização de uma comparação entre as saídas reais e as desejadas. Embora a ideia por trás desse conceito é simples, sua aplicação deve ser elaborada para cada caso.

Quatro análises de validação foram empregadas para avaliar a qualidade das RNA individuais. A qualidade da RNA de detecção de degradação é avaliada pela porcentagem de erros nos resultados da RNA, enquanto a qualidade das RNA de isolamento é avaliada pela taxa de acertos no isolamento, calculada a partir da matriz de confusão, e quantificação de falhas é avaliada pelo erro médio quadrático (EMQ) de cada componente das RNA.

Mesmo que as RNA de quantificação de falhas sejam todas avaliadas por seus EMQ, os resultados são apresentados de maneira diferente para cada tipo de avaliação. Por exemplo, enquanto os resultados da avaliação da RNA de quantificação de falha no compressor são apresentados em forma de matriz, os resultados da avaliação da RNA de quantificação de falha combinada são apresentados por sua média e desvio padrão.

Ainda, considerando as RNA de quantificação de falhas relacionadas ao conjunto de medições com ruído, foram tomadas quatro medidas de cada ponto. Para o caso das RNA de

quantificação de falhas do compressor e da turbina, o EMQ das quatro estimativas de medidas é calculado para cada ponto, de maneira a prover um conjunto adequado de elementos para serem apresentados na forma de matriz.

Finalmente, conjuntos distintos de amostras são utilizados para o treinamento e validação dos processos, onde amostras de validação discretas são tomadas entre duas amostras consecutivas de treinamento, de forma a realizar uma análise de todo o domínio. Ainda que cada RNA individual seja validada, o desempenho do sistema hierárquico de diagnóstico também é avaliado.

Em seguida, os métodos de avaliação das RNA mencionados são discutidos em detalhes. A implementação da metodologia de validação usando MATLAB é apresentada no Apêndice B.

3.5.1 Método de Validação da RNA de Detecção de Degradação

A qualidade da RNA de detecção de degradação é avaliada pela porcentagem de erro da estimativa, conforme indicado na Equação 3.16.

$$\varepsilon^{DD} = \frac{N_S - N_R}{N_S} \times 100\% \quad (3.16)$$

onde:

ε^{DD} : erro da estimativa da RNA de detecção de degradação

N_S : número total de estimativas

N_R : número de amostras detectadas com sucesso

3.5.2 Método de Validação da RNA de Isolamento de Falhas

A rede neural artificial de isolamento de falhas é uma rede neural probabilística de base radial que é capaz de detectar se o compressor, a turbina ou ambos estão degradados. A qualidade deste tipo de aplicação de RNA é comumente avaliada por meio da matriz de confusão (SIMON & ARMSTRONG, 2013; RAHME & MESKIN, 2015; NOZARI *et al.*, 2012).

Nesta Tese, a configuração adotada é apresentada na Tabela 3.2 a Taxa de Acertos no Isolamento de falhas é dada pela Equação 3.17.

Tabela 3.2- Matriz de Confusão para Avaliar a Qualidade da RNA de Isolamento de Falhas

		Falha Implantada no Modelo da Turbina a Gás		
Falha Isolada pela RNA	Tipo de Falha	Falha no Compressor	Falha na Turbina	Falha Combinada
	Falha no Compressor	$\frac{N_C^C}{N_C} \times 100\%$	$\frac{N_T^C}{N_T} \times 100\%$	$\frac{N_{CT}^C}{N_{CT}} \times 100\%$
	Falha na Turbina	$\frac{N_C^T}{N_C} \times 100\%$	$\frac{N_T^T}{N_T} \times 100\%$	$\frac{N_{CT}^T}{N_{CT}} \times 100\%$
	Falha Combinada	$\frac{N_C^{CT}}{N_C} \times 100\%$	$\frac{N_T^{CT}}{N_T} \times 100\%$	$\frac{N_{CT}^{CT}}{N_{CT}} \times 100\%$
Taxa de Acertos no Isolamento		T^{AI}		

$$T^{AI} = \frac{\left(\frac{N_C^C}{N_C}\right) + \left(\frac{N_T^T}{N_T}\right) + \left(\frac{N_{CT}^{CT}}{N_{CT}}\right)}{N_C + N_T + N_{CT}} \times 100\% \quad (3.17)$$

onde:

T^{AI} : taxa de acertos no isolamento de falhas

N_Y^X : número de casos X isolados pela RNA, treinada para isolar o componente Y

N_Y : número total de casos em que a RNA foi treinada para isolar o componente Y

C: falha no compressor

T: falha na turbina

CT: falha combinada

3.5.3 Método de Validação da RNA de Quantificação de Falhas

O sistema hierárquico de diagnóstico compreende três RNA de quantificação de falhas, que são a RNA de quantificação de falhas do compressor, a RNA de quantificação de falhas da turbina e a RNA de quantificação de falhas combinadas. Estas três RNA buscam estimar os desvios no coeficiente de vazão e na eficiência dos componentes da turbina a gás e, portanto,

as primeiras duas apresentam dois elementos no vetor de saída, enquanto a última apresenta quatro elementos no vetor de saída. Esta característica leva a necessidade de desenvolvimento de dois métodos diferentes de validação para as RNA de quantificação de falhas. Primeiramente, uma matriz dos EQM das estimativas dos desvios nos parâmetros independentes, com os desvios no coeficiente de vazão dispostos em colunas e os desvios na eficiência dispostos em linhas, é utilizada para avaliar a qualidade das RNA de quantificação de falhas do compressor e da turbina. Então, uma tabela apresentando a média e os desvios padrões dos erros das estimativas de falhas é utilizada para avaliar a qualidade da RNA de quantificação de falha combinada, este método é também empregado para avaliar o sistema hierárquico de diagnóstico de falhas e, por isso, será apresentado na próxima seção. Além disso, nos casos onde foram consideradas amostras de treinamento simuladas com ruído, a avaliação da qualidade das RNA de quantificação de falhas do compressor e da turbina são executadas através do EQM do conjunto de valores relacionados a cada ponto da tabela.

O EQM da RNA de quantificação de falhas do compressor, sem consideração de ruído nas amostras de treinamento, pode ser expresso pela Equação 3.18.

$$\varepsilon_{ij}^{CFQ} = \left[\sqrt{\frac{(\Delta\Gamma_C^S - \Delta\Gamma_C^R)^2 + (\Delta\eta_C^S - \Delta\eta_C^R)^2}{2}} \right]_{ij} \quad (3.18)$$

onde:

ε_{ij}^{CFQ} : EQM da estimativa da RNA relacionada ao ponto ij

$\Delta\Gamma_C^S$: Desvio implantado no coeficiente de vazão do compressor

$\Delta\Gamma_C^R$: Desvio estimado pela RNA no coeficiente de vazão do compressor.

$\Delta\eta_C^S$: Desvio implantado na eficiência do compressor

$\Delta\eta_C^R$: Desvio estimado pela RNA na eficiência do compressor

i : Desvio de coeficiente de vazão discreto

j : Desvio de eficiência discreto

De forma similar, o EQM da RNA de quantificação de falhas da turbina, sem consideração de ruído nas amostras de treinamento, pode ser expresso pela Equação 3.19.

$$\varepsilon_{ij}^{TFQ} = \left[\sqrt{\frac{(\Delta\Gamma_T^S - \Delta\Gamma_T^R)^2 + (\Delta\eta_T^S - \Delta\eta_T^R)^2}{2}} \right]_{ij} \quad (3.19)$$

As redes neurais artificiais de quantificação de falhas, com consideração de ruídos nas amostras de treinamento, são também avaliadas através do EQM na estimativa dos desvios. Contudo, neste caso, ambos os tipos de EQM dos desvios no coeficiente de vazão e desvios na eficiência, e o EQM do conjunto de medições relacionadas a cada ponto são calculados.

Então, o EQM dos desvios da RNA de quantificação de falhas do compressor, considerando medições com ruído, pode ser expresso pela Equação 3.20.

$$\varepsilon_{ij}^{CFQ} = \left\{ \sqrt{\frac{\sum_{k=1}^N \left[\sqrt{\frac{(\Delta\Gamma_C^S - \Delta\Gamma_C^R)^2 + (\Delta\eta_C^S - \Delta\eta_C^R)^2}{2}} \right]^2}{N}} \right\}_{ij} \quad (3.20)$$

Onde:

N : número de medições relacionadas ao ponto ij

Similarmente, o EQM dos desvios da RNA de quantificação de falhas da turbina, considerando medições com ruído, pode ser expresso pela Equação 3.21.

$$\varepsilon_{ij}^{TFQ} = \left\{ \sqrt{\frac{\sum_{k=1}^N \left[\sqrt{\frac{(\Delta\Gamma_T^S - \Delta\Gamma_T^R)^2 + (\Delta\eta_T^S - \Delta\eta_T^R)^2}{2}} \right]^2}{N}} \right\}_{ij} \quad (3.21)$$

3.5.4 Método do Sistema Hierárquico de Diagnóstico

Considerando que a RNA de quantificação de falha combinada apresenta quatro resultados, ou seja, desvio no coeficiente de vazão do compressor, desvio na eficiência do compressor, desvio no coeficiente de vazão da turbina e desvio na eficiência da turbina, os resultados da validação não podem ser dispostos em uma matriz bidimensional.

A RNA é avaliada pela análise da média e desvio padrão dos erros. Cada característica dos componentes é avaliada separadamente. As expressões da média e do desvio padrão são apresentadas, respectivamente, nas Equações 3.22 e 3.23.

$$\mu_k^{CTQ} = \frac{\sum_{i=1}^N (\Delta k_i^S - \Delta k_i^R)}{N} \quad (3.22)$$

$$\sigma_k^{CTQ} = \sqrt{\frac{\sum \left((\Delta k_i^S - \Delta k_i^R) - \mu_k^{CTQ} \right)^2}{N - 1}} \quad (3.23)$$

Onde:

Δk_i^S : Desvio implantado

Δk_i^R : Desvio estimado

N: número de amostras

3.6 Modelo de Diagnóstico de Falhas

Até este ponto neste capítulo, todas as tarefas de pré-processamento foram endereçadas, começando pelo processo de modelagem da turbina a gás, passando pelo procedimento de geração de amostras de treinamento e validação, que foi seguido pela criação da RNA e, finalmente, os métodos de validação das RNA. Esta seção descreve o algoritmo de diagnóstico de falhas, que é apresentado na Figura 3.4.

Primeiramente, o conjunto de desvios de medição é definido como dados de entrada. Então, os valores absolutos destes desvios são calculados. O conjunto dos desvios de medição absolutos é avaliado pela RNA de detecção de degradação, que resulta “0” para não degradação ou “1” para componente degradado. Quando a degradação é detectada, o conjunto de desvios de medição é utilizado como entrada da RNA de isolamento de falhas, que resulta “1” para degradação do compressor, “2” para degradação da turbina e “3” para degradação combinada. Finalmente, a correspondente RNA de quantificação de falhas para a degradação selecionada é utilizada para estimar os desvios nos parâmetros independentes dos componentes.




Figura 3.4 - Algoritmo de Diagnóstico de Falhas

3.7 Comentários

Este capítulo apresentou a metodologia desenvolvida nesta Tese para realizar a análise de diagnóstico de falhas em turbinas a gás. Esta metodologia compreende a simulação do modelo da turbina, a definição da estrutura do sistema hierárquico de diagnóstico, a definição da arquitetura das redes neurais individuais, os métodos de tratamento de sinais, os métodos de validação e o algoritmo de diagnóstico de falhas.

A existência de ruído nas medições torna a aplicação prática das técnicas de diagnóstico de falhas em turbinas a gás pouco eficazes, desta forma, é necessário realizar o devido tratamento dos sinais dos sensores de medição previamente a utilização de tais técnicas ou criar artifícios internos às próprias técnicas de diagnóstico para tratar o problema.

Finalmente, os métodos de validação avaliam a qualidade de cada RNA, contudo um estudo compreensivo deve ser realizado para estabelecer os níveis de erros aceitáveis.

Em resumo, esta metodologia é abrangente no sentido de cobrir todo o processo de diagnóstico de falhas de uma turbina a gás industrial de eixo simples.

4 MODELO DA TURBINA A GÁS

4.1 Introdução

Este capítulo abordará o modelo termodinâmico da turbina a gás, complementando as informações sobre a metodologia de diagnóstico de falhas proposta neste Tese.

A turbina a gás usada neste estudo foi a turbina industrial ALSTOM GT11N2, que compreende um compressor e uma turbina, montados no mesmo eixo, e um combustor tipo silo montado na vertical. O compressor possui 14 estágios de compressão e três IGV (*Inlet Guide Vanes*), produzindo uma razão de compressão de 16:1. A turbina possui quatro estágios com capacidade de produzir 115 MW de potência líquida. Este tipo de turbina a gás é bem difundido no mundo, compondo importantes instalações termelétricas em muitos países, como China, EUA, Canadá, México, Colômbia e Brasil (ALSTOM, 2007).

O modelo da turbina a gás foi elaborado durante o período que o doutorando complementou sua formação técnica na Universidade de Cranfield, na Inglaterra, quando recebeu orientação dos Professores Dr. Yiguang Li e Dr. Pericles Pilidis. Por orientação da equipe técnica local, foram utilizados os softwares PYTHIA 2.8 e TURBOMATCH, de propriedade da referida universidade, para simulação da turbina a gás.

Dados reais extraídos da turbina a gás através do sistema PI (OSISOFT, 2013) são utilizados para ajustar o modelo da turbina no PYTHIA 2.8. O modelo do ponto de referência operacional da turbina a gás é referente a uma condição de operação com alta probabilidade de ocorrência durante a campanha de produção, não guardando referência com o ponto de projeto do fabricante.

Os mapas de desempenho dos componentes da turbina a gás, utilizados no modelo para simulação de condições operacionais fora do ponto de referência, são obtidos a partir do escalonamento de mapas padrões, portanto, não representam os mapas reais estabelecidos pelo fabricante.

Nas seções deste capítulo, são apresentados uma breve descrição da ALSTOM GT11N2, a estratégia de simulação adotada, o modelo termodinâmico do ponto de referência operacional da turbina a gás, bem como os mapas de funcionamento de seus principais componentes.

4.2 Turbina ALSTOM GT11N2

A turbina a gás industrial GT11N2, introduzida no mercado pela ALSTOM no ano de 1989, alcançou 60 unidades instaladas no mundo. Esta turbina é adequada para todos os tipos de aplicações industriais, tais como operação em ciclo simples, geração de energia em ciclo combinado e cogeração. O portfólio desta classe de turbinas a gás da ALSTOM ainda contempla as turbinas a gás GT24, GT26 e GT14E3 (ALSTOM, 2007).

A GT11N2 pode ser ajustada para operar em 50 Hz ou 60 Hz, produzindo uma potência média em condição de carga base de 115 MW. Esta turbina a gás é adequada para queimar um amplo intervalo de composição de combustível, como gás natural, óleo diesel ou gases de forno. Além disso, a turbina a gás também apresenta bom comportamento em demandas de carga parcial e durante regimes de operação transiente. Por fim, seu projeto atende às restrições do meio ambiente, no que tange emissões de NOx (ALSTOM, 2007). As principais características da GT11N2 informadas pelo fabricante, ajustada para operar em 60 Hz com gás natural, são apresentadas na Tabela 4.1.

Tabela 4.1- Principais Características da ALSTOM GT11N2 (ALSTOM, 2010)

Combustível	Gás Natural	
Frequência	Hz	60
Potência Elétrica Bruta	MW	115,4
Eficiência Elétrica Bruta	%	33,9
<i>Heat Rate</i>	kJ/kWh	10619
Rotação	Rpm	3600
Razão de Pressão do Compressor	-	15,9:1
Fluxo de Gás de Saída	kg/s	400
Temperatura do Gás de Saída	°C	526
Emissão de NOx	Vppm	<25

Os componentes da turbina a gás são montados em um eixo, utilizando discos forjados soldados, que aumentam a rigidez do rotor e evitam problemas relacionados com parafusos transversais e desalinhamento de discos. A Figura 4.1 apresenta uma foto da turbina a gás, onde o compressor é exibido no plano da frente e a turbina é exibida no plano de trás.



Figura 4.1 - Secção Horizontal GT11N2 (ALSTOM,2007)

O combustor de silo da turbina a gás GT11N2, montado externamente na vertical, permite fácil inspeção visual de todo sistema de combustão e também da primeira fileira de pás da turbina (ALSTOM, 2007). Uma representação esquemática desta turbina a gás, mostrando um corte transversal do combustor de silo, é apresentada na Figura 4.2.



Figura 4.2 - Representação Esquemática da GT11N2 (ALSTON, 2010)

A turbina a gás pode ser equipada com três tipos de combustores: combustor dry-low-NOx EV (*environmental burner*), combustor LBTU e combustor SB. O combustor EV, que é

projetado para queimar gás natural, é indicado para aplicações em ciclo simples e combinado onde é requerido baixa emissão. Emissões de NO_x menores que 25 ppm podem ser alcançadas utilizando este tipo de combustor. O combustor LBTU, que é projetado para queimar combustíveis com poder calorífico inferior menor que 2000 kJ/kg, como os gases de fornos, é indicado para aplicações industriais onde estes gases estão disponíveis. O combustor SB, que é projetado para queimar óleo diesel ou combustível sintético, é indicado para aplicação de geração de pico em ciclo simples, dado a necessidade de injeção de grande quantidade de água no combustor, que aumenta a potência de saída, enquanto mantém emissões em níveis aceitáveis.

O compressor da GT11N2 apresenta 14 estágios, resultando em uma razão de pressão de 16:1. As primeiras três fileiras de pás do compressor são precedidas de pás direcionadoras de ângulo variável, que são responsáveis por manter um bom comportamento operacional em condições de carga parcial. A turbina apresenta quatro estágios, onde as pás do rotor e pás direcionadoras de fluxo dos dois primeiros estágios são equipadas com sistema de refrigeração de palheta (ALSTOM, 2007).

Esta turbina a gás é aplicada em instalações industriais ou usinas de geração de energia elétrica em todo mundo. A seguir são listadas as principais instalações equipadas com a ALSTOM GT11N2: (i) TERMOBARRANQUILLA, que é situada na Colômbia, começou a operar em 1996. Esta instalação é composta por cinco GT11N2 e duas turbinas a vapor, sendo capaz de entregar 750 MW, queimando gás natural; (ii) BAO SHAN, que é situada na China, começou a operar em 1997. Esta instalação é capaz de entregar 150 MW e 180 ton/h de vapor, queimando gás de forno; (iii) BURGIN, situada nos USA, começou a operação em 1994, sendo utilizada para produção de energia em períodos de pico de demanda, é composta por cinco GT11N2; (iv) SARNIA, situada no Canadá, foi projetada para operar com propósito de cogeração, sendo capaz de entregar 650 MW; (v) VALLE del MEXICO, começou a operação em 2002 e compreende três GT11N2, capazes de entregar 550 MW; (vi) TERMORIO (atualmente UTE Governador Leonel Brizola), situada no Brasil, começou a operação em 2002, compreendendo seis GT11N2 e três turbinas a vapor, sendo capaz de entregar 1000 MW (ALSTOM, 2007).

Em resumo, esta seção apresentou uma breve descrição das principais características da turbina ALSTOM GT11N2. A seguir, serão apresentados os resultados da simulação do modelo da turbina.

4.3 Simulação da Turbina Utilizando PYTHIA

O modelo da turbina a gás foi desenvolvido com o objetivo de simular o equipamento real ALSTOM GT11N2 instalada na TERMORIO, uma usina termelétrica da PETROBRAS. Dados operacionais coletados do sistema PI (OSISOFT, 2013) são utilizados para ajustar o ponto de referência operacional do modelo.

O software PYTHIA 2.8 é utilizado para simular a turbina a gás. Este software trabalha sob a plataforma do TURBOMATCH, uma ferramenta de simulação de turbina a gás desenvolvida pela Universidade de Cranfield que utiliza relações termodinâmicas e mecânicas para realizar a correspondência entre os mapas dos componentes da turbina a gás e, como isso, simular o desempenho do equipamento.

