



UNIVERSIDADE FEDERAL DE CAMPINA GRANDE  
CENTRO DE ENGENHARIA ELÉTRICA E INFORMÁTICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA  
ELÉTRICA

# **Diagnóstico de Falhas em Turbogenerador de Plataforma de Produção de Óleo e Gás Tipo FPSO**

Tese de Doutorado

**Patrício Fernandes de Castro**

**Orientadores:**

**Prof. Dr. George Rossany Soares de Lira**

**Prof. Dr. Pablo Bezerra Vilar**

Campina Grande - PB

Agosto de 2024





UNIVERSIDADE FEDERAL DE CAMPINA GRANDE  
CENTRO DE ENGENHARIA ELÉTRICA E INFORMÁTICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA  
ELÉTRICA

# Diagnóstico de Falhas em Turbogenerador de Plataforma de Produção de Óleo e Gás Tipo FPSO

Patrício Fernandes de Castro

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Campina Grande, como parte dos requisitos necessários para obtenção do grau de Doutor em Ciências no Domínio da Engenharia Elétrica.

Área de Concentração: Processamento da Energia

Orientadores:

Prof. Dr. George Rossany Soares de Lira

Prof. Dr. Pablo Bezerra Vilar

Campina Grande - PB

Agosto de 2024

C355d

Castro, Patrício Fernandes de.

Diagnóstico de falhas em turbogerador de plataforma de produção de óleo e gás tipo FPSO / Patrício Fernandes de Castro. – Campina Grande, 2024.

109 f. : il. color.

Tese (Doutorado em Engenharia Elétrica) – Universidade Federal de Campina Grande, Centro de Engenharia Elétrica e Informática, 2024.

"Orientação: Prof. Dr. George Rossany Soares de Lira, Prof. Dr. Pablo Bezerra Vilar".

Referências.

1. Sistema de Inferência Fuzzy (SIF). 2. Diagnóstico de Falha. 3. Turbogenerador. 4. *Floating Production Storage and Offloading – FPSO*. I. Lira, George Rossany Soares de. II. Vilar, Pablo Bezerra. III. Título.

CDU 621.3(043)

# Diagnóstico de Falhas em Turboogerador de Plataforma de Produção de Óleo e Gás Tipo FPSO

Patrício Fernandes de Castro

Tese aprovada. Campina Grande - PB, 14 de Agosto de 2024:



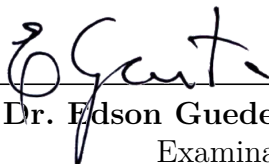
---

Prof. Dr. George Rossany Soares de Lira, UFCG  
Orientador



---

Prof. Dr. Pablo Bezerra Vilar, UFCG  
Orientador



---

Prof. Dr. Edson Guedes da Costa, UFCG  
Examinador



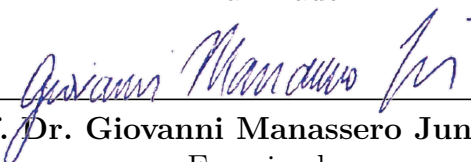
---

Prof. Dr. Karcus Marcelus Colaço Dantas, UFCG  
Examinador



---

Prof. Dr. Fabrício Braga Soares de Carvalho, UFPB  
Examinador



---

Prof. Dr. Giovanni Manassero Junior, USP  
Examinador



---

Dr. André da Silva Pelliccione, Petrobras  
Examinador

Campina Grande - PB



MINISTÉRIO DA EDUCAÇÃO  
**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE**  
POS-GRADUACAO EM ENGENHARIA ELETRICA  
Rua Aprigio Veloso, 882, - Bairro Universitario, Campina Grande/PB, CEP 58429-900

### REGISTRO DE PRESENÇA E ASSINATURAS

1. ATA DA DEFESA PARA CONCESSÃO DO GRAU DE DOUTOR EM CIÊNCIAS, NO DOMÍNIO DA ENGENHARIA ELÉTRICA, REALIZADA EM 14 DE AGOSTO DE 2024

**(Nº 379)**

CANDIDATO(A): **PATRÍCIO FERNANDES DE CASTRO**. COMISSÃO EXAMINADORA: EDSON GUEDES DA COSTA, D.Sc., UFCG - Presidente da Comissão e Examinador interno, GEORGE ROSSANY SOARES DE LIRA, D.Sc., UFCG, PABLO BEZERRA VILAR, D.Sc., UFCG, Orientadores, KARCIUS MARCELUS COLAÇO DANTAS, D.Sc., UFCG, Examinador Interno, FABRÍCIO BRAGA SOARES DE CARVALHO, Dr., UFPB, GIOVANNI MANASSERO JUNIOR, Dr., USP, ANDRÉ DA SILVA PELLICCIONE, Dr., Petrobras, Examinadores Externos. TÍTULO DA TESE: Diagnóstico de falhas em turbogerador de plataforma de produção de óleo e gás tipo FPSO. ÁREA DE CONCENTRAÇÃO: Processamento da Energia. HORA DE INÍCIO: **09h30** – LOCAL: **Auditório do Laboratório de Alta Tensão e Sala Virtual, conforme Art. 5º da PORTARIA SEI Nº 01/PRPG/UFCG/GPR, DE 09 DE MAIO DE 2022**. Em sessão pública, após exposição de cerca de 45 minutos, o(a) candidato(a) foi arguido(a) oralmente pelos membros da Comissão Examinadora, tendo demonstrado suficiência de conhecimento e capacidade de sistematização, no tema de sua tese, obtendo conceito APROVADO. Face à aprovação, declara o presidente da Comissão, achar-se o examinado, legalmente habilitado a receber o Grau de Doutor em Ciências, no domínio da Engenharia Elétrica, cabendo a Universidade Federal de Campina Grande, como de direito, providenciar a expedição do Diploma, a que o(a) mesmo(a) faz jus. Na forma regulamentar, foi lavrada a presente ata, que é assinada por mim, Leandro Ferreira de Lima, e os membros da Comissão Examinadora. Campina Grande, 14 de Agosto de 2024.

LEANDRO FERREIRA DE LIMA

Secretário

EDSON GUEDES DA COSTA, D.Sc., UFCG

Presidente da Comissão e Examinador Interno

GEORGE ROSSANY SOARES DE LIRA, D.Sc., UFCG

Orientador

PABLO BEZERRA VILAR, D.Sc., UFCG

Orientador

KARCIUS MARCELUS COLAÇO DANTAS, D.Sc., UFCG  
Examinador Interno

FABRÍCIO BRAGA SOARES DE CARVALHO, Dr., UFPB  
Examinador Externo

GIOVANNI MANASSERO JUNIOR, Dr., USP  
Examinador Externo

ANDRÉ DA SILVA PELLICCIONE, Dr., Petrobras  
Examinador Externo

PATRÍCIO FERNANDES DE CASTRO  
Candidato

## 2 - APROVAÇÃO

2.1. Segue a presente Ata de Defesa de Tese de Doutorado da candidato **PATRÍCIO FERNANDES DE CASTRO**, assinada eletronicamente pela Comissão Examinadora acima identificada.

2.2. No caso de examinadores externos que não possuam credenciamento de usuário externo ativo no SEI, para igual assinatura eletrônica, os examinadores internos signatários **certificam** que os examinadores externos acima identificados participaram da defesa da tese e tomaram conhecimento do teor deste documento.



Documento assinado eletronicamente por **LEANDRO FERREIRA DE LIMA, SECRETÁRIO (A)**, em 16/08/2024, às 10:41, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **KARCIUS MARCELUS COLACO DANTAS, PROFESSOR 3 GRAU**, em 16/08/2024, às 10:56, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **EDSON GUEDES DA COSTA, PROFESSOR 3 GRAU**, em 16/08/2024, às 12:29, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **PABLO BEZERRA VILAR, PROFESSOR(A) DO MAGISTERIO SUPERIOR**, em 19/08/2024, às 09:05, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **GEORGE ROSSANY SOARES DE LIRA, PROFESSOR(A) DO MAGISTERIO SUPERIOR**, em 19/08/2024, às 15:26, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **Patrício Fernandes de Castro, Usuário Externo**, em 26/08/2024, às 10:45, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).

---



A autenticidade deste documento pode ser conferida no site <https://sei.ufcg.edu.br/autenticidade>, informando o código verificador **4705115** e o código CRC **B3524311**.

---

Referência: Processo nº 23096.054849/2024-62

SEI nº 4705115



*Aos meus amados pais, Paulo (in memoriam) e Maria José, a eles todos os créditos pela minha educação e pessoa que me tornei.*

*À minha amada esposa Iara, e ao meu amado filho Heitor, pelo tempo que deixamos de estar juntos e pelo apoio que sempre me foi dado.*

Dedico



# Agradecimentos

Primeiramente a Deus pela força dada para a execução desse trabalho.

À Petrobras na pessoa do Sr. Guilherme Fortes pela autorização para utilização dos dados necessários para a realização desse trabalho e ao Sr. Rafael Tavares pelo suporte dado na publicação do artigo relacionado a desse trabalho.

Ao Prof. Dr. George Rossany Soares de Lira pelo constante incentivo à pesquisa e pelas orientações no período.

Ao Prof. Dr. Pablo Bezerra Vilar pelo apoio dado e pelas orientações no período.

Ao Prof. Dr. Edson Guedes da Costa, pela dedicação nas correções e orientações neste período de aprendizado.

Aos meus colegas de pós-graduação que tornaram um período de longa dedicação em algo divertido.



*"A persistência é o menor caminho do êxito."  
(Charles Chaplin, My Autobiography, 1964)*



# Resumo

O presente trabalho propõe uma análise diagnóstica dos dados operacionais de um sistema de óleo lubrificante mineral de turbogeradores, utilizando um sistema de inferência fuzzy (SIF). O estudo utiliza dados operacionais reais coletados de sensores de monitoramento supervisão em quatro turbogeradores instalados em unidades flutuantes de produção, armazenamento e transferência de petróleo e gás (FPSO, do inglês: *Floating Production Storage and Offloading*), ao longo de um período operacional de três anos, resultando em um conjunto de dados composto por 40.456.663 padrões de entrada. Os modos de falha foram estabelecidos por meio do conhecimento especializado, utilizando a análise de criticidade, modos e efeitos de falhas (FMECA, do inglês: *Failure Mode, Effect, and Criticality Analysis*) como base. Inicialmente, as variáveis universo do modelo foram construídas utilizando a faixa de calibração dos sensores, e em seguida, funções de pertinência trapezoidais fuzzy foram formuladas com base nos limites operacionais de cada parâmetro medido. O modelo de diagnóstico de falhas é fundamentado em um sistema de inferência fuzzy que emprega regras predefinidas, provenientes do conhecimento especializado, que encapsula tipologias de falhas específicas do sistema de óleo lubrificante mineral dos turbogeradores, utilizando a FMECA como base para definição dos modos de falhas e partes afetadas desse sistema. O SIF empregado como ferramenta de inteligência artificial (IA) demonstra eficácia no diagnóstico de falhas, com uma avaliação geral do desempenho do sistema que produz resultados satisfatórios, apresentando uma taxa de verdadeiro positivo de 98,35% para a classificação de falhas, juntamente com uma taxa de verdadeiro negativo para a classificação da condição de operação normal do sistema. Esses resultados destacam a viabilidade do modelo SIF para o diagnóstico de falhas do sistema de óleo lubrificante mineral dos turbogeradores, mostrando assim seu potencial para a melhoria da confiabilidade operacional e a eficiência da manutenção desses equipamentos. O modelo pode automatizar o processo de registro de falhas, fornecendo informações sobre as ocorrências de falhas e contribuindo para o seu registro e diagnóstico.

**Palavras-chave:** Sistema de Inferência Fuzzy; Diagnóstico de Falha; Turbogenerador; FPSO; Análise de Criticidade, Modos e Efeitos de Falhas (FMECA).





# Abstract

This work proposes a diagnostic analysis of the operational data of a turbogenerator mineral lubricating oil system, using a fuzzy inference system (FIS). The study uses real operational data collected from supervisory monitoring sensors in four turbogenerators installed in a Floating Production, Storage and Offloading Unit (FPSO) over a three-year operational period, resulting in a dataset composed of 40,456,663 input patterns. The failure modes were established through expert knowledge, using the Failure Mode, Effect, and Criticality Analysis (FMECA) documentation as a basis. Initially, the universe variables of the model were constructed using the calibration range of the sensors, and then, fuzzy trapezoidal membership functions were formulated based on the operational limits of each measured parameter. The fault diagnosis model is based on a fuzzy inference system that employs predefined rules derived from expert knowledge, which encapsulates specific fault typologies of the mineral lubricating oil system of turbogenerators, using FMECA as a basis for defining the failure modes and affected parts of this system. The FIS employed as an Artificial Intelligence (AI) tool demonstrates effectiveness in fault diagnosis, with an overall assessment of the system performance that produces satisfactory results, presenting a true positive rate of 98.35% for fault classification, together with a true negative rate of 99.99% for the classification of the normal operating condition of the system. These results highlight the viability of the FIS model for fault diagnosis of the mineral lubricating oil system of turbogenerators, thus showing its potential to improve the operational reliability and maintenance efficiency of these equipments. The model can automate the fault recording process, providing information on fault occurrences and contributing to their recording and diagnosis.

**Keywords:** Fuzzy Inference System; Failure Diagnosis; Turbogenerator; FPSO; Failure Mode, Effect, and Criticality Analysis (FMECA)



# Lista de ilustrações

Figura 1 – Plataforma de Produção de Óleo e Gás Tipo FPSO . . . . .	27
Figura 2 – Modelo de Diagnóstico de Falhas Atual . . . . .	29
Figura 3 – Modelo de Diagnóstico de Falhas Proposto . . . . .	30
Figura 4 – Sistema Elétrico da FPSO . . . . .	37
Figura 5 – Sistemas e subsistemas do turbogerador . . . . .	39
Figura 6 – Diagrama esquemático da turbina . . . . .	41
Figura 7 – Diagrama esquemático do sistema de óleo mineral . . . . .	43
Figura 8 – Arquitetura do SIF . . . . .	45
Figura 9 – Funções de pertinência típicas . . . . .	46
Figura 10 – Metodologia processo padrão inter-indústrias para mineração de dados (CRISP-DM, do inglês: <i>Cross Industry Standard Process for Data Mining</i> ) aplicada no SIF . . . . .	65
Figura 11 – Processo de coleta e seleção de dados . . . . .	71
Figura 12 – Limites das variáveis operacionais . . . . .	72
Figura 13 – Diagrama de fluxo do algoritmo empregado para o diagnóstico de falhas utilizando o SIF . . . . .	80
Figura 14 – Falhas por gerador no período de 1 ano . . . . .	82
Figura 15 – Funções de saída do SIF para classificação de falhas . . . . .	88



# Lista de tabelas

Tabela 1 – Quadro comparativo SIF x ANFIS . . . . .	51
Tabela 2 – Comparativo entre a revisão bibliográfica e o presente trabalho . . . . .	62
Tabela 3 – Partes afetadas e modos de falha do sistema de óleo mineral . . . . .	69
Tabela 4 – Variáveis de monitoramento do sistema de óleo mineral . . . . .	70
Tabela 5 – Variáveis dos conjuntos fuzzy do modelo de diagnóstico de falhas . . . . .	74
Tabela 6 – Conjunto de regras do SIF para diagnóstico de falhas do sistema de óleo mineral . . . . .	76
Tabela 7 – Limites das saídas <i>crisp</i> de diagnóstico do sistema de óleo mineral . . . . .	77
Tabela 8 – Matriz de correlação entre partes afetadas, modos de falha e meio de detecção . . . . .	83
Tabela 9 – Variáveis de monitoramento do sistema de óleo mineral . . . . .	84
Tabela 10 – Limites das entradas <i>crisp</i> do sistema de óleo lubrificante mineral . . . . .	85
Tabela 11 – Parâmetros das funções de pertinência trapezoidais da parcela antecedente	86
Tabela 12 – Parâmetros das funções de pertinência triangulares da parcela consequente	87
Tabela 13 – Avaliação do período e resultados . . . . .	88
Tabela 14 – Critério de desempenho do SIF . . . . .	89



# Lista de abreviaturas e siglas

AF	Ar Forçada
AN	Ar Natural
ANFIS	Sistema de Inferência Fuzzy Adaptativo (do inglês: <i>Adaptive Neuro-Fuzzy Inference System</i> )
AVR	Regulador Automático de Tensão (do inglês: <i>Automatic Voltage Regulator</i> )
BGRU	Unidade Recorrente Fechada Bidirecional (do inglês: <i>Bidirectional Gated Recurrent Unit</i> )
BPD	Barris por Dia
CA	Corrente Alternada
CC	Corrente Contínua
CCM	Centro de Controle de Motores
CDC	Centro de Distribuição de Carga
CRISP-DM	Processo Padrão Inter-indústrias para Mineração de Dados (do inglês: <i>Cross Industry Standard Process for Data Mining</i> )
CNN	Rede Neural Convolutacional (do inglês: <i>Convolutional Neural Network</i> )
FMECA	Análise de Criticidade, Modos e Efeitos de Falhas (do inglês: <i>Failure Mode, Effect, and Criticality Analysis</i> )
FP	Falso Positivo
FPSO	Unidade Flutuante de Produção, Armazenamento e Transferência de Petróleo e Gás (do inglês: <i>Floating Production Storage and Offloading</i> )
FN	Falso Negativo
GG	Turbina Geradora de Gás
GGI	Gerador de Gás Inerte
HSPT	Turbina de Alta Pressão (do inglês: <i>High-speed Power Turbine</i> )
HPU	Unidade Hidráulica de Potência (do inglês: <i>Hydraulic Power Unit</i> )

