



Tairo dos Prazeres Teixeira

**Sistema de Inferência Fuzzy com Extração Automática
de Regras para Diagnóstico de Desempenho de
Turbinas a Gás Aeronáuticas**

Dissertação de Mestrado

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da PUC-Rio como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Ricardo Tanscheit

Co-orientadora: Profa. Marley Maria Bernardes Rebuszi Vellasco

Rio de Janeiro

Abril de 2016



Tairo dos Prazeres Teixeira

Sistema de Inferência Fuzzy com Extração Automática de Regras para Diagnóstico de Desempenho de Turbinas a Gás Aeronáuticas

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Engenharia Elétrica do Departamento de Engenharia Elétrica do Centro Técnico Científico da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

Prof. Ricardo Tanscheit

Orientador

Departamento de Engenharia Elétrica – PUC-Rio

Profa. Marley Maria Bernardes Rebuzzi Vellasco

Co-Orientadora

Departamento de Engenharia Elétrica – PUC-Rio

Prof. Jorge Luís Machado do Amaral

UERJ

Prof. André Vargas Abs da Cruz

UEZO

Prof. Márcio da Silveira Carvalho

Coordenador Setorial do Centro

Técnico Científico

Rio de Janeiro, 25 de abril de 2016

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e do orientador.

Tairo dos Prazeres Teixeira

Graduou-se em Engenharia de Controle e Automação pela Pontifícia Universidade Católica do Rio de Janeiro - PUC-Rio em 2012. Trabalha como engenheiro de projetos atuando na área de Inteligência Artificial para diagnóstico automático de falhas em turbomáquinas e desenvolvimento de uma plataforma de simulação de malhas fluidodinâmicas para simuladores full-scope.

Ficha Catalográfica

Teixeira, Tairo dos Prazeres

Sistema de inferência fuzzy com extração automática de regras para diagnóstico de desempenho de turbinas a gás aeronáuticas / Tairo dos Prazeres Teixeira; orientador: Ricardo Tanscheit; co-orientadora: Marley Maria Bernardes Rebuzzi Vellasco. – 2016.

86 f.; 30 cm

Dissertação (mestrado) – Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Elétrica, 2016.

Inclui bibliografia

1. Engenharia Elétrica – Teses. 2. Lógica fuzzy. 3. Diagnóstico de falhas. 4. Turbina a gás. 5. Interpretabilidade. 6. Extração de Regras. I. Tanscheit, Ricardo. II. Vellasco, Marley Maria Bernardes Rebuzzi. III. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Elétrica. IV. Título.

CDD: 621.3

Agradecimentos

À minha família, em especial aos meus pais e irmãos, pelo apoio e incentivo durante a realização deste trabalho.

Ao meu orientador, Prof. Dr. Ricardo Tanscheit, e à minha co-orientadora, Profa. Dra. Marley Vellasco, pelos conhecimentos, incentivos e paciência, sem os quais não seria possível o desenvolvimento deste trabalho.

À GT2 Energia pela ajuda, compreensão e auxílio em recursos tais como o software de Lógica Fuzzy.

À PUC-Rio sou grato pelos auxílios concedidos.

Resumo

Teixeira, Tairo dos Prazeres; Tanscheit, Ricardo (Orientador); Vellasco, Marley Maria Bernardes Rebuzzi (Co-orientadora). **Sistema de Inferência Fuzzy com Extração Automática de Regras para Diagnóstico de Desempenho de Turbinas a Gás Aeronáuticas**. Rio de Janeiro, 2016. 86p. Dissertação de Mestrado - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

Turbinas a gás são equipamentos muito complexos e caros. No caso de falha em uma turbina, há obviamente perdas diretas, mas as indiretas são normalmente muito maiores, uma vez que tal equipamento é crítico para a operação de instalações industriais, aviões e veículos pesados. Portanto, é fundamental que turbinas a gás sejam providas com um sistema eficiente de monitoramento e diagnóstico. Isto é especialmente relevante no Brasil, cuja frota de turbinas tem crescido muito nos últimos anos, devido, principalmente, ao aumento do número de usinas termelétricas e ao crescimento da aviação civil. Este trabalho propõe um Sistema de Inferência *Fuzzy* (SIF) com extração automática de regras para diagnóstico de desempenho de turbinas a gás aeronáuticas. O sistema proposto faz uso de uma abordagem residual – medições da turbina real são comparadas frente a uma referência de turbina saudável – para tratamento dos dados brutos de entrada para os módulos de detecção e isolamento, que, de forma hierárquica, são responsáveis por detectar e isolar falhas em nível de componentes, sensores e atuadores. Como dados reais de falhas em turbinas a gás são de difícil acesso e de obtenção cara, a metodologia é validada frente a uma base de dados de falhas simuladas por um software especialista. Os resultados mostram que o SIF é capaz de detectar e isolar corretamente falhas, além de fornecer interpretabilidade linguística, característica importante no processo de tomada de decisão no contexto de manutenção.

Palavras-chave

Lógica *Fuzzy*; Diagnóstico de Falhas; Turbina a Gás; Interpretabilidade; Extração de Regras; Sistemas de Monitoramento; Confiabilidade.

Abstract

Teixeira, Tairo dos Prazeres; Tanscheit, Ricardo (Advisor); Vellasco, Marley Maria Bernardes Rebuzzi (Co-Advisor). **A Fuzzy Inference System with Automatic Rule Extraction for Gas Path Diagnosis of Aviation Gas Turbines.** Rio de Janeiro, 2016. 86p. MSc. Dissertation - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

A Gas turbine is a complex and expensive equipment. In case of a failure indirect losses are typically much larger than direct ones, since such equipment plays a critical role in the operation of industrial installations, aircrafts, and heavy vehicles. Therefore, it is vital that gas turbines be provided with an efficient monitoring and diagnostic system. This is especially relevant in Brazil, where the turbines fleet has risen substantially in recent years, mainly due to the increasing number of thermal power plants and to the growth of civil aviation. This work proposes a Fuzzy Inference System (FIS) with automatic rule extraction for gas path diagnosis. The proposed system makes use of a residual approach – gas path measurements are compared to a healthy engine reference – for preprocessing raw input data that are forwarded to the detection and isolation modules. These operate in a hierarchical manner and are responsible for fault detection and isolation in components, sensors and actuators. Since gas turbines failure data are difficult to access and expensive to obtain, the methodology is validated by using a database fault simulated by a specialist software. The results show that the SIF is able to correctly detect and isolate failures and to provide linguistic interpretability, which is an important feature in the decision-making process regarding maintenance.

Keywords

Fuzzy Logic; Fault Diagnosis; Gas Turbine; Interpretability; Rule Extraction; Monitoring Systems, Reliability.

Sumário

1 Introdução	14
1.1. Motivação	14
1.2. Objetivo	17
1.3. Contribuições	18
1.4. Estrutura do Dissertação	19
2 Turbinas a Gás e Diagnóstico de Falhas	20
2.1. Turbinas a Gás	20
2.2. Causas Típicas de Degradação em Turbinas a Gás	22
2.3. Diagnóstico de Falhas	27
3 Diagnóstico de Desempenho de Turbinas a Gás usando Lógica <i>Fuzzy</i>	33
3.1. Introdução	33
3.2. Base de Dados – ProDiMES	34
3.3. Arquitetura do Sistema de Diagnóstico de Desempenho de Turbinas a Gás	38
3.4. Pré-processamento	39
3.4.1. Correção	39
3.4.2. Geração dos Resíduos	42
3.5. Detecção e Isolamento de Falhas	48
3.5.1. Treinamento	49
3.5.2. Teste	53
4 Resultados e Discussão	57
4.1. Introdução	57
4.2. Ajuste do Sistema de Diagnóstico	58
4.3. Avaliação das Configurações do Sistema de Diagnóstico para Detecção de Falhas	60
4.4. Avaliação das Configurações do Sistema de Diagnóstico para Isolamento de Falhas	66
4.5. Interpretabilidade	70
4.6. Evolução Temporal e Severidade da Falha	72
4.7. Comparação com Resultados da Literatura	74
5 Conclusões	80
6 Referências bibliográficas	83

Lista de figuras

Figura 1 – Degradação da eficiência do ventilador de uma turbina a gás em função do tempo (BORGUET, 2012).	23
Figura 2 – Depósito de sal nas palhetas do compressor (KURZ; BRUN, 2012).	24
Figura 3 – Corrosão numa palheta de compressor (MONTEIRO, 2010).	25
Figura 4 – Erosão particulada em palheta de turbina (FLEMING et al., 2014).	26
Figura 5 – Risco de Danos Causados por Objetos Estranhos na indústria aérea.	27
Figura 6 – Princípio de funcionamento de diagnóstico de desempenho de turbinas a gás (URBAN, 1973).	34
Figura 7 – Arquitetura ProDiMES (SIMON et al., 2008b).	35
Figura 8 – Representação do motor genérico turbofan simulado pelo ProDiMES com as estações de medição, módulos e sensores (SIMON, 2010).	36
Figura 9 – Fluxograma da metodologia proposta.	38
Figura 10 – Etapas do módulo de pré-processamento dos dados.	39
Figura 11 – Comparação entre valores corrigidos (azul) e valores brutos (ciano) para oito medições ao longo do caminho do gás em situação sem falha.	41
Figura 12 – Comparação entre valores corrigidos (azul) e valores brutos (ciano) para oito medições ao longo do caminho do gás em situação com falha no ventilador.	41
Figura 13 – Comparação entre resíduos (ciano) e resíduos alisados exponencialmente (azul) para sete medições ao longo do caminho do gás em situação sem falha.	44
Figura 14 – Comparação entre resíduos (ciano) e resíduos alisados exponencialmente (azul) para sete medições ao longo do caminho do gás em situação com falha no ventilador.	44
Figura 15 – $\nabla \hat{r}_i(k)$ para sete medições ao longo do caminho do gás em situação sem falha.	45
Figura 16 – $\nabla \hat{r}_i(k)$ para sete medições ao longo do caminho do gás em situação com falha no ventilador.	46
Figura 17 – $N(\nabla \hat{r}_i(k))$ para sete medições ao longo do caminho do gás em situação sem falha.	47
Figura 18 – $N(\nabla \hat{r}_i(k))$ para sete medições ao longo do caminho do gás em situação com falha no ventilador.	48

Figura 19 – Exemplo de inspeção dos valores para qualquer variável de entrada $N(\nabla \hat{r}_i(k))$ para definição dos limites inferior (U-) e superior (U+). a) divisão do domínio em 3 regiões <i>fuzzy</i> ($N=1$). b) funções de pertinência correspondentes de a). c) divisão do domínio em 5 regiões <i>fuzzy</i> ($N=2$). d) funções de pertinência correspondentes de c).	50
Figura 20 – Conjuntos <i>fuzzy</i> de saída para o problema de detecção de falha.	50
Figura 21 – Conjuntos <i>fuzzy</i> de saída para o problema de isolamento de falha.	51
Figura 22 – Ilustração da convenção adotada na Tabela 12. a) função triangular; b) função trapezoidal; c) função semi-trapézio à esquerda; d) função semi-trapézio à direita.	62
Figura 23 – Verdadeiro Positivo em função do número de voos saudáveis necessários para cada alarme falso para os casos de 3, 5 e 7 conjuntos <i>fuzzy</i> .	65
Figura 24 – Matriz de confusão.	69
Figura 25 – Funções de pertinências referentes às sete entradas do módulo de detecção de falha.	71
Figura 26 – VP para diferentes naturezas de falhas.	73
Figura 27 – Coeficiente de Kappa para diferentes naturezas de falhas.	73
Figura 28 – <i>PCC</i> para diferentes severidades de falhas abruptas.	74
Figura 29 – <i>PCC</i> para diferentes severidades de falhas rápidas.	74
Figura 30 – Comparação da métrica VP para os métodos de diagnóstico MQP, RNP, FADFK, OEG e SIF em função de diferentes naturezas de falhas.	76
Figura 31 – Comparação da métrica <i>PCC</i> para os métodos de diagnóstico MQP, RNP, FADFK, OEG e SIF para falhas abruptas.	77
Figura 32 – Comparação da métrica <i>PCC</i> para os métodos de diagnóstico MQP, RNP, FADFK, OEG e SIF para falhas rápidas.	78

Lista de tabelas

Tabela 1 – Sensores emulados pelo ProDiMES (SIMON et al., 2013).	36
Tabela 2 – Tipos de falhas simuladas pelo ProDiMES.	37
Tabela 3 – Principais parâmetros para turbinas a gás e suas correções (SIMON, 2010).	40
Tabela 4 – Regras <i>fuzzy</i> hipotéticas com operado <i>AND</i> .	52
Tabela 5 – Regra <i>fuzzy</i> hipotética com operador <i>OR</i> .	52
Tabela 6 – Matriz de decisão para detecção de falha.	54
Tabela 7 – Matriz de confusão para isolamento de falha.	55
Tabela 8 – Operadores utilizados.	58
Tabela 9 – Características da base de dados usada para ajuste do sistema de diagnóstico de desempenho de turbinas a gás aeronáuticas.	59
Tabela 10 – Valor máximo, mínimo e desvio padrão de $N(\nabla \hat{r}_i(k))$ para sete medições usadas como entrada do sistema de diagnóstico <i>fuzzy</i> apenas para situação de turbina saudável.	61
Tabela 11 – Valor máximo, mínimo, desvio padrão e percentual de valores de $N(\nabla \hat{r}_i(k))$ entre -3 e 3 para sete medições usadas como entrada do sistema de diagnóstico para situação de turbina saudável e com falha.	62
Tabela 12 – Parâmetros dos conjuntos <i>fuzzy</i> para as variáveis de entrada.	63
Tabela 13 – Resultados dos casos de teste para ajuste do sistema de diagnóstico para detecção de falha.	64
Tabela 14 – Sistema de diagnóstico ajustado a partir do caso 6 da Tabela 13.	66
Tabela 15 – Resultados do caso de teste da Tabela 14.	66
Tabela 16 – Resultados dos casos de teste para ajuste do sistema de diagnóstico para isolamento de falha.	67
Tabela 17 – Sistema de diagnóstico <i>fuzzy</i> ajustado a partir do caso 5 da Tabela 16.	68
Tabela 18 – Resultados do caso de teste da Tabela 17.	68
Tabela 19 – Regras <i>fuzzy</i> de detecção de falha para saída saudável.	71
Tabela 20 – Regras <i>fuzzy</i> de detecção de falha para saída com falha.	71
Tabela 21 – Resultados do caso de teste para nova base de conhecimento.	72
Tabela 22 – Comparação de VP, Alarme Falso e Atraso de Detecção para os métodos de diagnóstico MQP, RNP, FADFK, OEG e SIF.	75
Tabela 23 – Comparação do Coeficiente de Kappa para os métodos de diagnóstico MQP, RNP, FADFK, OEG e SIF	77

Tabela 24 – Regra ativada durante avaliação de falha Fan para o módulo de detecção de falha.	79
Tabela 25 – Regra ativada durante avaliação de falha Fan para o módulo de detecção de falha.	79

Lista de Abreviaturas

AE – Algoritmos Evolucionários

AES – Alisamento Exponencial Simples

CBM – Manutenção Baseada em Condição de Máquina (Condition-Based Maintenance)

C-MAPS-SS – Software de Simulação em Regime Permanente de Turbina a Gás (Commercial Modular Aeropropulsion System Simulation Steady-State)

DOD – Dano Causado por Objeto Doméstico (Domestic Object Damage)

FADFK – Ferramenta de Análise de Desempenho com Filtro de Kalman

FOD – Dano Causado por Objeto Estranho (Foreign Object Damage)

GPA – Análise do Desempenho (Gas Path Analysis)

GUI – Interface Gráfica (Graphical User Interface)

HPC – Compressor de Alta Pressão (High Pressure Compressor)

HPT – Turbina de Alta Pressão (High Pressure Turbine)

IC – Inteligência Computacional

ICM – Matriz de Coeficientes de Influência (Influence Coefficient Matrix)

LF – Lógica Fuzzy

LGPA – Análise do Desempenho Linear (Linear Gas Path Analysis)

LPC – Compressor de Baixa Pressão (Low Pressure Compressor)

LPT – Turbina de Baixa Pressão (Low Pressure Turbine)

MLP – Perceptron Multicamadas (multilayer perceptron – MLP)

MQP – Mínimos Quadrados Ponderados

NLGPA – Análise do Desempenho Não Linear (Non-Linear Gas Path Analysis)

OEG – Observador/Estimador Genérico

PNN – Redes Neurais Probabilísticas (Probabilistic Neural Networks)

ProDiMES – Software de Simulação de Falhas em Turbina Aeronáutica (Propulsion Diagnostic Method Evaluation Strategy)

RNA – Redes Neurais Artificiais

RND – Rede Neural Dinâmica

RNP – Redes Neurais Probabilísticas

RNR – redes neurais recorrentes

SE – Sistema Especialista

SIF – Sistema de Inferência Fuzzy

SOM – Rede Auto-Organizáveis (Self-Organizing Maps)

1

Introdução

1.1

Motivação

Intervenções não programadas devidas a uma falha arbitrária são causa direta de prejuízo em instalações industriais. Confiabilidade sempre foi um aspecto importante na avaliação de produtos e/ou equipamentos industriais. Um equipamento bem projetado oferece altos níveis de confiabilidade, mas, independentemente de quão bom seja o projeto de um equipamento, este sempre irá se deteriorar com o tempo. Isto ocorre devido a situações de estresse presentes em ambientes reais de operação. Nesse contexto, a manutenção surge como uma maneira eficiente de garantir níveis aceitáveis de confiabilidade e qualidade durante o tempo de vida útil de equipamentos industriais (JARDINE; LIN; BANJEVIC, 2006; MARTIN, 1994).

As primeiras estratégias de manutenção adotadas pela indústria eram corretivas, em que a correção ocorria apenas quando o equipamento parava devido a uma falha ou pane em um ou mais de seus componentes. Uma segunda estratégia de manutenção, conhecida como manutenção preventiva, consiste em reduzir a probabilidade de falhas em equipamentos. É uma intervenção programada antes da data provável do aparecimento de uma falha.

Com o rápido desenvolvimento da tecnologia moderna, produtos se tornaram mais complexos e níveis mais altos de qualidade e confiabilidade são requeridos. Isto aumenta o custo de manutenção preventiva, que é um dos fatores mais caros para algumas instalações industriais. É natural, portanto, que estratégias mais eficientes de manutenção, como Manutenção Baseada em Condição de Máquina (do inglês *Condition-Based Maintenance* – CBM), sejam implementadas (BORGUET, 2012; CLIFTON; TARASSENKO, 2006; JARDINE; LIN; BANJEVIC, 2006; LOBODA, 2010; MARTIN, 1994).

CBM é um programa de manutenção que recomenda ações baseadas em informações coletadas do sistema de monitoramento. Seu objetivo é evitar ações

de manutenção desnecessárias, realizando-se apenas quando existe evidência de comportamento anormal de um determinado ativo físico.

Um sistema CBM consiste em três passos principais:

- Aquisição de dados: obtenção de dados relevantes sobre a saúde do equipamento;
- Processamento de dados: análise dos dados coletados para melhor entendimento e interpretação;
- Tomada de decisão dentro do contexto de manutenção: recomendações de políticas eficientes de manutenção.

Diagnóstico e prognóstico são dois importantes aspectos de um programa CBM. Diagnóstico lida com detecção, isolamento e identificação de falhas, enquanto prognóstico lida com a predição de falhas antes que elas ocorram. Embora prognóstico seja muito mais eficiente, diagnóstico é necessário quando a predição da falha está errada e uma falha acontece. Este trabalho está inserido no contexto de processamento de dados e tomada de decisão de manutenção e trata do problema típico de diagnóstico de falhas para turbinas a gás usando Lógica *Fuzzy*.