O TURBOMATCH realiza cálculos de desempenho da turbina a gás utilizando rotinas computacionais conhecidas como Blocos. A maioria dos Blocos representam processos termodinâmicos dos componentes do equipamento, mas também existem blocos para realização de operações aritméticas e para cálculo do desempenho. A interface entre os blocos é realizada por meio dos vetores de entrada e saída das respectivas estações. O vetor da estação de entrada representa as propriedades termodinâmicas iniciais do fluido de trabalho, como por exemplo, pressão estática, pressão de estagnação, temperatura estática e temperatura de estagnação. O vetor da estação de saída representa as propriedades termodinâmicas do fluido de trabalho após a transformação ocorrida no processo termodinâmico do Bloco. Complementando a estrutura básica de simulação do TURBOMATCH, existem o conjunto de dados do Bloco que representam as características dos componentes, como por exemplo, razão de pressão e eficiência do compressor, e o vetor de dados da Turbina a Gás que é composto pelos resultados da simulação. Esta estrutura é apresentada na Figura 4.3.




Figura 4.3 - Diagrama Básico de Processamento do TURBOMATCH (CRANFIELD UNIVERSITY, 1999)

O ponto de referência do modelo é referente a uma condição operacional com alta probabilidade de ocorrência durante a campanha de operação da turbina. O conjunto de medições utilizado para ajustar o modelo compreende temperatura ambiente, temperatura e pressão de saída do compressor, temperatura de entrada na turbina, temperatura de saída da turbina, potência de eixo, fluxo de gás e de combustível.

O sistema PI apresenta 4 medições da temperatura e pressão de saída do compressor e 32 medições da temperatura de saída da turbina, que foram tomadas como média de maneira a serem utilizadas no modelo da turbina a gás. Além disso, o sistema PI também apresenta dados para três ângulos de IGV (*Inlet Guide Vane*), que são negligenciados no ajuste do modelo porque são apenas utilizados para operação em carga parcial, distante do ponto de referência operacional.

O modelo do ponto de referência operacional no referido software é formado por oito blocos, a saber: duto de entrada, compressor, combustor, misturador, turbina, duto, bocal convergente e desempenho. Esta estrutura é apresentada no diagrama de blocos da Figura 4.4.

O procedimento de convergência utiliza a pressão e temperatura de saída do compressor, temperatura de saída da turbina, potência de eixo, fluxo de gás e fluxo de combustível como parâmetros alvos, enquanto usa temperatura de entrada da turbina como ajuste de potência e temperatura ambiente como parâmetro de condições ambientais.

De maneira a convergir o modelo para as condições desejadas para o ponto de referência operacional do equipamento, a eficiência e a perda de pressão de cada componente e a porcentagem de extração de ar do compressor para resfriamento da turbina foram alteradas até que o alvo fosse atingido.



Figura 4.4 - Estrutura do Modelo da Turbina

O arquivo TURBOMATCH apresentando os parâmetros de cada bloco e o resultado da simulação para o ponto de referência operacional é apresentado no Apêndice A.

A comparação entre os dados operacionais da turbina real e os dados simulados no modelo é apresentada na Tabela 4.2, de onde se pode observar que os erros máximos entre os valores simulados e reais da temperatura ambiente, temperatura de saída do compressor, temperatura de entrada da turbina, pressão de saída do compressor, potência de eixo e fluxo de gás não excedem o valor de 0,02%, enquanto os erros entre os valores simulados e reais da temperatura de saída da turbina e fluxo de combustível não excedem o valor de 0,08%. Portanto, o modelo do ponto de referência operacional da turbina pode ser considerado uma boa representação dos dados reais medidos de uma condição operacional específica da turbina a gás.

Tabela 4.2 – Resultados da Modelagem do Ponto de referência operacional

Parâmetro de Medição	Unidade	Condição Operacional	Condição Simulada	Desvio
Temperatura Ambiente	[K]	297,9	298,0	0,00%
Temperatura de Saída do Compressor	[K]	674,9	674,8	-0,01%
Temperatura de Entrada da Turbina	[K]	1358	1358	-0,02%
Temperatura de Saída da Turbina	[K]	809,9	810,5	0,08%
Pressão de Saída do Compressor	[atm]	13,52	13,52	0,02%
Potência de Eixo	[W]	1,068E+08	1,068E+08	-0,02%
Fluxo de Gás na Saída	[kg/s]	398,6	398,6	0,00%
Fluxo de Combustível	[kg/s]	6,966	6,963	-0,04%

4.4 Modelo Termodinâmico Turbina a Gás

A simulação no software PYTHIA 2.8, descrita na seção 4.3, resultou no modelo termodinâmico do ponto de referência operacional da turbina a gás. Este modelo, apresentado

esquemáticamente na Figura 4.5, é composto por 5 componentes, a saber: (i) Duto de Entrada, (ii) Compressor, (iii) Combustor, (iv) Turbina e (v) Duto de Saída.




Figura 4.5 - Representação Esquemática do Modelo da Turbina a Gás

Neste modelo esquemático não está representado a extração de ar dos últimos estágios do compressor, cuja finalidade é resfriar os primeiros estágios da turbina.

Os processos responsáveis pelas alterações nas propriedades termodinâmicas do fluído de trabalho em cada componente do modelo podem ser observados no diagrama T-S (Temperatura contra Entropia) apresentado na Figura 4.6. Os pontos de 1 a 7 representam as estações de cada componente da turbina a gás.




Figura 4.6 - Diagrama T-S (Temperatura x Entropia) do Ponto de Referência Operacional do Modelo da Turbina

O modelo considera o ar como fluido de trabalho desde a estação 1 até a estação 3, quando passa a considerar o gás resultante da queima do gás natural como fluido de trabalho. As expressões matemáticas que relacionam as propriedades destes fluidos (calores específicos a pressão e volume constante) com variações na temperatura e pressão ao longo do caminho gás utilizadas pelo PYTHIA 2.8 não são públicas e, portanto, não serão apresentadas neste trabalho.

Para o ponto de referência operacional, os processos termodinâmicos entre cada par sucessivo de estações são descritos a seguir:

- 1→2: Duto de Entrada de Ar: processo de escoamento em duto adiabático com perda de pressão de 3,0% em relação à pressão de entrada.
- 2→3: Compressor: processo de compressão adiabática e irreversível com eficiência isentrópica de 85,9%.
- 3→4: Combustor: processo de combustão com eficiência de 93,5% e perda de pressão de 5% em relação à pressão de saída do compressor.
- 4→5: 1º Estágio da Turbina: processo de mistura do ar extraído dos últimos estágios do compressor (1,75%) com os gases de saída do combustor, objetivando a redução de temperatura nos primeiros estágios da turbina. É importante destacar que o percentual de ar extraído do compressor de 1,75% foi utilizado para convergência do modelo, ou seja, para que os resultados apresentados na Tabela 4.2 fossem atingidos, não havendo a preocupação de representar a real extração de ar do compressor da referida turbina a gás.
- 5→6: Turbina: processo de expansão adiabática e irreversível com eficiência isentrópica de 89,0%
- 6→7: Duto de Saída de Ar: processo de escoamento em duto adiabático com perda de pressão de 1,4% em relação à pressão de saída da turbina.

Os valores das propriedades termodinâmicas do fluido de trabalho (temperatura e pressão) e do respectivo fluxo de massa em cada estação do modelo da turbina a gás, resultado dos processos descritos anteriormente, são apresentados na Tabela 4.3. É importante destacar que a temperatura de entrada, ou seja, a temperatura ambiente do ponto de referência operacional

do modelo não coincide com a temperatura ambiente padrão (ISA – *International Standard Atmosphere* – 288,15 K ou 15° C). Esse ajuste foi realizado com objetivo de retratar as condições ambientais do site onde a turbina a gás está instalada. Ainda, o diferencial de pressão na saída da turbina a gás é necessário para permitir a dissipação da pluma na atmosfera.

Tabela 4.3 - Valores das Propriedades Termodinâmicas nas Estações do Modelo

Seção	1	2	3	4	5	6	7
Temperatura [K]	298,0	298,0	674,82	1358	1347	810,45	810,45
Pressão [atm]	1,000	0,9700	13,52	12,85	12,85	1,090	1,075
Fluxo de Massa [kg/s]	391,6	391,6	384,7	391,7	398,6	398,6	398,6

4.5 Mapa dos Principais Componente da Turbina a Gás

O software PYTHIA 2.8 utiliza os mapas de desempenho dos componentes da turbina a gás para simular condições de operação do equipamento fora do ponto de projeto, conforme metodologia apresentada em detalhes em Saravanamuuto *et al.* (2009). A partir destes mapas é possível determinar, por exemplo, a eficiência isentrópica do compressor em função de sua vazão ou razão de pressão, ou ainda, prever condições de operação onde exista risco de ocorrência de surto.

No entanto, os fabricantes de turbina a gás não revelam estes mapas de desempenho para o mercado, pois consistem em um fator de vantagem competitiva sobre seus concorrentes. Desta forma, os mapas utilizados pelo software PYTHIA 2.8, aqui representados para a turbina a gás em estudo, são obtidos a partir de um escalonamento de mapas padrões, utilizando fatores de escalas calculados em relação ao ponto de referência operacional do modelo.

É importante destacar que para um cálculo preciso das condições de operação fora do ponto de referência operacional, seria necessário um escalonamento dos mapas padrões que utilizasse fatores de escala calculados, também, em relação às condições operacionais em cargas parciais, não ficando restrito à condição de referência. Para tanto, seria necessário aplicar algoritmos de otimização para determinar um mesmo fator de escala para ajustar todo intervalo de operação da máquina.

A escolha do mapa padrão do compressor considera a relação de pressão máxima dos mapas disponíveis, dado que é desejável manter o fator de escala da razão de pressão o tão próximo da unidade quanto possível. As razões de pressão máximas dos mapas padrões disponíveis no software PYTHIA 2.8 são apresentadas na Tabela 4.4.

Tabela 4.4 - Razão de Pressão Máxima dos Mapas de Compressores (Adaptado de LI, 2011)

Nº do Mapa	1	2	3	4	5
Razão de Pressão	1,7	2,0	15,0	2,6	11,0

O mapa do compressor escolhido no modelo da turbina a gás desta Tese foi o mapa número 3, dado que a razão de pressão do ponto de referência do modelo é 13,94, resultando em um fator de escala de razão de pressão de 1,7643. As Figura 4.7 e Figura 4.8 apresentam, respectivamente, o mapa de desempenho do compressor relacionando o fluxo de massa não dimensional com a razão de pressão e o mapa de desempenho relacionando a razão de pressão com a eficiência isentrópica do compressor.




Figura 4.7 - Mapa de Desempenho do Compressor (Fluxo de Massa x Razão de Pressão)




Figura 4.8 - Mapa de Desempenho do Compressor (Razão de Pressão x Eficiência)

A escolha do mapa da turbina considera a máxima razão de salto entálpico e a localidade do entupimento da turbina, dado que é desejável obter um fator de escala da razão do salto entálpico o tão próximo da unidade quanto possível. As razões de salto entálpicos dos mapas disponíveis no PYTHIA 2.8 são apresentados na Tabela 4.5.

Tabela 4.5 - Máxima Razão de Salto Entálpico dos Mapas de Turbinas (Adaptado de LI, 2011)

Nº do Mapa	1	2	3	4	5	6
Máxima Razão de Salto Entálpico	0,075	0,045	0,065	0,04	0,03	0,13
Localidade do Entupimento	Rotor	Rotor	Rotor	Mista	Bocal	Bocal

As Figura 4.9 e Figura 4.10 apresentam, respectivamente, o mapa de desempenho da turbina relacionando a função trabalho com o parâmetro de fluxo de massa e o mapa de desempenho relacionando a função trabalho com a eficiência isentrópica da turbina.




Figura 4.9 - Mapa de Desempenho da Turbina (Função Trabalho x Fluxo de Massa)




Figura 4.10 - Mapa de Desempenho da Turbina (Função Trabalho x Eficiência)

5 APLICAÇÃO DO SISTEMA HIERÁRQUICO DE DIAGNÓSTICO

5.1 Introdução

Este capítulo abordará a aplicação do sistema hierárquico de diagnóstico proposto nesta Tese para análise dos dados de medição de uma campanha anual de operação da turbina a gás ALSTOM GT11N2, instalada na Usina Termelétrica Governador Leonel Brizola.

A primeira etapa da metodologia consiste na simulação do modelo da turbina a gás, considerando desvios nos parâmetros independentes, para criar a base de dados de amostras de treinamento e validação das RNA. Neste sentido, são avaliados os comportamentos dos parâmetros dependentes Temperatura de Saída do Compressor, Temperatura de Saída da Turbina, Pressão de Saída do Compressor e Potência de Eixo em relação os desvios nos parâmetros independentes.

Em seguida, a base de dados das amostras é utilizada para treinar e validar as RNA de detecção, isolamento e quantificação de falhas em componentes da turbina a gás. Os métodos de análise de desempenho das RNA adotados nesta Tese permitem avaliar tanto o processo de treinamento quanto a qualidade da generalização da RNA.

O sistema hierárquico de diagnóstico é então utilizado para monitorar as condições dos componentes da turbina a gás durante a campanha operacional do ano de 2012, dado a indisponibilidade de dados da campanha operacional do ano de 2011.

Os valores dos parâmetros dependentes são, primeiramente, corrigidos pela temperatura ambiente e, então, são submetidos aos processos de suavização e diagnóstico de falhas. Os fatores de correção pela temperatura ambiente são calculados a partir dos valores de medição de novembro de 2010. A definição do filtro mais adequado para a suavização dos dados seguiu o critério da menor diferença entre valores de medição consecutivas.

Por fim, são avaliados os resultados da aplicação das diferentes configurações do sistema hierárquico de diagnóstico.

5.2 Amostras de Treinamento e Validação das RNA

As amostras de treinamento e validação da RNA são geradas a partir do modelo da turbina a gás. As simulações da turbina a gás degradada são executadas utilizando o módulo de simulação do PYTHIA 2.8. Primeiramente, desvios de coeficiente de vazão e de eficiência são aplicadas no bloco do compressor para simular a degradação deste componente. Então, desvios de coeficiente de vazão e de eficiência são aplicadas no bloco turbina para simular a degradação deste componente. Finalmente, a combinação destes desvios nos respectivos parâmetros é aplicada no modelo para simular a degradação combinada dos componentes. A seguir, são discutidos o comportamento dos parâmetros dependentes requeridos para treinamento e validação da RNA (temperatura de saída do compressor, temperatura de saída da turbina, pressão de saída do compressor e potência de eixo) devido aos desvios nos parâmetros independentes (coeficiente de vazão do compressor, eficiência do compressor, coeficiente de vazão da turbina e eficiência da turbina).

Os comportamentos dos parâmetros dependentes devido a degradação do compressor são determinados pela aplicação de desvios no coeficiente de vazão e na eficiência no modelo do compressor. Os desvios no coeficiente de vazão do compressor variam de 0,0% até -5,0%, enquanto a que na eficiência do compressor variam de 0,0% até -5,0%.

A Figura 5.1 apresenta o comportamento da temperatura de saída do compressor devido à degradação no compressor. O gráfico mostra um aumento na temperatura de saída do compressor à medida que o valor absoluto do desvio na eficiência aumenta. Por outro lado, o gráfico mostra uma diminuição na temperatura de saída do compressor à medida que o valor absoluto do desvio no coeficiente de vazão aumenta. Como este parâmetro dependente é sensível aos desvios na eficiência e no coeficiente de vazão do compressor, pode compor o vetor de entrada do sistema hierárquico de diagnóstico.

A Figura 5.2 apresenta o comportamento da temperatura de saída da turbina devido à degradação do compressor. O gráfico mostra que a temperatura de saída da turbina não é sensivelmente afetada pelo aumento no valor absoluto da eficiência do compressor. Por outro lado, o gráfico mostra um aumento na temperatura de saída da turbina à medida que o valor absoluto do desvio no coeficiente de vazão do compressor aumenta. Embora este parâmetro dependente tenha apresentado pouca sensibilidade às alterações na eficiência do compressor,

pelo fato de ser sensível ao desvio no coeficiente de vazão do compressor, pode compor o vetor de entrada do sistema hierárquico de diagnóstico.




Figura 5.1 - Comportamento da Temperatura de Saída do Compressor sob Degradação do Compressor




Figura 5.2 - Comportamento da Temperatura de Saída da Turbina sob Degradação do Compressor

A Figura 5.3 apresenta o comportamento da pressão de saída do compressor devido à degradação do compressor. O gráfico mostra que a pressão de saída do compressor não é afetada à medida que a eficiência do compressor é alterada. Por outro lado, o gráfico mostra

uma diminuição abrupta na pressão de saída do compressor à medida que o valor absoluto do desvio no coeficiente de vazão aumenta. Embora este parâmetro dependente não tenha apresentado sensibilidade às alterações na eficiência do compressor, pelo fato de ser sensível ao desvio no coeficiente de vazão do compressor, pode compor o vetor de entrada do sistema hierárquico de diagnóstico.




Figura 5.3 - Comportamento da Pressão de Saída do Compressor sob Degradação do Compressor

A Figura 5.4 apresenta o comportamento da potência de eixo devido à degradação do compressor. O gráfico mostra que a potência de eixo diminui à medida que o valor absoluto do desvio na eficiência do compressor aumenta. A mesma tendência pode ser notada à medida que o valor absoluto do desvio no coeficiente de vazão aumenta. Como este parâmetro dependente é sensível aos desvios na eficiência e no coeficiente de vazão do compressor, pode compor o vetor de entrada do sistema hierárquico de diagnóstico.

A análise do comportamento dos parâmetros dependentes devido à degradação da turbina é realizada através da aplicação de desvios no coeficiente de vazão e na eficiência no modelo da turbina a gás. Os desvios no coeficiente de vazão variam de -5,0% até 5,0%, enquanto os desvios na eficiência da turbina variam de 0,0% até -5,0%.

A Figura 5.5 apresenta o comportamento da temperatura de saída do compressor devido à degradação da turbina. O gráfico mostra um aumento na temperatura de saída do compressor à medida que o valor absoluto do desvio na eficiência da turbina aumenta. Por outro lado, o

gráfico mostra uma diminuição na temperatura de saída do compressor à medida que o desvio no coeficiente de vazão da turbina aumenta. Como este parâmetro dependente é sensível aos desvios na eficiência e no coeficiente de vazão da turbina, pode compor o vetor de entrada do sistema hierárquico de diagnóstico.




Figura 5.4 - Comportamento da Potência de Eixo sob Degradação do Compressor




Figura 5.5 - Comportamento da Temperatura de Saída do Compressor sob Degradação da Turbina

A Figura 5.6 apresenta o comportamento da temperatura de saída da turbina devido à degradação na turbina. O gráfico mostra um aumento na temperatura de saída da turbina à medida que o valor absoluto do desvio na eficiência da turbina aumenta. O mesmo comportamento pode ser notado com o aumento do desvio no coeficiente de vazão da turbina. Como este parâmetro dependente é sensível aos desvios na eficiência e no coeficiente de vazão da turbina, pode compor o vetor de entrada do sistema hierárquico de diagnóstico.




Figura 5.6 - Comportamento da Temperatura de Saída da Turbina sob Degradação da Turbina

A Figura 5.7 apresenta o comportamento da pressão de saída do compressor devido à degradação na turbina. O gráfico mostra um aumento na pressão de saída do compressor à medida que o valor absoluto do desvio na eficiência da turbina aumenta. Por outro lado, o gráfico mostra uma diminuição na pressão de saída do compressor à medida que o desvio no coeficiente de vazão da turbina aumenta. Como este parâmetro dependente é sensível aos desvios na eficiência e no coeficiente de vazão da turbina, pode compor o vetor de entrada do sistema hierárquico de diagnóstico.