IA	Inteligência Artificial
IU	Interface de Usuário
MTTR	Tempo Médio de Reparo (do inglês: <i>Mean Time To Repair</i> )
NASA	Administração Nacional de Aeronáutica e Espaço dos Estados Unidos (do inglês: <i>National Aeronautics and Space Administration</i> )
PI	Historiador da Planta de Processo (do inglês: <i>Plant Information</i> )
PT	Turbina de Potência (do inglês: <i>Power Turbine</i> )
P&ID	Diagrama de Processos e Instrumentação (do inglês: <i>Piping and Instrumentation Diagram</i> )
PMG	Gerador de Ímã Permanente (do inglês: <i>Permanent Magnet Generator</i> )
REM	Registro de Evento de Máquina
RNA	Rede Neural Artificial
SCADA	Sistema de Supervisão e Aquisição de Dados (do inglês: <i>Supervisory Control and Data Acquisition</i> )
SIF	Sistema de Inferência Fuzzy
SNF	Sistema de Neuro-Fuzzy
SVM	Máquina de Vetores de Suporte (do inglês: <i>Support Vector Machine</i> )
SVR	Regressão de Vetores de Suporte (do inglês: <i>Support Vector Regression</i> )
TCV	Válvula de Controle de Temperatura (do inglês: <i>Temperature Control Valve</i> )
TF	Transformador de Potência
TG	Turbogerador
UEP	Unidade Estacionária de Produção de Petróleo e Gás
UPS	Sistema de Energia Ininterrupta (do inglês: <i>Uninterruptible Power Supply</i> )
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo



# Lista de símbolos

$\mu$	Letra grega minúscula Mi
$\sigma$	Letra grega minúscula Sigma
$\forall$	Para todo
$\in$	Pertence
$\vee$	Operador lógico “ou”
$\wedge$	Operador lógico “e”
$\cup$	Operador união de conjuntos
$\cap$	Operador intersecção de conjuntos
$\leq$	Operador de relação menor igual
$\geq$	Operador de relação maior igual
$\int$	Operador de integração



# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>27</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>35</b>
<b>2.1</b>	<b>Sistema de Geração Elétrica da FPSO</b>	<b>35</b>
2.1.1	Sistema de Distribuição da FPSO	36
2.1.2	Turbogeradores	38
<b>2.2</b>	<b>Sistema de Inferência Fuzzy</b>	<b>43</b>
<b>2.3</b>	<b>Estudo Comparativo entre os Modelos de Inferência Fuzzy e Neuro-Fuzzy</b>	<b>50</b>
<b>2.4</b>	<b>FMECA - Análise de Criticidade, Modos e Efeitos de Falhas</b>	<b>51</b>
<b>2.5</b>	<b>Considerações finais</b>	<b>54</b>
<b>3</b>	<b>REVISÃO BIBLIOGRÁFICA</b>	<b>55</b>
<b>3.1</b>	<b>Diagnóstico de falhas em equipamentos</b>	<b>55</b>
<b>3.2</b>	<b>Diagnóstico de falhas em turbogeradores</b>	<b>60</b>
<b>3.3</b>	<b>Síntese da revisão bibliográfica</b>	<b>61</b>
<b>3.4</b>	<b>Considerações finais</b>	<b>62</b>
<b>4</b>	<b>METODOLOGIA</b>	<b>65</b>
<b>4.1</b>	<b>Entendimento do negócio</b>	<b>67</b>
<b>4.2</b>	<b>Entendimento dos dados</b>	<b>68</b>
<b>4.3</b>	<b>Preparação dos dados e modelagem</b>	<b>71</b>
4.3.1	Processo de modelagem do SIF	74
4.3.2	Codificação	77
<b>4.4</b>	<b>Avaliação</b>	<b>79</b>
<b>4.5</b>	<b>Considerações finais</b>	<b>79</b>
<b>5</b>	<b>RESULTADOS</b>	<b>81</b>
<b>5.1</b>	<b>Entendimento do negócio</b>	<b>81</b>
<b>5.2</b>	<b>Entendimento dos dados</b>	<b>82</b>
<b>5.3</b>	<b>Preparação dos dados e modelagem</b>	<b>85</b>
<b>5.4</b>	<b>Avaliação</b>	<b>89</b>
<b>5.5</b>	<b>Considerações</b>	<b>89</b>
<b>6</b>	<b>CONSIDERAÇÕES FINAIS</b>	<b>93</b>
<b>6.1</b>	<b>Trabalhos futuros</b>	<b>94</b>

Publicações . . . . . 97

Referências Bibliográficas . . . . . 99

**ANEXOS** **105**

**ANEXO A – LISTA DE CARGAS DO SISTEMA DE DISTRIBUI-  
ÇÃO DE ENERGIA ELÉTRICA DO FPSO . . . . . 107**

**A.1 Sistema de distribuição do *topside* . . . . . 107**

**A.2 Sistema de distribuição do casco . . . . . 109**

# 1 Introdução

No Brasil, especialmente nos campos do pré-sal, as FPSO são as instalações de produção mais utilizadas para extração de petróleo e gás natural (PETROBRAS, 2023). Essas plataformas são projetadas tipicamente para a produção superior a 150.000 barris por dia (BPD) de petróleo e 7 milhões de  $m^3$ /dia de gás (PARE, 2019), em novos projetos, essas unidades têm capacidade de produção de até 225.000 BPD de petróleo e 12 milhões de  $m^3$ /dia de gás (OFFSHORE ENGINEER MAGAZINE, 2023; PARE, 2024). A Figura 1 ilustra uma dessas plataformas instaladas atualmente na costa brasileira.

Figura 1 – Plataforma de Produção de Óleo e Gás Tipo FPSO



Referência: (RIBEIRO, 2024).

O sistema elétrico dessas plataformas são isolados e utilizam geradores acionados por turbinas a gás (VOLLET et al., 2017) para o fornecimento de energia elétrica, sendo o sistema de geração um dos principais sistemas dessas unidades, devido à demanda de energia elétrica para o acionamento dos equipamentos de produção de óleo e gás.

O diagnóstico de falhas desempenha um papel fundamental na indústria, pois reduz o tempo de interrupção dos sistemas com aumento em sua disponibilidade. No setor de óleo e gás, sobretudo em unidades com alta produção e custo elevado de interrupção, o aumento da disponibilidade é ainda mais significativo. Portanto, a utilização de técnicas de diagnóstico de falhas é uma ferramenta importante na prescrição de ações corretivas e preventivas para equipamentos e sistemas (GUAN et al., 2021).

A manutenção corretiva é executada quando um item ou equipamento apresenta

algum tipo de falha, buscando restaurar seu funcionamento normal. A manutenção preventiva é realizada de forma programada e regular, com base em um plano prévio, com o objetivo de evitar a ocorrência de falhas e garantir a operação contínua e eficiente dos equipamentos.

A manutenção preventiva pode ser dividida em três subcategorias: teste e inspeção, monitoramento da condição (preditiva/prescritiva) e periódica (ISO CENTRAL SECRETARY, 2006).

Em geral, a equipe de operação é responsável pela realização de preventivas, incluindo testes em equipamentos de reserva, como geradores de emergência, geradores auxiliares e bombas de combate a incêndio. Além disso, eles também conduzem inspeções preventivas, verificando parâmetros operacionais, lendo instrumentos e realizando avaliações visuais e auditivas. Essas medidas garantem a manutenção adequada e a prontidão dos equipamentos em caso de necessidade.

O monitoramento da condição, também conhecido como manutenção preditiva, envolve a medição de parâmetros do equipamento monitorado, que indicam se o equipamento está entrando em condição de degradação devido à alteração desses parâmetros. A manutenção prescritiva envolve a utilização de dados coletados e algoritmos de IA na prescrição de manutenções. Neste caso, o objetivo vai além do prever o que vai acontecer, tendo em vista a sugestão reparos baseados nos dados coletados.

Por sua vez, a manutenção preventiva periódica é caracterizada por um plano de manutenção baseado em calendário ou horas de funcionamento do equipamento. Quando o período determinado é atingido, o equipamento passa por uma intervenção para reestabelecer suas condições operacionais.

Ambas as categorias de manutenção são importantes para garantir a confiabilidade e disponibilidade dos equipamentos e sistemas, cada uma com sua abordagem específica para lidar com as falhas. A escolha da estratégia de manutenção adequada depende das características dos equipamentos, dos custos envolvidos e dos impactos operacionais das falhas (BRANCO FILHO, 2008).

Para definir as estratégias de manutenção preventiva dos equipamentos, é essencial considerar a criticidade do equipamento para o ativo, identificar os modos de falha e avaliar as recomendações do manual do fabricante. Além disso, é necessário determinar as intervenções necessárias, suas periodicidades e considerar os recursos de pessoal, materiais disponíveis e a disponibilidade dos equipamentos para operação.

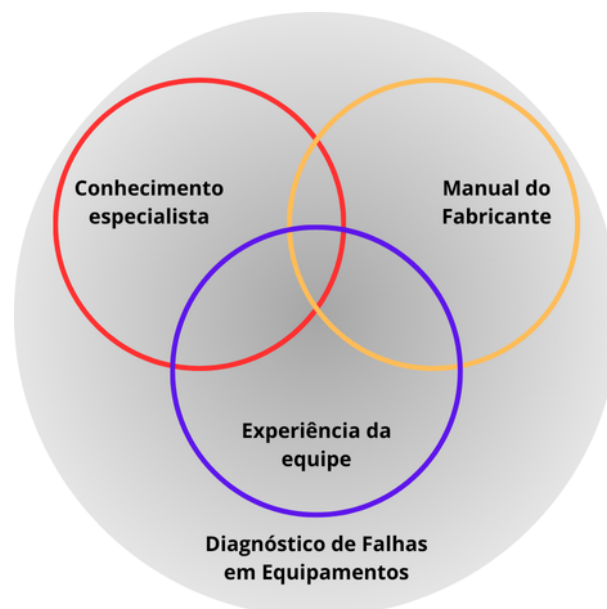
No contexto das avaliações de criticidade, modos e efeitos de falhas, a FMECA é a ferramenta utilizada para conduzir essas análises, sendo desenvolvida com base no conhecimento especializado das equipes de operação, manutenção e engenharia de manutenção, com o suporte de documentação técnica e manuais (GUERRERO; GUILLÉN; GÓMEZ,

2013). Todos os modos de falha e partes afetadas do equipamento avaliado são listados na FMECA, sendo os mecanismos de falha e modos de falha descritos e codificados de acordo com a ISO 14224:2006.

Em caso de falhas e realização de manutenções corretivas, há a necessidade inicial de se identificar o que ocasionou o equipamento a entrar em condição de falha. Nem sempre essa identificação é óbvia, ou em caso de equipamentos que possuam sistemas supervisórios, esses sistemas podem não fornecer o diagnóstico da falha do equipamento. Por vezes a equipe de operação e manutenção tem apenas a informação do efeito da falha e de qual variável que ocasionou a parada do equipamento, mas em geral não há a informação do diagnóstico da falha em si. Além disso, em alguns casos, o operador é responsável por registrar essas falhas em fichas de Registro de Evento de Máquina (REM), que às vezes são preenchidas manualmente.

A experiência das equipes, o conhecimento técnico do equipamento, o aprendizado com problemas anteriores e as seções de diagnóstico dos manuais dos fabricantes são exemplos de ferramentas utilizadas no dia a dia da manutenção para o diagnóstico e solução de problemas em equipamentos. A Figura 2 ilustra o modelo usualmente empregado no diagnóstico de falhas de equipamentos, aqui denominado de Modelo de Diagnóstico de Falhas Atual, tendo em vista ser o mais amplamente utilizado na indústria.

Figura 2 – Modelo de Diagnóstico de Falhas Atual



Referência: Elaborado pelo Autor.

Para desenvolver o modelo de diagnóstico, é necessário primeiro conhecer os modos de falha do sistema do equipamento. Essas informações podem ser acessadas por meio da documentação de engenharia que contém a FMECA.

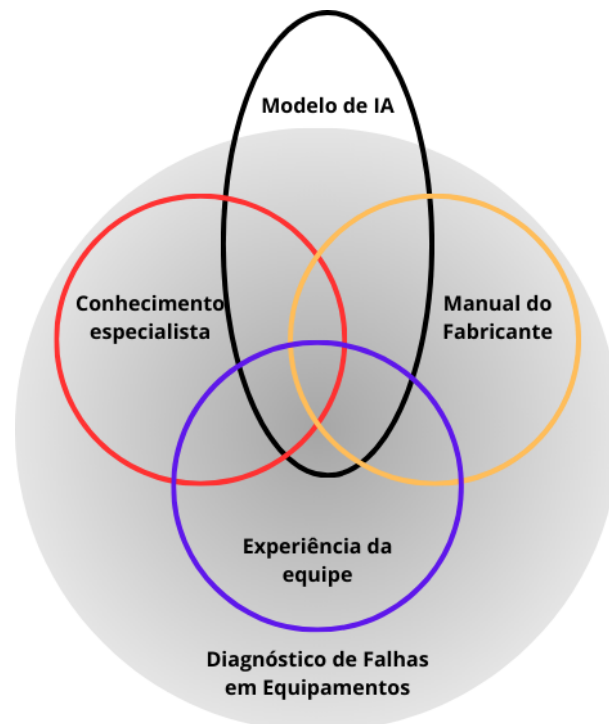
A utilização de técnicas relacionadas à ciência de dados no desenvolvimento de

algoritmos para tratamento de dados e extração de informações úteis para modelos de IA é um dos pilares da indústria moderna. O objetivo principal de incorporar novas tecnologias a um sistema elétrico é obter uma performance mais rentável, com melhores indicadores de confiabilidade e maior segurança energética (MISHRA et al., 2022). Portanto, o desenvolvimento de aplicações de IA e ciência de dados aplicadas a sistemas elétricos está alinhado às estratégias de negócio de várias empresas que utilizam energia como insumo em seu processo produtivo.

O setor de óleo e gás, especialmente na área de Exploração e Produção, busca implementar ações para reduzir a indisponibilidade de sistemas e garantir maior continuidade operacional na produção de petróleo.

Nesse contexto, a pesquisa tem como objetivo utilizar os dados coletados pelos sensores de monitoramento dos turbogeradores do sistema de geração principal de uma FPSO, para realizar o diagnóstico de falhas nos equipamentos dos seus sistemas de lubrificação por óleo mineral. Para isso, um SIF foi utilizado como ferramenta para a realização de diagnóstico e a classificação das falhas desses sistemas. O SIF utiliza os modos de falha identificados na FMECA, que são passíveis de serem identificados por meio do monitoramento de variáveis. A Figura 3 ilustra o modelo de diagnóstico de falhas em que modelo de IA é adicionado às ferramentas atualmente empregadas no diagnóstico de falhas, formando o modelo de diagnóstico de falhas proposto para este trabalho.

Figura 3 – Modelo de Diagnóstico de Falhas Proposto



Referência: Elaborado pelo Autor.

O modelo proposto é adequado para cenários com disponibilidade limitada de



dados de falha, nos quais outros modelos exigem conjuntos de dados extensos. Além disso, o modelo desenvolvido cria uma padronização para a transferência de conhecimento especializado em equipamentos para o modelo de IA, com base na FMECA do equipamento. Esse modelo é especificamente projetado para diagnosticar falhas em um sistema auxiliar de turbina a gás, aproveitando o conhecimento especializado no campo.

## Motivação

A operação de uma unidade estacionária de produção de petróleo e gás (UEP) tipo FPSO, que produz mais de 150.000 BPD, envolve custos operacionais diários superiores a US\$ 550.000,00 (PARE, 2019), com lucro cessante diário em torno de US\$ 12.150.000,00 para um custo de barril de petróleo da ordem de US\$ 81,00 (LAWDER, 2023). A tomada de decisões de negócios com base na análise de dados ajuda as pessoas a superar vieses e tomar as melhores decisões gerenciais alinhadas às estratégias de negócios. Na indústria de petróleo e gás, onde o tempo de inatividade representa um enorme custo para os operadores da plataforma, um processo de tomada de decisão orientado por dados estruturados e a utilização de análise de *Big Data* (MOHAMMADPOOR; TORABI, 2020) têm um alto valor agregado ao negócio.

Tendo em vista que este tipo de plataforma conta com sistemas elétricos de grande porte, com potência instalada de 100 MW e demanda contínua em torno de 72 MW, o diagnóstico de falhas pode ser utilizado para ter previsibilidade da ocorrência de uma parada do equipamento monitorado, e com isso tomar ações que evitem a mesma ou que minimizem suas consequências. Essas ações podem reduzir a taxa de falha do equipamento, bem como a redução do tempo médio de reparo (MTTR, do inglês: *Mean Time To Repair*), com impacto positivo no aumento da disponibilidade do sistema.

O sistema elétrico dessas unidades é composto por quatro turbogeradores com potência nominal de 25 MW cada. Dados históricos desta planta apontam uma probabilidade de 23,36% de pelo menos um dos quatro geradores apresentar falha, e uma probabilidade de 2,19% de dois dos quatro geradores estarem simultaneamente fora de operação para o período de observação de 1 ano (CASTRO; RODRIGUEZ; CARVALHO, 2022). Durante o período avaliado, o sistema de óleo mineral dos turbogeradores foi identificado como uma das áreas com maior incidência de falhas.

A motivação para o trabalho se dá pela relevância dos equipamentos do sistema de geração principal para a operação rentável da UEP, tendo como foco a redução da taxa de falhas do sistema e o aumento da disponibilidade operacional dos equipamentos que o compõe.

## Objetivos

### Objetivo Geral

Apresentar os modelos de inteligência artificial desenvolvidos durante a pesquisa, capazes de diagnosticar e classificar falhas do subsistema de lubrificação por óleo mineral de um turbogerador de uma FPSO.

### Objetivos Específicos

Para se atingir o objetivo geral da Tese, os seguintes objetivos específicos foram necessários:

- Realizar o mapeamento das grandezas de interesse da rede de sensores que monitoram o subsistema de interesse;
- Realizar o mapeamento dos modos de falha e das partes afetadas do subsistema em avaliação utilizando a metodologia da FMECA;
- Desenvolver um modelo de classificação e diagnóstico de falhas utilizando um SIF com base nas falhas identificadas na FMECA e detectáveis por meio do monitoramento de variáveis;
- Estabelecer critérios de desempenho para o modelo de classificação e diagnóstico de falhas;
- Propor modelo automatizado para o REM.