A literatura de diagnóstico de desempenho/termodinâmico de turbinas a gás é vasta e vem atraindo grande interesse da comunidade científica nos últimos anos (JAW, 2005; SIKORSKA; HODKIEWICZ; MA, 2011; SIMON, 2010). Recentemente, fabricantes de turbinas vêm adotando estratégias de Manutenção CBM, sendo possível determinar a saúde do equipamento por meio de sistemas de análise de dados inteligentes, com o objetivo de realizar intervenções de manutenção apenas quando necessário, ou simplesmente aumentar os períodos de intervenção programada (CLIFTON; TARASSENKO, 2006).

De acordo com a literatura, as técnicas mais populares de Inteligência Computacional (IC), além de Lógica *Fuzzy*, para diagnóstico de falhas em turbinas a gás são Redes Neurais Artificiais (RNA) (OGAJI; SINGH, 2003; SORSA; KOIVO, 1993; TAYARANI-BATHAIE; VANINI; KHORASANI, 2014; VOLPONI et al., 2003), Sistemas Especialistas (SE) (BO; ZHI-NONG; ZHONG-QING, 2012; ZHAO et al., 2014), Algoritmos Evolucionários (AE) (ISHIBASHI; LÚCIO; JÚNIOR, 2013) e técnicas híbridas (DEPOLD; GASS, 1998a; FRANK; KÖPPEN-SELIGER, 1997; PEEL; GOLD, 2008).

Dentre os trabalhos que abordam o problema de diagnóstico de desempenho de turbinas a gás usando Lógica *Fuzzy*, pode-se citar o trabalho de (GANGULI, 2003), que faz isolamento de falhas em nível de componente (HPT, LPC, LPT, FAN e HPC) para uma turbina a gás aeronáutica. O sistema usa quatro entradas oriundas da instrumentação acrescidas de níveis típicos de ruídos para os sensores considerados. O trabalho de (MARINAI; SINGH, 2006) aborda o problema de diagnóstico como um problema de regressão, em que o algoritmo tenta prever o valor de degradação, para cada componente da turbina, dos parâmetros de desempenho eficiência e capacidade de vazão. Porém o trabalho usa dados de operação gerados sempre nas mesmas condições ambientais e de potência, minimizando os efeitos de comparar turbinas a gás em diferentes pontos de operação. Em (BARBOSA; FERREIRA, 2012) apresenta-se um Sistema de Inferência *Fuzzy* (SIF) dedicado a cada falha, em que o sistema tem como saída a severidade da falha com valores variando de 0 a 100. No entanto, o sistema é testado apenas para duas falhas e não avalia os efeitos de ruídos nas medições.

Nos trabalhos acima, utiliza-se uma abordagem residual, em que a entrada para o SIF é o resultado de uma comparação com uma referência de turbina saudável. No entanto, algumas lacunas permanecem: (i) tratam apenas falhas em nível de componente, desconsiderando falhas em sensores e atuadores; (ii) desconsideraram a influência temporal na evolução das falhas, sendo as entradas correspondentes ao tempo atual; (iii) não tratam o problema de diagnóstico de forma hierárquica, com explicitação das etapas de detecção (indicação da presença ou não de uma falha), isolamento (isolar a falha em nível de componente) e identificação de falha (identificação da severidade e natureza da falha), sendo um único SIF responsável por todas as etapas.

Turbinas a gás são equipamentos muito complexos e caros. Por exemplo, o total de peças para uma turbina a gás industrial e seus auxiliares pode chegar a 20.000 e o seu custo a milhões de dólares (LOBODA, 2010). No caso de uma falha em uma turbina, há obviamente perdas diretas, mas as perdas indiretas são normalmente muito maiores, uma vez que tal equipamento é crítico para a operação de instalações industriais, aviões e veículos pesados como navios. Portanto, é fundamental que turbinas a gás sejam providas com um sistema eficiente de monitoramento e diagnóstico, principalmente no Brasil, onde a frota de tais turbinas cresceu muito nos últimos anos, devido, principalmente, ao

aumento do número de usinas termelétricas (BARBOSA, 2010) e ao crescimento da aviação civil.

1.2

Objetivo

Este trabalho trata do desenvolvimento e aplicação de um sistema de diagnóstico de desempenho de turbinas a gás aeronáuticas, utilizando um Sistema de Inferência *Fuzzy* para extração automática de regras (WANG; MENDEL, 1992) interpretáveis por um especialista. As regras serão geradas com base em dados de falhas simulados pelo software ProDiMES (SIMON, 2010).

Também é interesse deste trabalho tratar de características importantes de diagnóstico de turbinas a gás que ainda não foram exploradas usando Lógica *Fuzzy*. Assim, a metodologia proposta apresenta as seguintes características:

- Testado para falhas em nível de componentes, sensores e atuadores;
- Levar em consideração a influência temporal na evolução da falha;
- Lidar com o problema de diagnóstico de forma hierárquica, por meio das etapas de detecção e isolamento de falhas.

Modelos de Lógica *Fuzzy* são mais efetivos quando uma ou mais entradas são contínuas, um modelo matemático não está disponível e os dados contém altos níveis de ruído ou a informação é imprecisa ou incompleta. Também apresentam interpretabilidade linguística resultante da extração de conhecimento de uma base de regras *fuzzy* e uma das vantagens de Sistemas *Fuzzy* frente a SE é a quantidade menor de regras necessárias, pois uma regra *fuzzy* pode substituir várias regras convencionais (SIKORSKA; HODKIEWICZ; MA, 2011). Assim, o objetivo é contribuir para o aumento de confiabilidade de turbinas a gás, evitando paradas indesejadas e aumentando os períodos de intervenção programada. A indicação de presença de uma falha, no caso do sistema *fuzzy* proposto, vem acompanhado de quais regras foram ativadas, fornecendo ao especialista mais informação e um melhor direcionamento do que um sistema de diagnóstico típico forneceria.

1.3

Contribuições

Além do já apresentado nas seções anteriores, pode-se dizer que este trabalho apresenta as seguintes contribuições adicionais, que dizem respeito ao uso do software PRODIMES:

- Algoritmos para diagnóstico de desempenho de turbinas a gás necessitam, para seu completo desenvolvimento e validação, ter acesso a dados de operação e modelos da turbina. Isso se traduz em um banco de dados rico em informações coletadas em vários pontos de operação, níveis de deterioração e conhecimento da condição de falha. O software ProDiMES foi utilizado para simular possíveis falhas, uma vez que dados reais com a qualidade requerida são de difícil acesso e custosos. Embora um modelo de simulação não seja capaz de reproduzir todas as nuances presentes em dados reais de operação, ele apresenta algumas vantagens: (i) permite gerar, a custo desprezível quando comparado com dados reais, vários tipos de falhas e severidades, abrangendo um enorme conjunto de condições de operação; (ii) não há ambiguidade na condição de equipamento com falha ou saudável (SIMON, 2010; SIMON et al., 2008a, 2013);
- A literatura de diagnóstico de desempenho de turbina a gás usando lógica *fuzzy* contém diversos trabalhos, mas existe uma lacuna, provavelmente devido à ausência de dados reais de operação, quanto à geração automática de regras. Utilizando-se os dados de operação simulados pelo ProDiMES, é possível criar um sistema *fuzzy* de diagnóstico de desempenho de turbina a gás que extraia regras automaticamente a partir de exemplos de falhas.

1.4

Estrutura do Dissertação

Este trabalho é composto por cinco capítulos. Além da introdução tem-se:

No Capítulo 2 são apresentados uma introdução sobre turbinas a gás, os principais mecanismos de degradação dos componentes de tal equipamento e uma revisão sobre os principais métodos de diagnóstico que podem ser empregados, com ênfase naqueles que foram úteis para o desenvolvimento da metodologia aqui proposta.

No Capítulo 3 é feita a descrição em detalhe da metodologia para diagnóstico de desempenho de turbinas a gás. Isto envolve a descrição da arquitetura do sistema de diagnóstico, apresentação da base de dados utilizada e as principais métricas de diagnóstico utilizada para avaliação da solução.

No Capítulo 4 são apresentados os resultados obtidos frente as métricas específicas para diagnóstico. O sistema de diagnóstico é avaliado quanto a sua interpretabilidade linguística, quanto a falhas em componentes, sensores e atuadores, falhas de taxa de evolução abrupta e rápida e falhas com diferentes níveis de severidade. Por fim, os resultados são comparados com a literatura.

No Capítulo 5 são feitas conclusões e recomendações para trabalhos futuros.

2

Turbinas a Gás e Diagnóstico de Falhas

2.1

Turbinas a Gás

Turbinas a gás são turbomáquinas térmicas que atuam como elementos motores, usadas preferencialmente em aplicações em que energia mecânica é necessária, como, por exemplo, em indústrias de geração de energia, óleo e gás e na propulsão aeronáutica, naval e automotiva, pois apresentam (BARBOSA, 2010; BOYCE, 2011; LARSSON, 2014; PINTO, 2015; SARAVANAMUTTOO; ROGERS; COHEN, 2001):

- Baixa razão peso-potência;
- Robustez (poucas partes móveis, rotação em uma direção, níveis de vibração aceitáveis);
- Alta confiabilidade;
- Baixo consumo de óleo lubrificante;
- Independência de fontes de água;
- Inexistência de fluidos de trabalho intermediário;
- Baixa emissão de monóxido de carbono (CO);
- Flexibilidade de combustível.

Além disso, o calor desperdiçado nos gases de exaustão pode ser recuperado em uma configuração de ciclo combinado (SARAVANAMUTTOO; ROGERS; COHEN, 2001).

O desenvolvimento de turbinas a gás iniciou-se pouco antes da Segunda Guerra Mundial. Inicialmente, todo o esforço era voltado para produção de energia, embora sua baixa eficiência as tornassem pouco atrativas frente às turbinas a vapor e aos geradores diesel. Assim, a atenção foi direcionada para propulsão aeronáutica, campo em que as turbinas a gás provocaram grande impacto, principalmente pela sua característica de baixa razão peso-potência. Atualmente, com a evolução da aerodinâmica e da metalurgia, é possível construir

compressores mais eficientes (razão de compressão de 35:1 e eficiência de 85-90%) e turbinas que suportam temperatura de 1650 K em sua entrada. Tais características tornaram as turbinas a gás muito competitivas, inclusive para produção de energia.

O princípio de funcionamento de turbinas a gás é regido pelo ciclo Brayton. Esse trabalho não se aprofundará na análise termodinâmica e modelagem de turbinas a gás. Para maiores detalhes, vide (BOYCE, 2011; SARAVANAMUTTOO; ROGERS; COHEN, 2001). De forma simplificada, o processo de geração de energia mecânica na turbina pode ser resumido da seguinte forma: o primeiro passo do ciclo da turbina a gás é a compressão do fluido de trabalho (normalmente ar atmosférico); em seguida, o fluido de trabalho tem sua temperatura elevada no combustor pela queima de combustível. Por último, a expansão do fluido de trabalho quente no expensor gera potência mecânica, que também é utilizada para acionamento do compressor, sendo o excedente usado para os fins já mencionados (SARAVANAMUTTOO; ROGERS; COHEN, 2001).

Existem diversas configurações de turbinas a gás, que são função do tipo de aplicação. Embora o princípio geral de funcionamento de todas as turbinas seja o mesmo, pode-se dividi-las em dois grupos principais: turbina a gás aeronáutica e turbina a gás industrial. O primeiro grupo é usado para propulsão aeronáutica, enquanto o segundo grupo inclui todos os demais tipos de turbinas a gás. Essa distinção é feita por três motivos principais: (i) turbinas a gás industriais necessitam ser mais robustas, de forma que o seu tempo de vida útil é muito maior do que o de turbinas aeronáuticas; (ii) restrições de tamanho e peso para a área de aviação são muito maiores do que para qualquer outra área; (iii) a turbina aeronáutica utiliza a energia cinética dos gases de exaustão expelidos, enquanto que em outras aplicações de ciclo simples esta energia é desperdiçada.

Para aplicações industriais destacam-se as turbinas conhecidas como *heavy duty* e as aeroderivativas. As turbinas *heavy duty*, numa configuração de ciclo simples, podem atingir até 480MW e sua eficiência varia de 30 a 40%. Também apresentam alta robustez, baixo custo, alta confiabilidade e maior flexibilidade de combustível. As aeroderivativas, como o próprio nome o diz, são turbinas derivadas de motores aeronáuticos adaptadas para geração de energia. Normalmente apresentam potência de 2.5 MW até 50 MW e eficiência variando

de 35 a 45%; sua principal vantagem frente às *heavy duty* é a menor razão peso-potência.

Este trabalho faz uso do software ProDiMES para simulação de dados de operação com falhas em turbinas aeronáutica do tipo turbofan, mas, como o princípio de funcionamento de qualquer turbina a gás é o mesmo, a metodologia aqui proposta pode ser facilmente estendida para outros tipos de turbinas a gás.

2.2

Causas Típicas de Degradação em Turbinas a Gás

Degradação pode ser definida como um aumento de perdas de desempenho da turbina a gás. Na prática, a degradação nos componentes da turbina reflete-se no desempenho de todo o sistema na forma de perda de potência e aumento do consumo de combustível.

Alguns processos de degradação são parcialmente recuperáveis, como, por exemplo, depósito de material nas palhetas do compressor ou *fouling* no compressor. Outros são irre recuperáveis, pois sua correção se dá através da substituição de peças.

Normalmente, como pode ser visto na Figura 1, dividem-se os mecanismos de degradação em degradação gradual do desempenho ou degradação natural e degradação por eventos de falha. Degradação natural é causada por fenômenos como erosão, corrosão e *fouling*, e apresentam baixa taxa de evolução temporal. Degradação por eventos de falha se caracteriza pela imprevisibilidade e por mudanças rápidas no perfil de desempenho da turbina.

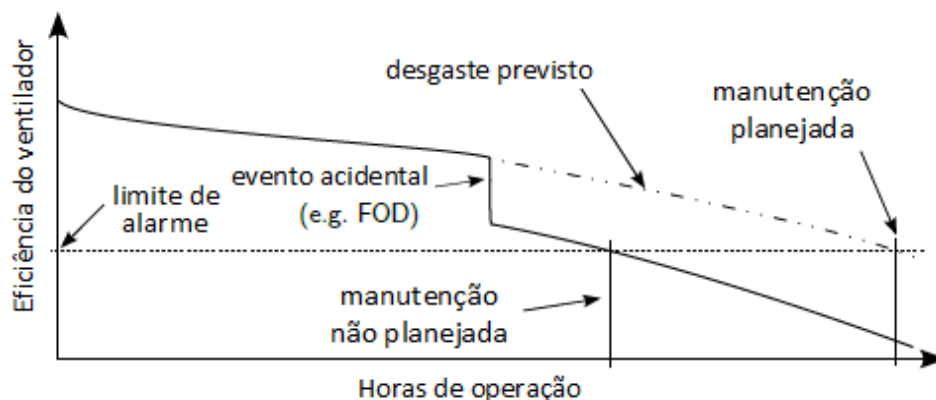


Figura 1 – Degradação da eficiência do ventilador de uma turbina a gás em função do tempo (BORGUET, 2012).

Apesar da característica contínua, os mecanismos envolvidos no processo de degradação natural não são determinísticos, pois são influenciados por fatores como uso, ambiente e tempo. No entanto, toda turbina está sujeita a este tipo de degradação.

Eventos de acidentes/falhas podem ter inúmeras causas, mas em todos os casos são imprevisíveis, prejudicando todo o planejamento da manutenção. Esta característica pode ser facilmente visualizada na Figura 1, onde a eficiência do ventilador é função do número de horas de operação. O planejamento da manutenção preventiva é baseado na média de degradação natural do equipamento, mas, como ocorre um evento de falha, o equipamento atinge as condições de manutenção antes do planejado.

Abaixo serão descritos os principais mecanismos de degradação dos componentes de turbinas a gás:

Depósito de Material nas Palhetas do Compressor

O *Compressor Fouling* é o acúmulo de depósitos sobre as palhetas que causa redução na área de escoamento, mudança no perfil aerodinâmico e desbalanceamento do rotor, com reflexos consideráveis no desempenho da turbina. É uma das causas mais comuns de degradação do desempenho de turbinas a gás e representa mais de 70% de toda a perda de desempenho acumulada durante o tempo de vida útil destes equipamentos. Segundo (ALKMIN FREIRE; BARBOSA, 2013), as perdas totais podem chegar a 2%, em condições favoráveis, e de 15 a 20% em condições adversas. Seus impactos consistem, primeiramente,

na redução da vazão mássica e diminuição da razão de pressão do compressor, resultando em redução da potência, aumento do *heat rate* e uma leve mudança de eficiência. Essas mudanças no comportamento do equipamento refletem-se também, ainda que indiretamente, em alterações no consumo de combustível, na temperatura de exaustão e nas emissões (DIAKUNCHAK S., 1992; OGAI et al., 2002). A Figura 2 ilustra o depósito de partículas de sal nas palhetas do compressor.



Figura 2 – Depósito de sal nas palhetas do compressor (KURZ; BRUN, 2012).

O ar ingerido pelo compressor contém poeira, fuligem, umidade na forma de vapor, óleo de rolamentos, pólen, sal, etc. Embora existam filtros modernos na entrada, partículas da ordem de 2 a 10 μm de diâmetro podem entrar e se depositar no compressor causando os efeitos já mencionados.

Existe um limite para o depósito de material nas palhetas do compressor, determinado pelas forças aerodinâmicas que previnem depósitos adicionais. A lavagem do compressor, seja ela *online* ou *off-line*, é uma forma de atenuar os efeitos do *fouling*. A recomendação é que a limpeza seja realizada quando a vazão mássica cai entre 2 - 3% em relação à operação normal (KURZ; BRUN, 2012; ROUMELIOTIS et al., 2012; ROUPA et al., 2013; YANG; XU, 2014).

Corrosão

Reações químicas entre contaminantes, ar, combustível, água e vapor ao longo do caminho do gás também provocam perda de material dos componentes da turbina a gás. Este processo é chamado de corrosão e está ilustrado na Figura 3.

É mais comum na parte quente da turbina, onde sua causa típica se dá através da presença de enxofre, oriundo do combustível, e cloreto de sódio, presente no ar, resultando em sulfato de sódio (ALKMIN FREIRE; BARBOSA, 2013; OGAI et al., 2002).

Corrosão no compressor reduz a sua vazão mássica e eficiência. Similarmente, corrosão na turbina resulta em aumento da vazão mássica e redução da eficiência. Nos dois casos é notável a diminuição da eficiência global do equipamento. Como esta falha consiste na remoção de material dos componentes ao longo do caminho do gás, sua correção é possível apenas pela substituição dos componentes afetados (ALKMIN FREIRE; BARBOSA, 2013).




Figura 3 – Corrosão numa palheta de compressor (MONTEIRO, 2010).

Erosão

A Figura 4 mostra um exemplo de erosão na palheta de uma turbina. Esta degradação é causada pelo impacto de partículas nos componentes ao longo do caminho do gás. As partículas com potencial para causar erosão têm diâmetro de 20 μm ou maior e geralmente são poeira, areia, cinza vulcânica, sal, fuligem e resíduos de carbono (combustão incompleta).

Segundo (ALKMIN FREIRE; BARBOSA, 2013), a erosão causa as seguintes mudanças:

- Perfil aerodinâmico, folgas no topo das palhetas do rotor (*tip clearance*) e ângulos de incidência;
- Rugosidade das superfícies;
- Folgas em labirintos de selagem;
- Área da secção transversal dos estágios.

Estas modificações reduzem o desempenho da turbina a gás. Similarmente à degradação causada por corrosão, sua correção é feita pela substituição dos componentes afetados. No entanto, a erosão normalmente afeta toda a região ao longo do caminho do gás, deixando sem recuperação um percentual da degradação.




Figura 4 – Erosão particulada em palheta de turbina (FLEMING et al., 2014).