Figura 5.7 - Comportamento da Pressão de Saída do Compressor sob Degradação da Turbina

A Figura 5.8 apresenta o comportamento da potência de eixo devido à degradação na turbina. O gráfico mostra uma diminuição na potência de eixo à medida que o valor absoluto do desvio na eficiência da turbina aumenta. Por outro lado, o gráfico mostra um aumento na potência de eixo à medida que o desvio no coeficiente de vazão da turbina aumenta. Como este parâmetro dependente é sensível aos desvios na eficiência e no coeficiente de vazão da turbina, pode compor o vetor de entrada do sistema hierárquico de diagnóstico.




Figura 5.8 - Comportamento da Potência de Eixo sob Degradação da Turbina

Os comportamentos dos parâmetros dependentes devido a degradação combinada do compressor e da turbina são determinados pela aplicação de desvios no coeficiente de vazão e eficiência no modelo destes blocos. Os desvios no coeficiente de vazão do compressor variam de 0,0% até -5,0% e na eficiência do compressor variam de 0,0% até -5,0%, enquanto os desvios no coeficiente de vazão da turbina variam de -5,0% até 5,0% e na eficiência da turbina variam de 0,0% até -5,0%. O resultado destas simulações é apresentado no Apêndice C.

5.3 Validação do Sistema Hierárquico de Diagnóstico

Esta seção apresenta a aplicação do processo de validação do sistema hierárquico de diagnóstico em dois casos, um considerando parâmetros dependentes simulados sem ruído e outro com ruído, simulados a partir dos valores típicos de desvios padrão dos sensores de medição.

O sistema hierárquico de diagnóstico compreende cinco RNA individuais. Inicialmente, uma RNA *perceptron* de camada única é utilizada para detectar se a turbina apresenta degradação. Então, uma RNA probabilística é utilizada para isolar a falha, ou seja, determinar se o compressor, a turbina ou ambos componentes estão degradados. Finalmente, três RNA multicamadas *feed-forward* são utilizadas para estimar a intensidade da degradação dos componentes. As arquiteturas das redes neurais artificiais são apresentadas no Apêndice D.

O processo de validação do sistema hierárquico de diagnóstico consiste na validação de cada RNA individual e na validação do próprio sistema hierárquico de diagnóstico. A qualidade da RNA de detecção de falhas é avaliada por sua porcentagem de erro. A qualidade da RNA de isolamento de falhas é avaliada pela taxa de acertos no isolamento de falhas. A qualidade da RNA de quantificação de falhas do compressor é avaliada pelo EQM da estimativa dos desvios no coeficiente de vazão e na eficiência do compressor, para cada ponto do domínio. A qualidade da RNA de quantificação de falhas da turbina é avaliada pelo EQM da estimativa dos desvios no coeficiente de vazão na eficiência da turbina, para cada ponto do domínio. Finalmente, a qualidade da RNA de quantificação de falha combinada é avaliada pelo desvio padrão do erro na estimativa da falha dos componentes de todo o conjunto.

5.3.1 Caso Teste Utilizando Simulações sem Ruído de Medição

O sistema hierárquico de diagnóstico é aplicado a um conjunto de parâmetros dependentes simulados no modelo da turbina para representar valores de medições sem ruído. Embora esta seja uma condição hipotética, dado que toda medição real contém erros, a premissa de sinal de medição limpo, ou seja, sem ruído, permitirá gerar dados para treinar e validar as redes neurais para serem aplicadas aos sinais de sensores processados por filtros de ruído.

O conjunto de parâmetros dependentes compreende temperatura de saída do compressor (T_3), temperatura de saída da turbina (T_6), pressão de saída do compressor (P_3), e potência de eixo (POT). O vetor de desvios nos parâmetros dependentes considera como linha de base os valores relativos à simulação do ponto de referência operacional sem a aplicação de degradação, também chamada de turbina saudável.

O sistema hierárquico de diagnóstico foi elaborado para prover informações confiáveis sobre as condições dos componentes da turbina em um intervalo limitado de degradação dos componentes. Este domínio é apresentado Expressão 5.01.

$$\begin{aligned}
 -5,0 &\leq \Delta\Gamma_c \leq 0,0 \\
 -5,0 &\leq \Delta\eta_c \leq 0,0 \\
 -5,0 &\leq \Delta\Gamma_T \leq +5,0 \\
 -5,0 &\leq \Delta\eta_T \leq 0,0
 \end{aligned}
 \tag{5.01}$$

Embora o domínio declarado acima seja aplicado para sistema hierárquico de diagnóstico, cada RNA individual que compreende sua estrutura tem domínio específico, que será descrito a frente nesta secção. As amostras de treinamento foram estabelecidas através da simulação do modelo da turbina a gás, onde diferentes níveis de degradações dos componentes são aplicados ao modelo da turbina a gás. Os resultados das simulações representam os parâmetros dependentes. Portanto, o vetor alvo de cada RNA consiste do conjunto de degradações nos componentes, ou parâmetros independentes, enquanto o vetor de entrada consiste no conjunto de parâmetros dependentes, ou seja, conjunto dos valores de medição simulados. Uma técnica similar foi aplicada para estabelecer as amostras de validação. A seguir, os processos de treinamento e validação das RNA individuais e do sistema hierárquico de diagnóstico serão discutidos.

5.3.1.1 Validação da RNA de Detecção de Degradação

A RNA de detecção de degradação tem como objetivo averiguar se a turbina está degradada por meio da análise do vetor de desvios nos parâmetros dependentes. Seu vetor de saída compreende um conjunto binário, onde o valor “0” é dado para a turbina saudável e o valor “1” é dado para a turbina degradada. Uma vez que a RNA de detecção de degradação foi estabelecida e treinada, o processo de treinamento e a qualidade da RNA é avaliado pela comparação da saída da RNA de detecção de degradação com aquela desejada.

A Tabela 5.1 apresenta o resumo da avaliação do processo de treinamento da RNA de detecção de degradação. O processo de treinamento foi avaliado utilizando a respectiva RNA para simular os 294 componentes do conjunto de amostras de treinamento. O vetor de saída da RNA foi então comparado com a saída desejável, ou seja, o vetor alvo da amostra de treinamento, resultando em erro zero. A precisão da RNA de detecção de degradação foi avaliada utilizando a respectiva RNA para simular os 174 componentes que compõem o conjunto das amostras de validação, resultando em erro de estimativa igual a zero. Portanto, esta RNA é considerada adequada para a análise de diagnóstico de falhas.

Tabela 5.1 - Avaliação da RNA de Detecção de Degradação

	Amostras de Treinamento	Amostras de Validação
Número Total de Análises	294	174
Número de Análises Corretas	294	174
Percentual de Erro [%]	0,0%	0,0%

5.3.1.2 Validação da RNA de Isolamento de Falhas

A RNA de isolamento de falhas objetiva averiguar qual componente está degradado, identificando se o compressor, a turbina ou ambos estão degradados, está última, chamada de degradação combinada. No caso em que a degradação do compressor é detectada, a RNA resulta no valor “1”, se degradação na turbina for detectada, a RNA resulta o valor “2” e, finalmente, se for detectado degradação em ambos componentes, a RNA resulta no valor “3”.

A avaliação do processo de treinamento é realizada utilizando o conjunto de amostras de treinamento, que compreende 36 casos de degradação do compressor, 66 casos de degradação da turbina e 192 casos de degradação combinada.

A Tabela 5.2 apresenta o resultado da avaliação do processo de treinamento, onde todos os casos com degradação na turbina e degradação combinada foram detectados e somente um caso de degradação no compressor não foi detectado para RNA de isolamento de falhas. A Taxa de Acertos no Isolamento desta RNA é 99,1%. Portanto o processo de treinamento atingiu o objetivo desejado.

Tabela 5.2 – Matriz de Confusão do Processo de Treinamento da RNA de Isolamento de Falhas

Componente Isolado pela RNA	Degradação Aplicada ao Modelo da Turbina a Gás		
	Compressor	Turbina	Combinada
Compressor	97%	0%	0%
Turbina	3%	100%	0%
Combinada	0%	0%	100%
Taxa de Acertos no Isolamento	99,1%		

A validação da RNA de isolamento de falhas é executada utilizando o conjunto de amostras de validação, que compreende 35 casos de degradação no compressor, 65 casos de degradação na turbina e 74 casos de degradação combinada. Os componentes do conjunto de validação são diferentes dos componentes do conjunto de amostras de treinamento de maneira a avaliar a generalização do desempenho da RNA.

A Tabela 5.3 apresenta os resultados da validação da RNA de isolamento de falhas, onde todos os casos de degradação do compressor foram detectados, 89% dos casos com degradação da turbina foram detectados e 92% dos casos de degradação combinada foram identificados. A Taxa de Acertos no Isolamento de Falhas desta RNA é de 93,7%.

Tabela 5.3 – Matriz de Confusão do Processo de Validação da RNA de Isolamento de Falhas

Componente Isolado pela RNA	Degradação Aplicada ao Modelo da Turbina a Gás		
	Compressor	Turbina	Combinada
Compressor	100%	5%	0%
Turbina	0%	89%	8%
Combinada	0%	6%	92%
Taxa de Acertos no Isolamento	93,7%		

5.3.1.3 Validação da RNA de Quantificação de Falhas no Compressor

A RNA de quantificação de falhas no compressor objetiva encontrar os desvios no coeficiente de vazão e na eficiência do compressor por meio da análise do vetor de desvio dos parâmetros dependentes, aqui representados pelos valores de medição simulados no modelo da turbina. Desta forma, o processo de treinamento da rede neural considera o conjunto de parâmetros independentes como vetor alvo e o conjunto de desvios nos parâmetros dependentes como vetor de entrada. Esta RNA resulta em informações confiáveis para os desvios no coeficiente de vazão e na eficiência do compressor variando no intervalo apresentado na Expressão 5.02.

$$\begin{aligned} -5,0 &\leq \Delta\Gamma_C \leq 0 \\ -5,0 &\leq \Delta\eta_C \leq 0 \end{aligned} \tag{5.02}$$

As amostras de treinamento e validação são criadas pela aplicação de desvios no coeficiente de vazão e na eficiência do compressor no modelo da turbina a gás. Cada simulação é realizada considerando a combinação desses parâmetros, onde os valores discretos dos parâmetros de treinamento são apresentados na Expressão 5.03 e os valores discretos dos parâmetros de validação são apresentados na Expressão 5.04.

$$\Delta\Gamma_C = \{0,0; -1,0; -2,0; -3,0; -4,0; -5,0\} \tag{5.03}$$

$$\Delta\eta_C = \{0,0; -1,0; -2,0; -3,0; -4,0; -5,0\}$$

$$\Delta\Gamma_C = \{0,0; -0,5; -1,5; -2,5; -3,5; -4,5\} \tag{5.04}$$

$$\Delta\eta_C = \{0,0; -0,5; -1,5; -2,5; -3,5; -4,5\}$$

Uma vez que os vetores alvo e entrada de treinamento foram criados, a rede neural de quantificação de falhas em compressores pode ser estabelecida utilizando as ferramentas de redes neurais do MATLAB, como foi demonstrado no Capítulo 3. A Tabela 5.4 apresenta os EQM do processo de treinamento da RNA de quantificação de falha no compressor para cada

um dos pares de desvio no coeficiente de vazão/desvio na eficiência do domínio das amostras de treinamento. O EQM geral do processo de treinamento da RNA é de 0,02%.

Tabela 5.4 - EQM do Processo de Treinamento da RNA de Quantificação de Falhas no Compressor

Compressor Treinamento Sem Ruído		Desvio no Coeficiente de Vazão do Compressor						
		0,0%	-1,0%	-2,0%	-3,0%	-4,0%	-5,0%	Média
Desvio na Eficiência do Compressor	0,0%	0,08%	0,05%	0,00%	0,05%	0,07%	0,21%	0,08%
	-1,0%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
	-2,0%	0,03%	0,00%	0,00%	0,00%	0,00%	0,08%	0,02%
	-3,0%	0,01%	0,00%	0,01%	0,00%	0,00%	0,07%	0,01%
	-4,0%	0,00%	0,04%	0,00%	0,00%	0,00%	0,04%	0,01%
	-5,0%	0,00%	0,04%	0,03%	0,00%	0,00%	0,00%	0,01%
	Média	0,02%	0,02%	0,01%	0,01%	0,01%	0,07%	0,02%

Mesmo com o excelente resultado alcançado, o processo de validação da RNA de quantificação de falha do compressor é necessário para garantir que a generalização da RNA. A Tabela 5.5 apresenta os EQM do processo de validação da RNA de quantificação de falhas no compressor para cada dos pares de desvio no coeficiente de vazão/desvio na eficiência do domínio das amostras de validação. O EQM geral do processo de validação da RNA é de 0,04%, mostrando uma boa generalização da RNA.

Tabela 5.5 - EQM do Processo de Validação da RNA de Quantificação de Falhas no Compressor

Compressor Validação Sem Ruído		Desvio no Coeficiente de Vazão do Compressor						
		0,0%	-0,5%	-1,5%	-2,5%	-3,5%	-4,5%	Média
Desvio na Eficiência do Compressor	0,0%	0,08%	0,04%	0,05%	0,03%	0,04%	0,12%	0,06%
	-0,5%	0,07%	0,04%	0,02%	0,02%	0,02%	0,03%	0,03%
	-1,5%	0,05%	0,09%	0,02%	0,00%	0,03%	0,06%	0,04%
	-2,5%	0,01%	0,07%	0,03%	0,02%	0,02%	0,06%	0,04%
	-3,5%	0,01%	0,09%	0,03%	0,02%	0,02%	0,05%	0,04%
	-4,5%	0,01%	0,13%	0,02%	0,02%	0,02%	0,03%	0,04%
	Média	0,04%	0,08%	0,03%	0,02%	0,03%	0,06%	0,04%

5.3.1.4 Validação da RNA de Quantificação de Falhas na Turbina

A RNA de quantificação de falhas na turbina tem a finalidade de averiguar os desvios no coeficiente de vazão e na eficiência da turbina por meio da análise do vetor de desvio dos parâmetros dependentes, aqui representados pelos valores de medição simulados no modelo da turbina a gás. Desta forma, o processo de treinamento da rede neural considera o conjunto de parâmetros independentes como vetor alvo e o conjunto de parâmetros dependentes como vetor de entrada. Esta RNA resulta em informações confiáveis para os desvios no coeficiente de vazão e na eficiência da turbina variando no intervalo apresentado pela Expressão 5.06:

$$\begin{aligned} -5,0 &\leq \Delta\Gamma_T \leq +5,0 \\ -5,0 &\leq \Delta\eta_T \leq 0,0 \end{aligned} \tag{5.05}$$

As amostras de treinamento e validação são criadas pela aplicação dos desvios no coeficiente de vazão e na eficiência da turbina no modelo da turbina a gás. Cada simulação é realizada considerando a combinação desses parâmetros, onde os valores discretos dos parâmetros de treinamento são apresentados na Expressão 5.06 e os valores discretos dos parâmetros de validação são apresentados na Expressão 5.07.

$$\Delta\Gamma_T = \{+5,0; +4,0; +3,0; +2,0; +1,0; 0,0; -1,0; -2,0; -3,0; -4,0; -5,0\} \tag{5.06}$$

$$\Delta\eta_T = \{0,0; -1,0; -2,0; -3,0; -4,0; -5,0\}$$

$$\Delta\Gamma_C = \{+4,5; +3,5; +2,5; +1,5; +0,5; 0,0; -0,5; -1,5; -2,5; -3,5; -4,5\} \tag{5.07}$$

$$\Delta\eta_C = \{0,0; -0,5; -1,5; -2,5; -3,5; -4,5\}$$

Uma vez que os vetores alvo e entrada de treinamento foram criados, a rede neural de quantificação de falhas em compressores pode ser estabelecida utilizando as ferramentas de redes neurais do MATLAB, como foi demonstrado no Capítulo 3. A Tabela 5.6 apresenta os EQM do processo de treinamento da RNA de quantificação de falha na turbina para cada um dos pares de desvio no coeficiente de vazão/desvio na eficiência do domínio das amostras de treinamento. O EQM geral do processo de treinamento da RNA é de 0,01%.

Tabela 5.6 - EQM do Processo de Treinamento da RNA de Quantificação de Falhas na Turbina

Turbina Treinamento Sem Ruído		Desvio no Coeficiente de Vazão da Turbina											
		5,0%	4,0%	3,0%	2,0%	1,0%	0,0%	-1,0%	-2,0%	-3,0%	-4,0%	-5,0%	Média
Desvio na Eficiência da Turbina	0,0%	0,00%	0,00%	0,01%	0,01%	0,00%	0,03%	0,01%	0,01%	0,00%	0,04%	0,00%	0,01%
	-1,0%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,02%	0,01%	0,06%	0,01%
	-2,0%	0,00%	0,00%	0,01%	0,01%	0,00%	0,00%	0,00%	0,01%	0,06%	0,01%	0,01%	0,01%
	-3,0%	0,00%	0,02%	0,01%	0,00%	0,00%	0,01%	0,02%	0,01%	0,05%	0,00%	0,00%	0,01%
	-4,0%	0,00%	0,01%	0,00%	0,00%	0,01%	0,01%	0,00%	0,00%	0,00%	0,03%	0,00%	0,01%
	-5,0%	0,01%	0,00%	0,00%	0,00%	0,00%	0,02%	0,01%	0,00%	0,00%	0,00%	0,02%	0,01%
	Média	0,00%	0,01%	0,01%	0,00%	0,00%	0,01%	0,01%	0,01%	0,02%	0,01%	0,02%	0,01%

O processo de validação da RNA de quantificação de falha na turbina é necessário para garantir que a generalização da RNA. A Tabela 5.7 apresenta os EQM do processo de validação da RNA de quantificação de falhas na turbina para cada um dos pares de desvio no coeficiente de vazão/desvio na eficiência do domínio das amostras de validação. O EQM geral do processo de validação da RNA é de 0,01%, mostrando uma boa generalização da RNA.

Tabela 5.7 - EQM do Processo de Validação da RNA de Quantificação de Falhas na Turbina

Turbina Validação Sem Ruído		Desvio no Coeficiente de Vazão da Turbina											
		4,5%	3,5%	2,5%	1,5%	0,5%	0,0%	-0,5%	-1,5%	-2,5%	-3,5%	-4,5%	Média
Desvio na Eficiência da Turbina	0,0%	0,01%	0,01%	0,01%	0,01%	0,01%	0,03%	0,02%	0,01%	0,01%	0,02%	0,04%	0,01%
	-0,5%	0,01%	0,00%	0,01%	0,01%	0,01%	0,01%	0,01%	0,00%	0,00%	0,02%	0,02%	0,01%
	-1,5%	0,00%	0,01%	0,01%	0,00%	0,01%	0,00%	0,00%	0,00%	0,02%	0,01%	0,01%	0,01%
	-2,5%	0,00%	0,00%	0,01%	0,01%	0,01%	0,00%	0,01%	0,01%	0,03%	0,02%	0,00%	0,01%
	-3,5%	0,00%	0,00%	0,01%	0,01%	0,01%	0,01%	0,02%	0,02%	0,03%	0,01%	0,01%	0,01%
	-4,5%	0,01%	0,01%	0,01%	0,00%	0,01%	0,00%	0,01%	0,01%	0,01%	0,03%	0,02%	0,01%
	Média	0,00%	0,00%	0,01%	0,01%	0,01%	0,01%	0,01%	0,01%	0,02%	0,02%	0,02%	0,01%

5.3.1.5 Validação da RNA de Quantificação de Falhas Combinadas

A RNA de quantificação de falhas combinadas tem a finalidade de encontrar os desvios no coeficiente de vazão e na eficiência do compressor e os desvios no coeficiente de vazão e na eficiência da turbina baseado nos parâmetros dependentes.