## Contribuições do trabalho

A partir das informações apresentadas nos objetivos e motivação do trabalho, pode-se destacar que as principais contribuições desta pesquisa são:

- Desenvolvimento de um modelo de diagnóstico e classificação de falhas que utiliza a FMECA para padronizar a transferência de conhecimento do especialista em equipamentos para o modelo de IA;
- Criação de regras que relacionam as leituras dos sensores do sistema de lubrificação de óleo mineral, com um conjunto predefinido de falhas identificadas durante a etapa de projeto do equipamento;
- Modelo projetado para ser usado em cenários onde há disponibilidade limitada de dados de falha para treinamento e teste;

- Abordagem simultânea do diagnóstico de falhas e sua classificação em termos de modos de falha definidos para turbogeradores empregados em plataformas tipo FPSO.

Adicionalmente, é esperado que esta pesquisa contribua a partir de seus resultados, com os seguintes pontos:

- Redução de MTTR em sistema de geração principal da FPSO;
- Redução de perdas de produção de petróleo por indisponibilidade de sistema de geração principal da FPSO;
- Aumento na disponibilidade de mão de obra da equipe de manutenção de bordo para outras atividades de maior valor agregado;
- Aumento na disponibilidade de mão de obra da equipe de engenharia de manutenção para outras atividades de maior valor agregado.

## Organização do texto

Esta Tese está dividida em seis capítulos. No Capítulo dois é apresentado o conteúdo teórico que serve de base para o desenvolvimento do trabalho. Este capítulo foi dividido em cinco seções. Na primeira seção é apresentado o sistema elétrico da FPSO, o turbogerador e seus subsistemas. A segunda seção trata do sistema de inferência fuzzy. Na terceira seção é apresentado estudo comparativo entre modelos de inferência fuzzy e neuro-fuzzy com base na avaliação feita na etapa de qualificação desta Tese. Na quarta seção é explicada a técnica empregada na FMECA e na quinta seção são feitas considerações finais sobre o capítulo dois, bem como uma breve descrição sobre o próximo capítulo.

No Capítulo três, que é dividido em quatro seções, é apresentada a revisão bibliográfica com os principais trabalhos correlatos ao tema desta Tese. Na primeira seção são elencados os trabalhos relacionados ao diagnóstico de falhas em equipamentos de uma forma geral. Na segunda seção são apresentados trabalhos relacionados ao diagnóstico de falhas em turbogeradores. Na terceira seção é realizada uma síntese com as principais contribuições de cada autor de modo a realizar uma comparação com as contribuições feitas por este trabalho. Finalmente, na quarta seção são feitas considerações finais sobre o capítulo de revisão bibliográfica, bem como uma breve descrição sobre o capítulo da metodologia.

O capítulo quatro foi dividido em cinco seções. Este capítulo trata da metodologia empregada no desenvolvimento da pesquisa. A primeira seção trata do entendimento do negócio, em que as necessidades do cliente são avaliadas para a proposição de uma solução.

A segunda seção é relativa ao entendimento dos dados, em que a coleta de dados referente ao problema a ser resolvido é feita. A terceira seção trata da preparação dos dados e modelagem, em que a preparação dos dados para carregamento no modelo e a modelagem do SIF são discutidos. Na quarta seção é apresentada forma de avaliação do modelo, sendo feitas considerações finais sobre o capítulo na quinta e última seção, em que uma breve descrição sobre o capítulo cinco é feita nessa seção.

Posteriormente, no capítulo cinco, os resultados obtidos são apresentados, bem como as devidas análises e discussões, abrangendo os testes computacionais.

Por fim, são apresentadas as considerações finais e os trabalhos futuros propostos para continuidade da pesquisa.

## 2 Fundamentação Teórica

Este capítulo aborda o sistema de geração elétrica de uma plataforma tipo FPSO, que é composto por quatro geradores principais acionados por turbinas a gás. Os turbogeradores são detalhados, incluindo a descrição da turbina a gás, caixa redutora e gerador elétrico. O sistema de distribuição elétrica da plataforma é apresentado, sendo dividido entre o *topside*, onde estão localizadas principalmente as cargas relacionadas ao processo, e o casco, que abriga principalmente as cargas relacionadas aos sistemas de facilidades e habitabilidade. Além disso, é apresentado o conceito do SIF, utilizado para modelar o diagnóstico de falhas. O SIF envolve etapas como fuzzificação, avaliação de regras e desfuzzificação, permitindo a análise e interpretação dos dados para a tomada de decisões. Uma avaliação comparativa entre o modelo de inferência aplicado neste trabalho e um modelo neuro-fuzzy que foi avaliado ao longo da pesquisa é apresentada, com discussões sobre as vantagens e desvantagens de cada modelo e da motivação para a aplicação do SIF na solução empregada. A FMECA como ferramenta de identificação e caracterização de riscos, bem como do mapeamento dos modos de falha dos sistemas avaliados são discutidos nesse capítulo, passando também pelos critérios mínimos de sua elaboração.

### 2.1 Sistema de Geração Elétrica da FPSO

O sistema de geração principal, da FPSO em estudo, é formado por quatro geradores principais acionados por turbinas a gás com potência nominal de 25 MW e tensão nominal de 13,8 kV, conforme ilustrado na Figura 4. A energia elétrica gerada em 13,8 kV é fornecida pelos turbogeradores ao painel principal, onde os motores com potência maior que 1.250 kW são conectados. O painel principal possui seu barramento seccionado em barramento A e B, sendo interligado por meio de um disjuntor Tie e um disjuntor BAL. Nessa interligação está instalado um limitador de curto-circuito denominado  $I_S$ -limiter.

$I_S$ -limiters são frequentemente usados para interligar dois sistemas ou partes de sistemas cuja capacidade de suportar curto-circuito não seria suficiente com a conexão em paralelo por meio de um disjuntor. O limitador de curto-circuito limita a corrente de curto-circuito de pico desde o início separando eletricamente o sistema em duas partes antes que a corrente de curto-circuito atinja níveis acima do projeto dos componentes do sistema, sendo a fonte do curto-circuito eliminada pela proteção do sistema que se reconfigurou após sua separação com um número menor de fontes contribuidoras para o curto-circuito. Para a sua atuação são necessários que alguns parâmetros sejam atingidos como corrente de curto-circuito limite, chamada de *tripping value*, que um diferencial de corrente de curto-circuito ( $\frac{di}{dt}$ ) esteja e os quatro turbogeradores estejam simultaneamente

em operação com seus disjuntores de máquina fechados, adicionalmente o  $I_S$ -limiter não deve operar para correntes de *inrush* de transformadores.

Todos painéis do tipo centro de distribuição de carga (CDC) também seguem a filosofia de barramento seccionado com interligação por disjuntor Tie, mas apenas o painel principal necessita de limitador de curto-circuito para manter o nível de curto-circuito desse painel em 50 kA, 1s. Assim, todo o sistema de distribuição segue a filosofia de secundário seletivo (CASTRO; SIMÕES FILHO, 2010), em que há a duplicação da alimentação dos barramentos dos painéis de distribuição pelos secundários dos transformadores. Nesta configuração do sistema de distribuição, há a possibilidade de alimentação das cargas por ambos os transformadores caso o Tie do painel de distribuição esteja aberto ou de todas as cargas por um dos transformadores caso a operação seja com o Tie fechado.

### 2.1.1 Sistema de Distribuição da FPSO

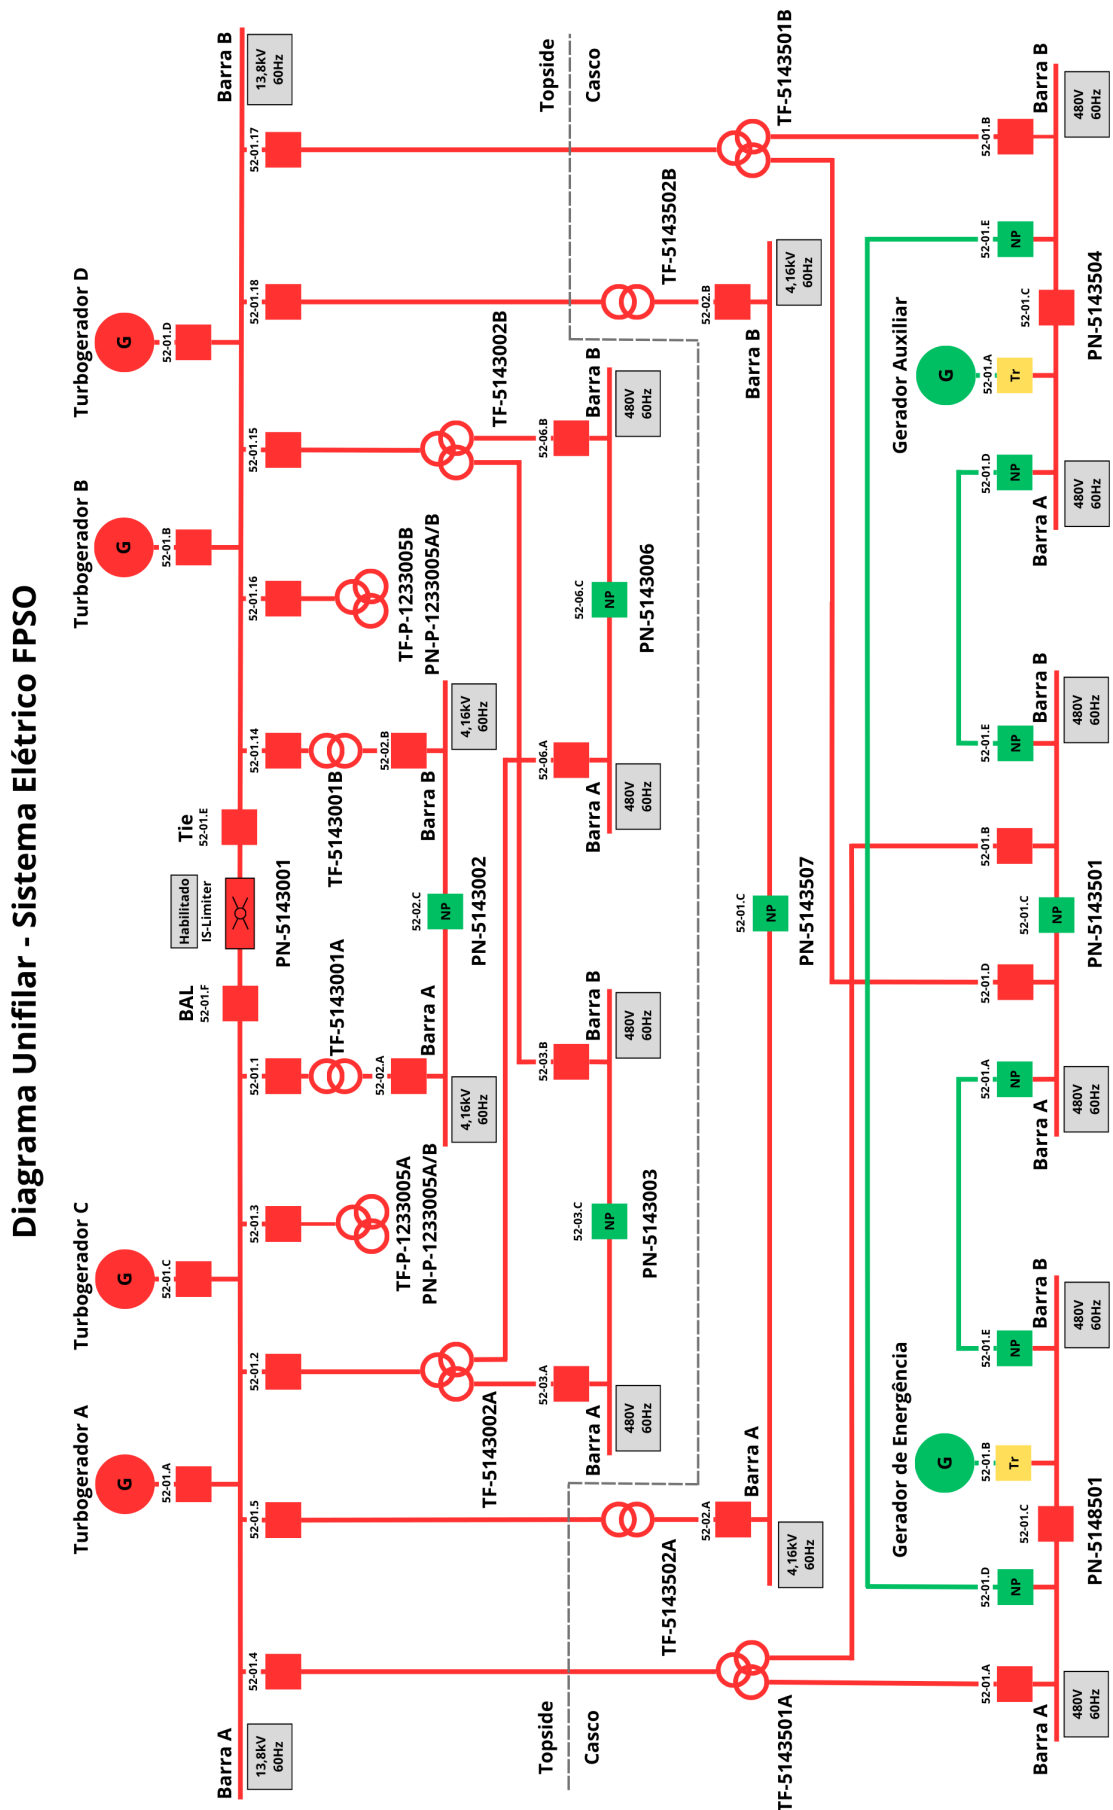
O sistema elétrico da FPSO é normalmente dividido em dois sistemas: *topside* e casco. No *topside* encontram-se as cargas relacionadas aos sistemas de produção da plataforma, como equipamentos da planta de produção de petróleo, compressores da planta de processamento de gás, bombas do sistema de injeção de água, bombas do sistema de refrigeração e aquecimento de água para o processo, e equipamentos do sistema de água produzida. No sistema elétrico do casco, estão as cargas relacionadas à habitabilidade e segurança da plataforma, salvatagem, ar comprimido, sistema de lastreamento e bombas de carga, sistema de alívio (*offloading*), guinchos de ancoragem, reboque, amarração e *pull-in*, guindastes, iluminação de emergência, alimentação dos sistemas de emergência, alimentação dos sistemas essenciais e painéis que alimentam os auxiliares dos geradores principais PN-TG-5147001-01-01/02.

No painel principal, localizado no *topside*, estão ligados os transformadores responsáveis pela distribuição de energia elétrica tanto para o próprio *topside* quanto para o casco. No *topside*, dois transformadores alimentam as cargas de 4,16 kV, dois transformadores de três enrolamentos alimentam aquecedores do processo de tratamento de gás em 690 V, e dois transformadores de três enrolamentos distribuem energia elétrica principalmente para as cargas do processo em 480 V.

Por meio do painel principal, localizado no *topside*, também são alimentados os transformadores de três enrolamentos TF-5143501A/B que distribuem energia elétrica em 480 V para o casco, bem como os dois transformadores TF-5143502A/B que distribuem energia em 4,16 kV para o sistema das bombas de transferência de petróleo, lastro e deslastro da FPSO.

A lista de cargas dos sistemas de distribuição do *topside* e casco pode ser consultada no Anexo A.

Figura 4 – Sistema Elétrico da FPSO



Referência: Adaptado de (CASTRO, 2020).

### 2.1.2 Turbogeneradores

Uma turbina a gás opera por meio do ciclo Brayton, que é um ciclo termodinâmico contínuo composto por quatro etapas principais: compressão, aquecimento, expansão e resfriamento (EBRAHIMI, 2023).

Primeiramente, um grande volume de ar é admitido e passa pelo compressor, que o comprime axialmente, fazendo com que ele passe por espaços cada vez menores. Esse processo de compressão ocorre entre a entrada de ar e a saída do compressor, na seção fria da turbina. Durante a compressão, tanto a pressão quanto a temperatura do ar aumentam. Em seguida, o ar é misturado com o combustível ao entrar na câmara de combustão. Nessa câmara, no momento da partida da turbina ocorre o centelhamento dos ignitores, dando início à queima, que após iniciada e dadas as condições de autossustentação, permanece de forma contínua até a parada da máquina. Os gases resultantes dessa combustão se expandem e saem da câmara com alta energia, sendo direcionados para as palhetas da turbina de alta pressão e para a turbina de potência. A turbina de potência (PT) é responsável por acionar a máquina movida, no caso em questão, um gerador elétrico. Por fim, os gases são direcionados para a exaustão, onde são liberados para a atmosfera. Esse ciclo de entrada de ar, compressão, combustão, expansão e exaustão se repete continuamente para manter a turbina a gás em funcionamento.