Folga no Topo das Palhetas do Rotor (*Tip Clearance*)

Fenômeno típico de máquinas de fluxo axial como turbinas e compressores axiais, a instabilidade é provocada pela distribuição não uniforme da folga da selagem no topo das palhetas. Isso provoca um diferencial na força axial do fluido sobre o rotor, gerando a componente desestabilizadora conhecida como “força de Alford” (MONTEIRO, 2010). Este fenômeno leva a uma diminuição da eficiência e da capacidade de bombeamento no compressor e do aproveitamento energético no expensor, influenciando a eficiência e a capacidade de vazão: um aumento de 0,8% na folga, para um compressor axial, leva a uma redução de 3% na vazão e a uma redução de 2% na eficiência. A eficiência é mais sensível ao *tip clearance* do que ao *fouling* (OGAJI et al., 2002).

Danos Causados por Objetos Domésticos ou Estranhos

Objetos que, por qualquer razão, são admitidos na turbina colidem com suas partes ao longo do caminho do gás, provocando danos. Se a origem do objeto é interna, como a formação de gelo no sistema de admissão de ar e o desprendimento de peças internas, a falha é classificada como Danos Causado por Objeto Doméstico (*Domestic Object Damage – DOD*). No caso de objetos de

origem externa, como na sucção de pássaros (Figura 5) por uma turbina a gás aeronáutica, a falha é classificada como Dano Causado por Objeto Estranho (*Foreign Object Damage – FOD*).



Figura 5 – Risco de Danos Causados por Objetos Estranhos na indústria aérea.

Até o momento foram apresentadas uma introdução às turbinas a gás e as causas típicas de degradação nestes equipamentos. A próxima seção se trata de um breve resumo sobre as principais técnicas utilizadas para a solução do problema de diagnóstico de turbinas a gás.

2.3

Diagnóstico de Falhas

Como dito anteriormente, a literatura de diagnóstico de desempenho de turbinas é vasta, sendo desnecessário fazer uma pesquisa exaustiva sobre o tema. Uma revisão sobre as principais técnicas aplicadas, estratégias de manutenção e programas CBMs são apresentados em (JARDINE; LIN; BANJEVIC, 2006; JAW, 2005; LI, 2002; LOBODA, 2010; MARINAI, 2004; MARTIN, 1994). O objetivo desta seção é fornecer uma visão geral sobre a tendência que o diagnóstico de desempenho vem seguindo.

O monitoramento da saúde de turbinas a gás depende do armazenamento e processamento de dados do motor para detectar e isolar falhas. Dado as inúmeras disciplinas envolvidas no processo de operação e projeto de turbinas, tais como aerodinâmica, termodinâmica, mecânica, mecânica dos fluidos e química, o diagnóstico destes equipamentos é dividido em (BORGUET, 2012):

- Monitoramento do óleo e partículas: detecta tamanho e quantidade de partículas que possam representar desgaste excessivo ou fadiga dos componentes da turbina, tais como caixas de engrenagens e mancais;
- Monitoramento de vibrações: interessa-se em descobrir possíveis desbalanceamentos causados por falhas em partes móveis;
- Monitoramento da vida útil: trata-se do cálculo do nível de desgaste e predição do tempo de vida útil dos componentes da turbina;
- Monitoramento do desempenho: também conhecido como análise do desempenho, depende de grandezas mensuráveis ao longo do caminho do gás para inferir problemas de desempenho nos componentes da turbina.

Apesar de existirem poucos trabalhos na literatura, há o consenso de que, para se ter uma ferramenta de diagnóstico extremamente eficiente, deve-se combinar os resultados das diversas técnicas em uma abordagem conhecida como fusão de informação ou fusão de dados (BORGUET, 2012). Abaixo, com exceção da Lógica Fuzzy – já apresentada na seção Motivação –, apresentam-se as principais metodologias de diagnósticos de desempenho de turbinas a gás:

Análise do Desempenho de Turbinas a Gás (GPA – *Gas Path Analysis*)

A análise do desempenho (*Gas Path Analysis* - GPA) é assim denominada porque são coletadas informações sobre a condição de operação como, por exemplo, pressão, temperatura, consumo de combustível, rotação, potência, etc., ao longo da turbina a gás, sendo o fluido de trabalho acompanhado desde o duto de entrada, passando pelo(s) compressor(es) até a sua saída no duto de exaustão, após a turbina de baixa pressão (MONTEIRO, 2010).

O trabalho pioneiro nesse campo foi apresentado por (URBAN, 1973), que hoje é conhecido como análise do caminho do gás linear e assumia que o modelo era acurado, sem ruído e um problema bem formulado, pois o número de parâmetros de desempenho era menor ou igual ao número de parâmetros medidos. A seguir, será explicado a versão linear da análise do caminho do gás e em seguida sua versão não linear:

- LGPA – *Linear Gas Path Analysis*

A relação entre os parâmetros dependentes da turbina a gás (temperatura, pressão, vazão mássica, etc.) e os parâmetros independentes (razão de pressão, vazão volumétrica e eficiência dos componentes) é não linear (LI, 2002). Uma primeira abordagem para este problema supõe que mudanças nos parâmetros de desempenho (independentes) são relativamente pequenas, sendo assim possível linearizar, por meio de uma série de Taylor em torno de um ponto em regime permanente de operação, o conjunto de equações que governa o sistema. Estas equações linearizadas são expressas em forma de matriz. O conjunto de M variações de medições Δz é expresso como uma combinação linear de N variações nos parâmetros de desempenho Δx .

$$\Delta z = H \cdot \Delta x \quad (1)$$

A matriz H é conhecida como matriz de coeficientes de influência, ICM (*Influence Coefficient Matrix*). Esta abordagem do problema leva a uma solução simples:

$$\Delta x = H^{-1} \cdot \Delta z \quad (2)$$

A matriz H^{-1} é referenciada como matriz de coeficientes de falha (FCM - *Fault Coefficient Matrix*). Esta metodologia supõe que ICM é inversível e que não há ruídos nas medições. No entanto, inverter a ICM requer que o número de parâmetros de desempenho seja menor ou igual ao número de medições ($N \leq M$). Esta condição é, às vezes, difícil de ser satisfeita devido ao número limitado de medições disponíveis (MARINAI; PROBERT; SINGH, 2004).

- NLGPA – *Non-Linear Gas Path Analysis*

Uma maneira de melhorar a precisão das estimativas é tratar de resolver a relação não linear entre os parâmetros considerados saudáveis e os valores obtidos das medições usando um processo iterativo, tal como descrito resumidamente em (OGAJI et al., 2002). Neste processo iterativo, uma aproximação linear é empregada recursivamente e uma solução exata é obtida pela técnica de Newton-Raphson. Essencialmente, uma ICM é gerada levando em consideração uma pequena deterioração do desempenho dos componentes e é invertida para calcular o vetor de variações nos parâmetros de desempenho dos componentes. A partir dos resultados calculados, uma nova ICM é gerada e o processo é recursivamente

repetido até que um critério de convergência que minimiza o erro (diferença entre valor medido e estimado) seja atingido, ou o processo é interrompido depois de um determinado número de interações (MARINAI; PROBERT; SINGH, 2004).

Redes Neurais Artificiais

As Redes Neurais Artificiais (RNAs) são paradigmas de processamento inspirados no sistema nervoso biológico. São modelos que tentam imitar o cérebro humano, desenvolveram-se desde elementos de processamento simples até redes de processamento massivamente paralelas e tem sido efetivas na solução de problemas complexos (SAMARASINGHE, 2006).

Assim, uma RNA consiste da junção de elementos de processamento simples conectados em uma estrutura complexa de rede que permite o modelo aproximar funções não lineares de uma ou mais entradas e uma ou mais saídas. O elemento de processamento é um nó e vários pesos, através dos quais a RNA é capaz de aprender uma função desconhecida, seguindo um algoritmo de aprendizado que ajusta os pesos da rede.

Diferentes tipos de redes neurais têm sido utilizados em tarefas de diagnóstico, incluindo redes de treinamento supervisionado e não-supervisionado. Os principais tipos de redes são: perceptron multicamadas (*multilayer perceptron* – *MLP*), redes neurais probabilísticas (*probabilistic neural networks* – *PNN*), redes auto-organizáveis (*self-organizing maps* – *SOM*), redes RBF (*radial basis function*), entre outras (OGAJI et al., 2002).

Segundo (MARINAI, 2004), o uso de RNA em diagnóstico de turbinas a gás apresenta as seguintes vantagens:

- RNAs são treinadas com dados de operação. Isso as tornam adequadas para problemas em que não existe solução exata, mas existe um grande número de exemplos;
- RNAs são capazes de responder corretamente a casos ausentes na etapa de treinamento, pois têm grande capacidade de generalização;
- RNAs lidam bem com a natureza não linear dos problemas de diagnóstico de desempenho de turbinas a gás.

E limitações:

- Necessitam de uma grande quantidade de dados de falhas no processo de treinamento, pois a RNA é incapaz de trabalhar confortavelmente fora do intervalo para o qual foi treinada;
- Mesmo dependendo da configuração da RNA, como tipo, tamanho e quantidade de dados de treinamento, normalmente o processo de aprendizagem da rede é longo;
- Pode-se dizer que RNAs são modelos do tipo “caixa-preta”, pois são incapazes de fornecer respostas interpretáveis.

Alguns dos trabalhos recentes que usam RNAs são: em (TAYARANI-BATHAIE; VANINI; KHORASANI, 2014) uma Rede Neural Dinâmica (RND) é usada para diagnóstico de falhas de uma turbina a gás com dinâmica altamente não linear. A RND é construída com base em redes MLP que usam filtros de respostas de impulso infinito para geração da dinâmica entre entrada e saída dos neurônios e, conseqüentemente, da rede inteira. A RND treinada é então usada para detecção e isolamento de componentes com falhas típicas de turbinas a gás de dois eixos.

Em (PENG et al., 2012), é apresentada uma abordagem para estimação de vida útil de turbinas aeronáuticas usando *Echo State Network* (ESN). Os autores sugerem que ESNs obtêm melhores resultados quando combinadas com Filtro de Kalman. Trabalhos semelhantes são apresentados em (PEEL; GOLD, 2008), usando MLP e RBF para regressão, juntamente com Filtro de Kalman que provê mecanismos para fusão de múltiplas redes neurais no tempo; e em (HEIMES; SYSTEMS, 2008), que faz uso de redes neurais recorrentes (RNRs) treinadas com algoritmos de retropropagação através de cálculos de gradientes no tempo, Filtro de Kalman estendido e algoritmos evolucionários para geração de um modelo mais compacto e acurado.

Em (SIMON et al., 2013), os autores desenvolveram um software de simulação de falhas – ProDiMES (*Propulsion Diagnostic Method Evaluation Strategy*) – para estabelecer uma referência que possibilite uma fácil comparação entre os diferentes métodos de diagnóstico de desempenho de turbinas a gás. Para demonstrar a eficácia do software, quatro métodos de diagnósticos são aplicados ao problema: Mínimos Quadrados Ponderados, Redes Neurais Probabilísticas, uma Ferramenta de Análise de Desempenho baseada em Filtro de Kalman e um Observador/Estimador Genérico para Isolamento de Falha Única.

Sistemas Especialistas

Sistemas Especialistas são programas que simulam especialistas humanos em um campo específico do conhecimento. Geralmente são formados por uma base de conhecimento contendo a experiência acumulada do especialista em um assunto e uma base de regras para aplicação do conhecimento em problemas particulares. As regras são formadas por sentenças SE-ENTÃO, geradas a partir de experiências heurísticas de um ou mais especialistas. Para ser confiável, uma base de conhecimento deve ser tão completa e acurada quanto possível. Em outras palavras, cada conjunto de entrada necessita de apenas uma saída e deve haver uma saída para todas as combinações possíveis de entrada. Esse fato provoca, em alguns casos, explosão combinatória do número de regras. Quanto maior o número de entradas e saídas, maior o número necessário de regras para abranger o campo de conhecimento modelado. Estas regras devem ser criadas e testadas de forma consistente, a base de conhecimento precisa ser atualizada à medida que novos conhecimentos são incorporados ou quando o sistema modelado se altera. Estes problemas podem ser amenizados pelo emprego da Lógica *Fuzzy*.

O tipo de SE mais popular para diagnóstico de turbina a gás aquele baseado em regras e conhecimento do especialista. Alguns exemplos são TEXMAS, para motores Lycoming T53, HELIX, para turbinas de helicópteros e SHERLOCK, para motores de helicópteros (KONG, 2014).

A maioria dos trabalhos relacionados a SE na literatura é antigo, como o trabalho de (DEPOLD; GASS, 1998b), que apresenta as seguintes características: (i) aplicação de filtros de análise estatística e redes neurais artificiais para melhorar a qualidade dos dados; (ii) redes neurais para detecção de mudanças de tendências de séries históricas e detecção de mudanças de desempenho; (iii) SE para diagnóstico, alertas e recomendações de ações de manutenção. Entre os trabalhos mais recentes, pode-se citar (ZHAO et al., 2014), que apresenta um SE de diagnóstico e prognóstico de falhas para turbinas a gás marítimas. É feita ainda uma introdução às principais características e aplicações de SE para diagnóstico e prognóstico, tomando como exemplo um sistema de combustível de turbina a gás para testar a capacidade e principais funções do modelo proposto. Em (KOPYTOV; LABENDIK; YUNUSOV, 2009), são apresentados tipos de sistemas de diagnósticos que podem ser usados para o desenvolvimento de um SE aplicado a diagnóstico de turbina a gás aeronáutica.

3

Diagnóstico de Desempenho de Turbinas a Gás usando Lógica *Fuzzy*

3.1

Introdução

Modificações na saúde dos componentes descritas no capítulo anterior não podem ser diretamente medidas (não há sensores para *fouling* ou erosão, por exemplo) nem podem ser detectadas sem uma inspeção profunda da turbina (inspeção boroscópica). O propósito de um sistema de diagnóstico de desempenho de turbina a gás é detectar, isolar e quantificar mudanças de desempenho nos módulos da turbina com base em medições ao longo do caminho do gás.

Esta abordagem pode ser vista como relativa, pois, ao invés de prever mudanças diretamente nos fenômenos físicos que governam as falhas, tais como *fouling* e erosão, as mudanças são previstas nos parâmetros de desempenho como eficiência e capacidade de vazão nos componentes. A análise de desempenho permite comparar a evolução da degradação em cada componente da turbina em relação a uma referência saudável. Assim, o princípio de funcionamento físico do sistema de diagnóstico apresentado neste trabalho e representado na Figura 6 leva em consideração as seguintes hipóteses:

- O estado de saúde dos componentes rotativos (Fan, LPC, HPC, HPT e LPT) pode ser representado por um conjunto de indicadores de desempenho independentes, denotados por parâmetros de saúde, que são tipicamente coeficientes de correção da capacidade de vazão e eficiência;
- Problemas físicos experimentados pelos componentes da turbina induzem modificações no seu desempenho que, por sua vez, refletem em mudanças nas medições ao longo do caminho do gás (temperaturas, pressões, rotações, etc.).




Figura 6 – Princípio de funcionamento de diagnóstico de desempenho de turbinas a gás (URBAN, 1973).

Conforme destacado em (BORGUET, 2012; MARINAI, 2004; MARINAI; PROBERT; SINGH, 2004), existem três problemas principais que podem dificultar o processo de diagnóstico de desempenho: (i) o comportamento de turbinas a gás é não-linear tanto para os parâmetros de saúde quanto para as condições de operação; (ii) as medições e informações, que são entradas para o sistema de diagnóstico, vêm normalmente acompanhadas de erros causados por ruídos, erros sistemáticos (*bias*) e incertezas; (iii) o número de sensores pode ser insuficiente para o correto mapeamento da relação entre falha e sintoma (medições); por exemplo: uma falha pode provocar o sintoma de alterar apenas uma temperatura, mas se não houver medição desta grandeza, detectar tal falha torna-se impraticável.

3.2

Base de Dados – ProDiMES

Como dito na seção Objetivo do Capítulo 1, algoritmos para diagnóstico de desempenho de turbinas a gás necessitam, para seu completo desenvolvimento e validação, ter acesso a dados de operação e modelos da turbina. Pelas vantagens já apresentadas, os dados deste trabalho foram gerados pelo software ProDiMES (SIMON, 2010), tornado disponível gratuitamente desde agosto de 2009 pelo departamento de pesquisa *Glenn Research Center* da NASA. O software foi programado em MATLAB e tem como objetivo permitir a comparação entre diferentes métodos de diagnóstico de desempenho de turbinas a gás aeronáuticas.

A arquitetura do ProDiMES, ilustrada na Figura 7, inclui uma interface GUI (*Graphical User Interface*) que permite especificar entradas como número de turbinas, número de ocorrências de cada falha, número de voos simulados por

turbina, voo do surgimento da falha, taxa de evolução da falha e geração dos dados com e sem ruídos. Contém um simulador de frota de turbinas a gás aeronáuticas do tipo turbofan e rotinas com diversas métricas de diagnóstico. A simulação da turbina, genérica do tipo turbofan, ilustrada na Figura 8, é realizada com o software C-MAPS-SS (*Commercial Modular Aeropropulsion System Simulation Steady-State*), também da NASA, que emula a aquisição de dados da instrumentação, fornecendo histórico dos parâmetros monitorados ao longo do caminho do gás, como pressão, temperatura e rotação.

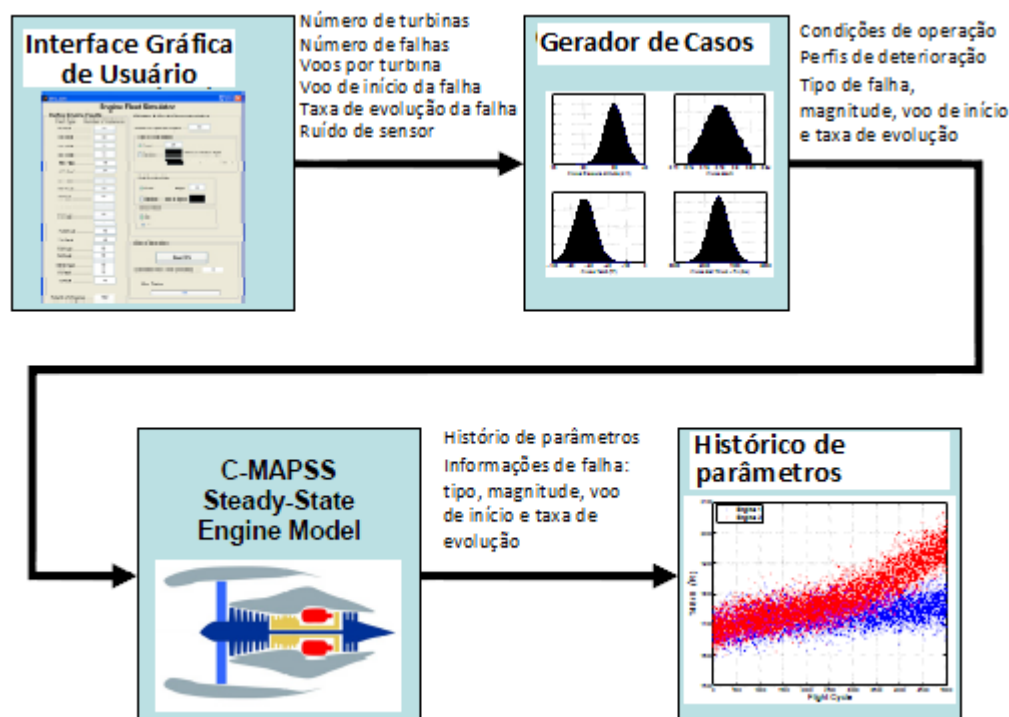


Figura 7 – Arquitetura ProDiMES (SIMON et al., 2008b).

Os dados são fotografias do estado da turbina, para cada voo, em condição de cruzeiro e decolagem. A Tabela 1 lista o conjunto de medições, sendo oito ao longo do caminho do gás e três condições de operação. O posicionamento dos sensores pode ser visto na Figura 8. Na Figura 7, o módulo *Case Generator* garante o realismo físico da simulação por meio da inclusão de variações estocásticas em condições de voo, configurações de potência e ruídos em sensores. Variações aleatórias em níveis de deterioração do desempenho da turbina também são incluídas, emulando causas naturais de deterioração como erosão, corrosão, *fouling* e folgas que toda turbomáquina está sujeita ao longo de

sua vida útil. Como a degradação natural não pode ser evitada, o foco do sistema de diagnóstico de desempenho de turbinas a gás aqui proposto é detectar os eventos de falha que, como mostrado na Figura 1, apresentam taxa de evolução rápida e são imprevisíveis. A degradação natural, por outro lado, é previsível, ficando ao encargo do planejamento de manutenção preventiva minimizar seus impactos no desempenho do equipamento.