O desempenho do processo de treinamento foi avaliado utilizando o vetor de parâmetros dependentes do conjunto de amostras de treinamento como vetor de entrada da RNA de quantificação de falha combinada. Os resultados foram comparados com as saídas desejadas, resultando em um vetor erro, do qual foram tomadas a média e o desvio padrão. Um processo similar foi realizado para executar a validação do desempenho da RNA. A Tabela 5.8 apresenta os resultados das avaliações mencionadas acima. O desempenho do processo de treinamento pode ser considerado bom, dado que o valor absoluto da média dos erros das estimativas não excedeu 0,06% e o desvio padrão máximo é de aproximadamente 0,7%. Por outro lado, o processo de validação apresenta os valores de média e desvio padrão superiores os atingidos no treinamento, indicando que a queda de desempenho na generalização da RNA.

Tabela 5.8 - Erros das Estimativas dos Parâmetros dos Componentes

	Amostras de Treinamento		Amostras de Validação	
	Média	Desvio Padrão	Média	Desvio Padrão
Erro na Estimativa de Desvio do Coeficiente de Vazão do Compressor	-0,03	0,07	0,88	1,96
Erro na Estimativa de Desvio da Eficiência do Compressor	-0,01	0,07	-0,49	0,94
Erro na Estimativa de Desvio do Coeficiente de Vazão da Turbina	-0,06	0,68	0,48	2,38
Erro na Estimativa de Desvio da Eficiência da Turbina	0,00	0,73	-0,14	1,05

5.3.1.6 Validação da Sistema Hierárquico de Diagnóstico

Os erros na estimativa de desvios nos parâmetros dos componentes da turbina a gás, apresentados na Tabela 5.9, são calculados submetendo os parâmetros dependentes das amostras de validação, ou seja, os valores medidos simulados no modelo da turbina a gás, à cada passo do sistema hierárquico de diagnóstico.

Tabela 5.9 - Estimativa de Erro da Sistema Hierárquico de Diagnóstico

	Média	Desvio Padrão
Erro na Estimativa de Desvio do Coeficiente de Vazão do Compressor	-0,03	0,45
Erro na Estimativa de Desvio da Eficiência do Compressor	0,25	0,62
Erro na Estimativa de Desvio do Coeficiente de Vazão da Turbina	0,82	1,81
Erro na Estimativa de Desvio da Eficiência da Turbina	-0,12	0,36

5.3.2 Caso Teste Utilizando Simulações com Ruído de Medição

Nesta seção, a metodologia do sistema hierárquico de diagnóstico é aplicada a um conjunto de parâmetros dependentes considerando ruído de medição, ou seja, ao conjunto de valores simulados pelo modelo da turbina foi adicionado uma parcela aleatória, representando a incerteza dos sensores de medição. Cada tipo de instrumento de medição apresenta um erro típico, que pode ser afetado pelas condições ambientais do local de medição. Os ruídos máximos permitidos para cada tipo de sensor são apresentados na Tabela 3.1.

Tanto as amostras de treinamento como de validação com ruído são baseados nas respectivas amostras sem ruído. Como mencionado na seção anterior, ambas as amostras de treinamento e validação foram geradas utilizando PYTHIA 2.8. A estas amostras, que eram originalmente livres de erros de medição, foram adicionados ruído através de um método estatístico utilizando uma planilha MS Excel. O ruído é então encontrado utilizando a curva normal inversa, com média e desvio padrão respectivamente zero e metade do valor máximo de ruído permitido para cada instrumento.

Uma vez a curva probabilística que descreve o comportamento do ruído foi estabelecida, é possível extrapolar a relação entre ruído e sua probabilidade de ocorrência usando a curva normal cumulativa inversa, onde a probabilidade de ocorrência é dada por uma função de geração de número aleatório. Cada valor medido simulado sem ruído é utilizado para gerar quatro valores medidos com ruído.

O domínio do sistema hierárquico de diagnóstico aplicado ao conjunto de parâmetros dependentes com ruído, que consiste do intervalo de desvios dos parâmetros independentes onde informações confiáveis podem ser obtidas, é o mesmo aplicado ao conjunto de parâmetros dependentes do sistema hierárquico de diagnóstico sem ruído, descritos na seção anterior.

A seguir, é realizada a avaliação do desempenho do processo de treinamento e da qualidade do sistema hierárquico de diagnóstico, seguindo o mesmo processo utilizado na seção anterior.

5.3.2.1 Validação da RNA de Detecção de Degradação

A Tabela 5.10 apresenta um resumo da avaliação do processo de treinamento e da qualidade da RNA de detecção de degradação, quando usando amostras de parâmetros dependentes com ruído. O processo de treinamento foi testado utilizando a respectiva RNA para simular os 1176 elementos que compreendem o conjunto da amostra de treinamento. O vetor de saída da RNA foi então comparado com a saída desejada, ou seja, as amostras de treinamento do vetor alvo, resultando em apenas um erro. A qualidade da RNA de detecção de degradação foi avaliada usando a respectiva RNA para simular 696 elementos que compõem as amostras de validação, resultando em 0,7% de erro. Portanto, esta RNA pode ser considerada adequada para realizar o diagnóstico de análise.

Tabela 5.10 - Avaliação da RNA de Detecção de Degradação (Simulação com Ruído)

	Amostras de Treinamento	Amostras de Validação
Número Total de Análises	1176	696
Número de Análises Corretas	1175	691
Percentual de Erro [%]	0,1%	0,7%

5.3.2.2 Validação da RNA de Isolamento de Falhas

A Tabela 5.11 apresenta o resultado da avaliação do processo de treinamento da RNA de isolamento de falhas, quando utilizando amostras de parâmetros dependentes com ruído. A Taxa de Acertos no Isolamento de falhas no compressor foi de 86%, o a Taxa de Acertos no Isolamento de falhas na turbina foi de 93% e a Taxa de Acertos no Isolamento de falhas combinada foi de 99%. Logo, a Taxa de Acertos no Isolamento da RNA foi de 92,8%. Quando comparado com os resultados do item 5.3.1.2, o desempenho do processo de treinamento da RNA de isolamento de falhas utilizando amostras com ruído é inferior ao processo que utiliza amostras sem ruído.

Tabela 5.11 - Avaliação do Processo de Treinamento da RNA de Isolamento de Falhas (Simulação com Ruído)

Componente Isolado pela RNA	Degradação Aplicada ao Modelo da Turbina a Gás		
	Compressor	Turbina	Combinada
Compressor	86%	2%	1%
Turbina	2%	93%	0%
Combinada	11%	5%	99%
Taxa de Acertos no Isolamento	92,8%		

A Tabela 5.12 apresenta o resultado da qualidade do processo de treinamento da RNA de isolamento de falhas, quando utilizando amostras de parâmetros dependentes com ruído. A Taxa de Acertos no Isolamento de falhas no compressor foi de 81%, o a Taxa de Acertos no Isolamento de falhas na turbina foi de 84% e a Taxa de Acertos no Isolamento de falhas combinada foi de 91%. Logo, a Taxa de Acertos no Isolamento da RNA foi de 85,4%. Estes resultados mostram o bom desempenho das RNA probabilísticas para problemas de isolamento de falhas.

Tabela 5.12 - Validação da RNA de Isolamento de Falhas (Simulação com Ruído)

Componente Isolado pela RNA	Degradação Aplicada ao Modelo da Turbina a Gás		
	Compressor	Turbina	Combinada
Compressor	81%	2%	1%
Turbina	4%	84%	8%
Combinada	16%	13%	91%
Taxa de Acertos no Isolamento	85,4%		

5.3.2.3 Validação da RNA de Quantificação de Falhas no Compressor

A Tabel 5.13 apresenta os EQM do processo de treinamento da RNA de quantificação de falha no compressor para cada um dos pares de desvio no coeficiente de vazão/desvio na eficiência do domínio das amostras de treinamento com ruído. O EQM geral do processo de treinamento da RNA é de 0,46%.

Tabela 5.13 - EQM do Treinamento da RNA de Quantificação de Falhas no Compressor (Simulação com Ruído)

Compressor Treinamento Com Ruído		Desvio no Coeficiente de Vazão do Compressor						Média
		0,0%	-1,0%	-2,0%	-3,0%	-4,0%	-5,0%	
Desvio na Eficiência do Compressor	0,0%	1,1%	0,2%	0,2%	0,5%	0,7%	0,7%	0,56%
	-1,0%	0,4%	0,2%	0,1%	0,5%	0,9%	0,3%	0,39%
	-2,0%	0,2%	0,2%	0,2%	1,4%	0,6%	0,2%	0,48%
	-3,0%	0,1%	0,5%	1,0%	0,9%	0,1%	0,1%	0,46%
	-4,0%	0,4%	0,6%	0,4%	0,2%	0,4%	0,8%	0,46%
	-5,0%	0,3%	0,2%	0,1%	0,6%	1,0%	0,2%	0,41%
	Média	0,42%	0,30%	0,33%	0,70%	0,61%	0,39%	0,46%

Apesar do bom resultado alcançado, o processo de validação da RNA de quantificação de falha do compressor é necessário para garantir que a generalização da RNA. A Tabela 5.14 apresenta os EQM do processo de validação da RNA de quantificação de falhas no compressor para cada um dos pares de desvio no coeficiente de vazão/desvio na eficiência do domínio das amostras de validação com ruído. O EQM geral do processo de validação da RNA é de 0,66%, mostrando uma boa generalização da RNA.

Tabela 5.14 - EQM da Validação da RNA de Quantificação de Falhas no Compressor (Simulação com Ruído)

Compressor Validação Com Ruído		Desvio no Coeficiente de Vazão do Compressor						
		0,0%	-0,5%	-1,5%	-2,5%	-3,5%	-4,5%	Média
Desvio na Eficiência do Compressor	0,0%	0,3%	0,5%	0,3%	0,7%	0,6%	0,7%	0,52%
	-0,5%	0,6%	0,6%	0,5%	0,6%	0,4%	0,4%	0,52%
	-1,5%	1,2%	0,5%	0,5%	0,3%	1,7%	0,6%	0,81%
	-2,5%	0,6%	0,9%	1,0%	1,0%	1,1%	0,5%	0,83%
	-3,5%	0,4%	0,6%	0,7%	0,6%	0,6%	0,3%	0,53%
	-4,5%	1,6%	0,9%	0,5%	0,8%	0,7%	0,3%	0,78%
	Média	0,78%	0,67%	0,57%	0,68%	0,83%	0,46%	0,66%

5.3.2.4 Validação da RNA de Quantificação de Falhas na Turbina

Uma vez que os vetores alvo e entrada de treinamento foram criados, a rede neural de quantificação de falhas em compressores pode ser estabelecida utilizando as ferramentas de redes neurais do MATLAB. A Tabela 5.16 apresenta os EQM do processo de treinamento da RNA de quantificação de falha na turbina para cada um dos pares de desvio no coeficiente de vazão/desvio na eficiência do domínio das amostras de treinamento com ruído. O EQM geral do processo de treinamento da RNA é de 0,35%.

Tabela 5.15 - EQM do Treinamento da RNA de Quantificação de Falhas na Turbina (Simulação com Ruído)

Turbina Treinamento Com Ruído		Desvio no Coeficiente de Vazão da Turbina											
		5,0%	4,0%	3,0%	2,0%	1,0%	0,0%	-1,0%	-2,0%	-3,0%	-4,0%	-5,0%	Média
Desvio na Eficiência da Turbina	0,0%	0,14%	0,20%	0,29%	0,39%	0,56%	0,07%	0,22%	0,29%	0,09%	0,68%	1,78%	0,43%
	-1,0%	0,98%	0,23%	0,49%	0,50%	0,74%	0,34%	0,18%	0,47%	0,30%	0,28%	0,49%	0,46%
	-2,0%	0,19%	0,12%	0,30%	0,60%	0,17%	0,23%	0,27%	0,11%	0,22%	0,09%	0,18%	0,23%
	-3,0%	0,11%	0,22%	0,31%	0,26%	0,46%	0,30%	0,22%	0,22%	0,53%	0,12%	0,62%	0,31%
	-4,0%	0,05%	0,24%	0,50%	0,31%	0,25%	0,17%	0,27%	0,09%	0,63%	0,08%	0,23%	0,26%
	-5,0%	0,11%	0,16%	0,38%	0,24%	0,39%	0,18%	0,16%	0,56%	1,27%	0,21%	1,24%	0,45%
	Média	0,26%	0,19%	0,38%	0,38%	0,43%	0,21%	0,22%	0,29%	0,51%	0,24%	0,76%	0,35%

O processo de validação da RNA de quantificação de falha na turbina é necessário para garantir que a generalização da RNA. A Tabela 5.16 apresenta os EQM do processo de validação da RNA de quantificação de falhas na turbina para cada um dos pares de desvio no coeficiente de vazão/desvio na eficiência do domínio das amostras de validação com ruído. O EQM geral do processo de validação da RNA é de 0,66%, mostrando uma boa generalização da RNA.

Tabela 5.16 - EQM do Processo de Validação da RNA de Quantificação de Falhas na Turbina

Turbina Validação Com Ruído		Desvio no Coeficiente de Vazão da Turbina											
		4,5%	3,5%	2,5%	1,5%	0,5%	0,0%	-0,5%	-1,5%	-2,5%	-3,5%	-4,5%	Média
Desvio na Eficiência da Turbina	0,0%	0,63%	0,80%	0,66%	0,65%	0,76%	0,37%	0,33%	0,51%	0,95%	0,62%	1,39%	0,70%
	-0,5%	0,45%	0,64%	0,71%	0,58%	1,50%	0,45%	0,35%	0,82%	0,69%	0,47%	0,94%	0,69%
	-1,5%	0,44%	0,65%	0,56%	1,13%	0,77%	0,71%	0,38%	0,74%	1,13%	0,48%	0,29%	0,66%
	-2,5%	0,50%	0,51%	0,63%	0,52%	1,11%	0,67%	0,85%	0,70%	0,63%	0,40%	0,67%	0,65%
	-3,5%	0,37%	0,82%	0,92%	0,99%	0,64%	0,29%	0,49%	0,62%	0,69%	0,36%	0,43%	0,60%
	-4,5%	0,33%	0,79%	0,44%	1,01%	0,49%	0,48%	0,61%	0,65%	0,63%	0,64%	0,79%	0,63%
	Média	0,46%	0,70%	0,65%	0,81%	0,88%	0,50%	0,50%	0,67%	0,79%	0,50%	0,75%	0,66%

5.3.2.5 Validação da RNA de Quantificação de Falhas Combinadas

O desempenho do processo de treinamento foi avaliado utilizando o vetor de parâmetros dependentes do conjunto de amostras de treinamento com ruído como vetor de entrada da RNA de quantificação de falha combinada. Os resultados foram comparados com as saídas desejadas, resultando em um vetor erro, do qual foram tomadas a média e o desvio padrão. Um processo similar foi realizado para executar a validação do desempenho da RNA. A Tabela 5.17 apresenta os resultados das avaliações mencionadas acima. O desempenho do processo de treinamento pode ser considerado bom, dado que o valor absoluto da média dos erros das estimativas não excedeu 0,02% e o desvio padrão máximo é de aproximadamente 0,8%. Por outro lado, o processo de validação apresenta os valores de média e desvio padrão superiores os atingidos no treinamento, indicando que a queda de desempenho na generalização da RNA.

Tabela 5.17 - Erros das Estimativas dos Parâmetros dos Componentes (Simulação com Ruído)

	Amostras de Treinamento		Amostras de Validação	
	Média	Desvio Padrão	Média	Desvio Padrão
Erro na Estimativa de Desvio do Coeficiente de Vazão do Compressor	0,01	0,39	0,88	2,16
Erro na Estimativa de Desvio da Eficiência do Compressor	0,01	0,34	-0,51	1,08
Erro na Estimativa de Desvio do Coeficiente de Vazão da Turbina	-0,02	0,80	0,42	2,58
Erro na Estimativa de Desvio da Eficiência da Turbina	0,00	0,74	-0,15	1,08

5.3.2.6 Validação da Sistema Hierárquico de Diagnóstico

Os erros na estimativa de desvios nos parâmetros dos componentes da turbina a gás, apresentados na Tabela 5.18, são calculados submetendo os parâmetros dependentes das amostras de validação, ou seja, os valores medidos simulados no modelo da turbina a gás, à cada passo do sistema hierárquico de diagnóstico.

Tabela 5.18 - Estimativa de Erro da Sistema Hierárquico de Diagnóstico (Simulação com Ruído)

	Média	Desvio Padrão
Erro na Estimativa de Desvio do Coeficiente de Vazão do Compressor	0,04	1,58
Erro na Estimativa de Desvio da Eficiência do Compressor	-0,01	0,79
Erro na Estimativa de Desvio do Coeficiente de Vazão da Turbina	-0,01	1,83
Erro na Estimativa de Desvio da Eficiência da Turbina	-0,02	0,70

5.4 Monitoramento da Campanha de Operação

Os dados de operação de 2010 foram utilizados como referência para a construção do modelo da turbina a gás. No entanto, não houve uma operação contínua do equipamento no ano de 2011, impossibilitando a utilização dos dados relativos a esta campanha para avaliação da metodologia. Assim, o sistema hierárquico de diagnóstico foi aplicado para monitorar as condições dos componentes da turbina a gás durante a campanha de operação do ano de 2012.

5.4.1 Correção dos Parâmetros Dependentes pela Temperatura Ambiente

O desempenho da turbina a gás é função das condições ambientais do local onde o equipamento está instalado. Por ser uma máquina volumétrica, a massa de ar admitida por um compressor axial, para determinada rotação e relação de pressão, depende da densidade do ar e, por conseguinte, da temperatura ambiente. Além disso, tendo em vista a relação isentrópica do processo de compressão, a temperatura de saída do compressor está diretamente relacionada à temperatura ambiente.

Desta forma, para que a metodologia de diagnóstico de falhas de componentes de turbinas a gás seja aplicada, é necessário corrigir os valores dos parâmetros dependentes pela temperatura ambiente.

Para determinar as relações entre os parâmetros dependentes e a temperatura ambiente, foram utilizados valores de medição do mês de novembro de 2010, período em que foram tomadas leituras para elaboração do modelo da turbina a gás, considerando apenas os casos em que o equipamento estava operando na condição de projeto, aqui representada pela temperatura de entrada da turbina variando de 1084,5 K à 1085,5 K.

A Figura 5.9 apresenta a relação entre a temperatura de saída do compressor e a temperatura ambiente, indicando uma dependência direta e de razão unitária entre esses parâmetros, como previsto na relação isentrópica do processo de compressão.

A Figura 5.10 apresenta a relação entre a temperatura de saída da turbina e a temperatura ambiente, indicando uma dependência direta entre esses parâmetros.

A Figura 5.11 apresenta a relação entre a pressão de saída do compressor e temperatura ambiente, indicando que praticamente não existe relação de dependência entre esses parâmetros.

A Figura 5.12 apresenta a relação entre a potência de eixo e a temperatura ambiente, indicando uma dependência inversa entre esses parâmetros, ou seja, para uma determinada condição operacional, quanto maior a temperatura ambiente, menor será a potência de eixo.




Figura 5.9 – Temperatura de Saída do Compressor versus Temperatura Ambiente




Figura 5.10 – Temperatura de Saída da Turbina *versus* Temperatura Ambiente




Figura 5.11 - Pressão de Saída do Compressor *versus* Temperatura Ambiente




Figura 5.12 – Potência de Eixo *versus* Temperatura Ambiente

As equações destacadas nas Figura 5.9, Figura 5.10, Figura 5.11 e Figura 5.12 representam as linhas de tendência lineares das distribuições dos pontos nos respectivos gráficos. As derivadas destas equações, que representam as variações nos respectivos parâmetros dependentes em função da variação na temperatura ambiente, são apresentadas, respectivamente, nas Equações 5.08, 5.09, 5.10 e 5.11.

$$\frac{dT_3}{dT_A} = 1,001 \quad (5.08)$$

$$\frac{dT_6}{dT_A} = 0,6169 \quad (5.09)$$

$$\frac{dP_3}{dT_A} = -0,0454 \quad (5.10)$$

$$\frac{dPOT}{dT_A} = -0,5700 \quad (5.11)$$

A variação da temperatura ambiente durante a campanha operacional de 2012 no site da turbina a gás é apresentada na Figura 5.13 Uma vez que a variação na pressão de saída do

compressor apresenta baixa dependência com a variação na temperatura ambiente, conforme Equação 5.03, os valores medidos deste parâmetro dependente não são corrigidos. Para os demais casos, as dispersões dos valores medidos e dos valores corrigidos, quando aplicadas as correções na campanha operacional do ano de 2012, são apresentadas nas Figura 5.14, Figura 5.15 e Figura 5.16.