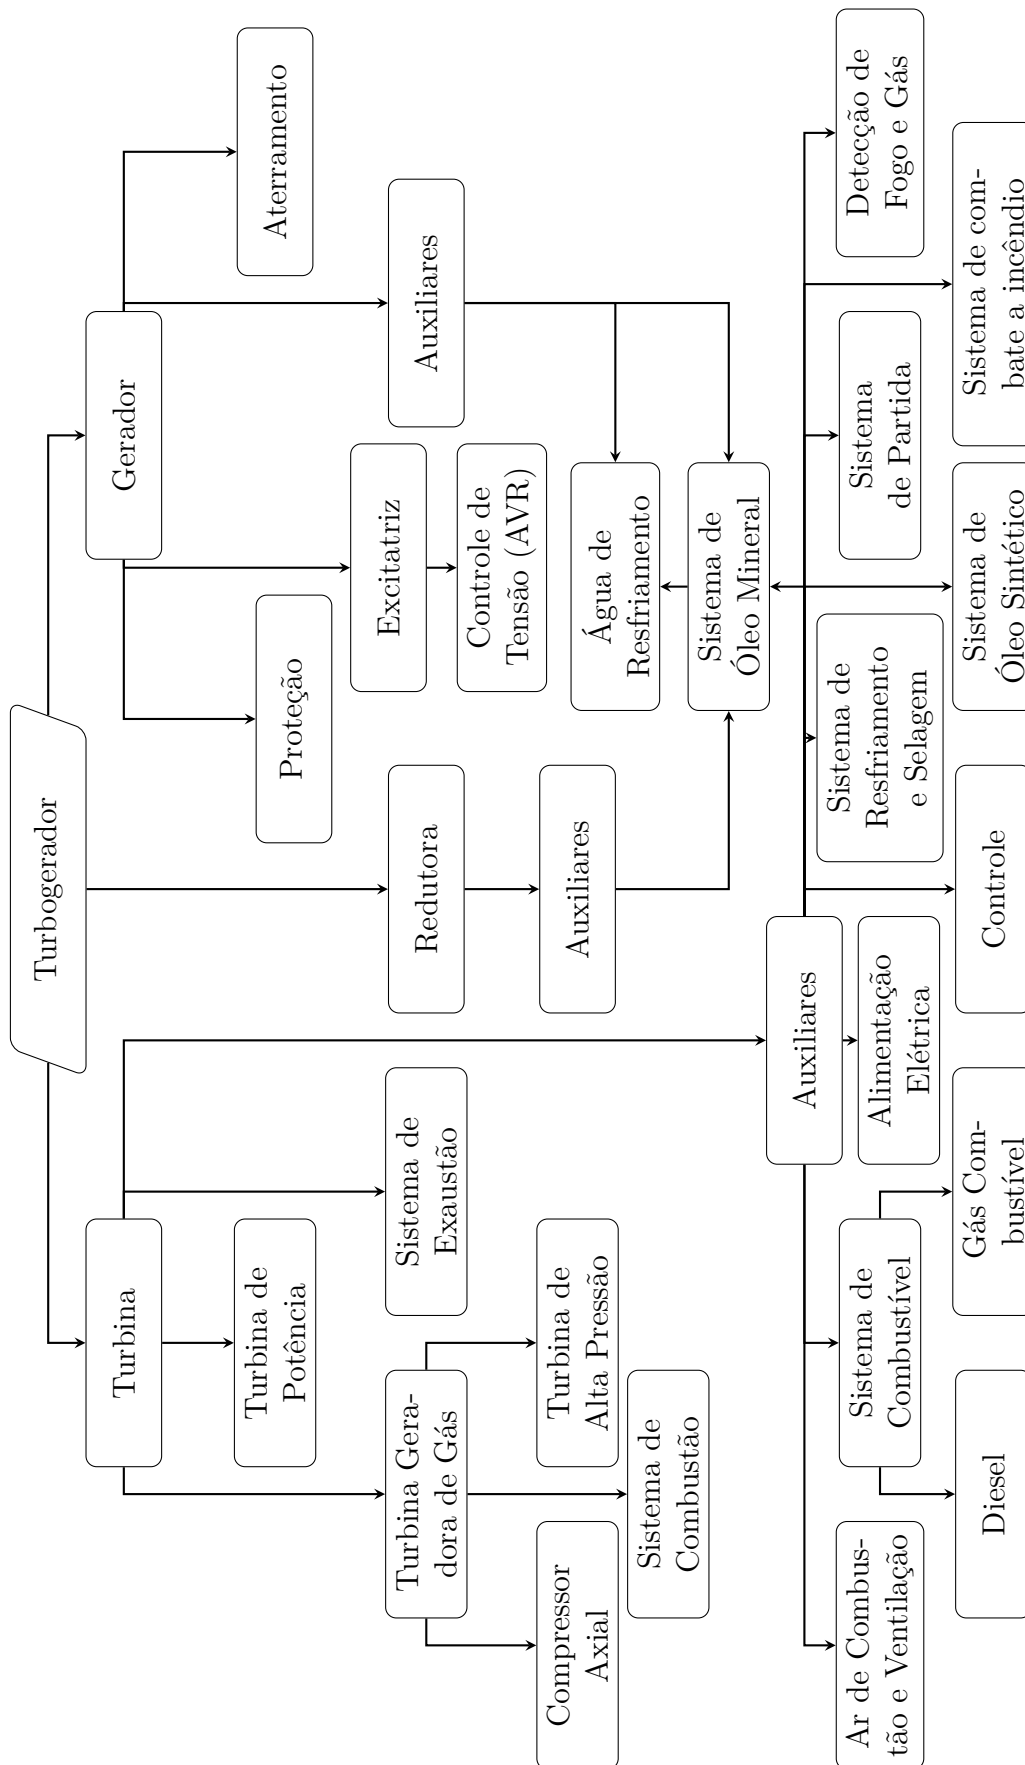
O turbogenerador do sistema em estudo é composto pela turbina a gás, que opera com combustível líquido (Diesel) ou com combustível gasoso (gás de processo), por uma caixa redutora e pelo gerador elétrico, conforme ilustrado na Figura 5.

O compressor axial é responsável por fornecer o fluxo de ar comprimido necessário para a combustão e o funcionamento do sistema antes da adição de calor. Ele é composto por uma série de estágios, onde cada estágio consiste em um par de rotores e estatores. Os rotores são discos giratórios que possuem pás ou lâminas curvadas em sua circunferência. Essas pás são projetadas de forma aerodinâmica para capturar o ar e acelerá-lo axialmente, ou seja, no mesmo eixo de rotação do rotor. À medida que o ar passa pelo rotor, ele é comprimido e sua pressão aumenta de acordo com o princípio de Bernoulli (EBRAHIMI, 2023).

Já os estatores são discos estacionários que também possuem pás ou lâminas curvadas com ângulo variável e não variável. O objetivo desse sistema é manter o fluxo de ar fora da condição de *surge*, que é a perda prolongada do fluxo de ar, e evitar a perda momentânea do fluxo de ar conhecida como *stall*, que pode causar vibração intensa e danos severos ao equipamento. Também estão localizados no estator os coletores de sangria de ar, que são utilizados para resfriar a PT e os bocais da turbina de alta pressão (HSPT, do inglês: *High-speed Power Turbine*), além de pressurizar e selar os mancais e equilibrar axialmente o eixo da PT. Há janelas de boroscopia em todos os estágios para inspeção



Figura 5 – Sistemas e subsistemas do turbogerador



Referência: (CASTRO; RODRIGUEZ; CARVALHO, 2022).

interna do compressor.

O conjunto de rotores e estatores em cada estágio trabalha em conjunto para aumentar a pressão do ar comprimido progressivamente. Conforme o ar passa por cada estágio, sua pressão vai aumentando gradualmente até atingir a pressão desejada para a combustão.

Além do aumento da pressão, o compressor axial também é responsável por fornecer um fluxo de ar contínuo e uniforme para a combustão. Isso é alcançado com o projeto das pás e estatores, que são otimizados para minimizar a perda de pressão e garantir um fluxo eficiente.

Para evitar incrustações e erosão das pás do compressor, o ar deve ser filtrado antes de ser admitido, para isso, diferentes sistemas são utilizados para o fornecimento de ar limpo em temperatura adequada para a operação do turbogerador (EBRAHIMI, 2023). Dessa maneira, tela para evitar que grandes objetos sejam succionados, sistemas de remoção da umidade do ar, pré-filtros e filtros de alta eficiência são instalados com o objetivo de filtrar o ar de sucção.


Na máquina em estudo, a câmara de combustão é composta por quatro componentes principais, formando um design anular único. Esses componentes são o conjunto do difusor, a cúpula, a camisa externa e a camisa interna. O conjunto do difusor desempenha fornece fluxo de ar uniforme para a combustão na cúpula, onde são encontrados trinta turbilhonadores e cubas de mistura que recebem o combustível dos injetores, misturam-no com o ar e estabilizam a chama. Para evitar a carbonização, os Venturi injetam ar frio constantemente nas paredes da câmara. As camisas externa e interna são protegidas do calor por meio do fornecimento constante de ar frio (LORA; NASCIMENTO, 2004). Os ignitores são responsáveis por produzir centelhas de alta energia até que a chama se torne autossustentável durante a partida da máquina. Durante a operação, sensores de chama monitoram continuamente a presença da chama.

A função da HSPT é extrair energia da corrente de gases de combustão quentes e de alta pressão na turbina a gás. Ao extrair energia da corrente de gases de combustão, a HSPT mantém o funcionamento contínuo do sistema, garantindo o fornecimento adequado de ar comprimido para a combustão e para acionar a PT. No modelo de turbina utilizado neste estudo, a PT não possui acoplamento com o eixo da turbina geradora de gás (GG), na configuração com turbina livre (LORA; NASCIMENTO, 2004), sendo movida pelos gases exaustos da HSPT. O conjunto compressor axial, câmara de combustão e HSPT formam a GG.

A PT do equipamento em estudo é composta por um rotor com seis estágios de palhetas, um estator, a estrutura traseira da turbina e um adaptador para acoplamento com a máquina movida. Essa turbina é acoplada a uma caixa multiplicadora que permite o

ajuste adequado da velocidade de rotação para a máquina movida. O rotor da turbina de potência possui vários estágios de palhetas, que são responsáveis por extrair a energia dos gases de combustão em expansão. À medida que os gases passam pelos estágios de palhetas, eles transferem sua energia cinética para o rotor, fazendo-o girar. Um esquemático da GG e da PT é ilustrado na Figura 6.

Figura 6 – Diagrama esquemático da turbina



Referência: Adaptado de (YAN et al., 2021)

A caixa redutora realiza a conversão de velocidade da turbina de potência para o gerador, ajustando assim a rotação necessária para sua operação.

O sistema de geração principal dessa unidade conta com quatro turbogeradores (unidades A/B/C/D), acionados por turbinas a gás, com potência nominal de 25 MW / 31,25 MVA, tensão nominal de 13,8 kV e frequência nominal de 60 Hz, que alimentam tanto o sistema elétrico do *topside* quanto o casco da plataforma.

O gerador elétrico é acoplado a uma caixa redutora e é uma máquina síncrona de 4 polos com frequência nominal de 60 Hz. Ele é composto por uma excitatriz, que fornece a tensão necessária para excitar o enrolamento de campo, além de possuir elementos de proteção elétrica e um sistema de aterramento de alta impedância.

O sistema de excitação é uma parte essencial do gerador elétrico e tem como objetivo controlar a tensão de saída do gerador. Nesse sistema, são utilizados um gerador a ímã permanente acoplado ao gerador principal e uma excitatriz sem escovas ou *brushless*. A excitatriz *brushless* é composta por uma armadura e um retificador rotativo, juntamente com um campo estático alimentado por um gerador de ímã permanente (PMG, do inglês: *Permanent Magnet Generator*). Essa configuração permite gerar a corrente de excitação necessária para o gerador principal.

Para garantir a regulação adequada da tensão, o sistema de excitação utiliza dois reguladores automáticos de tensão (AVR, do inglês: *Automatic Voltage Regulator*). Esses

reguladores de tensão são responsáveis por monitorar e ajustar continuamente a tensão de saída do gerador, assegurando que ela permaneça dentro dos limites especificados. Um dos AVR fica em serviço, controlando ativamente a tensão do gerador, enquanto o outro fica em *hot stand-by*, ou seja, fica em modo de espera pronto para assumir as operações caso o controlador que esteja em operação entre em falha.

Parte dos sistemas auxiliares é compartilhada entre a turbina GG e a PT, incluindo o sistema de ventilação, o sistema de exaustão, o sistema de resfriamento e selagem, e o sistema de combate a incêndio. Além disso, a PT compartilha o sistema de lubrificação por óleo mineral com o sistema de partida, a caixa redutora e o gerador.

Em relação ao sistema de lubrificação por óleo mineral, objeto de estudo deste trabalho, é importante destacar sua relevância para o equipamento, pois desempenha o papel de lubrificar a caixa redutora, os mancais do gerador e os mancais da PT. Além disso, é utilizado durante o processo de partida do turbogerador. Durante a partida, o óleo mineral é utilizado para deslocar os mancais do gerador, formando uma película de óleo que reduz o atrito nos mancais. Essa película de óleo ajuda a minimizar o desgaste e a reduzir o atrito até que o gerador atinja a rotação adequada.


O sistema de lubrificação de óleo mineral é composto pelos seguintes elementos: reservatório de óleo, bomba de óleo principal, bomba de óleo auxiliar, bomba de óleo de emergência, filtros de óleo, válvula de controle de pressão, válvula de controle de temperatura, eliminador de névoa, aquecedor, vaso acumulador de pressão, tubulações e conexões. A Figura 7 ilustra um diagrama esquemático de um sistema de óleo mineral típico de um turbogerador similar ao em avaliação.

O sistema de óleo mineral é composto por uma bomba principal e uma reserva acionadas por motores em corrente alternada (CA). Apenas uma bomba é operada de cada vez. Há uma bomba de emergência acionada por um motor elétrico de corrente contínua (CC) alimentado por um sistema com redundância de alimentação com banco de baterias, que é acionada na lógica de partida da turbina para verificação de funcionamento e em caso de perda de alimentação CA das bombas de óleo mineral principais, garantindo lubrificação aos mancais da PT, caixa redutora e gerador até que a turbina pare.

As bombas de óleo lubrificante são abastecidas a partir do tanque de óleo. O nível de óleo do tanque, a temperatura e os transmissores de pressão são permissivos para a partida das bombas. No entanto, durante a operação normal da turbina a gás, se algum dos parâmetros mencionados acima detectar uma falha, apenas o alarme relacionado será exibido. Antes da partida da turbina, o operador seleciona qual das duas bombas (principal ou auxiliar) será a principal no painel de controle de motores na interface de usuário (IU).

O sistema de óleo mineral possui dois trocadores de calor com uma válvula de comutação entre eles, permitindo o uso de qualquer um dos trocadores de calor durante a

Figura 7 – Diagrama esquemático do sistema de óleo mineral



Referência: Adaptado de (EBRAHIMI, 2023)

operação da turbina. Esses trocadores são resfriados por circuito fechado de água doce.

Dois filtros de óleo lubrificante mineral estão localizados imediatamente a montante dos trocadores de calor. Apenas um filtro está em serviço por vez, permitindo a limpeza, inspeção e manutenção do segundo filtro sem interromper o fluxo de óleo ou desligar a turbina a gás.

Um acumulador de óleo lubrificante mineral é fornecido no *header* do sistema para fornecer óleo durante qualquer transiente de pressão devido a falha nas bombas de óleo e em alguma troca de bombas durante a operação.

O sistema de óleo mineral requer um separador de vapores que opera o tempo todo quando as bombas de óleo estão em funcionamento.

## 2.2 Sistema de Inferência Fuzzy

A Lógica Fuzzy é uma lógica multivalorada em que as variáveis do conjunto Fuzzy assumem valores reais entre “0” e “1”. De forma linear, os “n” valores da lógica podem ser divididos neste intervalo conforme a Equação (2.1), em que  $n \geq 2$ . Esses valores são interpretados como graus de verdade (KLIR; YUAN, 1995).

$$T_n = \left\{ 0 = \frac{0}{n-1}, \frac{1}{n-1}, \frac{2}{n-1}, \dots, \frac{n-2}{n-1}, \frac{n-1}{n-1} = 1 \right\}. \quad (2.1)$$

Um modelo Fuzzy é construído pela associação de uma proposição “P” a um conjunto Fuzzy por meio de uma função de pertencimento, a fim de obter os graus de verdade daquela proposição. Para um dado conjunto Fuzzy “A”, os valores verdade “T” em função das proposições “P” são dados pela Equação (2.2), em que “ $\mu$ ” é a função que indica o grau de pertencimento da variável “x” ao conjunto Fuzzy “A” (HOODA; RAICH, 2017).

$$T(P) = \mu_A(x), \text{ onde } 0 \leq \mu_A \leq 1. \quad (2.2)$$

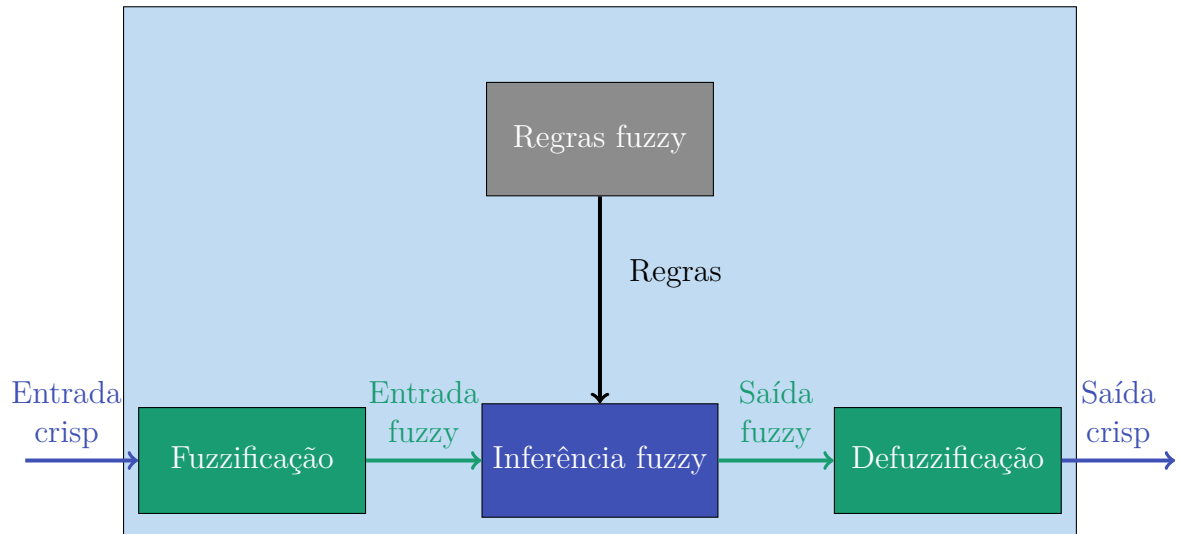
Existem dois métodos comumente utilizados em sistemas de inferência fuzzy: Mamdani e Takagi-Sugeno. O método de Mamdani é amplamente utilizado no desenvolvimento de sistemas em que regras linguísticas são empregadas para a avaliação das entradas de um sistema de inferências fuzzy (SPIRILI et al., 2021). Por outro lado, o método de Takagi-Sugeno estabelece uma relação matemática entre as entradas e as saídas do sistema. Em vez de usar regras linguísticas, o método de Takagi-Sugeno utiliza funções de pertinência lineares ou constantes para representar o comportamento do sistema. Isso torna o método de Takagi-Sugeno mais adequado para modelar sistemas que possuem um comportamento mais preciso e determinístico.

O método de Mamdani consiste em quatro etapas, conforme ilustrado na Figura 8, e são descritas abaixo:

- Fuzzificação de valores de entrada, também conhecidos como entradas *crisp*;
- Avaliação de regras;
- Saídas fuzzy;
- Desfuzzificação de saída.