Tabela 1 – Sensores emulados pelo ProDiMES (SIMON et al., 2013).

Index	Símbolo	Descrição
1	N_f	Velocidade do ventilador
2	N_c	Velocidade do eixo principal
3	P_{24}	Pressão total na saída do LPC
4	T_{24}	Temperatura total na saída do LPC
5	P_{s30}	Pressão estática na saída do HPC
6	T_{30}	Temperatura total na saída do HPC
7	T_{48}	Temperatura total na saída do HPT
8	W_f	Vazão de combustível
9	P_2	Pressão total na entrada do ventilador
10	T_2	Temperatura total na entrada do ventilador
11	P_{amb}	Pressão ambiental




Figura 8 – Representação do motor genérico turbofan simulado pelo ProDiMES com as estações de medição, módulos e sensores (SIMON, 2010).

Para a geração dos dados de operação e dos perfis de deterioração de cada turbina, o módulo *Case Generator* também é responsável por definir o tipo de falha, seu voo de início, sua severidade e sua taxa de evolução. Um resumo com os tipos de falhas e suas respectivas distribuições uniformes de severidade está disponível na Tabela 2. Falhas de componentes (Fan, LPC, HPC, HPT e LPT) são simuladas ajustando-se simultaneamente a eficiência, η , e a capacidade de vazão, γ , parâmetros de desempenho do componente. Também são mostrados na Tabela 2 a razão de distribuição uniforme dos parâmetros de desempenho de capacidade de vazão e eficiência e o desvio padrão, α , para partida e decolagem, usado para simulação de ruídos e de falhas em sensores.

Tabela 2 – Tipos de falhas simuladas pelo ProDiMES.

ID da Falha	Falha	Severidade	Falha γ : η razao	α para decolagem	α para cruzeiro
0	Saudável	---	---	---	---
1	Fan	1 a 7%	1 a 2	---	---
2	LPC	1 a 7%	1 a 2	---	---
3	HPC	1 a 7%	1 a 2	---	---
4	HPT	1 a 7%	-0.5 a -1	---	---
5	LPT	1 a 7%	-0.5 a -1	---	---
6	VSV	1 a 7%	---	---	---
7	VBV	1 a 7%	---	---	---
8	Nf	± 1 a 7% α	---	5.59 rpm	4.64 rpm
9	Nc	± 1 a 7% α	---	15.10 rpm	13.23 rpm
10	P15	± 1 a 7% α	---	0.042 psia	0.013 psia
11	P24	± 1 a 7% α	---	0.054 psia	0.016 psia
12	Ps30	± 1 a 7% α	---	0.889 psia	0.220 psia
13	T24	± 1 a 7% α	---	1.01 ° R	0.82 ° R
14	T30	± 1 a 7% α	---	2.47 ° R	1.92 ° R
15	T48	± 1 a 7% α	---	10.20 ° R	7.55 ° R
16	Wf	± 1 a 7% α	---	0.058 pps	0.011 pps
17	P2	± 1 a 7% α	---	0.023 psia	0.008 psia
18	T2	± 1 a 7% α	---	0.838 ° R	0.707 ° R

Maiores detalhes sobre o software ProDiMES e explicações aprofundadas de como as falhas são simuladas podem ser encontrados em (SIMON, 2010; SIMON et al., 2008a, 2013).

3.3

Arquitetura do Sistema de Diagnóstico de Desempenho de Turbinas a Gás

A Figura 9 mostra a arquitetura do sistema de diagnóstico de desempenho de turbinas a gás proposta neste trabalho. O processo começa pela geração dos dados pelo software ProDiMES, responsável por emular a aquisição de dados oriundos da instrumentação de turbinas com e sem falhas em vários pontos de operação, diferentes níveis de deterioração e conhecimento da condição de falha. Esses dados são então encaminhados para o módulo de pré-processamento, responsável por corrigir, gerar os resíduos, filtrar e normalizar os dados. Em seguida, os dados pré-processados passam pelo módulo de detecção e isolamento de falhas que, no caso de treinamento, gera automaticamente as regras *fuzzy* via método de Wang-Mendel, tanto para o problema de detecção quanto para o isolamento de falhas. No caso de teste, as regras previamente geradas são carregadas e o sistema de diagnóstico prediz o estado de saúde da turbina, avaliando as regras de detecção de falhas e, caso haja falha, as de isolamento de falhas. O processo é finalizado armazenando-se os resultados.

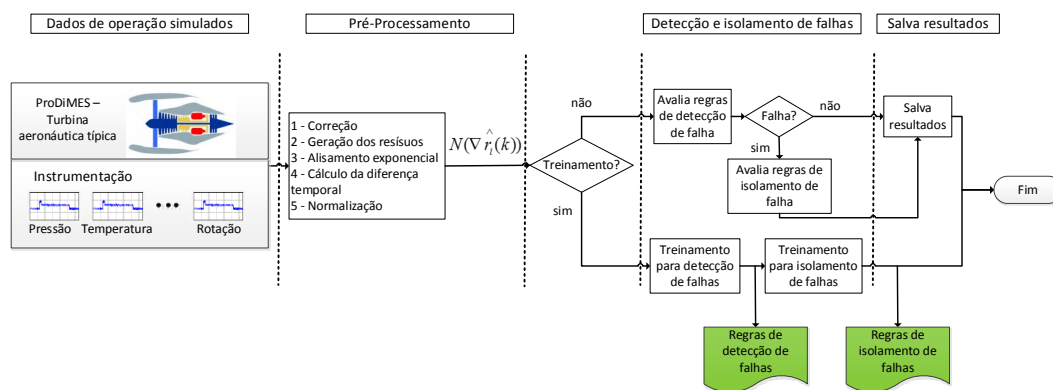


Figura 9 – Fluxograma da metodologia proposta.

O módulo de geração dos dados foi abordado na seção anterior, em conjunto com o funcionamento do ProDiMES. Os módulos de pré-processamento e detecção e isolamento de falhas serão detalhadamente abordados nas seções seguintes.

3.4

Pré-processamento

Pré-processamento de dados é uma tarefa comum no campo de IC, Aprendizado de Máquina e Mineração de Dados. Trata-se de qualquer método que recebe os dados brutos e os prepara para análise futura. No caso da Figura 10, o pré-processamento de dados por meio das etapas de correção, cálculo do resíduo, filtragem, cálculo da diferença e normalização, coloca os dados em um formato mais adequado ao módulo de detecção e isolamento de falhas. Os procedimentos realizados nessa etapa tendem a melhorar consideravelmente os resultados finais.

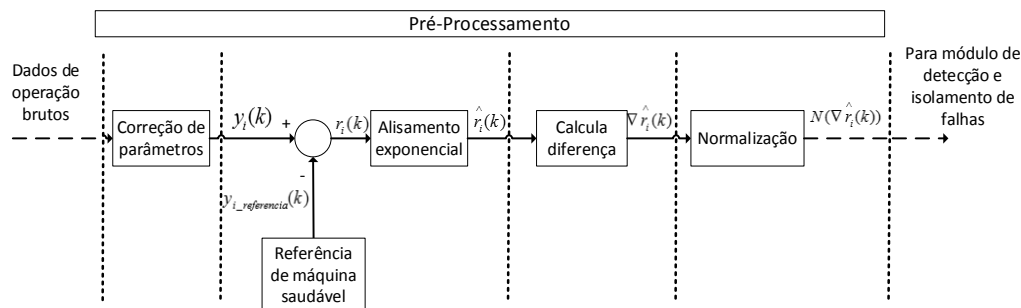


Figura 10 – Etapas do módulo de pré-processamento dos dados.

3.4.1

Correção

Os parâmetros presentes ao longo do caminho do gás – temperaturas, pressões, vazões e rotações – variam não apenas com o patamar de potência, mas também com as condições ambientais. Uma vez que mudanças em parâmetros de entrada como pressão e temperatura provocam mudanças nos valores ao longo do caminho do gás, a caracterização das relações aerotermodinâmicas entre os parâmetros do motor torna-se difícil se as condições ambientais não forem consideradas. Esse problema é usualmente resolvido através da correção dos parâmetros do motor (VOLPONI, 1998).

Dentro do contexto de diagnóstico, a correção de todos os parâmetros do motor é um passo inicial no pré-processamento e permite a comparação, em condições de operação diferentes, dos dados que serão usados em análise futura.

Segundo (SIMON, 2010; VOLPONI, 1998), a correção dos parâmetros ao longo de uma turbina é realizada por:

$$Parâmetro_{corrigido} = \frac{Parâmetro}{\theta^a \delta^b} \quad (3)$$

onde os termos de correção de temperatura e pressão, θ e δ respectivamente, são definidos como:

$$\theta = \frac{T2(^{\circ}R)}{518.67} \quad (4)$$

$$\delta = \frac{P2(psia)}{14.696} \quad (5)$$

É correto fazer uso de qualquer condição de pressão e temperatura ambiental como referência; no entanto, o mais comum é usar a condição ISA (*International Standard Atmosphere*) em que $T2=518.67^{\circ}R$ ($15^{\circ}C$) e $P2=16.696$ psia (101.325 kPa).

Os valores para a e b na equação (3) variam de acordo com o tipo e ciclo do motor, mas há valores clássicos presentes na literatura que são boas aproximações e usados na prática para turbinas a gás. A Tabela 3 apresenta os principais parâmetros ao longo do caminho do gás e suas correções para condições padrão.

Tabela 3 – Principais parâmetros para turbinas a gás e suas correções (SIMON, 2010).

Parâmetro	a	b	Parâmetro corrigido
Nf	0.5	0	$Nf_c = \frac{Nf}{\sqrt{\theta}}$
Nc	0.5	0	$Nc_c = \frac{Nc}{\sqrt{\theta}}$
$P24$	0	1	$P24_c = \frac{P24}{\delta}$
$Ps30$	0	1	$Ps30_c = \frac{Ps30}{\delta}$
$T24$	1	0	$T24_c = \frac{T24}{\theta}$
$T30$	0.94	0	$T30_c = \frac{T30}{\theta^{0.94}}$
$T48$	1	0	$T48_c = \frac{T48}{\theta}$
Wf	0.63	1	$Wf_c = \frac{Wf}{\theta^{0.63} \delta}$

A Figura 11 e a Figura 12 mostram os dados brutos e corrigidos pela equação (3) para oito medições ao longo do caminho do gás. Embora não seja perceptível, na Figura 12 os dados correspondem a 500 ciclos de voo de uma turbina que experimentou falha no ventilador no voo de número 250, enquanto na Figura 11 a turbina permaneceu saudável durante todos os voos.

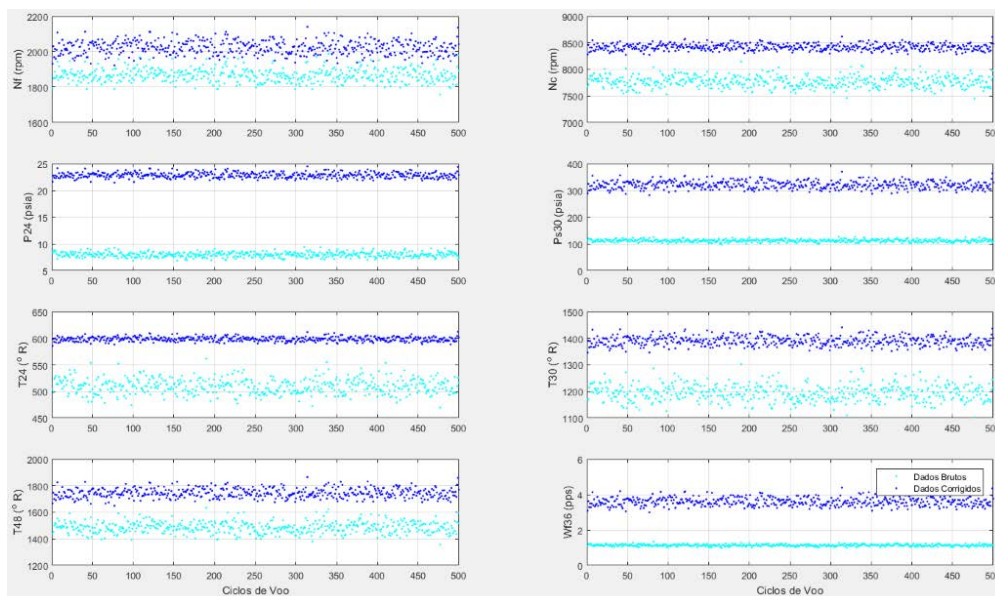


Figura 11 – Comparação entre valores corrigidos (azul) e valores brutos (ciano) para oito medições ao longo do caminho do gás em situação sem falha.

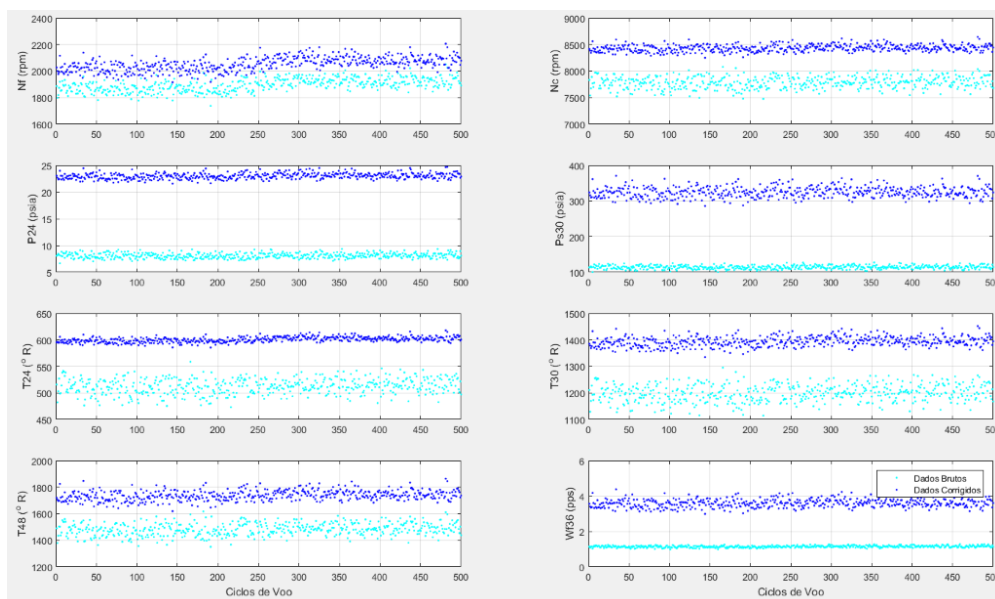


Figura 12 – Comparação entre valores corrigidos (azul) e valores brutos (ciano) para oito medições ao longo do caminho do gás em situação com falha no ventilador.

3.4.2

Geração dos Resíduos

Para a formulação do problema de uma maneira sequencial, é necessário considerar a evolução temporal dos parâmetros da saúde do motor ao longo do caminho do gás. Isso também pode ser entendido como evolução dos sintomas da falha desde o seu surgimento até a sua saturação.

O ProDiMES foi projetado de forma que as falhas podem se manifestar de duas formas: (i) gradual e (ii) abrupta. Vale frisar que todos os módulos de um motor serão afetados pela degradação natural ao longo do tempo. Isto é incluído na simulação de falhas do ProDiMES para emular causas físicas como erosão, corrosão, *fouling* e aumento de folgas às quais toda turbomáquina está sujeita. A deterioração gradual de módulos ao longo de sua vida útil não deve ser diagnosticada como falha: é uma situação natural, não pode ser evitada e apresenta baixa taxa de evolução temporal, sendo seus efeitos minimizados pela manutenção preventiva. Em contrapartida, o surgimento de uma falha abrupta ou rápida causa mudanças nítidas no perfil de desempenho do motor, indicando que algo ocorreu como resultado de uma única falha. A situação de duas falhas ao mesmo tempo não é simulada pelo ProDiMES, pois a probabilidade de ocorrência de um evento que se caracterize pelo surgimento simultâneo de duas falhas é considerada baixa.

É necessário usar uma abordagem de monitoramento de série temporal dos parâmetros da saúde do motor para capturar mudanças graduais de desempenho da turbina na forma de resíduos ou desvios de medições em relação a uma referência de máquina saudável. Esta referência foi criada simulando-se turbinas saudáveis para um envelope abrangente de operação e variando as condições ambientais e de contorno como altitude, pressão, número de Mach e velocidade do ventilador corrigida. Portanto, a referência se constitui em uma tabela com os resultados corrigidos de simulação de turbinas saudáveis para um envelope abrangente de condições de voo.

Dados coletados e corrigidos, para cada turbina em cada voo, são comparados a uma referência de máquina saudável, produzindo desvios de medição aqui tratados como resíduos $r_i(k)$, conforme:

$$r_i(k) = y_i(k) - y_{i_referencia}(k) \quad (6)$$

onde $y_i(k)$ é valor corrigido da i -ésima medição durante o k -ésimo voo e $y_{i_referencia}(k)$ é o valor de referência de máquina saudável nas mesmas condições de voo para as quais $y_i(k)$ foi coletado, ou seja, mesma altitude, pressão, número de Mach e velocidade do ventilador corrigida.

Como N_f , P_{amb} , P_2 e T_2 são usados para estabelecer as condições de operação do motor e correções dos demais parâmetros, $y_i(k)$ é calculada apenas para 7 das 11 medições disponíveis. Para suavizar a série temporal e minimizar o impacto de dados ruidosos e espúrios, um alisamento exponencial simples (AES) é aplicado aos resíduos calculados pela equação (6), conforme a equação abaixo (DEPOLD; GASS, 1998b):

$$\hat{r}_i(k) = \alpha \cdot r_i(k) - (1 - \alpha) \cdot \hat{r}_i(k-1) \quad (7)$$

onde $\hat{r}_i(k)$ é o valor residual alisado da i -ésima medição durante o k -ésimo voo e α é a constante de alisamento, $0 \leq \alpha \leq 1$. AES é uma média móvel ponderada que dá pesos maiores às observações mais recentes.

A Figura 13 e a Figura 14 mostram os valores residuais gerados pela equação (6) e os valores residuais alisados gerados pela equação (7) com $\alpha = 0.1156$. O procedimento, idêntico ao usado na Figura 11 e na Figura 12 para exemplificação da etapa de correção, abrangeu 500 ciclos de voo de duas turbinas: a Figura 13 corresponde à turbina saudável e a Figura 14, à turbina com falha no ventilador implantada no voo de número 250. Note-se que o alisamento exponencial suaviza a série temporal, além de deixar bastante perceptível nos resíduos a diferença no comportamento da turbina com falha no voo de número 250. Outro ponto importante diz respeito à sensibilidade dos valores dos resíduos: as medições ao longo do caminho de gás variam de forma diferente para cada tipo de falha. Na Figura 14, por exemplo, é evidente que o resíduo para a medição T_{24} sofre menos influência da falha no ventilador.