Figura 5.13 – Variação da Temperatura Ambiente Durante Campanha Operacional 2012




Figura 5.14 – Temperatura de Saída do Compressor: Valores Medidos e Corrigidos pela Temperatura Ambiente




Figura 5.15 – Temperatura de Saída da Turbina: Valores Medidos e Corrigidos pela Temperatura Ambiente




Figura 5.16 – Potência de Eixo: Valores Medidos e Corrigidos pela Temperatura Ambiente

5.4.2 Aplicação de Filtros nos Parâmetros Dependentes

A metodologia de diagnóstico de falhas em turbinas a gás, proposta nesta Tese, prevê a utilização de RNA para analisar medições com ruído e medições suavizadas. Para o primeiro caso, as RNA foram treinadas com amostras de parâmetros dependentes simuladas com ruído

e podem ser aplicadas diretamente para análise dos sinais de medição. Para o segundo caso, as RNA foram treinadas com amostras de parâmetros dependentes simuladas sem ruído, necessitando uma prévia suavização do sinal de medição para realização da análise.

A partir de valores de medição da campanha operacional de 2012, já corrigidos pela temperatura ambiente, são calculados os desvios dos parâmetros dependentes em relação à condição de projeto, resultando em ΔT_3 , ΔT_6 , ΔP_3 e ΔPOT . Esses valores de desvio são submetidos aos filtros: (i) média móvel (filtro linear de resposta à impulso finito), (ii) média móvel ponderada exponencial (filtro linear de resposta à impulso infinito), (iii) mediana ponderada centrada (filtro não linear), (iv) híbrido racional-mediana, (v) híbrido linear finito-mediana. As expressões matemáticas e as parametrizações desses filtros são apresentadas na Tabela 5.19..

Para fins de operacionalização do processo de diagnóstico de falha, foram levantados dados de medições com intervalo de tempo de 30 minutos. De forma a refletir nos valores filtrados a influência de meio dia de medição, os tamanhos dos filtros foram definidos como 24.

As Figura 5.17, Figura 5.18, Figura 5.19 e Figura 5.20 representam o comportamento do desvios dos parâmetros dependentes em relação às condições de projeto, ΔT_3 , ΔT_6 , ΔP_3 e ΔPOT , nos meses de outubro a dezembro de 2012, comparando os valores medidos com valores submetidos aos filtros média móvel e média móvel ponderada exponencial.

As Figura 5.21 e Figura 5.22, Figura 5.23 e Figura 5.24 representam o comportamento do desvios dos parâmetros dependentes supracitados, comparando os valores medidos com valores submetidos aos filtros mediana ponderada centrada ($K=12$) e ($K=24$).

As Figura 5.25, Figura 5.26, Figura 5.27 e Figura 5.28 representam o comportamento do desvios dos parâmetros dependentes supracitados, comparando os valores medidos com valores submetidos aos filtros mediana ponderada centrada ($K=24$) e híbrido racional-mediana.

As Figura 5.29, Figura 5.30, Figura 5.31 e Figura 5.32 representam o comportamento do desvios dos parâmetros dependentes supracitados, comparando os valores medidos com valores submetidos aos filtros mediana ponderada centrada ($K=24$) e híbrido linear finito-mediana.

Tabela 5.19 – Filtros Utilizados para Suavização dos Sinais de Medição

Filtro	Expressão	Parâmetros	ID
Média Móvel	$y(k) = \sum_{i=1}^N b(i)x(k-i+1)$	$b(i) = cte = \frac{1}{N}$ $N = 24$	(5.04)
Média Móvel Ponderada Exponencial	$y(k) = ax(k) + (1-a)y(k-1)$	$N = 0,25$	(5.05)
Mediana Ponderada Centrada	$y(k) = mediana(x(k-K), \dots, (2K-1)x(k), \dots, x(k+K))$	$K = 12$ $K = 24$	(5.06)
Híbrido Racional- Mediana	$\Delta_k = \frac{y_{k-1} + y_{k+1} + y_k \left[\tau(y_{k-1} - y_{k+1})^2 + \frac{1}{\omega} - 2 \right]}{\tau(y_{k-1} - y_{k+1})^2 + \frac{1}{\omega}}$	$\tau = 0,01$ $\omega = 0,16$	(5.07)
Híbrido Linear Finito-Mediana	$\Delta_k = mediana(\omega_1 * y_1, \omega_2 * y_2, \omega_3 * y_3, \omega_4 * y_4, \omega_5 * y_5)$ $y_1 = \frac{1}{I}(x_{k-1} + x_{k-2} + x_{k-3} + \dots + x_{k-I})$ $y_2 = h_1 * x_{k-1} + h_2 * x_{k-2} + h_3 * x_{k-3} + \dots + h_I * x_{k-I})$ $y_3 = x_k$ $y_4 = \frac{1}{I}(x_{k+1} + x_{k+2} + x_{k+3} + \dots + x_{k+I})$ $y_5 = h_1 * x_{k+1} + h_2 * x_{k+2} + h_3 * x_{k+3} + \dots + h_I * x_{k+I})$ $h_i = \frac{4I - 6i + 2}{I(I-1)}$	$\omega_1 = 2$ $\omega_2 = 1$ $\omega_3 = 1$ $\omega_4 = 2$ $\omega_5 = 1$ $I = 24$	(5.08)




Figura 5.17 – Filtros: Média Móvel e Média Móvel Ponderada Exponencial (T_3)




Figura 5.18 - Filtros: Média Móvel e Média Móvel Ponderada Exponencial (T_6)




Figura 5.19 - Filtros: Média Móvel e Média Móvel Ponderada Exponencial (P_3)




Figura 5.20 - Filtros: Média Móvel e Média Móvel Ponderada Exponencial (POT)




Figura 5.21 – Filtro: Mediana Ponderada Centrada (T_3)




Figura 5.22 – Filtro: Mediana Ponderada Centrada (T_6)




Figura 5.23 – Filtro: Mediana Ponderada Centrada (P_3)




Figura 5.24 – Filtro: Mediana Ponderada Centrada (POT)




Figura 5.25 - Filtros: Mediana Ponderada Centrada e Híbrido Racional-Mediana (T_3)




Figura 5.26 - Filtros: Mediana Ponderada Centrada e Híbrido Racional-Mediana (T_6)




Figura 5.27 - Filtros: Mediana Ponderada Centrada e Híbrido Racional-Mediana (P_3)




Figura 5.28 - Filtros: Mediana Ponderada Centrada e Híbrido Racional-Mediana (POT)




Figura 5.29 - Filtros: Mediana Ponderada Centrada e Híbrido Linear Finito-Mediana (T_3)




Figura 5.30 - Filtros: Mediana Ponderada Centrada e Híbrido Linear Finito-Mediana (T_6)




Figura 5.31 - Filtros: Mediana Ponderada Centrada e Híbrido Linear Finito-Mediana (P_3)




Figura 5.32 - Filtros: Mediana Ponderada Centrada e Híbrido Linear Finito-Mediana (POT)

A correção pela temperatura ambiente reduz expressivamente a flutuação dos valores medidos em relação aos respectivos valores esperados para as condições de projeto. Contudo, os

desvios dos valores corrigidos em relação às condições de projeto ainda apresentam níveis de ruído elevados, sendo necessário submeter esses dados a um processo de suavização antes de realizar o diagnóstico de falhas.

A aplicação de filtros lineares, sejam o filtro média móvel ou o filtro média móvel ponderada, elimina pontos espúrios e reduz a amplitude das flutuações, mas conserva a mesma característica dos ruídos de medição. Já a aplicação de filtros não-lineares elimina pontos espúrios e, em alguns casos, modifica a característica dos ruídos de medição. As aplicações dos filtros mediana ponderada centrada e híbrido racional-mediana resultaram em sinais com baixa flutuação e, em alguns intervalos, os sinais permaneceram constantes. Já aplicação do filtro híbrido linear finito-mediana apresentou resultados semelhantes aos dos filtros lineares.

Tendo em vista que a metodologia de diagnóstico de falhas proposta nesta tese tem a finalidade de determinar os desvios nas eficiências e nos coeficientes de vazão dos componentes das turbinas a gás, fruto de deteriorações de longo prazo, a técnica de suavização empregada deve apresentar a menor variação entre medições sucessivas. Com isso, para determinar a técnica mais apropriadas dentre as apresentadas nesta seção, foi adotado como critério o menor erro quadrático médio entre valores sucessivos, calculado pela Equação 5.05, onde j representa a quantidade de parâmetros dependentes e i representa a quantidade de pontos medidos.

$$EQM = \sum_{j=1}^4 \sum_i^N \frac{\sqrt{(x_{i+1}^j - x_i^j)^2}}{4 N} \quad (5.05)$$

Desta forma, com base nos resultados apresentados na Tabela 5.20, o filtro mediana ponderada centrada é o mais adequado para a suavização dos sinais de medição.

Tabela 5.20 - Comparação Entre as Técnicas de Suavização de Dados

Técnica de Suavização de Dados	Erro Quadrático Médio
Filtro Média Móvel	2,85E-04
Filtro Média Móvel Ponderada Exponencial	5,51E-04
Filtro Mediana Ponderada Centrada	9,60E-05
Filtro Híbrido Racional - Mediana	1,59E-04
Filtro Híbrido Linear Finito - Mediana	8,00E-04

5.4.3 Diagnóstico de Falhas dos Componentes da Turbina a Gás

Nesta seção serão analisados os resultados do sistema hierárquico de diagnóstico de falhas, quando aplicado à campanha operacional do ano de 2012 da turbina a gás ALSTOM GT11N2, instalada na Usina Termelétrica Governador Leonel Brizola.

O objetivo desta análise é identificar a configuração mais adequada do sistema hierárquico de diagnóstico para aplicação no ambiente industrial, ou seja, avaliar o comportamento das RNA treinadas com amostras de parâmetros dependentes sem ruído e das RNA treinadas com amostras de parâmetros dependentes com ruído, utilizando como vetor de entrada os dados de medição sem pré-processamento e os dados de medição pós suavização pelo Filtro Mediana Ponderada Centrada, visto que foi eleito o mais adequado para a referida aplicação pelo critério estabelecido na seção anterior.

As condições de simulação são: (i) RNA treinadas com amostras sem ruído e medições sem filtro; (ii) RNA treinadas com amostras sem ruído e medições com filtro; (iii) RNA treinadas com amostras com ruído e medições sem filtro; (iv) RNA treinadas com amostras com ruído e medições com filtro. Para fins de visualização, as figuras desta seção contemplam apenas os resultados das simulações para os meses de agosto a dezembro de 2012.

As Figura 5.33, Figura 5.34, Figura 5.35 e Figura 5.36 apresentam, respectivamente, as estimativas dos desvios no coeficiente de vazão do compressor para as condições (i), (ii), (iii) e (iv) de simulação do sistema hierárquico de diagnóstico.

As Figura 5.37, Figura 5.38, Figura 5.39 e Figura 5.40 apresentam, respectivamente, as estimativas dos desvios na eficiência do compressor para as condições (i), (ii), (iii) e (iv) de simulação do sistema hierárquico de diagnóstico.

As Figura 5.41, Figura 5.42, Figura 5.43 e Figura 5.44 apresentam, respectivamente, as estimativas dos desvios no coeficiente de vazão da turbina para as condições (i), (ii), (iii) e (iv) de simulação do sistema hierárquico de diagnóstico.

As Figura 5.45, Figura 5.46, Figura 5.47 e Figura 5.48 apresentam, respectivamente, as estimativas dos desvios na eficiência da turbina para as condições (i), (ii), (iii) e (iv) de simulação do sistema hierárquico de diagnóstico.




Figura 5.33 –Desvio no Coeficiente de Vazão do Compressor (RNA sem Ruído e Medição sem Filtro)




Figura 5.34 – Desvios no Coeficiente de Vazão do Compressor (RNA sem Ruído e Medição com Filtro)




Figura 5.35 – Desvios no Coeficiente de Vazão do Compressor (RNA com Ruído e Medição sem Filtro)




Figura 5.36 – Desvios no Coeficiente de Vazão do Compressor (RNA com Ruído e Medição com Filtro)



Figura 5.37 – Desvio na Eficiência do Compressor (RNA sem Ruído e Medição sem Filtro)




Figura 5.38 – Desvio na Eficiência do Compressor (RNA sem Ruído e Medição com Filtro)




Figura 5.39 – Desvio na Eficiência do Compressor (RNA com Ruído e Medição sem Filtro)




Figura 5.40 – Desvio na Eficiência do Compressor (RNA com Ruído e Medição com Filtro)




Figura 5.41 – Desvio no Coeficiente de Vazão da Turbina (RNA sem Ruído e Medição sem Filtro)




Figura 5.42 – Desvio no Coeficiente de Vazão da Turbina (RNA sem Ruído e Medição com Filtro)




Figura 5.43 – Desvio no Coeficiente de Vazão da Turbina (RNA com Ruído e Medição sem Filtro)




Figura 5.44 – Desvio no Coeficiente de Vazão da Turbina (RNA com Ruído e Medição com Filtro)




Figura 5.45 – Desvio na Eficiência da Turbina (RNA sem Ruído e Medição sem Filtro)




Figura 5.46 – Desvio na Eficiência da Turbina (RNA sem Ruído e Medição com Filtro)



Figura 5.47 – Desvio na Eficiência da Turbina (RNA com Ruído e Medição sem Filtro)



Figura 5.48 – Desvio na Eficiência da Turbina (RNA com Ruído e Medição com Filtro)

A avaliação da efetividade do sistema hierárquico de diagnóstico desenvolvido nesta Tese foi comprovada com por meio de sua aplicação no monitoramento de uma campanha operacional da turbina a gás ALSTOM GT11N2.

Na determinação dos índices de correção dos parâmetros dependentes foi constatado que, à exceção da Pressão de Saída do Compressor, os demais parâmetros dependentes definidos como vetor de entrada do sistema hierárquico de diagnóstico são sensíveis às alterações na Temperatura Ambiente.

Os filtros de ruído de sinais dos sensores de medição média móvel, média móvel ponderada exponencial, mediana ponderada centrada, híbrido racional-mediana e híbrido linear finito-mediana apresentaram bom desempenho. No entanto, pelo critério da diferença mínima entre medições sucessivas, o filtro mediana ponderada foi selecionado para realizar o pré-processamento dos dados do vetor de entrada do sistema hierárquico de diagnóstico.

A análise dos desvios no coeficiente de vazão do compressor, identificados pela aplicação do sistema hierárquico de diagnóstico, revela que a utilização de sinais de medição, sem pré-processamento para redução de ruídos, como vetor de entrada de RNA treinadas com amostras sem ruídos resulta em sinais de saída flutuantes e com pontos de desvios positivos. O pré-processamento dos sinais de medição melhora significativamente os sinais de saída desta RNA. Por outro lado, a utilização das RNA treinadas com amostras com ruído resultou em sinais de saída flutuantes e com desvios positivos tanto para o vetor de entrada com sinais de medição sem ruído, quanto para o vetor de entrada com sinais de medição pré-processados.

Em geral, os desvios nos demais parâmetros independentes dos componentes da turbina a gás apresentam o mesmo comportamento dos desvios no coeficiente de vazão, à exceção dos desvios na eficiência do compressor, obtidos pela utilização de sinais de medições pré-processadas como vetor de entrada da RNA treinada com amostras com ruído, que apresentaram pouca flutuação.

6 CONCLUSÕES E COMENTÁRIOS

O constante aumento no uso de termoelectricidade no Brasil levou a implantação de diversas iniciativas com objetivo de promover uma otimização completa nas instalações termelétricas, dentre as quais se destacam as medidas de redução de custos de operação e manutenção. Sistemas de monitoramento da saúde de turbinas apresentam grande potencial para o alcance desta meta, dado que eles revelam as condições dos componentes previamente à parada da turbina, permitindo melhor gerenciamento da manutenção, redução do tempo de máquina parada, maximização de lucro operacional e prevenção de falhas catastróficas.

Sistemas de monitoramento da saúde dos componentes do caminho do gás compreendem diversas técnicas, tais como LGPA, NLGPA, métodos de diagnóstico baseados em probabilidade e métodos de diagnóstico baseados em inteligência artificial. Este último inclui sistema especialista, lógica difusa, algoritmo genético e RNA. Todos estes métodos têm a intensão de representar o comportamento não linear dos parâmetros dependentes devido à influência da degradação de componentes. Neste contexto, as RNA apresentam um enorme potencial, visto que podem tratar facilmente de relações não lineares, realizando análises sem iterações, que permitem aplicações *on-line*. Entretanto, as técnicas de RNA apresentam fraquezas relacionadas com a definição de suas estruturas, seus processos de validação e métodos de treinamento. Não obstante seus pontos fracos, RNA tem contribuído para o desenvolvimento de sistemas de diagnóstico de diversas maneiras, tais como predição de medições de desempenho e estimativa de degradação de componentes, sendo esta última aplicada com mais sucesso através de um sistema hierárquico de diagnóstico.

Um sistema hierárquico de diagnóstico foi desenvolvido nesta Tese para realizar a análise de diagnóstico de falhas nos componentes de uma turbina industrial de eixo simples. A estrutura do sistema hierárquico de diagnóstico compreende as funções de detecção, isolamento e quantificação de falhas, que são, respectivamente, representadas por *perceptron* de camada única, RNA probabilística e RNA multicamadas *feed-forward*. O *perceptron* é adequado para problemas onde um resultado binário é esperado, a RNA probabilística é utilizada para identificar padrões em problemas de classificação, enquanto a RNA multicamadas *feed-forward* é adequada para tarefas de aproximação de funções.

Independentemente do método de diagnóstico utilizado, a qualidade dos dados de entrada é fundamental para a obtenção de resultados confiáveis. O pré-processamento dos sinais dos

sensores de medição por filtros tem a função de redução de ruídos e eliminação de pontos espúrios, permitindo que o algoritmo de diagnóstico produza sinais de saída consistentes.

O modelo da turbina a gás representou apenas o ponto de referência operacional da turbina ALSTOM GT11N2, visto que seriam necessários os mapas reais das características dos componentes do equipamento para modelar as condições de carga parciais. No entanto, esta restrição não comprometeu o desempenho do sistema hierárquico de diagnóstico porque a turbina a gás em análise opera na maior parte do tempo em carga total. Além disso, para simulação de condições de operação fora do ponto de referência, representando a degradação dos componentes, foram utilizados mapas padrões escalonados.

A potência de eixo do modelo da turbina a gás para o ponto de referência operacional é de 107 MW, conforme indicado na Tabela 4.2, enquanto a potência de para o ponto de projeto reportada pelo fabricante é de 115 MW, conforme indicado na Tabela 4.1. O motivo dessa diferença reside nas condições de referência para medição desta grandeza e no desgaste natural da turbina a gás instalada no site. O fabricante considera condições ISA e modelo considera as condições ambientais mais prováveis do site.

As IGV não foram consideradas no modelo da turbina a gás, uma vez que são utilizadas para o aumento de desempenho do equipamento operando em carga parcial, distante do ponto de referência de operação. O modelo foi elaborado com a finalidade de simular a condição de referência de operação da turbina a gás e sua vizinhança, para representar a degradação nos componentes, cujos parâmetros são obtidos a partir dos mapas dos componentes da turbina a gás.

O valor da temperatura de entrada da turbina indicada no relatório como uma grandeza medida pelo software PI, na verdade é resultado de um cálculo interno do sistema de controle da turbina a gás a partir da temperatura de saída da turbina. Devido à elevada temperatura na entrada da turbina, não é possível instalar um instrumento confiável e robusto para sua medição.