A primeira etapa para a criação de um SIF é a transformação das variáveis de entrada do sistema, chamadas de valores *crisp*, em valores fuzzy por meio do processo conhecido como fuzzificação. Essa etapa consiste em atribuir a esses conjuntos de valores de entrada funções de pertinência que representem essas variáveis em termos físicos para o sistema fuzzy que está sendo criado. Essas funções definem o grau em que os valores de entrada são membros do conjunto fuzzy (CHOI; O’KEEFE; BARUAH, 1992). As entradas fuzzy podem assumir valores reais entre “0” e “1”, dependendo do grau de pertencimento do valor de entrada a um dado conjunto. O grau de pertencimento mínimo corresponde ao valor “0”, enquanto o máximo corresponde ao valor “1”. Dessa forma, o

Figura 8 – Arquitetura do SIF



Referência: Adaptado de (YAMASSAKI, 2020).

grau de pertencimento de uma dada variável a um conjunto fuzzy pode ser expresso como mostrado na Equação (2.3) (BAGUA et al., 2018).

$$A = \{ ( x, \mu_A(x) ) \mid \forall x \in X \}, \quad (2.3)$$

em que “A” é o conjunto fuzzy, “ $\mu$ ” é a função de pertinência e “x” é a variável *crisp*.

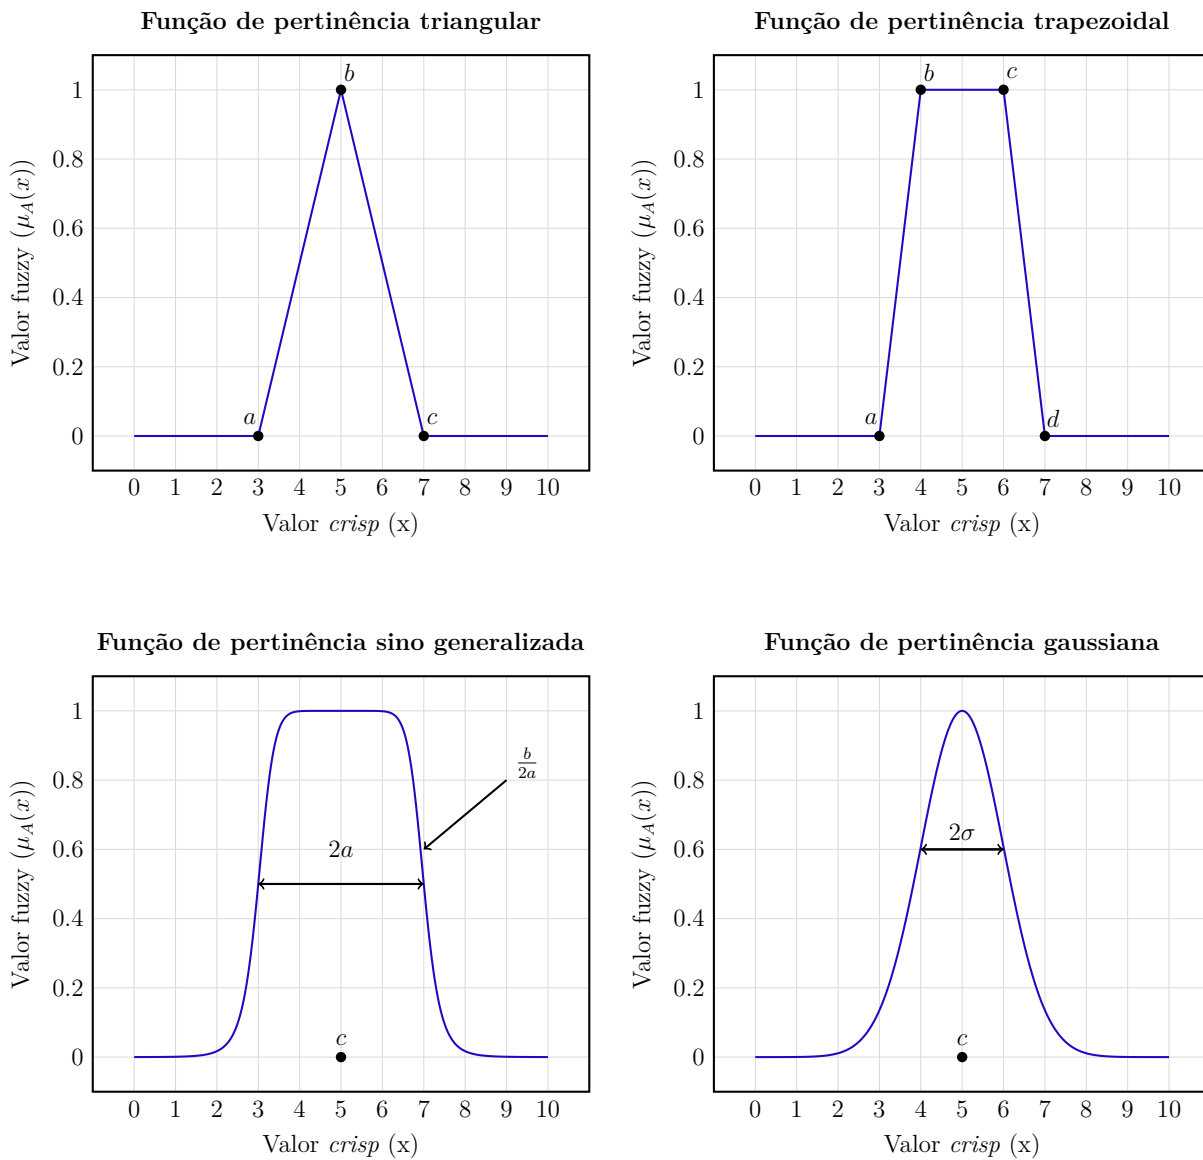
Um conjunto fuzzy nos permite expressar conceitos vagos na linguagem natural (KLIR; YUAN, 1995), como por exemplo, um valor de pressão que pode ser categorizado como baixo, normal ou alto, por meio de uma função que determina em que medida aquela grandeza pertence a cada categoria.

As funções de pertinência podem ter diferentes formatos, sendo as mais utilizadas a triangular e a trapezoidal (KLIR; YUAN, 1995; HOODA; RAICH, 2017). Outras funções, como sigmoide, gaussiana, dupla gaussiana e sino generalizada, também são amplamente utilizadas. A Figura 9 ilustra exemplos das funções de pertinência mais comuns.

A função de pertinência triangular é amplamente utilizada devido à sua simplicidade e interpretabilidade. Essa função possui valor máximo em um ponto específico e diminui linearmente em ambos os lados desse ponto. A função de pertinência triangular é definida pela Equação (2.4), sendo “a”, “b” e “c” os parâmetros que caracterizam a curva.

$$\mu_A(x) = \begin{cases} 0, & \text{se } x \leq a \\ \frac{x-a}{b-a}, & \text{se } a \leq x \leq b \\ \frac{c-x}{c-b}, & \text{se } b \leq x \leq c \\ 0, & \text{se } x \geq c \end{cases} \quad (2.4)$$

Figura 9 – Funções de pertinência típicas



Referência: Elaborado pelo autor.

em que  $x$  representa os valores das variáveis *crisp* e  $\mu$  representa os valores fuzzy correspondentes da função de pertinência.

A função de pertinência trapezoidal é caracterizada por ter um valor máximo em um intervalo específico e ser constante dentro desse intervalo. Essa função é definida pela Equação (2.5), em que “a”, “b”, “c” e “d” são os parâmetros que caracterizam a curva. A função trapezoidal é uma generalização da função triangular, pois quando os parâmetros “b” e “c” são iguais, a curva trapezoidal se torna triangular (MA et al., 2024), sendo



também uma função de pertinência com ampla aplicação.

$$\mu_A(x) = \begin{cases} 0, & \text{se } x \leq a \\ \frac{x-a}{b-a}, & \text{se } a \leq x \leq b \\ 1, & \text{se } b \leq x \leq c \\ \frac{d-x}{d-c}, & \text{se } c \leq x \leq d \\ 0. & \text{se } x \geq d \end{cases} \quad (2.5)$$

A função de pertinência sino generalizada é caracterizada por sua forma em formato de sino. Essa função é definida pela Equação (2.6), na qual o parâmetro “c” determina a posição do centro da curva. O parâmetro  $(\frac{b}{2a})$  determina a inclinação da curva, influenciando o grau de suavidade da inclinação. Além disso, o parâmetro “a” controla a abertura da curva, afetando o grau de espalhamento dos valores de pertinência em torno de “c”.

$$\mu_A(x) = \frac{1}{1 + \left| \left( \frac{x-c}{a} \right)^{2b} \right|}. \quad (2.6)$$

A função de pertinência gaussiana segue a distribuição normal ou gaussiana. A equação geral da função de pertinência gaussiana pela Equação (2.7), na qual o parâmetro “c” determina a posição do centro da curva e  $\sigma$  é o desvio padrão, que controla a abertura da curva, afetando o grau de espalhamento dos valores de pertinência em torno de “c”.

$$\mu_A(x) = e^{-\frac{(x-c)^2}{2\sigma^2}}. \quad (2.7)$$

Existem diferentes métodos de definição dos tipos de funções de pertinência e escolha dos parâmetros. Esta escolha pode ser feita por meio do conhecimento do problema (intuição), por experimentação, utilizando uma função que melhor caracterize os dados em termos de sua distribuição, ou utilizando algoritmos. Ao se utilizar a intuição, é essencial contar com o conhecimento do especialista do sistema, para determinar qual função melhor representa o conjunto de entradas do sistema e as variáveis linguísticas também devem ser conhecidas (HOODA; RAICH, 2017).

A lógica fuzzy, assim como a lógica booleana, utiliza conectivos lógicos ou operadores lógicos para operar proposições de conjuntos fuzzy diferentes. Os operadores lógicos básicos utilizados na lógica fuzzy são descritos nas Equações de (2.8) a (2.11).

O operador da Equação (2.8) é a negação, ou seja, o inverso do valor verdade de uma dada proposição “P”. Essa operação é considerada como semanticamente sinônima da negação em linguagem natural.

O operador da Equação (2.9) é o operador lógico “ou”, que corresponde ao valor máximo entre as avaliações feitas nas funções de pertinência das proposições “P” e “Q”

para cada conjunto fuzzy. Essa operação equivale à união dos conjuntos associados às proposições correspondentes.

Na Equação (2.10), é apresentado o operador “e”, que corresponde ao valor mínimo entre as avaliações feitas nas funções de pertinência das proposições “P” e “Q” para cada conjunto fuzzy. Essa operação equivale à interseção dos conjuntos associados às proposições correspondentes.

Por fim, na Equação (2.11), é apresentado o operador de implicação, que representa a operação “se” / “então”. Esse operador descreve a dependência do valor de uma variável linguística em relação ao valor de outra. Na lógica proposicional, proposições não relacionadas entre si podem ser combinadas para formar uma implicação (TANSCHHEIT, 2003).

$$T(\bar{P}) = 1 - T(P), \quad (2.8)$$

$$T(P \vee Q) = \max(T(P), T(Q)), \quad (2.9)$$

$$T(P \wedge Q) = \min(T(P), T(Q)), \quad (2.10)$$

$$T(P \rightarrow Q) = T(\bar{P} \vee Q) = \max(T(\bar{P}), T(Q)). \quad (2.11)$$

A lógica fuzzy tem como objetivo imitar o raciocínio humano, em que as regras são expressas por meio de implicações lógicas na forma “se” / “então”, utilizando o operador lógico de inferência. Na lógica fuzzy, uma regra é ativada sempre que houver um grau de similaridade diferente de zero entre uma dada premissa “se” e o antecedente da regra. O resultado será um conseqüente “então” com um grau de similaridade diferente de zero em relação ao conseqüente da regra (TANSCHHEIT, 2004).

As regras do SIF são baseadas na representação da linguagem natural e em modelos, em que as restrições aplicadas por meio de regras são conectadas por conectivos linguísticos como “ou”, “e”, “não” ou “então”. Essas restrições são aplicadas às ações de saída, ou conseqüentes das regras. Para exemplificar a decomposição linguística das regras envolvendo conectivos simples, Hooda e Raich (2017) apresentaram as Equações (2.12) a (2.17), que ilustram o processo de julgamento dos conectivos “e” e “ou”, respectivamente. Nessa etapa, o conhecimento do especialista é utilizado para estabelecer as relações entre os conjuntos fuzzy formados pelas entradas do SIF, de modo que um conjunto de regras seja formado para o julgamento do mecanismo de inferência fuzzy.

Na Equação (2.12), é apresentada uma variável *crisp* que submetida à inferência de pertencimento ao subconjunto fuzzy mostrado na Equação (2.13), por meio da avaliação do

valor mínimo entre as funções de pertinência avaliadas para essa variável, como mostrado na Equação (2.14). Isso ocorre em casos de regras com conectivos exclusivamente do tipo “e”. Após essa avaliação, é medido o grau de pertencimento daquela variável a esse conjunto fuzzy definido pela regra aplicada. Esse grau de pertencimento é representado pela saída “y”, que está relacionada ao conjunto de saídas fuzzy “B”.

$$\text{Se } x \text{ é } A^1 \text{ e } A^2 \text{ e } \dots \text{ e } A^L \text{ então } y \text{ é } B^S, \quad (2.12)$$

$$A^S = A^1 \cap A^2 \cap \dots \cap A^L, \quad (2.13)$$

$$\mu_{A^S}(x) = \min[\mu_{A^1}, \mu_{A^2}, \dots, \mu_{A^L}]. \quad (2.14)$$

Para o caso dos conectivos apresentados nas Equações (2.15), (2.16) e (2.17), uma análise análoga à realizada para o conectivo “ou” pode ser feita. A diferença ocorre na avaliação final da função de pertinência da Equação (2.17). No caso da regra “ou”, o grau de pertencimento da variável *crisp* ao conjunto fuzzy é avaliado obtendo-se o valor máximo entre as funções de pertinência avaliadas.

$$\text{Se } x \text{ é } A^1 \text{ ou } A^2 \text{ ou } \dots \text{ ou } A^L \text{ então } y \text{ é } B^S, \quad (2.15)$$

$$A^S = A^1 \cup A^2 \cup \dots \cup A^L, \quad (2.16)$$

$$\mu_{A^S}(x) = \max[\mu_{A^1}, \mu_{A^2}, \dots, \mu_{A^L}]. \quad (2.17)$$

A etapa de desfuzzificação consiste em transformar os valores de um conjunto fuzzy em valores *crisp*. Da mesma forma que na etapa de fuzzificação, essa transformação requer a aplicação de uma função de pertinência à saída fuzzy do SIF, que irá resultar em uma saída *crisp* correspondente para o sistema. Mais uma vez, se faz necessária a definição das funções de pertinência da parte consequente e obter as saídas desfuzzificadas de acordo com o critério de julgamento definido para o SIF.

Diversos métodos de desfuzzificação podem ser empregados, como centróide, média dos máximos, primeiro máximo, maior dos máximos, método da média ponderada, centro das somas e centro da maior área (HOODA; RAICH, 2017). Dentre eles, o método do centróide é o mais amplamente utilizado. Esse método consiste no cálculo do centro de gravidade da função de pertinência de saída do SIF, conforme mostra a Equação (2.18).

$$z^* = \frac{\int \mu_c(z)z dx}{\int \mu_c(z) dx}. \quad (2.18)$$

A operação de desfuzzificação é a última etapa do SIF. A desfuzzificação opera nos conjuntos fuzzy produzidos pelo mecanismo de inferência, permitindo obter um sinal de saída pontual a partir da região fuzzy resultante da agregação de todas as regras ativadas.

## 2.3 Estudo Comparativo entre os Modelos de Inferência Fuzzy e Neuro-Fuzzy

O sistema de inferência fuzzy adaptativo (ANFIS, do inglês: *Adaptive Neuro-Fuzzy Inference System*) é um modelo que combina o modelo Takagi-Sugeno de inferência Fuzzy com o modelo de redes neurais artificiais multicamadas. A capacidade de aprendizagem do ANFIS é utilizada para ajustar os parâmetros das funções de pertinência na etapa de treinamento do modelo, visando reduzir a taxa de erro na determinação das regras Fuzzy. Uma das vantagens desse sistema é que não é necessária uma etapa de desfuzzificação para obter a saída desejada.

No processo de treinamento do ANFIS, é utilizado um algoritmo de aprendizagem supervisionada que combina o método de convergência de mínimos quadráticos com o método de gradiente descendente. Esse algoritmo calcula o erro entre os valores de saída da rede e os valores do conjunto de treinamento do modelo (KARI et al., 2018). A realimentação do modelo ocorre pela atualização dos valores dos parâmetros das funções de pertinência, levando em consideração o critério de convergência ou o número de épocas definidas para a atualização do modelo.

Um aspecto relevante a ser considerado em relação ao ANFIS é a necessidade de treinamento do modelo e o custo computacional associado a esse processo, especialmente quando a quantidade de funções de pertinência aumenta para melhorar os resultados de saída.

A arquitetura da rede ANFIS é composta por 5 camadas, onde a primeira e a quarta camadas possuem nós adaptativos, enquanto as demais possuem nós fixos (SUPARTA; ALHASA, 2016).

Considerando que a obtenção de dados para treinar e testar a rede ANFIS pode ser uma limitação para modelos de diagnóstico de falhas. Como o sistema de lubrificação por óleo mineral dos turbogeradores possuem modos de falha e regras de diagnóstico bem estabelecidas e conhecidos pela equipe especializada, o SIF foi a aplicação mais adequada para o diagnóstico de falhas nesse caso específico.

Uma avaliação comparativa entre os modelos de inferência e neuro-fuzzy foi realizada

e resultado obtido ambos modelos apresentam bom desempenho no diagnóstico de falhas, porém o SIF se destacou em relação ao ANFIS, conforme quadro comparativo apresentado na Tabela 1.

Tabela 1 – Quadro comparativo SIF x ANFIS

<b>Critério comparativo</b>	<b>SIF</b>	<b>ANFIS</b>
Demanda conhecimento de especialista	X	X
Demanda conhecimento das funções de pertinência antecedentes	X	X
Demanda conhecimento das funções de pertinência consequentes	X	
Demanda conhecimento das regras	X	
Conjunto de dados para treinamento do modelo		X
Conjunto de dados para teste do modelo		X
Maior demanda computacional		X

Referência: Elaborado pelo Autor.