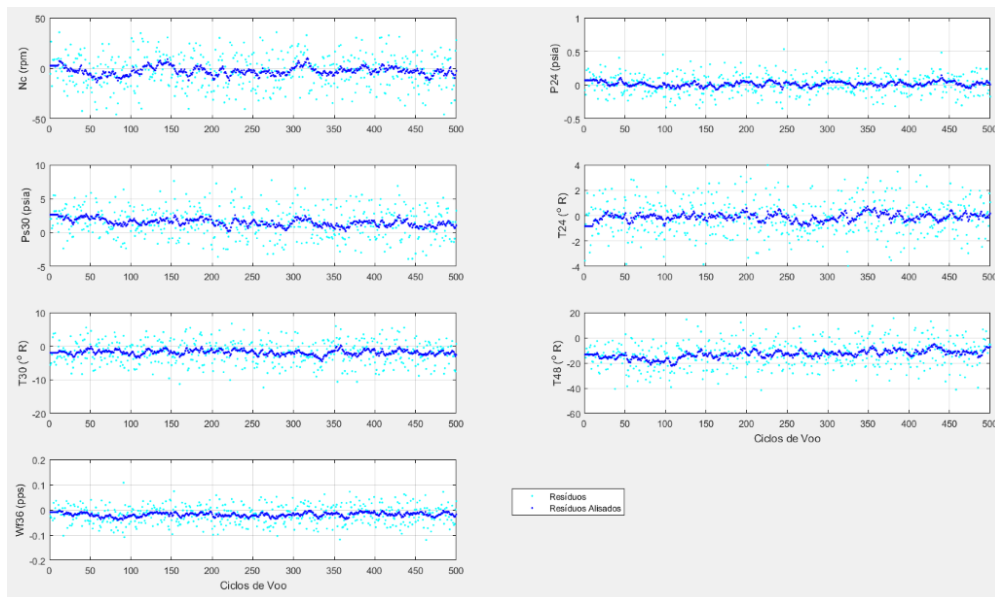


Figura 13 – Comparação entre resíduos (ciano) e resíduos alisados exponencialmente (azul) para sete medições ao longo do caminho do gás em situação sem falha.

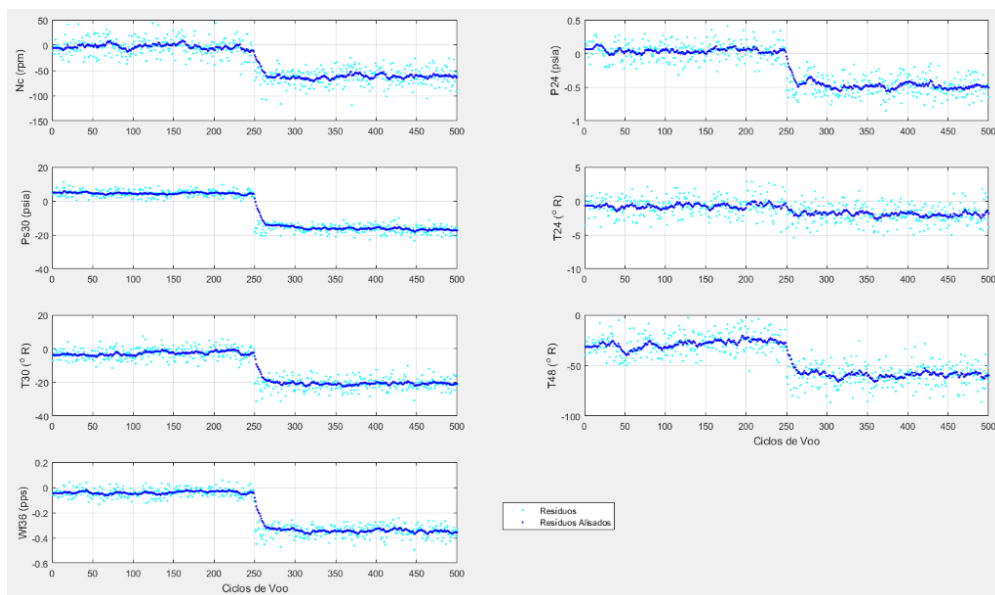


Figura 14 – Comparação entre resíduos (ciano) e resíduos alisados exponencialmente (azul) para sete medições ao longo do caminho do gás em situação com falha no ventilador.

Apresentou-se, até o momento, uma abordagem de como monitorar variações nos parâmetros de saúde do motor. Isso é importante, mas seria interessante, do ponto de vista de diagnóstico, detectar mudanças no comportamento da série que poderiam indicar o surgimento de uma falha. É

esperado, como pode ser visto na Figura 14, que o surgimento de uma falha cause rapidamente uma diferença nos valores observados entre uma turbina com falha no k -ésimo voo e uma turbina saudável no $(k - \beta)$ -ésimo voo. Esta comparação é realizada por meio do operador de diferença conhecido em técnicas de análise de séries temporais (BROCKWELL; DAVIS, 2006), chegando-se a:

$$\nabla \hat{r}_i(k) = \hat{r}_i(k) - \hat{r}_i(k - \beta) \quad (8)$$

onde $\nabla \hat{r}_i(k)$ é a diferença entre o valor residual alisado da i -ésima medição entre o k -ésimo voo e um voo $(k - \beta)$ anterior.

A Figura 15 e a Figura 16 mostram o resultado da aplicação do operador de diferença, com $\beta = 10$ ciclos de voo, para a simulação de duas turbinas por 500 ciclos. A Figura 15 retrata a turbina sem falha, enquanto que na Figura 16 a turbina experimentou falha no ventilador no voo de número 250.




Figura 15 – $\nabla \hat{r}_i(k)$ para sete medições ao longo do caminho do gás em situação sem falha.

É fácil identificar, na situação de falha, que, nos voos seguintes ao surgimento da falha, o valor em módulo de $\nabla \hat{r}_i(k)$ aumenta, atinge um pico e cai novamente. Isso ocorre pois, antes da ocorrência da falha, a diferença entre os

valores residuais alisados $\hat{\nabla} r_i(k)$ compara a turbina saudável com ela ainda saudável β voos anteriores; após o surgimento da falha, passados alguns voos, a comparação acontece com a turbina falhada com ela ainda com falha β voos anteriores. Essa abordagem é desejável para detecção do evento de surgimento de falha, pois permite identificar a falha com alguns voos de atraso.




Figura 16 – $\hat{\nabla} r_i(k)$ para sete medições ao longo do caminho do gás em situação com falha no ventilador.

Finalmente, chega-se à etapa de normalização, último passo da etapa de pré-processamento e uma tarefa comum em tratamento de dados para prover uma escala uniforme para todos os atributos. Uma forma padrão de normalização é dada pela equação (9):

$$N(y_i) = \frac{y_i(k) - \mu_i(k)}{\sigma_i(k)}, \forall i \quad (9)$$

onde, para a i -ésima medição durante o k -ésimo voo, $y_i(k)$ é o valor corrigido, $\mu_i(k)$ é a média do valor corrigido e $\sigma_i(k)$ é o desvio padrão do valor corrigido. Note-se que, na equação (6), a referência de máquina saudável foi usada. Isso é mais interessante dentro do contexto de diagnóstico de falha, pois o objetivo é estabelecer uma diferença clara entre o equipamento saudável e aquele com falha.

Assim, substituindo-se a média do valor corrigido, $\mu_i(k)$, pela referência de máquina saudável, $y_{i_referencia}(k)$, chega-se à normalização apresentada na equação (10):

$$N(\nabla \hat{r}_i(k)) = \frac{\nabla \hat{r}_i(k) - \nabla \hat{r}_i(k - \beta)}{\sigma_i(k)} \quad (10)$$

onde $N(\nabla \hat{r}_i(k))$ é a diferença normalizada entre o valor residual alisado da i -ésima medição entre o k -ésimo voo e um voo $(k - \beta)$ anterior e $\sigma_i(k)$ é o desvio padrão do valor corrigido para i -ésima medição.

A Figura 17 e a Figura 18 mostram o resultado da normalização para a simulação de duas turbinas por 500 ciclos de voo e são equivalentes à Figura 15 e à Figura 16 com os dados normalizados. A Figura 17 mostra o caso em que a turbina não experimentou falha, enquanto que, na Figura 18, a turbina experimentou falha no ventilador no voo de número 250.




Figura 17 – $N(\nabla \hat{r}_i(k))$ para sete medições ao longo do caminho do gás em situação sem falha.

O objetivo da normalização – prover uma escala uniforme entre os diferentes atributos da base de dados – foi alcançado, tornando as medições adimensionais. Desta forma é possível estabelecer limites genéricos, facilitando a

definição de critérios para detecção de falha. Por exemplo, uma falha é detectada

quando $\left| N(\nabla \hat{r}_i(k)) \right| > 2 \cdot \sigma_i(k)$.




Figura 18 – $N(\nabla \hat{r}_i(k))$ para sete medições ao longo do caminho do gás em situação com falha no ventilador.

3.5

Detecção e Isolamento de Falhas

O módulo de detecção e isolamento de falhas é responsável tanto por gerar as regras *fuzzy*, no caso do treinamento, quanto por avaliar o estado de saúde da turbina, no caso de teste. Até o momento foram apresentados o módulo de geração dos dados de operação e módulo de pré-processamento: o primeiro emula a aquisição de dados oriundos da instrumentação de turbinas com e sem falhas em vários pontos de operação, diferentes níveis de deterioração e conhecimento da condição de falha; o segundo, através das etapas de correção, cálculo do resíduo, filtragem, cálculo da diferença e normalização, coloca os dados em um formato mais adequado ao módulo de detecção e isolamento de falhas.

3.5.1

Treinamento

Para a metodologia de diagnóstico de desempenho de turbinas a gás proposta neste trabalho, utiliza-se o método de extração de regras *fuzzy* de Wang-Mendel (WANG; MENDEL, 1992). O objetivo é criar um conjunto de regras capaz de estabelecer um mapeamento correto entre as medições oriundas da instrumentação pré-processadas e as falhas. Apresenta-se a seguir um resumo das etapas envolvidas no processo de extração de regras aplicado ao problema abordado neste trabalho.

O método Wang-Mendel propõe cinco etapas para a obtenção das regras *fuzzy* a partir de dados numéricos:

Etapla 1: dividir as variáveis de entrada e saída em regiões *fuzzy*.

Para cada variável de entrada e saída é necessário definir seu domínio através dos limites inferior (U^-) e superior (U^+) que são obtidos com base na inspeção dos valores que cada variável pode assumir. Em seguida, divide-se cada domínio em $2N+1$ regiões *fuzzy*. A Figura 19 exemplifica esta etapa para $N=1$, Figura 19 (a) e (b) com três conjuntos *fuzzy*, e $N=2$, Figura 19 (c) e (d) com cinco conjuntos *fuzzy*. Os conjuntos *fuzzy* são denotados por: N , conjunto *fuzzy* central também chamado de *negligenciável*, pois é usado para representar a região de resíduo próximo de zero que está altamente associada à região em que o equipamento está saudável; r_{-N} é o conjunto *fuzzy* que representa os valores residuais negativos e r_{+N} representa os valores residuais positivos.

Note-se que, apesar do método Wang-Mendel sugerir funções triangulares, o conjunto *fuzzy* central, aqui chamado de *negligenciável*, é trapezoidal. Adianta-se que a base superior deste conjunto afeta muito os resultados para o problema de detecção de falhas, operando como fronteira entre as condições de equipamento saudável e com falha. Em outras palavras, uma base superior pequena para o conjunto *negligenciável* resulta em uma maior tendência em detectar falhas, aumentando a taxa de falso alarme (frequência com que o algoritmo sugere que o equipamento está com falha, estando na verdade saudável). Uma base superior grande tem efeito inverso, ou seja, há uma maior tendência em não se detectar falha.

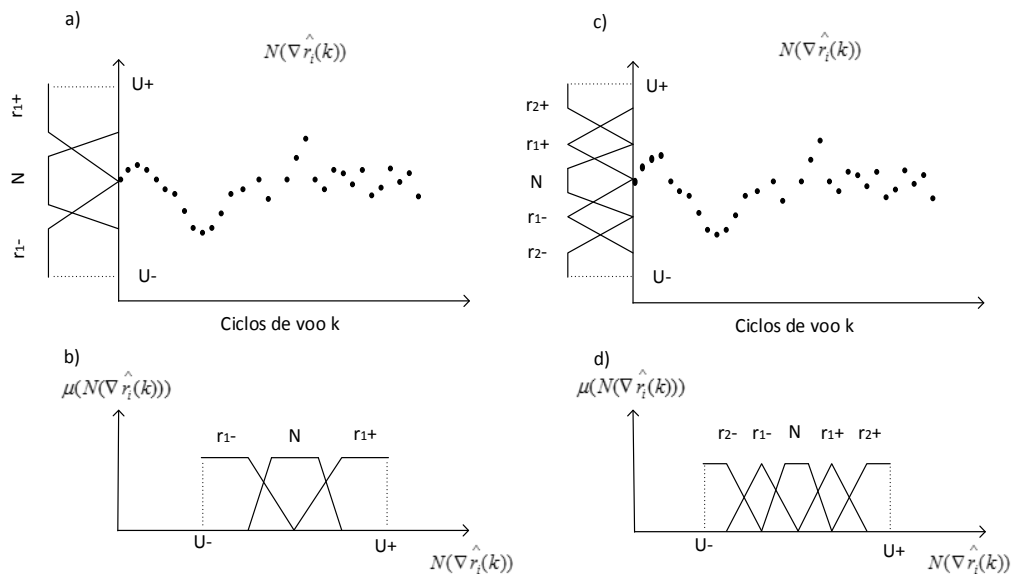


Figura 19 – Exemplo de inspeção dos valores para qualquer variável de entrada

$N(\nabla \hat{r}_i(k))$ para definição dos limites inferior (U_-) e superior (U_+). a) divisão do domínio em 3 regiões *fuzzy* ($N=1$). b) funções de pertinência correspondentes de a). c) divisão do domínio em 5 regiões *fuzzy* ($N=2$). d) funções de pertinência correspondentes de c).

Observe-se que o procedimento descrito acima é realizado para as sete variáveis de entrada ($N(\nabla \hat{r}_{Nc}(k))$, $N(\nabla \hat{r}_{P24}(k))$, $N(\nabla \hat{r}_{P30}(k))$, $N(\nabla \hat{r}_{T24}(k))$, $N(\nabla \hat{r}_{T30}(k))$, $N(\nabla \hat{r}_{T48}(k))$, $N(\nabla \hat{r}_{W36}(k))$). Como se trata de um problema de classificação os conjuntos *fuzzy* de saída são 2 funções de pertinência triangulares: estado saudável, centrado em 0, e estado com falha, centrado em 1 (Figura 20).




Figura 20 – Conjuntos *fuzzy* de saída para o problema de detecção de falha.

A Figura 21 representa a variável de saída para o problema de isolamento de falhas. Note-se que há 18 conjuntos *fuzzy* triangulares para representar as 18

falhas simuladas pelo ProDiMES. Cada conjunto *fuzzy* é centrado no seu respectivo ID, de acordo com a Tabela 2.




Figura 21 – Conjuntos *fuzzy* de saída para o problema de isolamento de falha.

O algoritmo de defuzzificação adotado é MOM (*Middle of Maximum*) que calcula uma medida de posição média do conjunto de maior grau de pertinência obtido. Como todos os conjuntos *fuzzy* das variáveis de saída são triangulares e simétricos, a saída defuzzificada pode assumir os valores centrais dos conjuntos triangulares, ou seja, 0 e 1 para o problema de detecção de falha e 1 a 18 para o problema de isolamento de falha.

Etapa 2: geração das regras *fuzzy* para cada exemplo (pares de dados de entrada e saída).

Para cada par de dados de entrada e saída, determina-se o grau de pertinência do valor de cada variável aos conjuntos *fuzzy* correspondentes. Em seguida associa-se, para cada variável, o conjunto *fuzzy* com maior grau de pertinência, gerando uma regra no formato dos exemplos ilustrativos:

Para detecção de falha:

Se $(N(\nabla \hat{r}_{Nc}(k))=N$ e $N(\nabla \hat{r}_{P24}(k))=N$ e $N(\nabla \hat{r}_{Ps30}(k))=N$ e $N(\nabla \hat{r}_{T24}(k))=N$ e $N(\nabla \hat{r}_{T30}(k))=N$ e $N(\nabla \hat{r}_{T48}(k))=N$ e $N(\nabla \hat{r}_{Ws36}(k))=N$ ENTÃO Estado=Saudável

Para isolamento de falha:

Se $(N(\nabla \hat{r}_{Nc}(k))=N$ e $N(\nabla \hat{r}_{P24}(k))=N$ e $N(\nabla \hat{r}_{Ps30}(k))=N$ e $N(\nabla \hat{r}_{T24}(k))=N$ e $N(\nabla \hat{r}_{T30}(k))=N$ e $N(\nabla \hat{r}_{T48}(k))=r+1$ e $N(\nabla \hat{r}_{Ws36}(k))=N$ ENTÃO TipoFalha=T48

Etapa 3: determinação de um peso para cada regra.

Como normalmente existem muitos pares de dados de entrada e saída, a quantidade de regras geradas é grande, sendo bastante provável o aparecimento de regras conflitantes (mesmos antecedentes e diferente consequente). Ainda durante a etapa de geração das regras *fuzzy* para cada exemplo, cada regra gerada tem um grau de pertinência associado a cada antecedente e ao consequente. A determinação do peso de cada regra se dá através do produto dos graus de pertinência dos antecedentes e do consequente. Para resolver o conflito, permanece a regra de maior peso.

Etapa 4: combinação da base de regras *fuzzy*.

As regras geradas são armazenadas em uma base de conhecimento, que pode ser enriquecida com regras fornecidas por um especialista.

Esta base de conhecimento é inspecionada com objetivo de agrupar várias regras e melhorar a interpretabilidade. Por exemplo, as regras da base de conhecimento hipotética da Tabela 4 podem ser substituídas pela regra da Tabela 5. Estas tabelas mostram os antecedentes, consequente e operador de cada regra.

Tabela 4 – Regras *fuzzy* hipotéticas com operado *AND*.

Antecedentes		Consequente	Operador
A	B	D	<i>AND</i>
B	A	D	<i>AND</i>
A	A	D	<i>AND</i>

Tabela 5 – Regra *fuzzy* hipotética com operador *OR*.

Antecedentes		Consequente	Operador
A	B	D	<i>OR</i>

Etapa 5: determinação do método de defuzzificação.

Normalmente, o método de defuzzificação utilizado é o do centroide, mas como o problema de diagnóstico de desempenho de turbina a gás é um problema de classificação, optou-se por utilizar o método MOM.

3.5.2

Teste

É comum em técnicas de IC para problemas de classificação dividir a base de dados em treinamento e teste. No caso do treinamento, como explicado na seção anterior, os exemplos são usados para gerar a base de conhecimento *fuzzy*. Já o conjunto de teste é utilizado para verificação da acurácia do modelo.

Como pode ser visto na Figura 9, o sistema de diagnóstico proposto é hierárquico: (i) o sistema *fuzzy* de detecção de falha, após carregar a base de conhecimento gerada na etapa de treinamento, avalia a saúde da turbina apenas tentando prever se há uma falha (sem se preocupar com o tipo); (ii) o sistema *fuzzy* para isolamento de falha, também após carregar a base de conhecimento gerada na etapa de treinamento, tenta descobrir o tipo de falha.

É perceptível que a primeira etapa – detecção de falha – é extremamente importante. Ela funciona como um filtro para a avaliação do sistema de isolamento de falha, pois, caso o sistema de detecção sugira que o equipamento está saudável, não há falha a descobrir e o sistema de isolamento não é ativado. Isso obriga a construção de um sistema de detecção de falha suficientemente bom; caso contrário, todo o processo de diagnóstico será prejudicado.

Mesmo quando o módulo de detecção de falha realiza uma previsão correta e o módulo de isolamento de falha efetua uma previsão errada, o objetivo principal da ferramenta nesta situação é alcançado: dar um direcionamento ao usuário para otimizar a tomada de decisão. Na prática o usuário saberia da existência de uma falha e poderia usar outras ferramentas de análise para investigar a resposta do sistema. Isto só é possível porque problema de diagnóstico é tratado de forma hierárquica (nas etapas de detecção e isolamento de falhas). Outra vantagem desta formulação está relacionada à dificuldade envolvida nas etapas, pois a detecção de uma falha é normalmente mais simples do que isolá-la. Sistemas que não tratam o problema de forma hierárquica tentam diretamente inferir qual a falha o sistema apresenta, não se valendo das vantagens da hierarquização.

Tendo em vista as características acima, é importante estabelecer métricas bem definidas para a avaliação do sistema de diagnóstico construído no processo de treinamento e, conseqüentemente, evoluir os módulos de detecção e isolamento

de falhas corretamente. A seguir serão apresentadas algumas métricas comuns em tarefas de diagnóstico de falhas retiradas de (SIMON et al., 2008a).