PYTHIA 2.8 foi utilizado com plataforma computacional para geração do modelo, baseado em parâmetros de medição reais. O ponto de referência operacional do modelo foi definido com base em uma análise não estruturada do conjunto de dados, mas uma ferramenta estatística poderia ter sido utilizada para encontrar a melhor solução. Além disso, um maior de número de medições resultaria provavelmente em uma melhor análise de diagnóstico.

O digrama de blocos do modelo construído no software PYTHIA 2.8 difere do diagrama do modelo termodinâmico no que tange aos blocos misturador, bocal convergente e desempenho. O bloco misturador é utilizado no modelo de simulação para dividir o fluxo na saída do compressor, representando a extração de ar para o resfriamento das partes quentes da turbina, não sendo necessário para representar os processos termodinâmicos. O bocal convergente foi utilizado em conjunto com o duto para representar o duto de saída. Por fim, o bloco de desempenho é um requisito do software.

A convergência do modelo da turbina a gás no software PYTHIA 2.8 foi realizada pelo método de tentativa e erro, ajustando os parâmetros internos de cada um de seus 8 blocos. Os resultados do modelo apresentam desvios menores que 0,08% em relação aos dados de referência. O módulo de otimização do software, que prevê o ajuste automático destes parâmetros para uma condição desejada, não apresentou resultados adequados às exigências de precisão do método de diagnóstico de falhas proposto neste Tese.

Uma vez que a metodologia para diagnóstico de falhas em componentes de turbinas a gás proposta neste Tese é aplicada apenas para a investigação das condições do equipamento, quando operando na condição de projeto, não foi realizado um estudo sobre os algoritmos de otimização de fatores de escala dos mapas de desempenho para condições de operação em carga parcial.

O processo de geração de amostras revelou importantes comportamentos dos parâmetros dependentes dos componentes devido à degradação da turbina. Por exemplo, o desvio na eficiência do compressor leva a um aumento na Temperatura de Saída do Compressor, uma pequena diminuição na Temperatura de Saída da Turbina e uma diminuição na Potência de Eixo, enquanto o desvio no coeficiente de vazão do compressor leva a uma diminuição na Temperatura de Saída do Compressor, um aumento na Temperatura de Saída da Turbina, uma diminuição abrupta na Pressão de Saída do Compressor e uma diminuição na Potência de Eixo. O mesmo tipo de análise foi realizado considerando os desvios nos parâmetros independentes da turbina a gás.

A simulação do modelo da turbina a gás, considerando diferentes níveis de degradação em seus componentes, revelou a tendência de desvios nos parâmetros dependentes devido aos desvios nos parâmetros independentes. Esta análise definiu que os desvios nos parâmetros dependentes Temperatura de Saída do Compressor, Temperatura de Saída da Turbina, Pressão

de Saída do Compressor e Potência de Eixo são adequados para compor o vetor de entrada do sistema hierárquico de diagnóstico de falhas.

No processo de validação do sistema hierárquico de diagnóstico, as RNA de detecção de degradação demonstraram excelente desempenho para medições com e sem ruído. Também, as RNA de isolamento de falhas apresentaram alta taxa de acertos no isolamento, sendo 99,1% para amostras sem ruído e 92,8% para amostras com ruído. As RNA de quantificação de falhas do compressor e da turbina apresentaram excelentes resultados para todos os casos, considerando que o EQM não ultrapassou 0,66%. Por outro lado, as RNA de quantificação de falhas combinadas apresentaram um nível de precisão inferior, considerando que o desvio padrão dos erros na estimativa de desvios no coeficiente de vazão da turbina foi de 2,58. Apesar disso, o sistema hierárquico de diagnóstico apresentou boa precisão quando analisando amostras com e sem ruído.

De maneira geral, as RNA individuais apresentaram excelente desempenho quando utilizando vetores de entrada compostos de amostras de dados simulados com e sem ruído. Entretanto, o sistema hierárquico de diagnóstico apresentou um desempenho inferior para ambos os casos. Para uma maior representatividade do processo, o número de elementos no conjunto de amostras de treinamento poderia ter sido maior, especialmente aqueles relacionados à RNA de quantificação de falhas combinadas e, também, outros parâmetros dependentes poderiam ter sido utilizados adicionalmente aos quatro usados para a realização da análise de diagnóstico. É importante destacar que esta metodologia é somente aplicada para análise de condições operacionais próximas às do ponto de referência.

A revisão bibliográfica mostra que as técnicas de diagnóstico de falhas em turbinas a gás por meio de redes neurais artificiais, inclusive a técnica de sistema hierárquico de diagnóstico, apresentam bons resultados quando utilizam resultados de simulações como vetor de entrada das RNA, contudo a aplicação prática em ambientes industriais requer um pré-processamento dos sinais dos sensores de medição. As análises realizadas nesta Tese demonstraram que o filtro não linear mediana ponderada centrada é o mais adequado para realização da suavização dos dados, antes de submetê-los ao sistema hierárquico de diagnóstico.

A partir da análise dos resultados do monitoramento da campanha operacional do ano de 2012 da turbina a gás ALSTOM GT11N2, que mostrou o comportamento dos desvios no coeficiente de vazão e na eficiência do compressor e nos desvios no coeficiente de vazão e na

eficiência da turbina, no período, foi possível constatar que a utilização de dados pré-processados por filtros para redução de ruído e eliminação de pontos espúrios melhora significativamente o desempenho do sistema hierárquico de diagnóstico. Além disso, a configuração que combina a utilização de redes neurais artificiais treinadas com amostras de dados sem ruído e o pré-processamento dos sinais de entrada apresentou melhor desempenho para a realização do diagnóstico de falhas nos componentes da turbina a gás.

6.1 Trabalhos Futuros

O desenvolvimento desta Tese suscitou a possibilidade de desenvolvimento de uma série de trabalhos para aumentar a eficiência dos métodos de diagnóstico de falhas em turbinas a gás. Em se tratando especificamente dos métodos que utilizam redes neurais artificiais, foram identificadas lacunas e fragilidades nos métodos existentes, que podem ser solucionadas por meio dos trabalhos propostos a seguir:

- Definição de metodologia, baseada em técnicas estatísticas, para estimar o ponto de projeto da turbina a gás, ou o ponto de referência do modelo, a partir de dados de operação do equipamento. Esta metodologia tem o potencial de reduzir os erros sistemáticos do modelo.
- Definição de metodologia, baseada em técnicas estatísticas, para estimar os mapas das características dos componentes da turbina a gás a partir de dados de operação do equipamento, possibilitando realizar o diagnóstico de falhas em condições de operação em carga parcial.
- Estudar arquiteturas de redes neurais artificiais apropriadas para tratamento dos ruídos de medição e eliminação de pontos espúrios.
- Estudar os níveis de erro aceitáveis nos processos de treinamento e validação das RNA.
- Definição de metodologia, utilizando lógica difusa, para “traduzir” os desvios nos parâmetros independentes em orientações de manutenção, como por exemplo, indicar a necessidade de lavagem de um compressor.

- Aplicação do sistema hierárquico de diagnóstico para monitorar outras configurações de turbina a gás, como por exemplo, uma turbina a gás de 2 eixos.
- Implementar o sistema hierárquico de diagnóstico para realização de monitoramento *on-line* do comportamento dos componentes da turbina a gás

REFERENCIAS BIBLIOGRAFICAS

ALSTOM. GT11N2 Gas Turbine: Unique in its fuel flexibility and reliability. Switzerland, 2007. Disponível em: <<http://alstomenergy.gepower.com/Global/Power/Resources/Documents/Brochures/gt11n2-gas-turbine-epslanguage=en-GB.pdf>>. Acesso em: 27 jan. 2015.

ALSTOM. Gas Product Solutions. Technical Performance: Gas Turbine Range. Switzerland, 2010. Disponível em: <<http://alstomenergy.gepower.com/Global/Power/Resources/Documents/Brochures/gas-turbines-technical-performance-epslanguage=en-GB.pdf>>. Acesso em: 27 jan. 2015.

BEALE, M. H.; HAGAN, M. T.; DEMUTH, H. B. **Matlab Neural Network** Toolbox User's Guide. [S.l.]: Mathworks, 2011.

EMPRESA DE PESQUISA ENERGÉTICA (Brasil). **Balanço Energético Nacional 2011:** Ano base 2010. Relatório Final. Brazilian Energy Balance 2011 Year 2010. Rio de Janeiro: EPE, 2011.

BOURGUET, S.; LÉONARD, O. **Comparion of adaptive filters for gas turbine performance monitoring**. Journal of Computational and Applied Mathematics, v. 234, Issue 7, p. 2202-2212, 1 ago. 2010.

CARLING, A. **Introducing Neural Networks**. Wilmslow: SIGMA PRESS, 1992.

CRANFIELD UNIVERSITY. **The Turbomatch Scheme**. Bedford: [s.n.], 1999.

DOEL, D. L. TEMPER — A Gas-Path Analysis Tool for Commercial Jet Engines. ASME. **Journal of Engineering for Gas Turbines and Power**, v. 116, Issue 1, p. 82-89, 1 jan. 1994.

DONAT, W. et al. Data Visualization, Data Reduction and Classifier Fusion for Intelligent Fault Diagnosis in Gas Turbine Engines. **ASME. Journal of Engineering for Gas Turbines and Power**, v. 130, Issue 4, p. 041602-041602-8, 29 abr. 2008.

ESCHER, P. C. **Pythia**: an object oriented gas-path analysis computer-program for general applications. 1995. 229f. Ph.D thesis - School of Mechanical Engineering, Cranfield University, UK, 1995. Disponível em: <<http://dspace.lib.cranfield.ac.uk/handle/1826/3457>>. Acesso em: 27 jan. 2015.

FAST, M.; PALME, T. Application of artificial neural network to the condition monitoring and diagnosis of a combined heat and power plant. **Energy**, v. 35, Issue 2, p. 1114-1120, feb. 2010.

FAST, M.; ASSADI, M.; DE, S. Development and multi-utility of an ANN model for an industrial gas turbine. **Applied Energy**, v. 86, Issue 1, p. 9-17, jan. 2009.

GANGULI, R. **GAS TURBINE DIAGNOSTICS: Signal Processing and Fault Isolation**. London: CRC Press Taylor and Francis Group, 2013.

GUPTA, M. M.; JIN, L.; HOMMA, N. **Static and dynamic neural networks: from fundamentals to advanced theory**. New Jersey: John Wiley & Sons, 2003.

HERTZ, J.; KROGH, A.; PALMER, R. G. **Introduction to the theory of neural computation**. Redwood City: Addison-Wesley, 1991.

HOU, F. **Development of a neural network fault diagnostic system for gas turbine engine**. Cranfield: Cranfield University, 2007.

KEVIN, L. P.; PAUL, E. K. **Artificial Neural Network: An Introduction**. Bellingham, Washington: SPIE PRESS, 2005.

KURZ, R.; BRUN, K. Degradation of gas turbine performance in natural gas service. **Journal of Natural Gas Science and Engineering**, v. 1, Issue 3, p. 95-102, set. 2009.

LI, Y. G.; SINGH, R. An advanced gas turbine gas path diagnostic system - PYTHIA. In: INTERNATIONAL SYMPOSIUM ON AIRBREATHING ENGINES, 17., 2005, Munich. **Paper...** Munich: [s.n.], 2005.

LI, Y. G. Gas turbine performance and health status estimation using adaptive gas path analysis. **ASME. Journal of Engineering for Gas Turbines and Power**, v. 132, Issue 4, p. 041701-041701-9, jan. 2010.

_____. **Gas Turbine Diagnostics**. [S.l.]: Cranfield University, 2011.

LIMA, B. Q.; CRUXEN, R. Compressor Failure Tres Lagoas, Brazil. In: F6FA USER CONFERENCE, 2015, [S.l.]. **Paper...** [S.l.]: [s.n.], 2015.

LIMA, Bruno de Queiroz; GUEDES, Luiz Daniel Folhaça; D'OLIVEIRA, Ricardo Cruxen Daemon. Monitoramento do Parque Termelétrico da Petrobras. In: FÓRUM DE TURBOMÁQUINAS, 10., 2015, Rio de Janeiro. **Paper...** Rio de Janeiro: [s.n.], 2015. 20 p.

LIPOWKY, H. et al. Application of bayesian forecasting to change detection and prognosis of gas turbine performance. **ASME. Journal of Engineering for Gas Turbines and Power**, v. 132, Issue 3, p. 031602-031602-8, dez. 2009.

LOU, F.; FABIAN, J.; KEY, N. L. The Effect of Gas Models on Compressor Efficiency Including Uncertainty. **ASME. Journal of Engineering for Gas Turbines and Power**, v. 136, Issue 1, p. 012601-012601-8, out. 2013.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 5, Issue 4, p. 115-133, 1943.

NAEEM, M.; SINGH, R.; PROBERT, D. Implications of Engine Deterioration for Operational Effectiveness of Military Aircraft. **Applied Energy**, v. 60, Issue 3, p. 115-152, jul. 1998.

NKOI, B.; PILIDIS, P.; NIKOLAIDIS, T. Performance Assessment of Simple and Modified Cycle Turbohaft Gas Turbines. **Propulsion and Power Research**, v. 2, Issue 2, p. 96-106, jun. 2013.

NOZARI, H. A. et al. Model-based robust fault detection and isolation of an industrial gas turbine prototype using soft computing techniques. **Neurocomputing**, v. 91, Issue 15, p. 29-47, Ago. 2012.

OGAJI, S. O. T. et al. Parameter selection for diagnosing a gas-turbine's performance-deterioration. **Applied Energy**, v. 73, Issue 1, p. 25-46, set. 2002.

OGAJI, S. O. T. **Advanced gas-path fault diagnostic for stationary gas turbines**. 2003. 295f. Ph.D thesis - School of Engineering, Cranfield University, UK, 2003.

OGAJI, S.; SINGH, R. Advanced engine using artificial neural networks. **Applied Soft Computing**, v. 3, Issue 3, p. 259-271, nov. 2003.

OSISOFT. PI Data Link 2013, v. 5.0.0., software.

PALME, T.; FAST, M.; THERN, M. Gas turbine sensor validation through classification with artificial neural network. **Applied Energy**, v. 88, Issue 11, p. 3898-3904, nov. 2011.

PETROBRAS. Portal Petrobras. Disponível em: <<http://www.petrobras.com.br/pt/nossas-atividades/principais-operações/termelétricas/governador-leonel-brizola.htm>>. Acesso em: 11 fev. 2016.

RAHME, S.; MESKIN, N. Adaptive sliding mode observer for sensor fault diagnosis of an industrial gas turbine. **Control Engineering Practice**, v. 38, p. 57-74, mai. 2015.

SARAVANAMUTTOO, H. et al. Gas Turbine Theory. 6 ed. Padstow, Cornwall: Pearson Education Limited, 2009.

SHIVAKUMAR; PAI, P.S.; RAO, B. R. S. Artificial Neural Network based prediction of performance and emission characteristic of a variable compression ratio CT engine using WCO as a biodiesel at different injection timings. **Applied Energy**, v. 88, p. 2344-2354, 2011.

SIMON, D. L.; ARMSTRONG, J. B. An Integrated Approach for Aircraft Engine Performance Estimation and Fault Diagnostics. **ASME. Journal of Engineering for Gas Turbines and Power**, v. 135, Issue 7, p. 071203-071203-10, jun. 2013.

SINA, T.-B. S.; KHORASANI, K. Fault Detection and Isolation of Gas Turbina Engine Using a Bank os Neural Networks. **Journal of Process Control**, v. 36, p. 22-41, dez. 2015.

SINGH, R. Managing gas turbine availability, performance and life usage via advanced diagnostics. In: Gas Turbine Users Association Annual Conference, 44., 1999, Dubai. **Paper...** Dubai: [s.n.], 1999.

URBAN, L. A. Parameter selection for multiple fault diagnostic of gas turbine engines. **Journal of engineering for Power**, v. 97, Issue 2, p. 225-230, abr. 1975.

VODOPIANOV, V. E. Probabilistic gas path analysis for gas turbine engines and its application. In: ASME Turbo Expo 2004: Power for Land, Sea, and Air, v. 2, 2004, Vienna. **Paper...** Vienna: ASME, 2004. p. 563-571

YE, J. Fault diagnosis of turbine based on fuzzy entropy of vague sets. **Expert Systems with applications**, v. 36, Issue 4, p. 8103-8106, mai. 2009.

APÊNDICES

Apêndice A – Código de Simulação no TURBOMATCH

TURBOMATCH SCHEME - Windows NT version (October 1999)

!TURBOMATCH SCHEME DESIGN FILE

!ENGINE TYPE: GT11N2_GPA

////

OD SI GT CT FP

-1

-1

INTAKE S1,2 D1,2,3,4,5,6 R300

COMPRES2,3,22,0 D7,8,9,10,11,12,13,14,15,16,17,18,19,20 R301 V7 V8

BURNER S3,4 D22,23,24,25,26,27,28,29 R302

MIXEES S4,22,5

TURBIN S5,6 D30,31,32,33,34,35,36,37,38,39,40 V30 V31

DUCTER S6,7 D42,43,44,45 R303

NOZCON S7,8,1 D46,47 R304

PERFOR S1,0,0 D30,49,50,51,304,300,302,0,0,0,0,0,0

CODEND

DATA////

1 0.0

2 9.8

3 0.0

4 .97

5 0.0

6 86

7 -1.0

8 -1

9 13.94

10 .858

11 0.0

12 3

13 1

14 1
15 1
16 1
17 1
18 .0175
19 1
20 0.0
22 0.05
23 0.935
24 -1.0
25 0.0
26 340.0
27 0.0
28 1
29 -1
30 106803886
31 -1.0
32 -1.0
33 .89
34 -1.0
35 1
36 1
37 1000
38 1
39 1
40 1
42 0.0
43 0.0144227
44 0.0
45 0
46 -1.0

47 1.0

49 -1.0

50 0.0

51 0.0

-1

1 2 391.6

4 6 1358

-1

Number of Variables calculated by Appendix 4 Procedure

(excluding any Splitters and/or Compressors on same Shaft) = 3

Number of obligatory Errors calculated by Appendix 4 Procedure = 2

Time Now 12:42:28

The Units for this Run are as follows:-

Temperature = K Pressure = Atmospheres Length = metres

Area = sq metres Mass Flow = kg/sec Velocity = metres/sec

Force = Newtons s.f.c.(Thrust) = mg/N sec s.f.c.(Power) = mug/J

Sp. Thrust = N/kg/sec Power = Watts

1

***** DESIGN POINT ENGINE CALCULATIONS *****

***** AMBIENT AND INLET PARAMETERS *****

Alt. = 0.0 I.S.A. Dev. = 9.800 PDev. = 0.000

Mach No. = 0.00 E_{tar} = 0.9700 Momentum Drag = 0.00

Rel.Humidity = 86.00

***** COMPRESSOR 1 PARAMETERS *****

PRSF = 0.17643E+01 ETASF = 0.10222E+01 WASF = 0.40929E+01

DGPRSF = 0.10000E+01 DGETASF = 0.10000E+01 DGWASF = 0.10000E+01

Z = 0.85000 PR = 13.940 ETA = 0.85800

PCN = 1.0000 CN = 1.00000 COMWK = 0.15357E+09

SURGE = 0.15000 WAC = 410.519

***** COMBUSTION CHAMBER PARAMETERS *****

ETASF = 0.93500E+00 DGETASF = 0.10000E+01

ETA = 0.93500 DLP = 0.6761 WFB = 6.9633 WWB = 0.00000

***** TURBINE 1 PARAMETERS *****

CNSF = 0.10278E+03 ETASF = 0.10394E+01 TFSF = 0.28123E+01

DHSF = 0.13589E+05

DGETASF = 0.10000E+01 DGTFSF = 0.10000E+01 DGDHSF = 0.10000E+01

TF = 404.966 ETA = 0.89000 CN = 2.800

AUXWK = 0.10680E+09

***** CONVERGENT NOZZLE 1 PARAMETERS *****

NCOSF = 0.10000E+01 DGNCOSF = 0.10000E+01

Area = 4.8850 Exit Velocity = 183.92 Gross Thrust = 71271.78

Nozzle Coeff. = 0.97230E+00 EXIT MACH No = 0.3334

Station	F.A.R.	Mass Flow	Pstatic	Ptotal	Tstatic	Ttotal	Vel	Area	W.A.R.	X
1	0.00000	391.600	1.00000	1.00000	297.95	297.95	0.0	*****	0.01705	1.000
2	0.00000	391.600	*****	0.97000	*****	297.95	*****	*****	0.01705	1.000
3	0.00000	384.747	*****	13.52181	*****	674.82	*****	*****	0.01705	1.000
4	0.01841	391.710	*****	12.84572	*****	1358.00	*****	*****	0.01705	1.000
5	0.01808	398.563	*****	12.84572	*****	1347.34	*****	*****	0.01705	1.000
6	0.01808	398.563	*****	1.09044	*****	810.45	*****	*****	0.01705	1.000
7	0.01808	398.563	*****	1.07471	*****	810.45	*****	*****	0.01705	1.000
8	0.01808	398.563	1.00000	1.07471	795.83	810.45	183.9	4.8850	0.01705	1.000
9	0.00000	0.000	*****	0.00000	*****	0.00	*****	*****	0.00000	0.000
10	0.00000	0.000	*****	0.00000	*****	0.00	*****	*****	0.00000	0.000
11	0.00000	0.000	*****	0.00000	*****	0.00	*****	*****	0.00000	0.000
12	0.00000	0.000	*****	0.00000	*****	0.00	*****	*****	0.00000	0.000
13	0.00000	0.000	*****	0.00000	*****	0.00	*****	*****	0.00000	0.000
14	0.00000	0.000	*****	0.00000	*****	0.00	*****	*****	0.00000	0.000
15	0.00000	0.000	*****	0.00000	*****	0.00	*****	*****	0.00000	0.000
16	0.00000	0.000	*****	0.00000	*****	0.00	*****	*****	0.00000	0.000
17	0.00000	0.000	*****	0.00000	*****	0.00	*****	*****	0.00000	0.000