Dependendo da disponibilidade de informações sobre o histórico de falhas de um determinado sistema ou do conhecimento das regras que regem as falhas daquele sistema, o especialista pode optar pela técnica que melhor se adequar ao seu sistema.

Das vantagens apresentadas do SIF em relação ao ANFIS na classificação de falhas do sistema estudado, destacam-se os seguintes fatores:

- Menor custo computacional;
- Sistema baseado em regras não depende que conjunto de dados esteja balanceado quanto à quantidade de falhas;
- Conjunto de regras é de domínio da equipe especialista do sistema.

## 2.4 FMECA - Análise de Criticidade, Modos e Efeitos de Falhas

A análise de criticidade, modos e efeitos de falhas é uma técnica de avaliação de confiabilidade que examina os potenciais modos de falha dentro de um sistema e seus equipamentos, a fim de determinar seus efeitos na performance dos equipamentos e sistema avaliado (LEE; AKPUDO; HUR, 2021). Essa metodologia envolve uma análise quantitativa de falhas e aborda funcionalidades para avaliação de riscos, tendo sido originalmente desenvolvida pela Administração Nacional de Aeronáutica e Espaço dos Estados Unidos (NASA, do inglês: *National Aeronautics and Space Administration*) para melhorar e verificar a confiabilidade do *hardware* do seu programa espacial (BORGIVINI; PEMBERTON; ROSSI, 1993). Na indústria de óleo e gás, a norma ISO 14224:2006 é utilizada para padronizar os modos de falha e as partes afetadas identificadas na FMECA,

unificando a linguagem, os termos e o formato de coleta e troca de dados de confiabilidade e manutenção de equipamentos (ISO CENTRAL SECRETARY, 2006).

A importância de menores custos de construção para novas instalações e de manutenção tanto para novas unidades quanto para as existentes tem crescido, assim como a necessidade do compartilhamento de informações de falhas, dos mecanismos de falha e de dados de manutenção entre plantas. Para análises eficazes, é essencial ter dados de confiabilidade e manutenção dos equipamentos. A coleta de dados deve ser vista como uma atividade de longo prazo, planejada e executada com objetivos claros. A padronização de dados, combinada com sistemas de gerenciamento aprimorados, pode melhorar a qualidade dos dados. A cooperação da indústria e a padronização das práticas de coleta de dados facilitam a troca de informações entre as partes envolvidas, como operadores de plantas, proprietários do negócio, fabricantes e fornecedores.

Ao longo dos anos, a indústria tem trabalhado com o intuito de reduzir o risco de falha em produtos, sistemas, projetos, processos e serviços. Isso tem motivado o crescimento da engenharia de confiabilidade com trabalhos cada vez mais voltados para a definição desses riscos e não apenas para a sua redução. Cada vez mais análises quantitativas de confiabilidade são demandadas de modo a se identificar a performance passada dos sistemas e se prever sua performance futura (BILLINTON; ALLAN, 1992).

Um pobre gerenciamento de ativos pode resultar em graves consequência de segurança, elevados custos e elevadas perdas por baixas performances. Busca-se operar um ativo de forma a encontrar um ponto ideal, onde os custos de investimento, custos operacionais e riscos de falha estejam equilibrados. Essa busca pode ser realizada de várias maneiras, seja por meio de uma abordagem simplificada baseada no julgamento de especialistas, ou de forma mais sofisticada, realizando análises de sensibilidade que levem em consideração as incertezas dos dados e modelagem de cenários possíveis para um determinado ativo (WOODHOUSE, 2016).

Para se alcançar o ponto ótimo de operação de um ativo, é necessário considerar os riscos envolvidos em todas as etapas do seu ciclo de vida. A gestão de riscos ajuda a determinar qual é o nível aceitável de risco para um dado ativo, levando em consideração fatores como segurança, confiabilidade, sustentabilidade e conformidade legal. Adicionalmente, a gestão de riscos permite a identificação e mitigação de problemas futuros, incluindo a implementação de programas de manutenção preventiva, preditiva, monitoramento e avaliações contínuas do desempenho dos ativos. O gerenciamento de riscos envolve quatro principais estágios (INTERNATIONAL ELECTROTECHNICAL COMMISSION, 2019):

- Identificação dos riscos;
- Caracterização dos riscos;

- Seleção e implementação de tratamentos de risco ou controles adequados;
- Validação/monitoramento da efetividade dos controles.

O FMECA é a ferramenta que oferece uma metodologia de avaliação cujo objetivo é o mapeamento dos modos de falha dos sistemas avaliados, como eles ocorrem, bem como sua criticidade, em que a identificação e caracterização dos riscos dos sistemas são realizadas de forma preliminar.

As informações obtidas sobre os modos de falha mais frequentes e críticos são utilizadas na tomada de ações necessárias para eliminar ou mitigar falhas de acordo com as prioridades estabelecidas. Além disso, ao documentar o conhecimento atual sobre os modos de falha de um sistema ou equipamento por meio de avaliações qualitativas e quantitativas, a FMECA fornece orientações adequadas para os fabricantes ou para a engenharia de manutenção sobre as falhas que podem ocorrer naquele sistema ou equipamento, seus efeitos, consequências e criticidades, além de indicar métodos de detecção de falhas e ações preventivas a serem adotadas.

A FMECA também oferece uma oportunidade adicional para identificar novos perigos que não foram previamente identificados durante as etapas de análise de perigos e riscos, possibilitando, assim, a descoberta das etapas necessárias para prevenir catástrofes e direcionar recursos valiosos para as necessidades apropriadas (LEE; AKPUDO; HUR, 2021). As informações de perigos e riscos, podem ser utilizadas tanto a etapa de projeto quando de operação dos sistemas para a proposição de melhorias de projetos ou alterações de existentes com o objetivo de redução dos riscos buscando-se minimizar os perigos. Caso alterações sejam realizadas em busca de melhorias dos sistemas, uma nova avaliação dos modos de falhas deve ser realizada de modo a identificar se novos riscos foram inseridos no sistema.

Na etapa de planejamento de uma FMECA deve ser definida a motivação para sua realização, quais itens ou elementos do processo serão analisados e em quais cenários. Em sistemas complexos, a análise pode ser subdividida em subsistemas. Antes de iniciar a análise, é importante definir os critérios para determinar quais modos de falha requerem tratamento e estabelecer as prioridades de ação, o que deve ser feito durante a etapa de planejamento (INTERNATIONAL ELECTROTECHNICAL COMMISSION, 2018).

De acordo com a norma IEC 60812, a FMECA deve incluir, no mínimo, os seguintes itens:

- Descrição do sistema, item ou processo sob análise;
- Descrição clara do escopo da análise;
- Critério usado quando um tratamento é necessário;

- Suposições feitas sobre o item ou processo analisado e os cenários de uso relevantes;
- Uma descrição clara e detalhada da metodologia que fundamente a análise;
- Identificação dos responsáveis pela análise;
- Uma descrição do método utilizado para realizar a análise de criticidade;
- Fonte de dados e outros materiais em que a FMECA está baseado;
- Identificação dos modos de falha, seus efeitos e, se apropriado, suas criticidades e causas;
- Resumo dos resultados e recomendações dos tratamentos que foram gerados;
- Limitações ou deficiências da análise que devem ser tratadas em atualizações futuras;
- Alterações de projeto que foram feitas no item como resultado da FMECA e qualquer ação não solucionada;
- Registros de análises que podem ser incluídos com um anexo ao relatório.

Os resultados de uma FMECA fornecem informações sobre a criticidade de um item complexo de processo, as quais podem ser usadas como entrada para diversas aplicações, incluindo técnicas de resolução de problemas durante manutenções corretivas ou diagnóstico de falhas.

## 2.5 Considerações finais

No capítulo de fundamentação teórica, foram abordados diversos aspectos relevantes para o contexto do trabalho. Foram apresentados o sistema elétrico da plataforma de petróleo onde o turbogerador está instalado, o ciclo termodinâmico pelo qual o turbogerador opera e os detalhes das partes que compõem o turbogerador, incluindo o seu sistema de lubrificação por óleo mineral. Além disso, foi realizada uma análise comparativa entre o SIF e a rede ANFIS, destacando a escolha do SIF como a ferramenta selecionada para o diagnóstico de falhas no sistema de óleo mineral do turbogerador ao longo deste trabalho. Uma seção tratou sobre a FMECA, a qual utiliza a ISO 14224:2006 para padronizar os modos de falha e as partes afetadas dos equipamentos.

No próximo capítulo, são apresentadas pesquisas recentes sobre o diagnóstico de falhas em equipamentos e turbogeradores. Essas referências são fundamentais para contextualizar o estado da arte e embasar a abordagem adotada neste estudo.



## 3 Revisão Bibliográfica

Neste capítulo, é apresentada a revisão bibliográfica do tema estudado. Para uma melhor organização do texto, o capítulo foi subdividido em três seções distintas. A Seção 3.1 aborda os principais estudos relacionados ao diagnóstico de falhas em equipamentos utilizando técnicas de inteligência artificial. A Seção 3.2 apresenta os principais estudos relacionados ao diagnóstico de falhas em turbogeradores, também utilizando técnicas de inteligência artificial. A Seção 3.3 contém um quadro sinóptico que resume as principais contribuições de cada autor em relação ao diagnóstico de falhas, além das contribuições deste trabalho. Por fim, na Seção 3.4 é feito um apanhado das principais informações da revisão bibliográfica realizada, abordando diversas técnicas de diagnóstico de falhas em equipamentos, com destaque para as aplicações em turbogeradores. Além disso, é mencionado que o próximo capítulo apresentará a metodologia proposta para o diagnóstico de falhas em turbogeradores.

### 3.1 Diagnóstico de falhas em equipamentos

Diferentes tipos de ferramentas análises diagnósticas de falhas em equipamentos têm sido empregados com o uso de algoritmos de inteligência artificial. Entre eles, podem-se citar a lógica fuzzy, redes neurais artificiais, sistemas híbridos de lógica fuzzy e redes neurais artificiais, aprendizado por reforço e modelos *ensemble* (KARI et al., 2018; XU et al., 2019; SUNDARAM et al., 2021). O objetivo do diagnóstico é detectar, isolar e identificar a falha que ocorreu, sendo essa etapa realizada em duas fases: (1) extração de atributos e (2) classificação e identificação das causas das falhas utilizando determinados atributos.

No campo relacionado à extração de atributos aplicada ao diagnóstico de falhas em equipamentos, em que se realiza a identificação e seleção de características relevantes e informativas a partir de conjuntos de dados brutos, várias técnicas têm sido empregadas.

Em Tran, Elsisi e Liu (2021), por exemplo, a entropia difusa foi utilizada para selecionar atributos de sinais de vibração de uma máquina de usinagem CNC. Nesse caso, um dinamômetro coletava a força de corte da bancada onde estava fixada uma peça fresada. Em seguida, um classificador era adotado para distinguir o estado do corte como estável ou instável. Um classificador de similaridade foi usado para classificar o corte estável e o corte instável em diferentes velocidades do fuso e profundidade de corte.

Quando se trata de modelos de diagnóstico de falhas usando modelagem matemática, Felipe, Melo e Freitas (2021) desenvolveram um modelo para uma usina fotovoltaica,

utilizando medidas elétricas como base de dados, permitindo a identificação de alguns modos de falhas. Shutenko e Ponomarenko (2022) propuseram um modelo de regressão para determinar o envelhecimento do óleo isolante de transformadores de potência. Dao (2022) utiliza uma abordagem de modelos de regressão para detectar o estado operacional anormal de uma turbina eólica. Os dados foram adquiridos por meio do sistema de supervisão e aquisição de dados (SCADA, do inglês: *Supervisory Control and Data Acquisition*), e o teste de Chow foi aplicado para identificar possíveis mudanças nos parâmetros dos modelos de regressão. No trabalho apresentado por Pang, Nazari e Tang (2022), foi proposto um modelo recursivo de decomposição variacional dos modos para o diagnóstico de falhas em rolamentos.

Nos estudos que utilizam modelagem matemática, é evidente a necessidade de um modelo matemático representativo, o que demanda um conhecimento aprofundado do sistema, a fim de garantir sua validade e representação adequada de todas as suas condições. No entanto, é importante destacar que as incertezas inerentes ao modelo podem não ser completamente abrangidas pela modelagem matemática convencional, devido às variações do processo e às influências externas que podem ocorrer.

Elshenawy et al. (2021) aplicaram uma técnica de aprendizado não supervisionado para detecção e diagnóstico de falhas em plantas de geração de energia nuclear. No estudo, foram monitoradas 81 variáveis para detectar 20 cenários de falha. É importante destacar que o objetivo desse trabalho era a detecção dos cenários de falha estabelecidos no software PCTTRAN, que simula um reator nuclear pressurizado a água, e não estava direcionado para detecção de falhas nos equipamentos da planta de geração. Embora os autores tenham relacionado as variáveis de processo aos cenários de falha do software PCTTRAN, padronizando os modos de falha a serem avaliados de acordo com o previsto para esse tipo de instalação e correlacionando as alterações nas variáveis com os eventos, nenhum diagnóstico foi realizado para identificar a causa da falha nesse trabalho.

Benouioua et al. (2022) realizaram a extração de atributos em dados de monitoramento de tensão de células combustíveis, com o objetivo de diagnosticar falhas por meio da identificação de divergências entre o regime operacional das células e suas assinaturas iniciais. Utilizaram um classificador baseado em máquina de vetores de suporte (SVM, do inglês: *Support Vector Machine*). Essa técnica apresenta a desvantagem de exigir um experimento em laboratório para coletar as assinaturas iniciais das células combustíveis. Trata-se de uma abordagem baseada em dados que não reflete o fenômeno físico presente nas células combustíveis e avalia o reconhecimento de padrões por meio da análise das assinaturas de sinais de tensão medidos em uma pilha de células combustíveis. Essas assinaturas foram obtidas a partir de padrões normais e padrões de falhas introduzidos em duas células combustíveis que serviram como casos de teste para o diagnóstico. O conhecimento do especialista foi incorporado ao modelo, buscando-se uma classificação

baseada no reconhecimento de padrões.

No estudo de Brito et al. (2022), foi realizada a extração de atributos de sinais de vibração utilizando o processo de rotulagem dos dados. Alguns atributos foram selecionados manualmente com base no conhecimento prévio sobre análise de vibração. Para a classificação de falhas, um algoritmo de detecção de anormalidades foi inicialmente empregado. Caso uma anomalia seja detectada, é verificado se os atributos relacionados à anormalidade estão associados a uma única falha ou a diferentes tipos de falha. Se estiverem associados a uma única falha, o algoritmo realiza a classificação da falha. Caso contrário, é realizada uma classificação não supervisionada para determinar qual característica é mais relevante para a falha, em vez de classificá-la. É necessário ter um banco de dados para treinamento e testes, e o conhecimento do especialista não é incorporado ao modelo de detecção de falhas. Além disso, é necessário desenvolver diferentes tipos de algoritmos, um para identificação de falhas, outro para diagnóstico de falhas e outro para análise de causas raízes, aumentando a complexidade do modelo.

Vários trabalhos têm utilizado com sucesso a rede neural convolucional (CNN, do inglês: *Convolutional Neural Network*) para a extração de atributos, como Li, Li et al. (2021), Yang, Yin et al. (2022), Liu, Ma et al. (2021) e Wang et al. (2021). Nesses casos, o objetivo da CNN é formar grupos de atributos para que um modelo possa classificar cada tipo de falha. Esses algoritmos também são aplicados como método de classificação no diagnóstico de falhas. Para que a CNN seja eficaz, é necessário ter um conjunto de dados disponível, fornecendo ao modelo exemplos de estados das condições de falha e disponibilidade dos equipamentos. As desvantagens desse modelo são a necessidade de um conjunto de dados de treinamento/fase de treinamento e baixos requisitos para o conhecimento do especialista a ser adicionado ao modelo, o que pode resultar em uma representação física pobre do sistema.

Em Zhou et al. (2022), foi implementado um modelo de diagnóstico baseado em aprendizado de recursos gráficos para diagnosticar falhas em uma caixa de engrenagens. Os autores extraíram atributos de valores normalizados por meio da decomposição dos valores singulares de matrizes contendo os sinais dos sensores de vibração do equipamento monitorado. Em seguida, uma rede convolucional de grafos realizou a extração de atributos de alto nível para que um classificador *softmax* pudesse categorizar as falhas. Assim como no caso da CNN, esse modelo também requer uma fase de treinamento e conhecimento do especialista não é incorporado ao modelo.

Outros autores têm utilizado técnicas de Deep Learning para o diagnóstico de falhas. Por exemplo, Li e Zhang (2021) desenvolveram um modelo de rede neural artificial (RNA) para o diagnóstico de falhas em rolamentos. No trabalho, eles avaliaram o banco de dados chamado “Case Western Reserve University”, que continha falhas de uma máquina rotativa ensaiada em uma bancada. O diagnóstico foi realizado por meio de redes neurais aplicadas

na adaptação parcial de domínios. Essa técnica consiste em disponibilizar um conjunto de dados, que é um banco com a fonte de dados de treinamento contendo informações das classes de falhas dos equipamentos, para que o sistema treine essas falhas em um domínio fonte e possa prever um conjunto de falhas em um domínio alvo. Foi aplicada uma técnica de aprendizado não supervisionado para avaliar a consistência da predição dos diagnósticos. No entanto, nesse trabalho, não foi realizada nenhuma avaliação das falhas dos equipamentos, limitando-se apenas à avaliação do banco de dados do estudo de caso.

Em Gao et al. (2021), foi desenvolvido um modelo de RNA para o diagnóstico de falhas mecânicas em disjuntores de alta tensão. Em ambos os artigos mencionados, houve o tratamento dos dados utilizando técnicas de IA, mas sem agregar o conhecimento do especialista dos equipamentos ao modelo, o que também é observado nos exemplos apresentados por Sundaram et al. (2021).