A Tabela 6 apresenta a matriz de decisão usada para a avaliação de problemas de detecção de falhas. Trata-se de uma matriz 2x2 que traduz a habilidade do algoritmo de diferenciar entre os estados saudável e com falha. Sua diagonal principal reflete o número de predições corretas e a diagonal secundária reflete o número de predições erradas. A partir desta matriz é possível calcular as seguintes métricas:

Verdadeiro Positivo (VP): número de detecções corretas de estados de falha dividido pelo total de casos de falha.

Verdadeiro Negativo (VN): número de detecções corretas de estados saudáveis dividido pelo número total de casos saudáveis.

Falso Positivo (FP): número de detecções incorretas de estados de falha dividido pelo total de casos de estados saudáveis. Essa métrica indica a taxa de falso alarme, ou seja, a frequência com que o algoritmo sugere que o equipamento está com falha, estando na verdade saudável.

Falso Negativo (FN): número de detecções incorretas de estados saudáveis dividido pelo total de casos de estados de falha.

Tabela 6 – Matriz de decisão para detecção de falha.

		Estado Predito	
		Falha	Saudável
Estado Verdadeiro	Falha	Verdadeiro Positivo	Falso Negativo
	Saudável	Falso Positivo (alarmes falsos)	Verdadeiro Negativo

Embora a matriz de decisão forneça informação sobre a capacidade do algoritmo de detectar falha, informações adicionais são necessárias para avaliar a sua capacidade de isolar ou classificar diferentes tipos de falhas. A Tabela 7

mostra a matriz de confusão, bastante usada para avaliação de problemas de classificação. É uma matriz quadrada de dimensão n , onde n é a quantidade de classes – no caso, a quantidade de tipos de falhas mais o estado saudável.

Tabela 7 – Matriz de confusão para isolamento de falha.

		Estado Predito			
Estado Verdadeiro		Falha 1	Falha 2	...	Saudável
	Falha 1	C_{11}	C_{12}	...	C_{1n}
	Falha 2	C_{21}	C_{22}	...	C_{2n}
	⋮	⋮	⋮	...	⋮
	Saudável	C_{n1}	C_{n2}	...	C_{nn}

A diagonal principal desta matriz reflete as classificações corretas. Para calcular o percentual de acerto para o p -ésimo estado, PCC_p , pode-se dividir o número de classificações corretas do estado p pelo número total de observações do estado p , de acordo com:

$$PCC_p = \frac{C_{pp}}{\sum_{q=1}^n C_{pq}} \cdot 100\% \quad (11)$$

Enquanto as matrizes de decisão e confusão fornecem uma visão geral da habilidade do algoritmo de diagnóstico, elas não estão em um formato que permite uma comparação direta entre diferentes algoritmos, principalmente quando se lida com muitos casos de falhas. Desta forma, é apresentado o Coeficiente de Kappa, que resume o conteúdo da matriz de confusão em um único número. É uma medida da habilidade do algoritmo em classificar corretamente uma falha, levando em consideração o valor esperado de classificações corretas fruto do acaso. Assim, é possível estabelecer uma comparação direta entre dois métodos de classificação. O Coeficiente de Kappa, denotado por k , pode ser calculado a partir da matriz de confusão da Tabela 7:

$$k = \frac{P_0 - P_E}{P_T - P_E} \quad (12)$$

sendo:

$$P_0 = \sum_{p=1}^n C_{pp} \quad (13)$$

$$P_T = \sum_{p=1}^n \sum_{q=1}^n C_{pq} \quad (14)$$

$$P_E = \sum_{p=1}^n \left\{ \sum_{q=1}^n \frac{C_{pq}}{P_T} \cdot \sum_{q=1}^n C_{qp} \right\} \quad (15)$$

onde P_0 é a quantidade de classificações corretas, P_T é o total de observações e P_E é a quantidade esperada de classificações corretas geradas pelo acaso. Se um sistema de diagnóstico é perfeito e acerta todas as classificações, $k=1$. Se o desempenho de classificação é menor que o valor esperado de classificações corretas geradas pelo acaso, então $k < 0$.

4

Resultados e Discussão

4.1

Introdução

Este capítulo se dedica a avaliar o sistema de diagnóstico proposto no qual muitos parâmetros devem ser definidos em cada módulo, conforme segue:

- Geração dos dados de operação:
 - Número de turbinas;
 - Número de ocorrências de cada falha e número de ocorrências de turbina saudável;
 - Número de voos simulados para cada turbina;
 - Voo de surgimento da falha;
 - Taxa de evolução da falha;
 - Dados gerados com e sem ruído.
- Pré-processamento: coloca os dados em um formato mais adequado ao módulo de detecção e isolamento de falhas.
 - α : constante de alisamento exponencial simples (AES), $0 \leq \alpha \leq 1$;
 - β : distância entre voos para cálculo da diferença do valor residual alisado.
- Deteção e isolamento de falhas: SIF responsável por gerar as regras, no caso de treinamento, e por avaliar o estado de saúde do equipamento, no caso de teste para detecção e isolamento de falhas.
 - Definição dos domínios das variáveis de entrada e saída por meio dos limites inferior (U^-) e superior (U^+);
 - Divisão de cada domínio em $2N+1$ regiões *fuzzy* (Figura 19);
 - Definição do conjunto *fuzzy* central N , aqui denominado *negligenciável* e definido por uma função trapezoidal;

- Definição dos demais conjuntos *fuzzy* r_{-N} e r_{+N} – triangular, semi-trapézio à esquerda e semi-trapézio à direita (Figura 22);

Como há um grande número de configurações possíveis, torna-se impraticável testar todas elas. Assim, é necessário estabelecer uma estratégia coerente para encontrar uma configuração suficientemente boa. Por meio de uma base de dados gerada especificamente para avaliação do sistema, o objetivo é aperfeiçoar os módulos do sistema e encontrar a combinação adequada de parâmetros. A próxima seção apresenta a estratégia adotada para encontrar esta configuração, avaliando o sistema sempre frente às métricas de diagnóstico vistas no capítulo anterior.

4.2

Ajuste do Sistema de Diagnóstico

A seguinte estratégia foi adotada para ajuste dos parâmetros:

1. Os operadores de interseção, união, agregação, implicação e o método de defuzzificação utilizados são resumidos na Tabela 8.

Tabela 8 – Operadores utilizados.

#	Método
Operador <i>AND</i>	mínimo
Operador <i>OR</i>	máximo
Implicação	mínimo
Agregação	máximo
Defuzzificação	MOM (<i>Middle of Maximum</i>)

2. Valores sugeridos na literatura para α e β (BORGUET, 2012; SIMON et al., 2008b) foram adotados neste trabalho: $\alpha = 0.1156$ e $\beta = 10$;
3. Com relação ao módulo de geração dos dados de operação, percebe-se que é possível gerar bases de dados mais ou menos abrangentes. Isto se refletirá na capacidade do algoritmo de lidar com diferentes situações, tais como presença de ruído, falhas em nível de componentes, sensores e atuadores, com diferentes níveis de

severidade. Como o objetivo é gerar um sistema de diagnóstico capaz de lidar com situações reais, a base de dados deve apresentar as seguintes características:

- a. Presença de ruído;
- b. Falhas em componentes, sensores e atuadores;
- c. Falhas com evolução temporal abrupta e rápida;
- d. Falhas com diferentes níveis de severidade;
- e. Razão da quantidade de dados saudáveis e com falha deve ser alta, pois, na prática, falha é um evento raro.

Para satisfazer estes requisitos, os dados foram gerados de acordo com a Tabela 9 para as bases de treinamento e teste.

Tabela 9 – Características da base de dados usada para ajuste do sistema de diagnóstico de desempenho de turbinas a gás aeronáuticas.

Parâmetro	Valor/Características
Número de voos por turbina	50
Voo de início da falha	aleatório entre os voos 11 e 35
Presença de ruído	sim
Evolução temporal da falha	50% abrupta e 50% rápida
Severidade das falhas	33% baixa, 33% média e 33% alta
Casos saudáveis	1800
Casos de falha no componente Fan	100
Casos de falha no componente LPC	100
Casos de falha no componente HPC	100
Casos de falha no componente HPT	100
Casos de falha no componente LPT	100
Casos de falha no atuador VSV	100
Casos de falha no atuador VBV	100
Casos de falha no sensor Nf	100
Casos de falha no sensor Nc	100
Casos de falha no sensor P15	100
Casos de falha no sensor P24	100
Casos de falha no sensor Ps30	100
Casos de falha no sensor T24	100
Casos de falha no sensor T30	100
Casos de falha no sensor T45	100
Casos de falha no sensor Wf	100
Casos de falha no sensor P24	100
Casos de falha no sensor T24	100

4. O módulo de detecção de falhas foi ajustado da seguinte forma:
 - a. Determinação, via inspeção da base de dados, dos domínios das variáveis de entrada e saída – limites inferior (U^-) e superior (U^+);
 - b. Definição de $2N+1$ conjuntos *fuzzy* para $N = 1$ (3 conjuntos), $N = 2$ (5 conjuntos) e $N = 3$ (7 conjuntos);
 - c. Variação da base superior do conjunto *fuzzy* trapezoidal;
 - d. Ajuste fino para as configurações que apresentarem melhor resultado.
5. Após a definição da melhor configuração para o módulo de detecção de falha, o módulo de isolamento foi ajustado seguindo os mesmos critérios.

Esta estratégia não garante que a configuração seja ótima, mas, dada a grande quantidade de possíveis configurações, os critérios estabelecidos permitem obter um sistema minimamente adequado para a tarefa pretendida.

4.3

Avaliação das Configurações do Sistema de Diagnóstico para Detecção de Falhas

Os dados de treinamento gerados com base na Tabela 9 foram inspecionados para definição do universo de discurso das variáveis linguísticas *fuzzy* e para definição das funções de pertinência. Do total de 3600 turbinas simuladas (1800 saudáveis e 1800 com falhas), 4 não convergiram, restando 3596 (1799 saudáveis e 1797 com falhas). A Tabela 10 reúne informações de valores máximo, mínimo e desvio padrão de $N(\nabla \hat{r}_i(k))$, diferença normalizada entre o valor residual alisado da i -ésima medição entre o k -ésimo voo e um voo $(k-\beta)$ anterior, para os 1799 casos de turbinas saudáveis simulados. Analisar os casos saudáveis separadamente é importante para definição do conjunto *negligenciável* que estabelece a fronteira entre os estados saudável e com falha.

A Tabela 11 reúne informações de valores máximo, mínimo, desvio padrão e o percentual de valores de $N(\nabla \hat{r}_i(k))$ que se encontra entre -3 e 3 para os 3596 casos de turbinas saudáveis e com falhas. Note-se que, como esperado, o módulo

dos valores máximo e mínimo é maior do que o módulo dos valores máximo e mínimo dos casos saudáveis (Tabela 10). Contudo, é necessário avaliar criticamente estes valores para a definição do universo de discurso das variáveis de entrada, pois a grande maioria está no intervalo -3 a 3. Como são dados com falhas, é possível que os valores de máximo e mínimo retratem situações raras de falha muito grave.

A partir da Tabela 10 e da Tabela 11 foram construídos os domínios *fuzzy* das variáveis de entrada – -3 para o limite inferior (U) e 3 para o limite superior (U^+) – e a configuração dos conjuntos *fuzzy*, conforme mostrado na Tabela 12. Os casos de testes mostrados nesta tabela compreendem as situações de $N = 1$ (3 conjuntos), $N = 2$ (5 conjuntos) e $N = 3$ (7 conjuntos). Para cada valor de N , variou-se o tamanho da base superior do conjunto *negligenciável* em 2, 1.5 e 1. A tabela segue o padrão da Figura 22, que representa os conjuntos *fuzzy* triangular, trapezoidal, semi-trapézio à esquerda e semi-trapézio à direita.

Tabela 10 – Valor máximo, mínimo e desvio padrão de $N(\nabla \hat{r}_i(k))$ para sete medições usadas como entrada do sistema de diagnóstico *fuzzy* apenas para situação de turbina saudável.

#	Máximo	Mínimo	Desvio padrão
$N(\nabla \hat{r}_{Nc}(k))$	1.36	-1.31	0.2601
$N(\nabla \hat{r}_{P24}(k))$	1.22	-1.26	0.2619
$N(\nabla \hat{r}_{Ps30}(k))$	1.29	-1.30	0.2682
$N(\nabla \hat{r}_{T24}(k))$	1.23	-1.36	0.2601
$N(\nabla \hat{r}_{T30}(k))$	1.52	-1.29	0.2686
$N(\nabla \hat{r}_{T48}(k))$	1.44	-1.21	0.2602
$N(\nabla \hat{r}_{Ws36}(k))$	1.22	-1.32	0.2576

Tabela 11 – Valor máximo, mínimo, desvio padrão e percentual de valores de $N(\nabla \hat{r}_i(k))$ entre -3 e 3 para sete medições usadas como entrada do sistema de diagnóstico para situação de turbina saudável e com falha.

#	Máximo	Mínimo	DP	% $(-3 < N(\nabla \hat{r}_i(k)) < 3)$
$N(\nabla \hat{r}_{Nc}(k))$	16.83	-10.74	1.0230	97.94
$N(\nabla \hat{r}_{P24}(k))$	8.41	-7.96	0.6755	98.97
$N(\nabla \hat{r}_{Ps30}(k))$	8.78	-11.00	1.0795	96.96
$N(\nabla \hat{r}_{T24}(k))$	7.05	-7.12	0.6474	98.94
$N(\nabla \hat{r}_{T30}(k))$	11.34	-7.15	1.0143	96.54
$N(\nabla \hat{r}_{T48}(k))$	15.99	-8.78	1.0966	97.38
$N(\nabla \hat{r}_{Ws36}(k))$	7.65	-9.86	0.8772	97.31

Vale lembrar que apenas as variáveis de entrada tiveram seus conjuntos avaliados para diferentes configurações, pois os da variável de saída foram definidos no Capítulo 3 (Figura 20 e Figura 21). Como se trata de um problema de classificação, os conjuntos *fuzzy* são triangulares e simétricos de forma que a saída defuzzificada (por MOM) assume apenas os valores centrais dos conjuntos, ou seja, 0 e 1 para o problema de detecção de falha e de 1 a 18 para isolamento de falha.




Figura 22 – Ilustração da convenção adotada na Tabela 12. a) função triangular; b) função trapezoidal; c) função semi-trapézio à esquerda; d) função semi-trapézio à direita.

Tabela 12 – Parâmetros dos conjuntos *fuzzy* para as variáveis de entrada.

	N = 1 (3 conjuntos fuzzy)											
Conjunto	Base Superior = 2				Base Superior = 1.5				Base Superior = 1			
	A	B	C	D	A	B	C	D	A	B	C	D
r_{-1}	-1.0	-1.6	----	----	-1.35	-0.75	----	----	-1.1	-1.5	----	----
N (negligenciável)	-1.6	-1.0	1.0	1.6	-1.35	-0.75	0.75	1.35	-1.1	-0.5	0.5	1.1
r_{+1}	1.0	1.6	----	----	0.75	1.35	----	----	0.5	1.1	----	----
	N = 2 (5 conjuntos fuzzy)											
Conjunto	Base Superior = 2				Base Superior = 1.5				Base Superior = 1			
	A	B	C	D	A	B	C	D	A	B	C	D
r_{-2}	-2.2	-1.6	----	----	-1.95	-1.35	----	----	-1.7	-1.1	----	----
r_{-1}	-2.2	-1.6	-1.0	----	-1.95	-1.35	-0.75	----	-1.7	-1.1	-1.5	----
N (negligenciável)	-1.6	-1.0	1.0	1.6	-1.35	-0.75	0.75	1.35	-1.1	-0.5	0.5	1.1
r_{+1}	1.0	1.6	2.2	----	0.75	1.35	1.95	----	0.5	1.1	1.7	----
r_{+2}	1.6	2.2	----	----	1.35	1.95	----	----	1.1	1.7	----	----
	N = 3 (7 conjuntos fuzzy)											
Conjunto	Base Superior = 2				Base Superior = 1.5				Base Superior = 1			
	A	B	C	D	A	B	C	D	A	B	C	D
r_{-3}	-2.8	-2.2	----	----	-2.55	1.95	----	----	-2.3	-1.7	----	----
r_{-2}	-2.8	-2.2	-1.6	----	-2.55	-1.95	-1.35	----	-2.3	-1.7	-1.1	----
r_{-1}	-2.2	-1.6	-1.0	----	-1.95	-1.35	-0.75	----	-1.7	-1.1	-1.5	----
N (negligenciável)	-1.6	-1.0	1.0	1.6	-1.35	-0.75	0.75	1.35	-1.1	-0.5	0.5	1.1
r_{+1}	1.0	1.6	2.2	----	0.75	1.35	1.95	----	0.5	1.1	1.7	----
r_{+2}	1.6	2.2	2.8	----	1.35	1.95	2.55	----	1.1	1.7	2.3	----
r_{+3}	2.2	2.8	----	----	1.95	2.55	----	----	1.7	2.3	----	----

A base de testes também foi gerada segundo a Tabela 9. De posse das bases de teste e treinamento, o sistema *fuzzy* foi configurado para cada caso da Tabela 12 e os resultados são mostrados na Tabela 13. Esta traz informações do ID do teste, valor de N usado na criação das regiões *fuzzy*, tamanho da base superior do conjunto central trapezoidal e resultados das métricas de detecção de falhas: verdadeiro positivo (VP), verdadeiro negativo (VN), falso positivo (FP), falso negativo (FN), alarme falso (número de voos saudáveis necessários para o algoritmo erroneamente detectar uma falha) e número de regras geradas. Estes resultados referem-se a todos os casos da base de teste, i.e., considerando todos os tipos, diferentes taxas de evolução e severidade das falhas e dados com presença de ruído.

Tabela 13 – Resultados dos casos de teste para ajuste do sistema de diagnóstico para detecção de falha.

ID	N	Base Superior	VP	VN	FP	FN	Alarme Falso	Número de Regras
1	1	1	43.90%	99.50%	0.50%	56.10%	200.60	1721
2	1	1.5	43.29%	99.91%	0.09%	56.71%	1155.81	975
3	1	2	42.02%	99.94%	0.06%	57.98%	1618.13	1004
4	2	1	48.26%	99.43%	0.57%	51.74%	175.88	3455
5	2	1.5	43.41%	99.84%	0.16%	56.59%	638.74	2597
<u>6</u>	<u>2</u>	<u>2</u>	<u>45.69%</u>	<u>99.94%</u>	<u>0.06%</u>	<u>54.31%</u>	<u>1619.30</u>	<u>2120</u>
7	3	1	47.45%	99.21%	0.79%	52.55%	126.42	4654
8	3	1.5	43.66%	99.84%	0.16%	56.34%	622.36	3371
9	3	2	42.81%	99.86%	0.14%	57.19%	693.49	2670

Antes de analisar os resultados, é importante reforçar as características desejáveis que o sistema de diagnóstico proposto deve apresentar:

- Baixa frequência de alarme falso: o erro frequente em indicar falha afeta a credibilidade do sistema de diagnóstico;
- Acurácia: traduz-se pela diagonal, VP e VN, da matriz de decisão (Tabela 6);
- Interpretabilidade: baixo número de regras.

Diante dessas características, é possível descartar os testes com alta taxa de alarme falso. Tomando como limite 1 alarme falso a cada 1000 voos saudáveis, eliminam-se os casos 1, 4, 5, 7, 8 e 9. Dentre os casos 2, 3 e 6, optou-se por escolher o caso 6 em virtude de sua melhor acurácia, apesar do elevado número de regras *fuzzy*. Para melhorar a interpretabilidade, após o sistema estar configurado, uma etapa final consiste em diminuir a quantidade de regras geradas via método Wang & Mendel. Isto é realizado por meio do agrupamento de regras com antecedentes de operador *AND* em uma regra com antecedente de operador *OR*, como explicado no capítulo anterior.