18	0.00000	0.000	*****	0.00000	*****	0.00	*****	*****	0.00000	0.000
19	0.00000	0.000	*****	0.00000	*****	0.00	*****	*****	0.00000	0.000
20	0.00000	0.000	*****	0.00000	*****	0.00	*****	*****	0.00000	0.000
21	0.00000	0.000	*****	0.00000	*****	0.00	*****	*****	0.00000	0.000
22	0.00000	6.853	*****	13.52181	*****	674.66	*****	*****	0.01705	1.000

Shaft Power = 106803888.00

Net Thrust = 71271.78

Equiv. Power = 111399280.00

Fuel Flow = 6.9633

S.F.C. = 65.1973

E.S.F.C. = 62.5078

Sp. Sh. Power = 272737.19

Sp. Eq. Power = 284472.09

Sh. Th. Effy. = 0.3111

Time Now 12:42:28

Apêndice B – Código de Treinamento e Validação das RNA

Table B-1 - No noise degradation detection RNA training and validation files

Item	Description	MATLAB Code
cdnet	no noise degradation detection ANN	cdnet = newp (cdi,cdt) cdnet = train (cdnet, cdi, cdt) cdnet.b{1} = [-0.0001]
cdi	no noise degradation detection ANN input file	N/A
cdt	no noise degradation detection ANN target file	N/A
cds	no noise degradation detection ANN simulation file	cds = sim (cdnet, cdi)
cde	no noise degradation detection ANN error file	cde = cds- cdt
vdi	no noise degradation detection ANN input validation file	N/A
vdt	no noise degradation detection ANN target validation file	N/A
vds	no noise degradation detection ANN simulation validation file	vds = sim (cdnet, vdi)
vde	no noise degradation detection ANN error validation file	vde = vds- vdt

Table B-2 - No noise fault isolation RNA training and validation files

Item	Description	MATLAB Code
cinet	no noise fault isolation ANN	cinet = newpnn (ciim,citv)
cii	no noise fault isolation ANN input file	N/A
ciim	no noise fault isolation ANN input file	[ciim, ciip] = mapminmax (cii)
ciip	no noise fault isolation ANN input file processing set	[ciim, ciip] = mapminmax (cii)
cit	no noise fault isolation ANN target file	N/A
citv	no noise fault isolation ANN target file vector	citv = ind2vec (cit)
cisv	no noise fault isolation ANN target simulation file vector	cisv = sim (cinet, ciim)
cis	no noise fault isolation ANN target simulation	cis = vec2ind (cisv)
vii	no noise fault isolation ANN input validation file	N/A
viim	no noise fault isolation ANN input validation file normalized	viim= mapminmax ('apply', vii, ciip)
visv	no noise fault isolation ANN target simulation file validation vector	visv = sim (cinet, viim)
vis	no noise fault isolation ANN target simulation file validation	vis = vec2ind (visv)
vit	no noise fault isolation ANN target validation	N/A
vie	no noise fault isolation ANN error validation file	vie = vis - vit

Table B-3 - No noise compressor fault quantification RNA training and validation files

Item	Description	MATLAB Code
cqcnet	no noise compressor quantification fault ANN	cqcnet = newff (cqci, cqct, 20) cqcnet = train (cqcnet, cqci, cqct)
cqci	no noise compressor quantification fault ANN input file	N/A
cqct	no noise compressor quantification fault ANN target file	N/A
cqcs	no noise compressor quantification fault ANN simulation file	cqcs = sim (cqcnet, cqci)
cqce	no noise compressor quantification fault ANN error file	cqce = cqcs - cqct
cqcerms	no noise compressor quantification fault ANN rms file	cqcerms = sqrt ((cqce(1, :).*cqce(1,:) + cqce(2, :).*cqce(2,:))/2)
cqcermsr	no noise compressor quantification fault ANN rms file to the chart	cqcermsr = reshape (cqcerms, 6,6)
vcqi	no noise compressor quantification fault ANN input validation file	N/A
vcqt	no noise compressor quantification fault ANN target validation file	N/A
vcqs	no noise compressor quantification fault ANN simulation validation file	vcqs = sim (cqcnet, vcqi)
vcqe	no noise compressor quantification fault ANN error validation file	vcqe = vcqs - vcqt
vcqcerms	no noise compressor quantification fault ANN rms validation file	vcqcerms = sqrt ((vcqe(1, :).*vcqe(1,:) + vcqe(2, :).*vcqe(2,:))/2)
vcqcermsr	no noise compressor quantification fault ANN rms validation file to the chart	vcqcermsr = reshape (vcqcerms, 6,6)

Table B-4 - No noise turbine fault quantification RNA training and validation files

Item	Description	MATLAB Code
cqtnet	no noise turbine quantification fault ANN	cqtnet = newff (cqti, cqtt, 20) cqtnet = train (cqtnet, cqti, cqtt)
cqti	no noise turbine quantification fault ANN input file	N/A
cqtt	no noise turbine quantification fault ANN target file	N/A
cqts	no noise turbine quantification fault ANN simulation file	cqts = sim (cqtnet, cqti)
cqte	no noise turbine quantification fault ANN error file	cqte = cqts - cqtt
cqterms	no noise turbine quantification fault ANN rms file	cqterms = sqrt ((cqte(1, :).*cqte(1,:) + cqte(2, :).*cqte(2,:))/2)
cqtermsr	no noise turbine quantification fault ANN rms file to the chart	cqtermsr = reshape (cqterms, 6,11)
cqtermsro	no noise turbine quantification fault ANN rms file to the chart ordenated	cqtermsro = [cqtermsr (:, 11), cqtermsr (:, 10), cqtermsr (:, 09), cqtermsr (:, 08), cqtermsr (:, 07), cqtermsr (:, 01), cqtermsr (:, 02), cqtermsr (:, 03), cqtermsr (:, 04), cqtermsr (:, 05), cqtermsr (:, 06)]
vqti	no noise turbine quantification fault ANN input validation file	N/A
vqtt	no noise turbine quantification fault ANN target validation file	N/A
vqts	no noise turbine quantification fault ANN simulation validation file	vqts = sim (cqtnet, vqti)
vqte	no noise turbine quantification fault ANN error validation file	vqte = vqts - vqtt
vqterms	no noise turbine quantification fault ANN rms validation file	vqterms = sqrt ((vqte(1, :).*vqte(1,:) + vqte(2, :).*vqte(2,:))/2)
vqtermsr	no noise turbine quantification fault ANN rms validation file to the chart	vqtermsr = reshape (vqterms, 6,11)
vqtermsro	no noise turbine quantification fault ANN rms validation file to the chart ordenated	vqtermsro = [vqtermsr (:, 07), vqtermsr (:, 08), vqtermsr (:, 09), vqtermsr (:, 10), vqtermsr (:, 11), vqtermsr (:, 01), vqtermsr (:, 02), vqtermsr (:, 03), vqtermsr (:, 04), vqtermsr (:, 05), vqtermsr (:, 06)]

Table B-5 - No noise combined fault quantification RNA training and validation files

Item	Description	MATLAB Code
cqctnet	no noise combined quantification fault ANN	cqctnet = newff (cqcti, cqctt, 20) cqctnet = train (cqctnet, cqcti, cqctt)
cqcti	no noise combined quantification fault ANN input file	N/A
cqctt	no noise combined quantification fault ANN target file	N/A
cqcts	no noise combined quantification fault ANN simulation file	cqcts = sim (cqctnet, cqcti)
cqcte	no noise turbine quantification fault ANN error file	cqcte = cqcts - cqctt
cqctsd	no noise turbine quantification fault ANN error standard deviation file	cqctsd = std (cqcte, 0, 2)
cqctav	no noise turbine quantification fault ANN error mean deviation file	cqctav = mean (cqcte, 2)
vkcti	no noise combined quantification fault ANN input validation file	N/A
vkctt	no noise combined quantification fault ANN target validation file	N/A
vkcts	no noise combined quantification fault ANN validation simulation file	vkcts = sim (vkctnet, vkcti)
vkcte	no noise turbine quantification fault ANN error validation file	vkcte = vkcts - vkctt
vkctsd	no noise turbine quantification fault ANN error standard deviation validation file	vkctsd = std (vkcte, 0, 2)
vkctav	no noise turbine quantification fault ANN error mean deviation validation file	vkctav = mean (vkcte, 2)

Table B-6 - Noise degradation detection RNA training and validation files

Item	Description	MATLAB Code
ndnet	noise degradation detection ANN	ndnet = newp (ndi,ndt) ndnet = train (ndnet, ndi, ndt) ndnet.b{1} = [-0.001]
ndi	noise degradation detection ANN input file	N/A
ndt	noise degradation detection ANN target file	N/A
nds	noise degradation detection ANN simulation	nds = sim (ndnet, ndi)
nde	noise degradation detection ANN error file	nde = nds- ndt
vxdi	noise degradation detection ANN input validation file	N/A
vxd	noise degradation detection ANN target validation file	N/A
vxds	noise degradation detection ANN simulation validation file	vxds = sim (ndnet, vxdi)
vxde	noise degradation detection ANN error validation file	vxde = vxds- vxd

Table B-7 - Noise fault isolation RNA training and validation files

Item	Description	MATLAB Code
ninet	noise fault isolation ANN	ninet = newpnn (niim,nitv)
nii	noise fault isolation ANN input file	N/A
niim	noise fault isolation ANN input file normalized	[niim, niip] = mapminmax (nii)
niip	noise fault isolation ANN input file processing set	[niim, niip] = mapminmax (nii)
nit	noise fault isolation ANN target file	N/A
nitv	noise fault isolation ANN target file vector	nitv = ind2vec (nit)
nisl	noise fault isolation ANN target simulation file	nisl = sim (ninet, niim)
nisl	noise fault isolation ANN target simulation file	nisl = vec2ind (nisl)
vxii	noise fault isolation ANN input validation file	N/A
vxiiim	noise fault isolation ANN input validation file normalized	vxiiim= mapminmax ('apply', vxii, ciip)
vxisl	noise fault isolation ANN target simulation validation file vector	vxisl = sim (ninet, vxiiim)
vxisl	noise fault isolation ANN target simulation validation file	vxisl = vec2ind (vxisl)
vxisl	noise fault isolation ANN target validation file	N/A

Table B-8 - Noise compressor fault quantification RNA training and validation files

Item	Description	MATLAB Code
nqcnet	noise compressor quantification fault ANN	nqcnet = newff (nqci, nqct, 50) nqcnet = train (nqcnet, nqci, nqct)
nqci	noise compressor quantification fault ANN input file	N/A
nqct	noise compressor quantification fault ANN target file	N/A
nqcs	noise compressor quantification fault ANN simulation file	nqcs = sim (nqcnet, nqci)
nqce	noise compressor quantification fault ANN error file	nqce = nqcs - nqct
nqcerms	noise compressor quantification fault ANN rms file	nqcerms = sqrt ((nqce(1, :). * nqce(1, :) + nqce(2, :). * nqce(2, :)) / 2)
nqcermsc	noise compressor quantification fault ANN rms file column	nqcermsc = reshape (nqcerms, 36, 4)
nqcermsp	noise compressor quantification fault ANN rms file point	nqcermsp = sqrt ((nqcermsc (:, 1). * nqcermsc (:, 1) + nqcermsc (:, 2). * nqcermsc (:, 2) + nqcermsc (:, 3). * nqcermsc (:, 3) + nqcermsc (:, 4). * nqcermsc (:, 4)) / 4)
nqcermsr	noise compressor quantification fault ANN rms file to chart	nqcermsr = reshape (nqcermsp, 6, 6)
vxqci	noise compressor quantification fault ANN input validation file	N/A
vxqct	noise compressor quantification fault ANN target validation file	N/A
vxqcs	noise compressor quantification fault ANN simulation validation file	vxqcs = sim (cqcnet, vxqci)
vxqce	noise compressor quantification fault ANN error validation file	vxqce = vxqcs - vxqct
vxqcerms	noise compressor quantification fault ANN rms validation file	vxqcerms = sqrt ((vxqce(1, :). * vxqce(1, :) + vxqce(2, :). * vxqce(2, :)) / 2)
vxqcermsc	noise compressor quantification fault ANN rms validation file column	vxqcermsc = reshape (vxqcerms, 36, 4)
vxqcermsp	noise compressor quantification fault ANN rms validation file point	vxqcermsp = sqrt ((vxqcermsc (:, 1). * vxqcermsc (:, 1) + vxqcermsc (:, 2). * vxqcermsc (:, 2) + vxqcermsc (:, 3). * vxqcermsc (:, 3) + vxqcermsc (:, 4). * vxqcermsc (:, 4)) / 4)
vxqcermsr	noise compressor quantification fault ANN rms validation file to chart	vxqcermsr = reshape (vxqcermsp, 6, 6)

Table B-9 - Noise turbine fault quantification RNA training and validation files

Item	Description	MATLAB Code
nqtnet	noise turbine quantification fault ANN	nqtnet = newff (nqti, nqtt, 50) nqtnet = train (nqtnet, nqti, nqtt)
nqti	noise turbine quantification fault ANN input file	N/A
nqtt	noise turbine quantification fault ANN target file	N/A
nqts	noise turbine quantification fault ANN simulation file	nqts = sim (nqtnet, nqti)
nqte	noise turbine quantification fault ANN error file	nqte = nqts - nqtt
nqterms	noise turbine quantification fault ANN rms file	nqterms = sqrt ((nqte(1, :). * nqte(1, :) + nqte(2, :). * nqte(2, :)) / 2)
nqtermssc	noise turbine quantification fault ANN rms file column	nqtermssc = reshape (nqterms, 66, 4)
nqtermssp	noise turbine quantification fault ANN rms file point	nqtermssp = sqrt ((nqtermssc (:, 1). * nqtermssc (:, 1) + nqtermssc (:, 2). * nqtermssc (:, 2) + nqtermssc (:, 3). * nqtermssc (:, 3) + nqtermssc (:, 4). * nqtermssc (:, 4)) / 4)
nqtermssr	noise turbine quantification fault ANN rms file to the chart	nqtermssr = reshape (nqtermssp, 6, 11)
nqtermssro	noise turbine quantification fault ANN rms file to the chart ordenated	nqtermssro = [nqtermssr (:, 11), nqtermssr (:, 10), nqtermssr (:, 09), nqtermssr (:, 08), nqtermssr (:, 07), nqtermssr (:, 01), nqtermssr (:, 02), nqtermssr (:, 03), nqtermssr (:, 04), nqtermssr (:, 05), nqtermssr (:, 06)]
vxqti	noise turbine quantification fault ANN input validation file	N/A
vxqtt	noise turbine quantification fault ANN target validation file	N/A
vxqts	noise turbine quantification fault ANN simulation validation file	vxqts = sim (nqtnet, vxqti)
vxqte	noise turbine quantification fault ANN error validation file	vxqte = vxqts - vxqtt
vxqterms	noise turbine quantification fault ANN rms validation file	vxqterms = sqrt ((vxqte(1, :). * vxqte(1, :) + vxqte(2, :). * vxqte(2, :)) / 2)
vxqtermssc	noise turbine quantification fault ANN rms validation file column	vxqtermssc = reshape (vxqterms, 66, 4)
vxqtermssp	noise turbine quantification fault ANN rms validation file point	vxqtermssp = sqrt ((vxqtermssc (:, 1). * vxqtermssc (:, 1) + vxqtermssc (:, 2). * vxqtermssc (:, 2) + vxqtermssc (:, 3). * vxqtermssc (:, 3) + vxqtermssc (:, 4). * vxqtermssc (:, 4)) / 4)
vxqtermssr	noise turbine quantification fault ANN rms validation file to the chart	vxqtermssr = reshape (vxqtermssp, 6, 11)
vxqtermssro	noise turbine quantification fault ANN rms validation file to the chart ordenated	vxqtermssro = [vxqtermssr (:, 07), vxqtermssr (:, 08), vxqtermssr (:, 09), vxqtermssr (:, 10), vxqtermssr (:, 11), vxqtermssr (:, 01), vxqtermssr (:, 02), vxqtermssr (:, 03), vxqtermssr (:, 04), vxqtermssr (:, 05), vxqtermssr (:, 06)]

Table B-10 - Noise combined fault quantification RNA training and validation files

Item	Description	MATLAB Code
nqctnet	noise combined quantification fault ANN	nqctnet = newff (nqcti, nqctt, 50) nqctnet = train (nqctnet, nqcti, nqctt)
nqcti	noise combined quantification fault ANN input file	N/A
nqctt	noise combined quantification fault ANN target file	N/A
nqcts	noise combined quantification fault ANN simulation file	nqcts = sim (nqctnet, nqcti)
nqcte	noise turbine quantification fault ANN error file	nqcte = nqcts - nqctt
nqctsd	noise turbine quantification fault ANN error standard deviation file	nqctsd = std (nqcte, 0, 2)
nqctav	noise turbine quantification fault ANN error mean deviation file	nqctav = mean (nqcte, 2)
vxqcti	noise combined quantification fault ANN input validation file	N/A
vxqctt	noise combined quantification fault ANN target validation file	N/A
vxqcts	noise combined quantification fault ANN simulation validation file	vxqcts = sim (nqctnet, vxqcti)
vxqcte	noise turbine quantification fault ANN error validation file	vxqcte = vxqcts - vxqctt
vxqctsd	noise turbine quantification fault ANN error standard deviation validation file	vxqctsd = std (vxqcte, 0, 2)
vxqctav	noise turbine quantification fault ANN error mean deviation validation file	vxqctav = mean (vxqcte, 2)

Apêndice C – Comportamento dos Parâmetros Dependentes (Degradação Combinada)