Zhang et al. (2023) propõem em seu estudo a extensão da vida útil de um conversor booster cc-cc. O modelo, baseado em redes neurais, é treinado para direcionar a distribuição de potência do sistema e equalizar o desgaste cumulativo entre as células. As variáveis consideradas são corrente, tensão de entrada e saída, temperatura das células e desgaste cumulativo estimado das células. O objetivo é aumentar o tempo até a falha dos componentes do sistema em avaliação. O artigo apresenta uma abordagem de modelagem baseada em dados, eliminando a necessidade de um conhecimento prévio de um modelo matemático para estimar a condição do equipamento. No entanto, é importante observar que a validação do estudo foi realizada em bancada e não foram utilizados dados de campo. Além disso, a avaliação feita pelos autores não incluiu uma análise diagnóstica, concentrando-se principalmente no aumento do tempo até a falha dos componentes do sistema em questão.

Em Liu, Liu et al. (2022), foi proposto um algoritmo geral para equalização de bases de dados, com o objetivo de otimizar a análise de falhas em bases de dados desbalanceadas, como é o caso da base de dados de falhas, em que geralmente se tem um grande número de dados relacionados ao sistema em operação normal e um pequeno conjunto de dados relacionados às falhas. A proposta dos autores é utilizar o algoritmo de Bagging com uma SVM para aumentar o número de amostras minoritárias e, assim, reduzir a razão de desbalanceamento do banco de dados, formando um novo conjunto de dados. Além disso, é empregado um algoritmo que utiliza uma unidade recorrente fechada bidirecional (BGRU, do inglês: *Bidirectional Gated Recurrent Unit*), uma variante de rede neural recorrente, no diagnóstico de falhas. As redes neurais recorrentes são um tipo de RNA projetada para lidar com dados sequenciais ou de séries temporais. Embora o balanceamento do banco de dados de falhas seja um diferencial desse trabalho, o conhecimento do especialista dos sistemas avaliados não é agregado ao modelo de rede neural.

Um sistema de inferência fuzzy foi aplicado com sucesso por Pei et al. (2020)

para diagnosticar falhas em células de combustível. As falhas avaliadas no estudo foram inundação e desidratação. Funções de pertinência triangulares e trapezoidais foram definidas para as variáveis de entrada, estabelecendo três condições para cada uma delas. O SIF produziu três classes de saída: desidratação, normal e inundação. Um conjunto de regras foi estabelecido para identificar as falhas previstas, mas sem identificar o componente específico com falha no sistema. Os autores não realizaram uma análise comparativa entre diferentes modelos e não houve padronização dos modos de falha específicos para esse tipo de equipamento.

Karnavas, Chasiotis e Vrangas (2017) apresentaram um trabalho de diagnóstico de falhas em barras de rotores de motores de indução trifásicos do tipo gaiola de esquilo. Nesse estudo, foi utilizada uma rede ANFIS com o objetivo de identificar se o motor estava com alguma barra do rotor quebrada ou não, utilizando análise de dados de escorregamento, número de polos do motor, frequências laterais à frequência fundamental do motor e assinatura de corrente. A utilização de uma rede ANFIS foi justificada pelos autores por contar com a vantagem da aprendizagem das redes neurais e pela facilidade de entendimento das regras do SIF. No entanto, uma avaliação comparativa entre as técnicas teria embasado a escolha feita pelos autores.

Forouhari e Abu-Siada (2018) apresentaram uma rede ANFIS para a estimativa de vida útil de transformadores de potência com base em parâmetros do óleo isolante e umidade. A utilização de um sistema neuro-fuzzy (SNF) permite que todas as normas operacionais do conjunto de transformadores em estudo sejam introduzidas no modelo, auxiliando em um gerenciamento mais eficiente desses equipamentos. Segundo os autores, o SNF apresentou melhores resultados do que um SIF utilizado em outros artigos de referência, devido à otimização das funções de pertinência a cada treinamento do sistema ANFIS.

Barbosa et al. (2022) propuseram um modelo que utiliza uma combinação de rede ANFIS e regressão de vetores de suporte (SVR, do inglês: *Support Vector Regression*) para estimar a vida útil de para-raios de óxido metálico. Nesse trabalho, séries temporais foram utilizadas para expandir um banco de dados adquirido a partir de medições realizadas em campo. Um comparativo entre três modelos foi realizado pelos autores, sendo eles um modelo de rede ANFIS, um modelo de SVR e o modelo combinado dessas duas técnicas. O objetivo principal do estudo foi estimar a vida útil dos para-raios investigados. No entanto, a avaliação realizada pelos autores não incluiu uma análise diagnóstica, direcionando seus estudos na previsão do tempo até a falha dos componentes.

## 3.2 Diagnóstico de falhas em turbogeradores

No campo de diagnóstico de falhas em turbogeradores, destacam-se os seguintes trabalhos:

- Bide et al. (2001) propuseram um método baseado em clusterização utilizando lógica fuzzy e transformada Wavelet para o diagnóstico de falhas na lubrificação de mancais, desbalanço e desalinhamento. Os autores limitaram sua avaliação a esses três modos de falhas, considerados os mais comuns para os mancais do equipamento avaliado. Os sinais de vibração da máquina foram coletados como entrada para o sistema. Durante o estudo, o modelo conseguiu identificar duas falhas ocorridas no equipamento. No entanto, o modelo apresentou limitações na avaliação superficial dos modos de falha do equipamento e na aplicação para a classificação de outros tipos de falhas, focando principalmente na análise de vibração;
- Yang e Wang (2006) e Yang e Zhang (2008) apresentaram modelos de diagnóstico de falha para turbogeradores baseados em sistemas híbridos de lógica fuzzy e redes neurais artificiais. Esses trabalhos avaliaram duzentos casos típicos de falhas por vibração, fuzzificando dezoito sintomas de falha para entrada na rede neural. A rede neural possuía três camadas, sendo a camada de saída composta por sete nós, sendo um para o estado do turbogerador e os demais para as falhas a serem diagnosticadas, como empenamento de rotor, quebra de lâmina, *oil-whip*, roçamento, desbalanceamento e desalinhamento. É importante observar que, para o treinamento da rede neural, todos os modos de falha devem ser mapeados e gerados os conjuntos de dados correspondentes;
- Huaying e Guangjian (2007) aplicaram a transformada Wavelet e um SNF com o objetivo de realizar o reconhecimento de padrões de falhas em um turbogerador acionado por uma turbina a vapor. Os autores utilizaram o sinal transformado no domínio Wavelet, que foi aplicado a um sistema de matrizes de correlação difusa. Nesse caso, uma rede neural combinada com lógica fuzzy foi utilizada para a detecção de seis tipos de falhas nesse tipo de máquina;
- Mousavi et al. (2022) propuseram um modelo de diagnóstico de falhas para uma turbina a gás *heavy-duty*, baseado em uma rede ANFIS e funções de base ortonormal. Esse modelo foi desenvolvido para capturar a dinâmica da falha e aprimorar a detecção de falhas, reduzindo os efeitos indesejados de medições, como ruído e perturbações. Além disso, um SIF foi utilizado para verificar se existem parâmetros dos sensores da turbina que estão se desviando de um determinado limite. Por fim, um algoritmo de árvore de decisão foi empregado para classificar os cenários de falha mapeados. Os modos de falha definidos para o modelo foram estabelecidos

pelos autores com base no que normalmente ocorre no tipo de turbina estudada, sem uma análise documental específica para a turbina em avaliação, considerando os modos de falha previstos para o equipamento, como é realizado na FMECA. A validação do modelo foi realizada utilizando dados experimentais, porém, não houve uma confirmação em campo para verificar a efetividade dos resultados.

### 3.3 Síntese da revisão bibliográfica

Nesta Tese, foi abordado o diagnóstico de falhas em turbogeradores aplicados na indústria de petróleo e gás. Na literatura existem diversas técnicas empregadas no diagnóstico de falhas de equipamentos em geral, bem como em turbogeradores, porém nenhuma delas se dedicou à padronização da transferência de conhecimento do especialista em equipamentos para modelos de IA aplicados ao diagnóstico de falhas. Para suprir essa lacuna, foi utilizado o mapeamento dos modos de falha do equipamento pela FMECA e a codificação dos modos de falhas e partes afetadas de acordo com a ISO 14224:2006.

Ao comparar o SIF com a rede ANFIS, observa-se que o sistema de inferência se destacou de forma positiva em relação ao modelo neuro-fuzzy, sendo uma de suas principais vantagens seu bom desempenho mesmo com um banco de dados desbalanceado, tendo em vista essa ser uma característica comum em banco de dados de falhas. Além disso, o SIF não requer dados de treinamento e testes do modelo. Outra vantagem atribuída à solução é a capacidade de lidar com incertezas nas variáveis de processo pela natureza probabilística das distribuições fuzzy, o que é uma limitação comum em modelos baseados em abordagens matemáticas convencionais.

De modo a sintetizar as contribuições dos trabalhos analisados, a seguir é apresentada uma tabela com as principais referências e contribuições abordadas na revisão bibliográfica. Na Tabela 2, são apresentadas, de forma sumarizada, as contribuições dos trabalhos relacionados ao diagnóstico de falhas em equipamentos. Além disso, a contribuição científica alcançada a partir desta pesquisa também está inserida dentro do contexto apresentado.

Com base na avaliação das referências bibliográficas sobre o tema, observa-se que o presente trabalho consegue preencher lacunas deixadas por outros autores, especialmente ao avaliar o tipo de modelo a ser empregado em situações em que não se tem disponibilidade plena de dados de falhas para treinamento e teste dos modelos, o que é uma exigência comum. Além disso, destaca-se que nenhuma pesquisa abordou de forma simultânea a metodologia de diagnóstico e classificação de falhas utilizada no presente estudo.

Tabela 2 – Comparativo entre a revisão bibliográfica e o presente trabalho

<b>Trabalho</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>
(TRAN; ELSISI; LIU, 2021)	X			X		
(FELIPE; MELO; FREITAS, 2021)	X					
(SHUTENKO; PONOMARENKO, 2022)				X		X
(DAO, 2022)				X		X
(PANG; NAZARI; TANG, 2022)	X					
(ELSHENAWY et al., 2021)	X			X	X	
(BENOUIOUA et al., 2022)				X		
(BRITO et al., 2022)			X	X		
(LI; LI et al., 2021)			X	X		
(YANG; YIN et al., 2022)				X		
(LIU; MA et al., 2021)			X	X		
(WANG et al., 2021)			X	X		
(ZHOU et al., 2022)				X		
(LI; ZHANG, 2021)			X	X		
(GAO et al., 2021)				X		
(SUNDARAM et al., 2021)				X		
(ZHANG et al., 2023)				X		
(LIU; LIU et al., 2022)		X	X	X		X
(PEI et al., 2020)	X	X		X		
(BARBOSA et al., 2022)	X			X		X
(KARNAVAS; CHASIOTIS; VRANGAS, 2017)	X			X		
(FOROUHARI; ABU-SIADA, 2018)	X	X	X	X		
(BIDE et al., 2001)				X		X
(YANG; WANG, 2006)	X			X		
(YANG; ZHANG, 2008)	X			X		X
(HUAYING; GUANGJIAN, 2007)				X		X
(MOUSAVI et al., 2022)	X			X		
<b>Este Trabalho</b>	<b>X</b>	<b>X</b>	<b>X</b>	<b>X</b>	<b>X</b>	<b>X</b>

1 - Conhecimento do especialista agregado ao modelo;

2 - Avaliação do tipo de modelo a ser empregado com base na disponibilidade de dados para treinamento e teste;

3 - Análise comparativa entre modelos de diagnóstico e classificação de falhas;

4 - Modelo lida com incertezas das variáveis de processo;

5 - Padronização da transferência de conhecimento do especialista para o modelo de IA;

6 - Validação dos resultados do modelo com dados de campo.

Referência: Elaborado pelo Autor.

### 3.4 Considerações finais

Neste capítulo, foi realizada uma revisão bibliográfica abrangendo várias técnicas de diagnóstico de falhas em equipamentos. Uma seção específica foi dedicada ao diagnóstico de falhas em turbogeradores, que é o foco principal desta Tese. Além disso, foi realizado um levantamento comparativo entre as referências bibliográficas relacionadas ao tema e o trabalho desenvolvido nesta Tese, destacando as contribuições adicionais deste estudo em



relação às pesquisas anteriores. Essa análise permitiu identificar as inovações introduzidas e as lacunas preenchidas por esta pesquisa, evidenciando as contribuições significativas para o campo do diagnóstico de falhas em turbogeradores.

No próximo capítulo, é apresentada a metodologia proposta para o diagnóstico de falhas em turbogeradores, com enfoque no sistema de lubrificação de óleo mineral de uma unidade de produção de petróleo e gás do tipo FPSO. A metodologia adotada é orientada pelas necessidades do negócio e tem como foco principal a solução efetiva do problema em questão.



## 4 Metodologia

Neste capítulo, é apresentada a metodologia adotada neste trabalho, que é baseada no processo padrão inter-indústrias para mineração de dados (CRISP-DM, do inglês: *Cross Industry Standard Process for Data Mining*). Embora esse processo tenha sido desenvolvido para a ciência de dados, ele pode ser aplicado em diferentes projetos. A metodologia é composta por seis etapas distintas, conforme ilustrado na Figura 10. Essa abordagem foi aplicada na criação de um modelo de classificação de falhas para o sistema de geração principal de uma plataforma tipo FPSO composto por quatro turbogeradores. Cada turbogerador possui uma tensão nominal de 13,8 kV e potência nominal de 25 MW, e como ferramenta foi utilizado um sistema de inferência fuzzy.

Figura 10 – Metodologia CRISP-DM aplicada no SIF



Referência: Elaborado pelo Autor.

A primeira etapa do processo de desenvolvimento da solução, que é o entendimento do negócio, é fundamental para identificar as necessidades do negócio e dos usuários finais. É importante destacar que o sucesso do ciclo de desenvolvimento do projeto depende do alinhamento com uma necessidade real do negócio. Isso assegura que o projeto esteja direcionado para resolver problemas ou atender a necessidades específicas, agregando valor real à organização. Nessa etapa, os modos de falha avaliados pelo modelo foram definidos

de acordo com a necessidade do sistema, bem como as partes do sistema que foram afetadas por esses modos de falha.

A segunda etapa, o entendimento dos dados, é onde são definidas as variáveis de interesse e realizada a coleta de dados. Trata-se da etapa com maior dispêndio de tempo, tendo em vista a necessidade de coleta de informações de diversas fontes e sua organização para análise.

As etapas três e quatro do processo, que são a preparação dos dados e a modelagem, respectivamente, aqui foram agrupadas em um único bloco, considerando que a preparação dos dados para o modelo envolve a fuzzificação das entradas *crisp*, que é parte integrante da etapa de modelagem. Nesses estágios, os dados de entrada passam por uma seleção para eliminar valores espúrios, e os dados resultantes foram mapeados em conjuntos fuzzy por meio das funções de pertinência. A modelagem do sistema de inferência fuzzy foi realizada seguindo um modelo Mamdani, com os valores de saída desfuzzificados indicando a classe, seja ela a operação normal do sistema ou a classe da falha identificada, de acordo com o conjunto de falhas definidas na segunda etapa do processo de desenvolvimento da solução.

Na etapa de avaliação, são definidos os critérios de desempenho do modelo de classificação de falhas de modo a avaliar sua efetividade. Também é a etapa de realização de testes para validar se atendem às necessidades do negócio e determinar a confiança dos dados.

A etapa de implantação trata-se da etapa em que todas as etapas anteriores foram concluídas e o modelo encontra-se pronto e validado. É a fase dedicada à integração e implantação prática do modelo, permitindo que ele seja utilizado de forma efetiva. Para isso, é necessário criar um plano de implantação, com os detalhes necessários para o modelo evoluir do ambiente de desenvolvimento para produção. Nessa solução, a aplicação ainda não migrou para o ambiente de produção, assim, esta etapa da metodologia não foi aplicada.

As etapas do CRISP-DM, utilizadas no processo de desenvolvimento da solução, foram divididas em cinco seções distintas neste capítulo, visando uma melhor organização do texto. A Seção 4.1 aborda o entendimento do negócio, onde são identificadas as necessidades da solução proposta com base nas dificuldades enfrentadas no negócio. A Seção 4.2 trata da coleta e seleção dos dados para entrada no modelo. Na Seção 4.3, é descrita a forma de modelagem do sistema de inferência fuzzy, assim como a preparação dos dados de entrada e saída do modelo para a classificação da situação operacional dos turbogeradores avaliados. Na Seção 4.4, são apresentadas as métricas de desempenho do modelo. Na Seção 4.5 são apresentadas as considerações finais sobre a metodologia empregada no desenvolvimento da solução empregada.

## 4.1 Entendimento do negócio

O objetivo do entendimento do negócio é definir os requisitos do projeto e entender as necessidades do usuário. Nesse sentido, a avaliação realizada nesta Tese iniciou-se com a necessidade de aprimoramento do diagnóstico de falhas dos turbogeradores de uma plataforma tipo FPSO, tendo em vista a importância desse tipo de instalação industrial, bem como a relevância do sistema estudado para o seu processo produtivo.

Ao analisar os registros da lista de eventos e alarmes do supervisor dos turbogeradores do sistema de geração em estudo, constatou-se que nem todos esses registros fornecem ao operador o diagnóstico da falha quando de sua ocorrência, tendo em vista que essa lista visa o atendimento da matriz de causa e efeito do equipamento, cujo objetivo principal é a proteção e segurança de pessoas e do equipamento. Dessa forma, a lista de eventos e alarmes, em geral, fornece informações sobre valores muito baixos, baixos, altos ou muito altos de sensores que geraram alarmes e desligamentos.

Como nem sempre as informações sobre as falhas ocorridas não se encontram disponíveis, a equipe de operação e manutenção desses equipamentos necessitam recorrer à consulta a manuais de resolução de problemas ou empreender uma investigação para o diagnóstico de falhas do equipamento.

O tempo decorrido na investigação das causas de uma falha está diretamente relacionado ao aumento do MTTR, em que seu aumento impacta na diminuição da disponibilidade do equipamento. O diagnóstico de falhas aqui proposto visa suprir esta lacuna de modo que as equipes de operação e manutenção possam, de maneira ágil, identificar qual a causa de eventual falha no equipamento.