Algumas características importantes sobre o comportamento do sistema podem ser destacadas com base na Tabela 13. Fica claro que a frequência de alarme falso é muito dependente do conjunto *fuzzy* central trapezoidal, apresentando alta frequência de alarme falso quando a base superior deste conjunto é muito pequena (casos 1, 4 e 7).

Outro comportamento interessante diz respeito novamente à taxa de alarme falso e à acurácia de detecção de falha (VP), pois, como observado na Figura 23, percebe-se que há uma tendência em aumentar a frequência de alarme falso (indesejado) à medida que se melhora a métrica VP (desejado). De fato, a frequência de alarme falso funciona como uma fronteira para a acurácia de detecção de falha.




Figura 23 – Verdadeiro Positivo em função do número de voos saudáveis necessários para cada alarme falso para os casos de 3, 5 e 7 conjuntos *fuzzy*.

Ainda com relação a Tabela 13, para um mesmo tamanho da base superior do conjunto *negligenciável*, verifica-se que o número de regras geradas aumenta com a quantidade de conjuntos *fuzzy*. Este é um comportamento esperado, pois se trata do problema de explosão combinatória do número de regras *fuzzy*, bastante conhecido na literatura de SIFs (KOSKO, 1996).

O caso 6 da Tabela 13 foi o escolhido e submetido a diversos ajustes na tentativa de melhorar seus resultados. Basicamente houve ajustes nos conjuntos *fuzzy*, buscando otimizar a acurácia, mas mantendo o limite de 1 alarme falso a cada 1000 voos saudáveis. A Tabela 14 mostra a configuração final do sistema de diagnóstico *fuzzy* para detecção de falha; a Tabela 15 mostra os resultados frente às métricas de detecção de falha.

Tabela 14 – Sistema de diagnóstico ajustado a partir do caso 6 da Tabela 13.

	N = 2 (5 conjuntos fuzzy)			
Conjunto	Base Superior = 2.32			
	A	B	C	D
r_{-2}	-1.32	-1.24	----	----
r_{-1}	-1.16	-1.24	-1.32	----
N (negligenciável)	-1.24	-1.16	1.16	1.24
r_{+1}	1.16	1.24	1.32	----
r_{+2}	1.24	1.32	----	----

Tabela 15 – Resultados do caso de teste da Tabela 14.

N	Base Superior	VP	VN	FP	FN	Alarme Falso	Número de Regras
2	2.32	45.72%	99.90%	0.10%	54.28%	1033.60	1537

4.4

Avaliação das Configurações do Sistema de Diagnóstico para Isolamento de Falhas

De modo similar ao o problema de detecção de falha, a quantidade de possíveis configurações do sistema de diagnóstico para isolamento de falhas é bastante grande. Desta forma, a estratégia adotada aqui é semelhante àquela apresentada na seção anterior. A principal diferença entre os dois problemas diz respeito às métricas utilizadas: enquanto que se utiliza a matriz de decisão para detecção, faz-se uso da matriz de confusão e o coeficiente de Kappa no caso de isolamento de falha.

A base de dados de treinamento e teste, baseada na Tabela 9, é idêntica à usada na seção anterior. Assim, a parte de inspeção e definição do universo de discurso também se aplica agora (as entradas do módulo de detecção são idênticas às do módulo de isolamento). Por conseguinte, os casos de testes da Tabela 12 aplicam-se coerentemente para avaliação do módulo de isolamento. Vale lembrar que a Tabela 16 segue o padrão da Figura 22, que representa os conjuntos *fuzzy* triangular, trapezoidal, semi-trapézio à esquerda e semi-trapézio à

direita, e os casos de testes compreendem as situações de $N = 1$ (3 conjuntos), $N = 2$ (5 conjuntos) e $N = 3$ (7 conjuntos). Para cada valor de N , variou-se o tamanho da base superior do conjunto *negligenciável* em 2, 1.5 e 1.

Uma vez que a arquitetura (Figura 9) do sistema de diagnóstico proposto é hierárquica, deve-se inicialmente detectar a falha e então isolá-la. Os dados da Tabela 14 foram utilizados para avaliação das configurações de isolamento. Semelhantemente à Tabela 12, os resultados dos casos de teste são mostrados na Tabela 16 que traz informações do ID do teste, valor de N usado na criação das regiões *fuzzy*, tamanho da base superior do conjunto central trapezoidal, Coeficiente de Kappa e número de regras geradas. Os resultados desta tabela se referem a todos os casos da base de teste, i.e., considerando todos os tipos, diferentes taxas de evolução e severidade das falhas e dados com presença de ruído.

Tabela 16 – Resultados dos casos de teste para ajuste do sistema de diagnóstico para isolamento de falha.

ID	N	Base Superior	Coeficiente de Kappa	Número de Regras
1	1	1	0.481	1621
<u>2</u>	<u>1</u>	<u>1.5</u>	<u>0.478</u>	<u>972</u>
3	1	2	0.484	1003
4	2	1	0.499	3349
<u>5</u>	<u>2</u>	<u>1.5</u>	<u>0.502</u>	<u>2590</u>
6	2	2	0.491	2120
7	3	1	0.501	4494
8	3	1.5	0.496	3361
9	3	2	0.489	2670

Todos os casos da tabela apresentaram Coeficiente de Kappa muito próximos, variando de 0.478 para o caso 2 a 0.502 para o caso 5. Assim, decidiu-se arbitrariamente escolher os casos 2 e 5. Estas configurações (3 e 5 conjuntos *fuzzy*) passaram por ajuste fino por meio de testes de tentativa e erro para melhora dos resultados. A melhor configuração encontrada e seus resultados são apresentados na Tabela 17, na Tabela 18 (número de regras e Coeficiente de Kappa) e na Figura 24 (Matriz de Confusão).

Tabela 17 – Sistema de diagnóstico *fuzzy* ajustado a partir do caso 5 da Tabela 16.

	N = 2 (5 conjuntos fuzzy)			
Conjunto	Base Superior = 1.56			
	A	B	C	D
r_{-2}	-1.82	-1.30	----	----
r_{-1}	-0.78	-1.30	-1.82	----
N (negligenciável)	-1.30	-0.78	0.78	1.30
r_{+1}	0.78	1.30	1.82	----
r_{+2}	1.30	1.82	----	----

Tabela 18 – Resultados do caso de teste da Tabela 17.

N	Base Superior	Coeficiente de Kappa	Número de Regras
2	1.56	0.517	1621

A matriz de confusão da Figura 24 revela o *PCC* de cada falha individualmente. De forma geral, as falhas Fan, HPC, HPT, LPT e VSV são isoladas satisfatoriamente pelo SIF, enquanto que falhas como VBV, Nc, Ps30, T48, P2 e Pamb são difíceis tanto de detectar quanto de isolar. O problema pode estar relacionado ao fato destas falhas serem difíceis de detectar, pois o módulo de detecção errou em 98.0% das falhas Pamb, 81.8% das falhas P2, 89.7% das falhas Nc e 79.0% das falhas VBV, com impacto negativo na capacidade de isolamento.

Outra característica mostrada por esta matriz, em se tratando das falhas em nível de componentes, sensores e atuadores, é a tendência de confundir a falha do sensor com a falha do componente localizado em sua vizinhança (a informação sobre a localização dos sensores e componentes está evidenciada na Figura 8). Para a falha no sensor P24 (acurácia de 25,82%), por exemplo, o algoritmo identificou 34,098% das observações como sendo falha no LPC; para a falha no sensor Nf, 17.29% das observações foram identificadas como falha no Fan, e a falha no sensor T48 foi considerada como falha no HPT em 58.548% dos casos.

Estado Preditto															
	Fan	LPC	HPC	HPT	LPT	VSV	VBV	Nf	Nc	P24	Ps30	T24	T30	T48	WF36
Fan	57.769%	0	0	0	0	0	0	0.558%	0	0	0	0	0	0	0
LPC	0.784%	13.176%	0	0	0	0	0	0	0.392%	0	0	0	0	0	0
HPC	0	0	63.502%	0	0	0	0	0	0	0	0	0	0	0	0
HPT	3.387%	0	0	79.113%	0	0	0	0	0	0	0	0	0	0	0
LPT	2.031%	0	0	0	61.328%	0	0	0	0	0	0	0	0	0	0.313%
VSV	0	0	0	0	0	81.230%	0	0	0	0	0	0	0	0	0
VBV	0.316%	12.885%	0.316%	0	0	0	7.510%	0	0	0	0	0	0	0	0
Nf	17.291%	0	0	0	0.717%	0	0	44.542%	0	0	0	0	0	0	0.080%
Nc	1.496%	2.756%	0.236%	0	0	4.173%	0.079%	0	1.575%	0	0	0	0	0	0
P24	1.721%	34.098%	0	0	0	0	0.656%	0	0	25.820%	0	0	0	0	0
Ps30	6.537%	0.233%	1.245%	1.323%	10.350%	0	0	0	0	0	5.136%	0	0	0	1.089%
T24	1.550%	3.101%	1.240%	0	0	8.450%	11.860%	0	0	0	0	20.155%	0	0	0
T30	1.943%	0.081%	8.745%	0	0	0	0	0	14.980%	0	0	0	23.320%	0	0
T48	1.532%	0	0	58.548%	0	0	0.081%	0	0	0	0	0	0	2.742%	0
WF36	2.996%	0	0.324%	0	0.324%	0	0	0.486%	0	0	0	0	0	0	41.134%
P2	2.451%	4.032%	0.395%	0	0	0	0.158%	0.079%	0	1.186%	0	0	0	0	9.881%
T2	1.967%	0.656%	0.902%	0	0	0	1.721%	0.656%	0	0	0	0	0	0	0
Pamb	0.480%	0.240%	0.160%	0	0.640%	0	0	0.320%	0	0	0	0	0	0	0
No	0.037%	0.031%	0.008%	0.002%	0.012%	0	0.002%	0.002%	0	0	0	0	0	0	0.160%
Fault															
No															
Fault															

Figura 24 – Matriz de confusão.

4.5

Interpretabilidade

Dado que a interpretabilidade linguística constitui uma das vantagens de sistemas *fuzzy* frente a outros métodos como redes neurais e SVM, este trabalho tenta explorar este aspecto principalmente no problema de detecção de falhas. Entre os pontos que interferem na interpretabilidade linguística, o número de regras é extremamente importante. Outros fatores como número de entradas e saídas e número de funções de pertinência também influenciam a capacidade de um especialista entender a resposta do algoritmo.

Quando se introduz o quesito "interpretabilidade", incorre-se, em geral, no problema conhecido como Dilema Interpretabilidade-Acurácia (*Accuracy-Interpretability Tradeoff*) (ISHIBUCHI; NOJIMA, 2007). O desafio consiste em obter uma boa interpretabilidade sem afetar significativamente a acurácia.

No caso de detecção de falha, o modelo proposto apresentou os resultados da Tabela 15, em que a base de teste, projetada para ser a mais próxima da realidade, tem suas características expostas na Tabela 9. Como pode ser visto, 1537 regras foram geradas via método Wang & Mendel, o que é considerado um valor alto, mesmo que poucas regras sejam ativadas durante a avaliação de um exemplo.

A Figura 25 apresenta as funções de pertinências usadas para as sete medições do módulo de detecção de falha. É interessante observar que, por se tratar da melhor configuração encontrada, os conjuntos r_{1-} e r_{1+} abrangem pouco o universo de discurso em relação aos demais conjuntos e são justamente estes os conjuntos que separam o conjunto *negligenciável* dos conjuntos extremos. Esta característica está relacionada ao fato de as fronteiras entre o conjunto *negligenciável* (estado saudável) e os conjuntos r_{2-} e r_{2+} (estado com falha) não serem bem definidas.

Analisando a base de regras, percebeu-se que havia apenas 7 regras para o caso saudável; 1530 regras restantes diziam respeito ao caso com falha. A Tabela 19 mostra todas as regras para o caso saudável, sendo os antecedentes de cada regra referente $N(\nabla \hat{r}_i(k))$ para cada uma das entradas do módulo de detecção. Foi perceptível nas demais regras que, sempre que apareciam os conjuntos r_{2-} e

r_{2+} , tratava-se de um caso com falha. Assim, foram criadas as regras da Tabela 20, em substituição às 1344 regras de casos com falha. Com base nisto, é possível afirmar que a quantidade grande de regras para a classe com falha é fruto das possíveis combinações entre os antecedentes de cada regra.

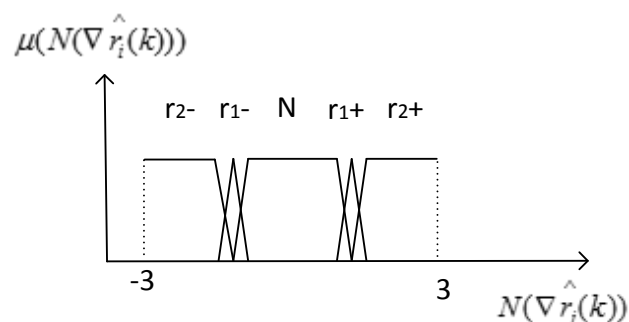


Figura 25 – Funções de pertinências referentes às sete entradas do módulo de detecção de falha.

Tabela 19 – Regras *fuzzy* de detecção de falha para saída saudável.

Antecedentes							Consequente	Operador
N	N	N	N	N	N	N	Saudável	AND
N	N	N	r1+	N	N	N	Saudável	AND
N	N	N	N	r1-	N	N	Saudável	AND
N	N	N	r1-	N	N	N	Saudável	AND
N	N	N	N	r1+	N	N	Saudável	AND
N	N	r1-	N	N	N	N	Saudável	AND
r1-	N	N	N	N	N	N	Saudável	AND

Tabela 20 – Regras *fuzzy* de detecção de falha para saída com falha.

Antecedentes							Consequente	Operador
r2+	r2+	r2+	r2+	r2+	r2+	r2+	Falha	OR
r2-	r2-	r2-	r2-	r2-	r2-	r2-	Falha	OR

Com a manipulação da base de conhecimento sugerida, restaram 193 regras. O módulo de detecção foi reavaliado para esta nova base de conhecimento e os resultados são mostrados na Tabela 21. Os resultados da Tabela 15 e da Tabela 21 ficaram muito próximos: o VP passou de 45.72% para 45.73% e a quantidade de alarme falso passou de 1 a cada 1033.60 voos saudáveis para 1 a cada 1022.72

voos saudáveis. Em contrapartida, o número de regras passou de 1537 para 193, melhorando consideravelmente a interpretabilidade.

Tabela 21 – Resultados do caso de teste para nova base de conhecimento.

<i>N</i>	Base Superior	VP	VN	FP	FN	Alarme Falso	Número de Regras
2	2.32	45.73%	99.90%	0.10%	54.27%	1022.72	193

Infelizmente o procedimento manual não pode ser aplicado ao módulo de isolamento de falha. Devido ao número de classes do módulo de isolamento (18 classes) ser muito maior do que aquele para o módulo de detecção (2 classes), encontrar padrões de falhas que pudessem ser agregadas de forma manual mostrou-se uma tarefa muito difícil.

Neste contexto, o uso de algoritmos genéticos pode trazer significativa evolução no método aqui proposto, pois, explorando-se a capacidade de otimização baseada no paradigma de evolução natural, é possível projetar métodos de extração de regras por meio de uma otimização multi-objetivo que respeite o compromisso entre acurácia e interpretabilidade. Modelos como Sistemas *Fuzzy* Genéticos, Redes Neurais *Fuzzy* Genéticas e Algoritmos de Agrupamento *Fuzzy* Genéticos são alguns dos métodos que podem ser usados para extração de regras *Fuzzy* (CINTRA, 2007) a partir de exemplos numéricos.

4.6

Evolução Temporal e Severidade da Falha

A base de dados usada para teste (Tabela 9) contém falhas com diferentes taxas de evolução temporal (rápida e abrupta) e diferentes severidades (baixa, média e alta). A evolução temporal está relacionada ao tempo necessário, em ciclos de voo, entre o surgimento da falha e sua saturação, enquanto que a severidade da falha está diretamente ligada ao afastamento da referência de máquina saudável, i.e., quanto mais afastada, maior a severidade. A Figura 26 e a Figura 27 explicitam a acurácia de detecção de falha e o Coeficiente de Kappa, respectivamente, para as diferentes naturezas de falhas citadas, respeitando-se o limite de 1 alarme falso a cada 1000 voos saudáveis. Tanto o módulo de detecção

quanto o de isolamento apresentam melhor desempenho para falhas abruptas com severidade alta.

O melhor desempenho para falhas com severidade alta pode ser atribuído ao módulo do valor residual, $r_i(k)$, ser maior nestes casos, implicando numa maior facilidade de detecção da falha. Como as falhas de severidade baixa estão muito próximas da fronteira entre as classes saudáveis e com falha, naturalmente o algoritmo tem mais dificuldade de classificá-las. No que concerne às falhas rápidas, como sua taxa de evolução é mais lenta, o módulo da diferença entre o valor residual alisado da i -ésima medição entre o k -ésimo voo e um voo $(k-\beta)$ anterior, $\nabla \hat{r}_i(k)$, tende a ser menor e, novamente, torna menor a diferença entre as classes saudáveis e com falha.




Figura 26 – VP para diferentes naturezas de falhas.




Figura 27 – Coeficiente de Kappa para diferentes naturezas de falhas.

A Figura 28 e a Figura 29 apresentam o percentual de classificações corretas (*PCC*) para cada falha em relação às falhas abruptas e às falhas rápidas para diferentes níveis de severidade. Estas figuras refletem a diagonal principal da matriz de confusão, mas explicitando o desempenho de isolamento para diferentes naturezas de falhas.




Figura 28 – *PCC* para diferentes severidades de falhas abruptas.




Figura 29 – *PCC* para diferentes severidades de falhas rápidas.

4.7

Comparação com Resultados da Literatura

A base de dados usada neste trabalho, como dito na seção Base de Dados – ProDiMES, tem como objetivo permitir a comparação entre diferentes métodos de diagnóstico de desempenho de turbinas a gás aeronáuticas. Assim, nesta seção, os

resultados obtidos pela metodologia aqui proposta serão comparados aos apresentados em (SIMON et al., 2013), em que os métodos utilizados são:

- Mínimos Quadrados Ponderados – MQP;
- Redes Neurais Probabilísticas – RNP;
- Ferramenta de Análise de Desempenho com Filtro de Kalman – FADFK;
- Observador/Estimador Genérico – OEG;

A Tabela 22 apresenta as métricas de VP, alarme falso e atraso de detecção para os quatro métodos de diagnóstico retirados da literatura e para o método de diagnóstico deste trabalho, considerando todos os tipos de falhas, taxa de evolução e severidade. Os métodos apresentaram resultados muito próximos para o atraso de detecção e para a frequência de alarme falso, respeitando o limite de 1 alarme falso a cada 1000 voos e permitindo uma justa comparação da métrica VP, uma vez que esta é dependente da taxa de alarme falso (comportamento explicado na Figura 23). É possível afirmar, portanto, que, apesar de nenhum dos métodos apresentar VP muito alto, o proposto neste trabalho apresenta acurácia de detecção semelhante aos métodos MQP e RNP, mas inferior às dos métodos FADFK e OEG.

Obviamente nenhum dos métodos da literatura tem compromisso com a interpretabilidade, sendo impossível extrair explicações das respostas destes algoritmos. Em se tratando de algoritmos que podem ser usados para apoiar a tomada de decisão, interpretabilidade torna-se uma vantagem clara neste contexto, pois a resposta do SIF vem acompanhada de quais regras foram ativadas, fornecendo ao especialista mais informação e um melhor direcionamento.

Tabela 22 – Comparação de VP, Alarme Falso e Atraso de Detecção para os métodos de diagnóstico MQP, RNP, FADFK, OEG e SIF.