Tabela C-1- Comportamento dos Parâmetros Dependentes-Degradação Combinada

Desvios nos Parâmetros Independentes				Parâmetros Dependentes			
Compressor		Turbina		T3	T6	P3	POT
$\Delta\Gamma_c$ [%]	$\Delta\eta_c$ [%]	$\Delta\Gamma_T$ [%]	$\Delta\eta_T$ [%]	[K]	[K]	[atm]	[W]
0,0	-1,0	0,0	-1,0	678,9	816,9	13,55	1,020E+08
0,0	-1,0	0,0	-5,0	680,2	842,3	13,64	8,961E+07
0,0	-1,0	-1,0	-1,0	680,8	815,8	13,68	1,016E+08
0,0	-1,0	-1,0	-5,0	682,1	841,1	13,77	8,925E+07
0,0	-1,0	-2,0	-1,0	682,7	814,7	13,81	1,012E+08
0,0	-1,0	-2,0	-5,0	684,4	841,1	13,93	8,817E+07
0,0	-1,0	-3,0	-1,0	684,7	813,6	13,95	1,008E+08
0,0	-1,0	-3,0	-5,0	687,8	841,3	14,09	8,646E+07
0,0	-1,0	-4,0	-1,0	687,5	812,5	14,08	9,991E+07
0,0	-1,0	-4,0	-5,0	691,5	841,5	14,26	8,461E+07
0,0	-1,0	-5,0	-1,0	690,5	811,5	14,21	9,892E+07
0,0	-1,0	-5,0	-5,0	695,3	841,6	14,42	8,277E+07
0,0	-1,0	0,0	-1,0	678,9	816,9	13,55	1,020E+08
0,0	-1,0	0,0	-5,0	680,2	842,3	13,64	8,961E+07
0,0	-1,0	1,0	-1,0	677,0	817,9	13,42	1,025E+08
0,0	-1,0	1,0	-5,0	678,3	843,3	13,51	9,003E+07
0,0	-1,0	2,0	-1,0	675,1	819,0	13,29	1,029E+08
0,0	-1,0	2,0	-5,0	676,4	844,3	13,38	9,043E+07
0,0	-1,0	3,0	-1,0	673,2	820,1	13,17	1,033E+08
0,0	-1,0	3,0	-5,0	674,6	845,3	13,26	9,084E+07
0,0	-1,0	4,0	-1,0	671,4	821,1	13,04	1,037E+08
0,0	-1,0	4,0	-5,0	672,7	846,3	13,13	9,125E+07
0,0	-1,0	5,0	-1,0	669,6	822,2	12,92	1,040E+08
0,0	-1,0	5,0	-5,0	670,9	847,4	13,01	9,160E+07
0,0	-5,0	0,0	-1,0	694,6	816,8	13,56	9,525E+07
0,0	-5,0	0,0	-5,0	696,0	842,2	13,65	8,282E+07
0,0	-5,0	-1,0	-1,0	696,6	815,7	13,69	9,483E+07
0,0	-5,0	-1,0	-5,0	697,9	840,9	13,78	8,250E+07
0,0	-5,0	-2,0	-1,0	698,6	814,6	13,82	9,438E+07
0,0	-5,0	-2,0	-5,0	700,4	841,0	13,94	8,129E+07
0,0	-5,0	-3,0	-1,0	700,6	813,5	13,96	9,393E+07
0,0	-5,0	-3,0	-5,0	703,9	841,2	14,10	7,948E+07
0,0	-5,0	-4,0	-1,0	703,6	812,4	14,09	9,296E+07
0,0	-5,0	-4,0	-5,0	707,7	841,4	14,27	7,759E+07
0,0	-5,0	-5,0	-1,0	706,7	811,4	14,22	9,194E+07
0,0	-5,0	-5,0	-5,0	711,5	841,6	14,43	7,569E+07
0,0	-5,0	0,0	-1,0	694,6	816,8	13,56	9,527E+07
0,0	-5,0	0,0	-5,0	696,0	842,2	13,65	8,282E+07
0,0	-5,0	1,0	-1,0	692,6	817,8	13,43	9,570E+07
0,0	-5,0	1,0	-5,0	694,0	843,2	13,52	8,326E+07
0,0	-5,0	2,0	-1,0	690,7	818,9	13,30	9,613E+07
0,0	-5,0	2,0	-5,0	692,1	844,2	13,39	8,370E+07
0,0	-5,0	3,0	-1,0	688,7	819,9	13,18	9,656E+07
0,0	-5,0	3,0	-5,0	690,1	845,3	13,27	8,413E+07
0,0	-5,0	4,0	-1,0	686,8	821,0	13,05	9,700E+07
0,0	-5,0	4,0	-5,0	688,2	846,2	13,14	8,457E+07
0,0	-5,0	5,0	-1,0	684,9	822,1	12,93	9,737E+07
0,0	-5,0	5,0	-5,0	686,3	847,3	13,02	8,496E+07

Tabela C-1- Comportamento dos Parâmetros Dependentes-Degradação Combinada (continuação)

Desvios nos Parâmetros Independentes				Parâmetros Dependentes			
Compressor		Turbina		T3	T6	P3	POT
$\Delta\Gamma_c$ [%]	$\Delta\eta_c$ [%]	$\Delta\Gamma_T$ [%]	$\Delta\eta_T$ [%]	[K]	[K]	[atm]	[W]
-1,0	-1,0	0,0	-1,0	677,0	818,5	13,42	1,011E+08
-1,0	-1,0	0,0	-5,0	678,3	843,8	13,51	8,885E+07
-1,0	-1,0	-1,0	-1,0	678,9	817,4	13,55	1,007E+08
-1,0	-1,0	-1,0	-5,0	680,3	842,9	13,64	8,831E+07
-1,0	-1,0	-2,0	-1,0	680,8	816,2	13,68	1,003E+08
-1,0	-1,0	-2,0	-5,0	682,7	843,0	13,81	8,717E+07
-1,0	-1,0	-3,0	-1,0	682,8	815,1	13,81	9,991E+07
-1,0	-1,0	-3,0	-5,0	686,1	843,1	13,97	8,547E+07
-1,0	-1,0	-4,0	-1,0	685,5	814,1	13,95	9,906E+07
-1,0	-1,0	-4,0	-5,0	689,8	843,3	14,13	8,365E+07
-1,0	-1,0	-5,0	-1,0	688,6	813,0	14,08	9,809E+07
-1,0	-1,0	-5,0	-5,0	693,5	843,5	14,29	8,184E+07
-1,0	-1,0	0,0	-1,0	686,1	843,1	13,97	8,547E+07
-1,0	-1,0	0,0	-5,0	685,5	814,1	13,95	9,906E+07
-1,0	-1,0	1,0	-1,0	689,8	843,3	14,13	8,365E+07
-1,0	-1,0	1,0	-5,0	688,6	813,0	14,08	9,809E+07
-1,0	-1,0	2,0	-1,0	693,5	843,5	14,29	8,184E+07
-1,0	-1,0	2,0	-5,0	674,5	845,8	13,25	8,965E+07
-1,0	-1,0	3,0	-1,0	671,3	821,7	13,04	1,023E+08
-1,0	-1,0	3,0	-5,0	672,7	846,9	13,13	9,005E+07
-1,0	-1,0	4,0	-1,0	669,5	822,8	12,92	1,026E+08
-1,0	-1,0	4,0	-5,0	670,8	848,0	13,01	9,039E+07
-1,0	-1,0	5,0	-1,0	667,7	823,8	12,80	1,030E+08
-1,0	-1,0	5,0	-5,0	669,0	849,0	12,88	9,079E+07
-1,0	-5,0	0,0	-1,0	692,6	818,4	13,43	9,442E+07
-1,0	-5,0	0,0	-5,0	694,0	843,7	13,52	8,216E+07
-1,0	-5,0	-1,0	-1,0	694,6	817,3	13,56	9,401E+07
-1,0	-5,0	-1,0	-5,0	696,1	842,8	13,65	8,158E+07
-1,0	-5,0	-2,0	-1,0	696,6	816,2	13,69	9,357E+07
-1,0	-5,0	-2,0	-5,0	698,5	842,9	13,82	8,039E+07
-1,0	-5,0	-3,0	-1,0	701,6	814,0	13,95	9,220E+07
-1,0	-5,0	-3,0	-5,0	705,9	843,3	14,14	7,673E+07
-1,0	-5,0	-4,0	-1,0	701,6	814,0	13,95	9,220E+07
-1,0	-5,0	-4,0	-5,0	705,9	843,3	14,14	7,673E+07
-1,0	-5,0	-5,0	-1,0	704,6	812,9	14,09	9,120E+07
-1,0	-5,0	-5,0	-5,0	709,7	843,4	14,30	7,487E+07
-1,0	-5,0	0,0	-1,0	692,6	818,4	13,43	9,443E+07
-1,0	-5,0	0,0	-5,0	694,0	843,7	13,52	8,216E+07
-1,0	-5,0	1,0	-1,0	690,6	819,4	13,30	9,486E+07
-1,0	-5,0	1,0	-5,0	692,0	844,7	13,39	8,259E+07
-1,0	-5,0	2,0	-1,0	688,7	820,5	13,17	9,528E+07
-1,0	-5,0	2,0	-5,0	690,1	845,8	13,26	8,301E+07
-1,0	-5,0	3,0	-1,0	686,8	821,6	13,05	9,570E+07
-1,0	-5,0	3,0	-5,0	688,1	846,8	13,14	8,344E+07
-1,0	-5,0	4,0	-1,0	684,8	822,7	12,93	9,607E+07
-1,0	-5,0	4,0	-5,0	686,2	847,9	13,02	8,382E+07
-1,0	-5,0	5,0	-1,0	682,9	823,7	12,81	9,649E+07
-1,0	-5,0	5,0	-5,0	684,3	848,9	12,90	8,424E+07

Tabela C-1- Comportamento dos Parâmetros Dependentes-Degradação Combinada (continuação)

Desvios nos Parâmetros Independentes				Parâmetros Dependentes			
Compressor		Turbina		T3	T6	P3	POT
$\Delta\Gamma_c$ [%]	$\Delta\eta_c$ [%]	$\Delta\Gamma_T$ [%]	$\Delta\eta_T$ [%]	[K]	[K]	[atm]	[W]
-3,0	-1,0	0,0	-1,0	673,1	821,7	13,16	9,922E+07
-3,0	-1,0	0,0	-5,0	674,4	847,0	13,25	8,723E+07
-3,0	-1,0	-1,0	-1,0	675,0	820,6	13,28	9,884E+07
-3,0	-1,0	-1,0	-5,0	676,7	846,8	13,40	8,626E+07
-3,0	-1,0	-2,0	-1,0	676,9	819,5	13,41	9,846E+07
-3,0	-1,0	-2,0	-5,0	679,1	846,8	13,56	8,517E+07
-3,0	-1,0	-3,0	-1,0	678,9	818,3	13,55	9,808E+07
-3,0	-1,0	-3,0	-5,0	682,6	847,0	13,72	8,348E+07
-3,0	-1,0	-4,0	-1,0	681,5	817,3	13,67	9,730E+07
-3,0	-1,0	-4,0	-5,0	686,2	847,1	13,87	8,173E+07
-3,0	-1,0	-5,0	-1,0	684,5	816,2	13,80	9,637E+07
-3,0	-1,0	-5,0	-5,0	689,9	847,2	14,03	8,002E+07
-3,0	-1,0	0,0	-1,0	673,1	821,8	13,16	9,921E+07
-3,0	-1,0	0,0	-5,0	674,4	847,0	13,25	8,723E+07
-3,0	-1,0	1,0	-1,0	671,2	822,8	13,03	9,960E+07
-3,0	-1,0	1,0	-5,0	672,5	847,9	13,12	8,768E+07
-3,0	-1,0	2,0	-1,0	669,4	824,0	12,91	9,992E+07
-3,0	-1,0	2,0	-5,0	670,7	848,9	12,99	8,806E+07
-3,0	-1,0	3,0	-1,0	667,5	825,1	12,78	1,003E+08
-3,0	-1,0	3,0	-5,0	668,8	850,1	12,87	8,839E+07
-3,0	-1,0	4,0	-1,0	665,7	826,1	12,66	1,007E+08
-3,0	-1,0	4,0	-5,0	667,0	851,1	12,75	8,877E+07
-3,0	-1,0	5,0	-1,0	663,9	827,2	12,55	1,010E+08
-3,0	-1,0	5,0	-5,0	665,2	852,1	12,63	8,914E+07
-3,0	-5,0	0,0	-1,0	688,6	821,6	13,17	9,275E+07
-3,0	-5,0	0,0	-5,0	690,0	846,9	13,26	8,075E+07
-3,0	-5,0	-1,0	-1,0	690,5	820,5	13,29	9,234E+07
-3,0	-5,0	-1,0	-5,0	692,3	846,8	13,41	7,972E+07
-3,0	-5,0	-2,0	-1,0	692,5	819,4	13,42	9,194E+07
-3,0	-5,0	-2,0	-5,0	694,8	846,8	13,57	7,859E+07
-3,0	-5,0	-3,0	-1,0	694,6	818,2	13,56	9,152E+07
-3,0	-5,0	-3,0	-5,0	698,5	847,0	13,73	7,681E+07
-3,0	-5,0	-4,0	-1,0	697,4	817,2	13,68	9,066E+07
-3,0	-5,0	-4,0	-5,0	702,3	847,1	13,88	7,501E+07
-3,0	-5,0	-5,0	-1,0	700,5	816,1	13,81	8,970E+07
-3,0	-5,0	-5,0	-5,0	706,0	847,1	14,04	7,326E+07
-3,0	-5,0	0,0	-1,0	688,6	821,6	13,17	9,274E+07
-3,0	-5,0	0,0	-5,0	690,0	846,9	13,26	8,075E+07
-3,0	-5,0	1,0	-1,0	686,6	822,7	13,04	9,315E+07
-3,0	-5,0	1,0	-5,0	688,0	847,8	13,13	8,122E+07
-3,0	-5,0	2,0	-1,0	684,7	823,8	12,92	9,355E+07
-3,0	-5,0	2,0	-5,0	686,0	848,9	13,00	8,163E+07
-3,0	-5,0	3,0	-1,0	682,8	825,0	12,80	9,391E+07
-3,0	-5,0	3,0	-5,0	684,1	850,0	12,88	8,199E+07
-3,0	-5,0	4,0	-1,0	680,9	826,1	12,68	9,431E+07
-3,0	-5,0	4,0	-5,0	682,2	851,0	12,76	8,239E+07
-3,0	-5,0	5,0	-1,0	679,0	827,1	12,56	9,471E+07
-3,0	-5,0	5,0	-5,0	680,3	852,0	12,64	8,280E+07

Tabela C-1- Comportamento dos Parâmetros Dependentes-Degradação Combinada (continuação)





Desvios nos Parâmetros Independentes				Parâmetros Dependentes			
Compressor		Turbina		T3	T6	P3	POT
$\Delta\Gamma_c$ [%]	$\Delta\eta_c$ [%]	$\Delta\Gamma_T$ [%]	$\Delta\eta_T$ [%]	[K]	[K]	[atm]	[W]
-5,0	-1,0	0,0	-1,0	669,2	825,1	12,89	9,731E+07
-5,0	-1,0	0,0	-5,0	670,8	850,7	13,00	8,527E+07
-5,0	-1,0	-1,0	-1,0	671,1	824,0	13,02	9,695E+07
-5,0	-1,0	-1,0	-5,0	673,1	850,8	13,16	8,421E+07
-5,0	-1,0	-2,0	-1,0	673,0	822,8	13,15	9,659E+07
-5,0	-1,0	-2,0	-5,0	675,4	850,8	13,31	8,314E+07
-5,0	-1,0	-3,0	-1,0	674,9	821,7	13,28	9,622E+07
-5,0	-1,0	-3,0	-5,0	679,0	850,9	13,47	8,148E+07
-5,0	-1,0	-4,0	-1,0	677,5	820,6	13,40	9,551E+07
-5,0	-1,0	-4,0	-5,0	682,6	851,0	13,62	7,979E+07
-5,0	-1,0	-5,0	-1,0	680,5	819,5	13,53	9,462E+07
-5,0	-1,0	-5,0	-5,0	686,2	850,8	13,77	7,826E+07
-5,0	-1,0	0,0	-1,0	669,2	825,1	12,89	9,731E+07
-5,0	-1,0	0,0	-5,0	670,8	850,7	13,00	8,528E+07
-5,0	-1,0	1,0	-1,0	667,3	826,3	12,77	9,762E+07
-5,0	-1,0	1,0	-5,0	668,6	851,2	12,86	8,603E+07
-5,0	-1,0	2,0	-1,0	665,5	827,4	12,65	9,797E+07
-5,0	-1,0	2,0	-5,0	666,8	852,2	12,74	8,640E+07
-5,0	-1,0	3,0	-1,0	663,6	828,5	12,53	9,833E+07
-5,0	-1,0	3,0	-5,0	664,9	853,3	12,62	8,676E+07
-5,0	-1,0	4,0	-1,0	661,8	829,6	12,41	9,869E+07
-5,0	-1,0	4,0	-5,0	661,8	829,6	12,41	9,869E+07
-5,0	-1,0	5,0	-1,0	661,3	855,3	12,38	8,748E+07
-5,0	-1,0	5,0	-5,0	660,0	830,6	12,30	9,904E+07
-5,0	-5,0	0,0	-1,0	686,1	850,7	13,01	7,896E+07
-5,0	-5,0	0,0	-5,0	684,5	825,0	12,90	9,104E+07
-5,0	-5,0	-1,0	-1,0	686,4	823,9	13,03	9,065E+07
-5,0	-5,0	-1,0	-5,0	688,6	850,7	13,17	7,787E+07
-5,0	-5,0	-2,0	-1,0	688,4	822,7	13,16	9,026E+07
-5,0	-5,0	-2,0	-5,0	691,1	850,8	13,32	7,673E+07
-5,0	-5,0	-3,0	-1,0	690,4	821,6	13,29	8,987E+07
-5,0	-5,0	-3,0	-5,0	694,8	850,9	13,47	7,501E+07
-5,0	-5,0	-4,0	-1,0	693,2	820,5	13,41	8,908E+07
-5,0	-5,0	-4,0	-5,0	698,6	851,0	13,63	7,328E+07
-5,0	-5,0	-5,0	-1,0	696,3	819,4	13,54	8,815E+07
-5,0	-5,0	-5,0	-5,0	702,3	850,8	13,78	7,172E+07
-5,0	-5,0	0,0	-1,0	684,5	825,0	12,90	9,104E+07
-5,0	-5,0	0,0	-5,0	686,1	850,7	13,01	7,897E+07
-5,0	-5,0	1,0	-1,0	682,5	826,2	12,78	9,137E+07
-5,0	-5,0	1,0	-5,0	683,9	851,1	12,87	7,978E+07
-5,0	-5,0	2,0	-1,0	680,6	827,3	12,66	9,175E+07
-5,0	-5,0	2,0	-5,0	682,0	852,2	12,74	8,017E+07
-5,0	-5,0	3,0	-1,0	678,7	828,4	12,54	9,214E+07
-5,0	-5,0	3,0	-5,0	680,1	853,2	12,63	8,056E+07
-5,0	-5,0	4,0	-1,0	676,8	829,5	12,42	9,252E+07
-5,0	-5,0	4,0	-5,0	678,2	854,2	12,51	8,095E+07
-5,0	-5,0	5,0	-1,0	674,9	830,5	12,31	9,290E+07
-5,0	-5,0	5,0	-5,0	676,3	855,3	12,39	8,133E+07

Apêndice D – Arquiteturas das Redes Neurais Artificiais

Tabela D-1- Arquitetura das Redes Neurais Artificiais (sem ruído de medição)

REDE NEURAL ARTIFICIAL	ARQUITETURA
Detecção de Degradação	
Isolamento de Falhas	
Quantificação de Falhas no Compressor	
Quantificação de Falhas na Turbina	
Quantificação de Falhas Combinadas	

Tabela D-2- Arquitetura das Redes Neurais Artificiais (com ruído de medição)

REDE NEURAL ARTIFICIAL	ARQUITETURA
Detecção de Degradação	
Isolamento de Falhas	
Quantificação de Falhas no Compressor	
Quantificação de Falhas na Turbina	
Quantificação de Falhas Combinadas	