Método de Diagnóstico	VP (%)	Alarme Falso	Atraso de Detecção
MQP	44.7	1087	4.86
RNP	44.7	1087	4.86
FADFK	50.9	1082	4.02
OEG	51.9	1069	4.24
SIF	45.7	1023	4.3

A Figura 30 apresenta a acurácia de detecção, assim como na Tabela 22, mas enfocando diferentes severidades de falha (baixa, média e alta) e diferentes taxas de evolução de falha (abrupta e rápida). É possível afirmar que a tendência percebida na seção anterior – melhor acurácia para falhas abruptas com severidade alta – também é válida para os métodos de diagnóstico MQP, RNP, FADFK e OEG.




Figura 30 – Comparação da métrica VP para os métodos de diagnóstico MQP, RNP, FADFK, OEG e SIF em função de diferentes naturezas de falhas.

Os resultados referentes ao Coeficiente de Kappa para os cinco métodos de diagnóstico são mostrados na Tabela 23. Uma vez que o Coeficiente de Kappa é um reflexo da habilidade do algoritmo de isolar/classificar corretamente as falhas, pode-se afirmar que se faz necessário que o SIF melhore a sua capacidade de isolamento, pois, mesmo apresentando acurácia de detecção semelhante às dos métodos MQP e RNP, sua acurácia no isolamento de falha é menor.

É válido lembrar a influência que o módulo de detecção tem sobre o módulo de isolamento, pois, dado que o diagnóstico é feito de forma hierárquica, um erro de detecção significa obrigatoriamente um erro de isolamento, assim, a comparação da habilidade de dois algoritmos em isolar corretamente uma falha deve ser feita usando acurácia de detecção semelhante.

Tabela 23 – Comparação do Coeficiente de Kappa para os métodos de diagnóstico MQP, RNP, FADFK, OEG e SIF

Método	Coeficiente de Kappa
MQP	0.588
RNP	0.59
FADFK	0.627
OEG	0.617
SIF	0.517

A Figura 31 e a Figura 32 apresentam o *PCC* para os cinco métodos de diagnóstico em relação às falhas abruptas e rápidas, respectivamente. Conforme mencionado, falhas abruptas tendem a ser mais facilmente isoladas que falhas rápidas, e é perceptível que o método SIF apresenta *PCC* semelhante aos dos demais métodos para as falhas Fan, LPC, HPC, HPT, LPT, VSV, Nf e WF36. No entanto, para as falhas P24, Ps30, T24, T30, T48 e Pamb, o desempenho do SIF é inferior, indicando que, assim como expresso pelo Coeficiente de Kappa da Tabela 23, sua capacidade de isolamento necessita de aprimoramento. No que diz respeito às falhas LPC, VBV, Nc, P2 e Pamb, houve dificuldade de diagnosticá-las, revelando que são inerentemente mais difíceis de detectar.




Figura 31 – Comparação da métrica *PCC* para os métodos de diagnóstico MQP, RNP, FADFK, OEG e SIF para falhas abruptas.

Em relação à capacidade de diagnóstico para falhas em componentes, sensores e atuadores, pode-se dizer que, de modo geral, as falhas em nível de componente são mais fáceis de detectar, pois todos os métodos apresentaram bons resultados, exceto para o LPC; os algoritmos apresentaram bons resultados para

falhas no atuador VSV, mas resultados ruins para as falhas no atuador VBV. Finalmente, em relação às falhas em sensores, há algumas de diagnóstico fácil (Nf, P24, T24, T30, T48, WF36 e T2) e outras nem tanto (Nc, Ps30, P2 e Pamb), embora o SIF tenha apresentado desempenho pior para falhas em sensores.




Figura 32 – Comparação da métrica *PCC* para os métodos de diagnóstico MQP, RNP, FADFK, OEG e SIF para falhas rápidas.

Embora o método aqui proposto – SIF – tenha apresentado menor habilidade de isolar as falhas do que os métodos MQP, RNP, FADFK e OEG, é importante reforçar novamente que a interpretabilidade linguística é uma vantagem importante. Para efeito de ilustração, a Tabela 24 e a Tabela 25 exibem, respectivamente, regras de detecção e isolamento de falhas ativadas durante a avaliação da falha no componente Fan. Estas tabelas mostram os antecedentes das regras ativadas, $N(\nabla \hat{r}_i(k))$, para as sete medições usadas como entradas, o consequente e o operador de cada regra. Por meio destas tabelas, é possível afirmar que houve detecção de falha, pois um dos parâmetros de entrada apresentou valores inferiores ao normal (referência saudável). E a falha é do tipo Fan, pois os parâmetros N_c , P_{24} , Ps_{30} , T_{30} , T_{48} e w_f apresentaram valores inferiores ao normal, enquanto que o parâmetro T_{24} se manteve dentro da normalidade.

Tabela 24 – Regra ativada durante avaliação de falha Fan para o módulo de detecção de falha.

Nc	P24	Ps30	T24	T30	T48	Wf	Consequente	Operador
r2-	r2-	r2-	r2-	r2-	r2-	r2-	Falha	<i>OR</i>

Tabela 25 – Regra ativada durante avaliação de falha Fan para o módulo de detecção de falha.

Nc	P24	Ps30	T24	T30	T48	Wf	Consequente	Operador
r2-	r1-	r2-	N	r2-	r2-	r2-	Falha	<i>AND</i>

Conclusões

Este trabalho, fundamentado principalmente em fornecer um enfoque de interpretabilidade linguística ao problema de diagnóstico de desempenho de turbinas a gás aeronáuticas, utilizou-se de um Sistema de Inferência *Fuzzy* com extração automática de regras via método Wang & Mendel. A partir de falhas simuladas por um software especialista, foi possível desenvolver os módulos de pré-processamento, detecção e isolamento de falhas, validá-los e comparar o seu desempenho com os de outros métodos disponíveis na literatura aberta de diagnóstico.

O modelo propõe uma abordagem de diagnóstico residual – medições da turbina real são comparadas frente a uma referência de turbina saudável – acrescida de etapas de tratamento dos dados brutos para melhor adequá-los às etapas seguintes de detecção e isolamento de falhas. Desta forma, os dados brutos são corrigidos, comparados a uma referência de turbina saudável, gerando os resíduos que são então filtrados, comparados com a mesma turbina em alguns voos anteriores e, finalmente, normalizados.

Do total de onze medições disponíveis, quatro são usadas para estabelecer as condições de operação do motor e correções dos demais parâmetros. As outras sete são usadas como entradas para os módulos de detecção e isolamento de falhas, ambos constituídos por SIFs que atuam de forma hierárquica.

Após um longo processo de ajuste manual dos parâmetros de configuração dos módulos de detecção e isolamento de falhas, a configuração que apresentou melhores resultados foi testada para uma base de dados projetada para ser a mais próxima da realidade. Os resultados finais foram analisados para diferentes métricas de diagnóstico e explicitados para falhas em componentes, sensores e atuadores e de naturezas distintas, tais como diferentes níveis de severidades e diferentes taxas de evolução temporal.

O módulo de detecção de falha apresentou resultados satisfatórios, uma vez que sua acurácia ficou próxima das apresentadas por outros métodos. Sua interpretabilidade linguística foi consideravelmente melhorada pela agregação das

regras geradas: com apenas 193 regras, este módulo atingiu um excelente compromisso entre interpretabilidade e acurácia.

O módulo de isolamento de falhas apresentou resultados inferiores aos dos demais métodos disponíveis na literatura. Apesar de apresentar boa capacidade de isolamento para algumas falhas, principalmente em nível de componente, seu *PCC* foi consideravelmente inferior para outras, em especial para aquelas em sensores.

No que diz respeito à interpretabilidade, o módulo de isolamento apresentou um nível menor de interpretabilidade do que o módulo de detecção. Considerando que o isolamento tem 18 classes de saídas – frente a 2 classes na detecção –, a etapa manual de agregação das regras geradas via Wang & Mendel não foi possível de ser realizada. Ainda assim, foi verificado que poucas regras são ativadas durante a sua avaliação, favorecendo, em consequência, o quesito interpretabilidade.

Com base nos resultados obtidos, é possível afirmar que os objetivos deste trabalho foram alcançados. Independentemente da necessidade de uma maior acurácia no módulo de isolamento, um Sistema de Inferência *Fuzzy* hierárquico e dedicado ao diagnóstico de desempenho de turbinas a gás foi desenvolvido e testado frente a falhas em nível de componentes, sensores e atuadores, levando em consideração a evolução temporal (abrupta e rápida), diferentes níveis de severidades (baixa, média e alta) de falhas e tendo sempre em vista a interpretabilidade.

Como trabalhos futuros, pode-se citar:

- Otimização do módulo de isolamento, principalmente quanto à sua acurácia;
- Uso do Teste de Tukey (BRETZ; HOTHORN; WESTFALL, 2016) para minimizar a tendência em confundir a falha do sensor com a falha do componente localizado em sua vizinhança;
- Informações redundantes e inconsistentes normalmente estão presentes na base de treinamento, provocando o aumento de regras conflitantes (SIQUEIRA et al., 2014), i.e., com antecedentes iguais e consequentes diferentes. Nesta situação, o método de Wang-Mendel sugere o descarte destas regras. O sistema desenvolvido neste trabalho apresentou certa dificuldade em diferenciar a falha do

sensor da falha no componente localizado em sua vizinhança – observaram-se muitas regras conflitantes para esta situação (vide matriz de confusão da Figura 24). Sugere-se como estudo futuro a possibilidade de manter, criteriosamente, regras conflitantes;

- Como as etapas de ajuste manual dos SIFs de detecção e isolamento são extremamente custosas, seria aconselhável fazer uso de um otimizador como Algoritmos Genéticos para encontrar uma configuração ótima dos módulos. Sugere-se uma otimização multi-objetivo entre a métrica VP e alarme falso para o módulo de detecção e uma otimização simples do Coeficiente de Kappa para o módulo de isolamento;
- Agregação de regras por Algoritmos Genéticos, por exemplo;
- Utilização de Sistemas *Fuzzy* Genéticos para geração de regras buscando atender ao compromisso acurácia x interpretabilidade.

Referências bibliográficas

FREIRE, R.L.A.; BARBOSA, J.R. **Development and Validation of a Methodology for Stationary Gas Turbine Performance Prognostic**. In: ASME Turbo Expo 2013: Turbine Technical Conference and Exposition. San Antonio: 2013.

BARBOSA, R.; FERREIRA, S. **Industrial gas turbine diagnostics using fuzzy logic**. In: ASME Turbo Expo 2012: Turbine Technical Conference and Exposition. p. 803-808. Copenhagen, 2012.

BARBOSA, R.S. **Diagnóstico de Falhas de Turbinas a Gás com o Uso de Lógica Fuzzy**. 2010. Dissertação. PUC-Rio.

BO, M.; ZHI-NONG, J.; ZHONG-QING, W. **Development of the Task-Based Expert System for Machine Fault Diagnosis**. In: Journal of Physics: Conference Series. p. 012043. IOP Publishing, 2012.

BORGUET, S. **Variations on the Kalman filter for enhanced performance monitoring of gas turbine engines**. 2012. Tese de Doutorado. Université de Liège, Bélgica.

BOYCE, M.P. **Gas turbine engineering handbook**. Elsevier, 2011.

BRETZ, F.; HOTHORN, T.; WESTFALL, P. **Multiple comparisons using R**. CRC Press, 2016.

BROCKWELL, P.J.; DAVIS, R.A. **Introduction to time series and forecasting**. Springer Science & Business Media, 2006.

CINTRA, M.E. **Geração Genética de Regras Fuzzy com pré-seleção de regras Candidatas**. Encontro Nacional de Inteligência Artificial – ENIA. p. 1341-1350. Rio de Janeiro, 2007.

CLIFTON, D.; TARASSENKO, L. **Condition monitoring of gas-turbine engines**. Transfer Report, Department of Engineering Science, University of Oxford, 2006.

DEPOLD, H.R.; GASS, F.D. **The application of expert systems and neural networks to gas turbine prognostics and diagnostics**. In: ASME 1998 International Gas Turbine and Aeroengine Congress and Exhibition. Stockholm, 1998.

DIAKUNCHAK S.I. **Performance deterioration in industrial gas turbines**. Journal of Engineering for Gas Turbines and Power. v. 114, n. 2, p. 161-168, 1992.

FLEMING, D. et al. **Corrosion and Erosion Behavior in Supercritical CO2 Power Cycles**. In: ASME Turbo Expo 2014: Turbine Technical Conference and Exposition. Düsseldorf, 2014.

FRANK, P.M.; KÖPPEN-SELIGER, B. **Fuzzy logic and neural network applications to fault diagnosis**. International Journal of Approximate Reasoning, v. 16, n. 1, p. 67-88, 1997.

GANGULI, R. **Application of Fuzzy Logic for Fault Isolation of Jet Engines**. Journal of Engineering for Gas Turbines and Power, 2003.

HEIMES, F.O.; SYSTEMS, B.A.E. **Recurrent Neural Networks for Remaining Useful Life Estimation**. Prognostics and Health Management. PHM 2008. p. 1-6, 2008.

ISHIBASHI, R.; LÚCIO, C.; JÚNIOR, N. **GFRBS-PHM: A Genetic Fuzzy Rule-Based System for PHM with Improved Interpretability**. Prognostics and Health Management (PHM), p. 1-7, 2013 IEEE Conference on. IEEE, 2013.

ISHIBUCHI, H.; NOJIMA, Y. **Analysis of interpretability-accuracy tradeoff of fuzzy systems by multiobjective fuzzy genetics-based machine learning**. International Journal of Approximate Reasoning, v. 44, n. 1, p. 4-31, 2007.

JARDINE, A.K.S.; LIN, D.; BANJEVIC, D. **A review on machinery diagnostics and prognostics implementing condition-based maintenance**. Mechanical Systems and Signal Processing, v. 20, n. 7, p. 1483-1510, out. 2006.

JAW, L.C. **Recent advancements in aircraft engine health management (EHM) technologies and recommendations for the next step**. ASME Turbo Expo 2005: Power for Land, Sea, and Air. Reno, 2005.

KONG, C. **Review on Advanced Health Monitoring Methods for Aero Gas Turbines using Model Based Methods and Artificial Intelligent Methods**. International Journal of Aeronautical and Space Sciences, v. 15, n. 2, p. 123-137, 2014.

KOPYTOV, E.; LABENDIK, V.; YUNUSOV, S. **Diagnostics models in expert systems of measuring the status condition of the aircraft power plants**. International Conference Reliability and Statistics in Transportation and Communication, p. 355-361, Riga, 2009.

KOSKO, B. **Fuzzy engineering**. Prentice-Hall, Inc., 1996.

KURZ, R.; BRUN, K. **Fouling Mechanisms in Axial Compressors**. Journal of Engineering for Gas Turbines and Power, v. 134, n. 3, p. 32401, 2012.

LARSSON, E. **Model Based Diagnosis and Supervision of Industrial Gas Turbines**. 2014. Dissertação. Linköping University.

LI, Y.G. **Performance-analysis-based gas turbine diagnostics: A review**. Proceedings of the Institution of Mechanical Engineers, Part A: Journal of Power and Energy, v. 216, n. 5, p. 363-377, 2002.

LOBODA, I. **Gas Turbine Condition Monitoring and Diagnostics**. INTECH Open Access Publisher, 2010.

MARINAI, L. **Gas-path Diagnostics and Prognostics for Aero-engines Using Fuzzy Logic and Time Series Analysis**. 2004. Tese de Doutorado. Cranfield University, Inglaterra.

MARINAI, L.; PROBERT, D.; SINGH, R. **Prospects for aero gas-turbine diagnostics: a review**. Applied Energy, v. 79, n. 1, p. 109-126, 2004.

MARINAI, L.; SINGH, R. **A fuzzy logic approach to gas path diagnostics in aero-engines**. In: Computational Intelligence in Fault Diagnosis. Springer, p. 37-79, 2006.

MARTIN, K.F. **A review by discussion of condition monitoring and fault diagnosis in machine tools**. International Journal of Machine Tools and Manufacture, v. 34, n. 4, p. 527-551, 1994.

MONTEIRO, U.A.B.V. **Simulação Termodinâmica de Turbinas a Gás para Diagnóstico de Falhas**. 2010. Tese de Doutorado. Universidade Federal do Rio de Janeiro.

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

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

PEEL, L.; GOLD, I. **Data Driven Prognostics using a Kalman Filter Ensemble of Neural Network Models**. Prognostics and Health Management, 2008. PHM 2008. International Conference on. IEEE, p. 1-6, 2008.

PENG, Y. et al. **A modified echo state network based remaining useful life estimation approach**. 2012 IEEE Conference on Prognostics and Health Management, p. 1-7, 2012.

PINTO, G.R.S. **Avaliação do desempenho de usinas termelétricas a ciclo combinado integradas com gaseificação via integração de programas especialistas**. 2015. Dissertação. Universidade Federal do Rio de Janeiro.

ROUMELIOTIS, I. et al. **Modelling and Assessment of Compressor Faults on Marine Gas Turbines**. ASME Turbo Expo 2012: Turbine Technical Conference and Exposition. p. 375-386. Copenhagen, 2012.

ROUPA, A. et al. **Study of Wash Fluid Cleaning Effectiveness on Industrial Gas Turbine Compressor Foulants**. ASME Turbo Expo 2013: Turbine Technical Conference and Exposition. San Antonio, 2013.

SAMARASINGHE, S. **Neural networks for applied sciences and engineering: from fundamentals to complex pattern recognition**. CRC Press, 2006.

SARAVANAMUTTOO, H.I.H.; ROGERS, G.F.C.; COHEN, H. **Gas turbine theory**. Pearson Education, 2001.

SIKORSKA, J.Z.; HODKIEWICZ, M.; MA, L. **Prognostic modelling options for remaining useful life estimation by industry**. Mechanical Systems and Signal Processing, v. 25, n. 5, p. 1803-1836, 2011.

SIMON, D.L. et al. **Benchmarking Gas Path Diagnostic Methods: A Public Approach**. ASME Turbo Expo 2008: Power for Land, Sea, and Air. p. 325-336. 2008.

SIMON, D.L. **Propulsion Diagnostic Method Evaluation Strategy (ProDiMES) User's Guide**. Citeseer, 2010.

SIMON, D.L. et al. **Aircraft Engine Gas Path Diagnostic Methods: Public Benchmarking Results**. Journal of Engineering for Gas Turbines and Power, v. 136, n. 4, p. 41201, 2013.

SIQUEIRA, J.M. et al. **Generating fuzzy rules by learning from olive tree transpiration measurement—An algorithm to automatize Granier sap flow data analysis**. Computers and Electronics in Agriculture, v. 101, p. 1-10, 2014.

SORSA, T.; KOIVO, H. N. **Application of artificial neural networks in process fault diagnosis**. Automatica, v. 29, n. 4, p. 843-849, 1993.

TAYARANI-BATHAIE, S.S.; VANINI, Z.N.S.; KHORASANI, K. **Dynamic neural network-based fault diagnosis of gas turbine engines**. Neurocomputing, v. 125, p. 153-165, 2014.

URBAN, L.A. **Gas path analysis applied to turbine engine condition monitoring**. Journal of Aircraft, v. 10, n. 7, p. 400-406, 1973.

VOLPONI, A.J. **Gas turbine parameter corrections**. ASME 1998 International Gas Turbine and Aeroengine Congress and Exhibition. Stockholm, 1998.

VOLPONI, A.J. et al. **The Use of Kalman Filter and Neural Network Methodologies in Gas Turbine Performance Diagnostics: A Comparative Study**. Journal of Engineering for Gas Turbines and Power, v. 125, n. 4, p. 917, 2003.

WANG, L.-X.; MENDEL, J.M. **Generating fuzzy rules by learning from examples**. Fuzzy Systems IEEE Transactions on, vol. 6, pp. 362-372, 1992.

YANG, H.; XU, H. **Numerical Simulation of Gas-Solid Two Phase Flow in Fouled Axial Flow Compressor**. ASME Turbo Expo 2014: Turbine Technical Conference and Exposition. Düsseldorf, 2014.

ZHAO, N. et al. **Remote intelligent expert system for operation state of marine gas turbine engine**. Intelligent Control and Automation (WCICA), 2014 11th World Congress on. IEEE, p. 3210-3215, 2014.