Os estados definidos para modelagem do comportamento dos geradores em termos de seu funcionamento são discretos, identificáveis e contínuos no tempo representando um processo de Markov (CASTRO; RODRIGUEZ; CARVALHO, 2022). Ou seja, em termos de estado operacional ou em estado de falha, cada equipamento do sistema se encontrará em um dos estados e permanecerá nesse estado até que migre para o próximo estado. Sendo assim, o processo de diagnóstico de falhas passa não só pela identificação do estado em que se encontra o turbogerdor objeto de avaliação, mas também o que o faz residir naquele estado de falha.

Para desenvolver o modelo de diagnóstico, é necessário primeiro entender os modos de falha do sistema de óleo lubrificante mineral. Essas informações podem ser acessadas por meio da documentação de engenharia que contém a FMECA, onde todos os modos de falha e peças afetadas desse sistema estão listados. Os mecanismos e modos de falha são então descritos e codificados de acordo com a ISO 14224:2006. Os efeitos das falhas são avaliados e a criticidade é definida para estabelecer a estratégia de manutenção e peças de reposição. Algumas estratégias de manutenção incluem o monitoramento de parâmetros

para detecção de falhas.

Os modos de falha cuja FMECA mapeia como possíveis de serem detectados pelo monitoramento da condição podem ter seus parâmetros coletados por meio da coleta de dados online por sensores, verificações de rotas operacionais, manutenção preditiva ou por manutenção preventiva.

O conhecimento especializado sobre o equipamento, seus modos de falha, partes afetadas, variáveis de interesse para monitoramento da condição e como essas se relacionam podem ser incorporados a um modelo de IA. Os modelos fuzzy são amplamente conhecidos por suas características de serem um método de modelagem baseado em conhecimento, que utiliza descrições semânticas obtidas de operadores humanos e/ou conhecimento especializado como entradas do modelo com limites graduais em vez de numéricos discretos (OUELLET et al., 2021), sendo uma ferramenta valiosa para a aplicação desenvolvida.

A utilização de sinais dos sensores de monitoramento como entradas para o modelo fuzzy implementado preenche a lacuna no sistema supervisor dos turbogeradores ao diagnosticar as falhas ocorridas no sistema de óleo mineral, de acordo com os modos de falha estabelecidos pelos especialistas do sistema como detectáveis por monitoramento online.

Quando do planejamento para a coleta de dados de falha, deve-se observar que uma falha pode ocorrer em diferentes modos, dessa maneira o anexo “B” da ISO 14224:2006 nas suas Tabelas B.6 a B.14 são apresentados os modos de falhas para os diversos equipamentos empregados na indústria de óleo e gás, bem como a codificação desses modos de falha de acordo com esta norma. A partir da lista da FMECA do sistema avaliado, uma lista de falhas que podem ser detectadas por meio de monitoramento online foi extraída e apresentada na Tabela 3, em que todos os modos de falhas já se apresentam codificados. Além disso, duas outras falhas foram adicionadas ao modelo tendo em vista sua relevância para o processo: falha na ventilação do tanque de óleo lubrificante mineral e divergência na medição dos sensores de monitoramento.

A relação entre as partes afetadas e seus modos de falha serviram com insumo para as saídas para o modelo de diagnóstico fuzzy, tendo em vista que o modo de falha de uma parte afetada caracteriza o diagnóstico de sua falha.

## 4.2 Entendimento dos dados

Pressão, temperatura e nível são as grandezas que estão diretamente disponíveis nos sensores do sistema de óleo lubrificante mineral. Esses sensores monitoram determinados pontos de interesse do sistema para fornecer informações aos sistemas de controle e proteção

Tabela 3 – Partes afetadas e modos de falha do sistema de óleo mineral

<b>Parte afetada</b>	<b>Modo de falha FMECA</b>	<b>ISO 14224:2006 Tabelas B6, B7 e B9</b>
Bomba lubrificação principal	Desgaste interno	STD
Bomba lubrificação auxiliar	Desgaste interno	STD
Linhas de óleo mineral	Afrouxamento de conexões / rompimento	BRD
Filtros de óleo mineral	Obstrução	PLU
Trocadores de calor	Obstrução / contaminação das placas	PLU/IHT
Válvula de controle de temperatura	Travamento / emperramento / perda de vedação	SPO/ELP
Vent do tanque de óleo mineral	Obstrução	PLU
Sensores redundantes	Divergência de medições	AIR

Referência: Elaborado pelo Autor.

dos turbogeradores, possibilitando a operação segura dessas máquinas.

Para cada modo de falha potencial, foi realizada uma análise metódica utilizando a FMECA e a documentação de projeto para identificar os sensores capazes de detectar falhas específicas relacionadas aos componentes. Vale ressaltar que nem todos os sensores do sistema de óleo lubrificante mineral eram entradas necessárias para a construção do modelo, tendo em vista que alguns dos sensores do sistema são chaves de pressão do circuito de óleo lubrificante já monitorado por outros sensores de pressão analógicos e monitorados pelo modelo.

Nos casos em que a FMECA não abrangia determinados modos de falha, contou-se com a expertise do especialista do sistema para selecionar o conjunto apropriado de sensores para detecção. Os sensores identificados na FMECA e na análise do especialista como necessários para o modelo de diagnóstico estão listados na Tabela 4.

Após estabelecer a matriz de sensores com base nos modos de falha mapeados do sistema, a próxima tarefa envolve a obtenção de faixas de calibração para cada sensor de monitoramento de variável de processo, a fim de determinar as variáveis universo do SIF. Essas faixas representam os limites mínimos e máximos de leitura que o instrumento pode fornecer ao sistema de monitoramento e controle da máquina monitorada. Qualquer leitura acima ou abaixo desses valores será truncada. Portanto, a limitação dos valores das variáveis universo, utilizando os limites de calibração dos sensores, mostrou-se uma

Tabela 4 – Variáveis de monitoramento do sistema de óleo mineral

<b>Tag da variável</b>	<b>Descrição</b>
LIT-511	Nível do tanque de óleo mineral
PDIT-555-A	Pressão diferencial do tanque de óleo mineral
PDIT-555-B	Pressão diferencial do tanque de óleo mineral
PIT-548-A	Pressão do <i>manifold</i> de óleo mineral
PIT-548-B	Pressão do <i>manifold</i> de óleo mineral
TE-559-A	Temperatura do óleo mineral
TE-559-B	Temperatura do óleo mineral
PDIT-556	Pressão diferencial dos filtros de óleo mineral
PIT-562	Pressão de descarga das bombas de óleo mineral
PIT-5124018	Pressão do <i>header</i> de água de refrigeração
TIT-5124009	Temperatura do <i>header</i> de água de refrigeração

Referência: Elaborado pelo Autor.

estratégia adequada para esta aplicação.

Utilizando documentação do projeto, como listas de instrumentos, diagrama de processos e instrumentação (P&ID, do inglês: *Piping and Instrumentation Diagram*) e diagramas elétricos, é possível determinar os limites inferior e superior de cada variável monitorada pelos sensores do sistema.

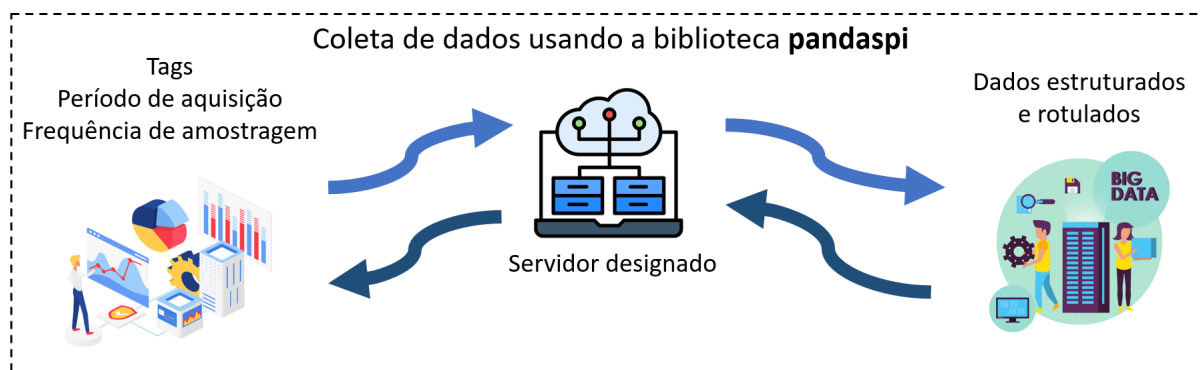
A aquisição e processamento de dados dos sensores de monitoramento das máquinas em estudo foram realizados por meio da coleta de dados do sistema supervisório da planta de produção, onde os turbogeradores estão instalados. Para essa finalidade, utilizou-se a biblioteca Python chamada “pandaspi”, que permite a interface de comunicação em Python com o sistema de coleta e armazenamento de dados de processo da FPSO, conhecido como historiador da planta de processo (PI, do inglês: *Plant Information*) (MENEZES et al., 2020), sendo esses dados adquiridos em formato de *dataframe*. Para a aquisição de dados por essa biblioteca foi desenvolvida uma aplicação para o acesso ao servidor designado e obtenção dos dados de leitura. A Figura 11 ilustra o processo de coleta de dados, em que para o acesso a esse servidor deve-se fornecer as seguintes informações: credenciais de acesso ao sistema de monitoramento, data e horário de início da aquisição, data e horário de fim da aquisição, tempo entre amostras e *tags* dos sensores que se deseja adquirir os dados.

Foi estabelecido um período de amostragem de 60 segundos com o objetivo de diagnosticar os modos de falha listados na Tabela 3. A escolha desse período se baseia na constatação de que os valores das variáveis monitoradas, mencionados na Tabela 4, continuam sendo representativos ao longo do período avaliado.

Uma etapa de seleção de dados foi necessária para filtrar valores indesejados, como “Bad”, “No Data”, “Scan Timeout” e “Pt Created”, que foram coletados do sistema PI.



Figura 11 – Processo de coleta e seleção de dados



Referência: Elaborado pelo Autor.

Esses valores foram eliminados do conjunto de dados. Dados faltantes foram estimados com o auxílio de um estimador na linguagem de programação Python pertencente à classe “IterativeImputer”, que faz parte da biblioteca “Scikit-learn”.

Os sensores de chama, da câmara de combustão da turbina, foram utilizados como sinalizadores de que a máquina estava em funcionamento. Assim, o diagnóstico de falhas só é realizado para o caso do equipamento na condição em operação e ao migrar para o estado indisponível o modelo não realiza qualquer ação de diagnóstico. Como a informação de chama detectada era fornecida ao PI em formato de texto, esse valor foi transformado para um inteiro em que o valor “0” representa nenhuma chama detectada na câmara de combustão da turbina e “1” chama detectada na câmara de combustão da turbina.

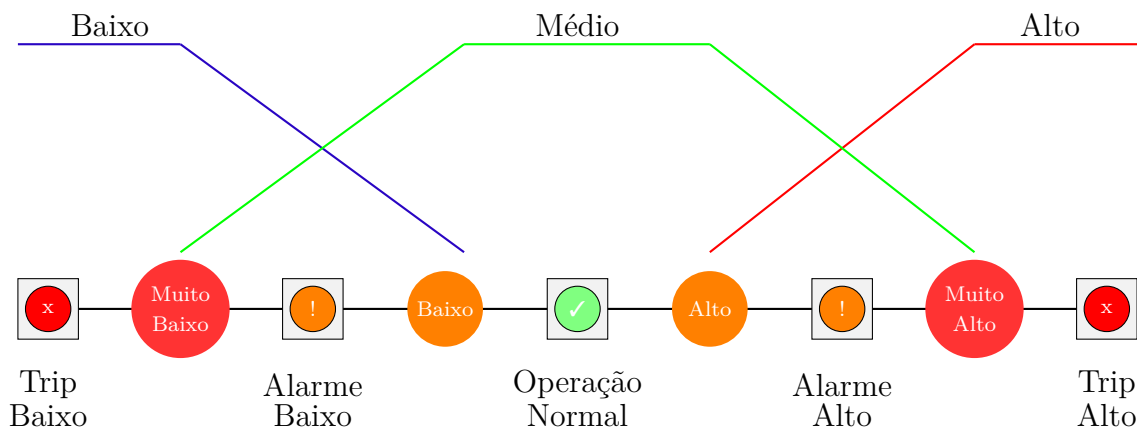
### 4.3 Preparação dos dados e modelagem

Ao longo da operação dos turbogeradores, uma série de sensores monitora vários componentes das máquinas. As variáveis monitoradas por esses sensores podem operar em cinco faixas, como ilustrado na Figura 12. Essas faixas são:

1. Desligamento por valor abaixo do limite estabelecido ou “Trip Baixo”, representado pelos valores medidos menores ou iguais ao definido como “Muito Baixo”.
2. Faixa de “Alarme Baixo”.
3. Faixa de “Operação Normal”.
4. Faixa de “Alarme Alto”.
5. Desligamento por valor acima do limite estabelecido ou “Trip Alto”, representado pelos valores medidos maiores ou iguais ao definido como “Muito Alto”.

As faixas operacionais indicam diferentes pontos de operação das grandezas medidas pelos sensores, permitindo identificar situações de desligamento, alarme ou operação normal, de acordo com os limites estabelecidos. Por se tratar de um sistema complexo, em que as informações sobre as leituras dos sensores de monitoramento são variáveis independentes e podem pertencer a conjuntos diferentes, os graus de pertinência dessas leituras podem ser interpretados como probabilidades subjetivas, indicando a probabilidade de que uma dada leitura pertença a um determinado conjunto fuzzy.

Figura 12 – Limites das variáveis operacionais



Referência: Elaborado pelo Autor.

Dos conjuntos fuzzy, tem-se que a faixa de “Operação Normal” está compreendida entre os limites de “Alarme Baixo” e “Alarme Alto” e é a faixa em que a máquina opera em condições normais sem que haja qualquer alarme.

Já a faixa de alarme geralmente é dividida em faixas de “Alarme Baixo” e “Alarme Alto”. Quando um parâmetro da máquina está dentro de qualquer uma dessas faixas, a máquina mantém sua funcionalidade, embora o status do parâmetro não seja mais considerado como uma condição de operação normal estando a máquina a uma condição operacional mais próxima à falha, uma vez que o parâmetro está mais próximo do valor de desligamento do que quando opera em condições normais de operação. Nesse caso há um desvio do parâmetro monitorado e a máquina opera mais próxima ao seu desligamento ou *trip*.

Para as faixas de desligamento, representadas na Figura 12 pelas faixas “Trip Baixo” e “Trip Alto”, a mesma analogia das faixas de alarme pode ser feita. A diferença é que os limites dos valores de alarme e desligamento são diferentes e estabelecidos pelo fabricante da máquina para protegê-la.

Os limites de desligamento e de alarme de cada variável de entrada foram usados como parâmetros para os limites das funções de pertinência no modelo SIF. Como nem todos os sensores são projetados exclusivamente para medidas de proteção, mas alguns

também têm propósitos de diagnóstico, a configuração dos limites das funções de pertinência requer a experiência de especialistas para elaborar uma estratégia ideal para o modelo.

Pela característica operacional dos equipamentos em avaliação, em que há um patamar de operação em que a máquina encontra-se em operação normal, outros patamares em que a máquina encontra-se em *trip* e pontos de transição entre as condições de operação normal para *trip* e vice-versa, a função trapezoidal foi uma escolha do especialista para representar o comportamento das entradas devido às suas características de alta associação com o comportamento dessas variáveis.

Em relação ao conjunto de entradas fuzzy, foram estabelecidos três conjuntos para cada entrada, sendo eles: “Baixo”, “Médio” e “Alto”. Esses conjuntos agrupam os valores de entrada do SIF de acordo com seu grau de pertencimento a cada um deles.

O conjunto de leituras classificado como “Baixo” indica que as leituras dos sensores estão abaixo da faixa de operação normal da máquina para a grandeza medida. Nesse caso, a parte plana da função trapezoidal representa as leituras de desligamento por valor abaixo do limite estabelecido para aquela grandeza. À medida que os valores de entrada se afastam do valor de desligamento e entram na zona de “Alarme Baixo”, seu grau de pertencimento a esse conjunto diminui, até alcançar o valor zero no limite dessa zona em relação à “Operação Normal”.

O conjunto de leituras classificado como “Médio” indica que as leituras dos sensores estão dentro de sua faixa normal de operação da máquina para a grandeza medida. A parte plana da função trapezoidal representa as leituras normais das grandezas medidas, sendo esse conjunto de valores aqueles que possuem o maior grau de pertencimento a esse conjunto. Conforme os valores de entrada se aproximam das zonas de “Alarme Baixo” ou “Alarme Alto”, o grau de pertencimento dos valores lidos começa a diminuir, indicando que eles estão se aproximando dos limites de desligamento.

O conjunto de leituras classificado como “Alto” indica que as leituras dos sensores estão acima da faixa de operação normal da máquina para a grandeza medida. A parte plana da função trapezoidal representa as leituras de desligamento por valor acima do limite estabelecido para aquela grandeza. À medida que os valores de entrada se afastam do valor de desligamento e entram na zona de “Alarme Alto”, seu grau de pertencimento a esse conjunto diminui, até alcançar o valor zero no limite dessa zona em relação à “Operação Normal”.

Os conjuntos fuzzy para cada variável do sistema de óleo mineral, bem como a respectiva variável fuzzy, são apresentados na Tabela 5, em que cada variável fuzzy representada corresponde a uma função de pertinência do conjunto fuzzy associado.

Tabela 5 – Variáveis dos conjuntos fuzzy do modelo de diagnóstico de falhas

<i>Tag</i> da variável	Descrição	Conjunto fuzzy	Variável fuzzy
LIT-511	Nível do tanque de óleo mineral	Baixo Médio Alto	LIT511[‘low’] LIT511[‘medium’] LIT511[‘high’]
PDIT-555-A	Pressão diferencial do tanque de óleo mineral	Baixo Médio Alto	PDIT555A[‘low’] PDIT555A[‘medium’] PDIT555A[‘high’]
PDIT-555-B	Pressão diferencial do tanque de óleo mineral	Baixo Médio Alto	PDIT555B[‘low’] PDIT555B[‘medium’] PDIT555B[‘high’]
PIT-548-A	Pressão do <i>manifold</i> de óleo mineral	Baixo Médio Alto	PIT548A[‘low’] PIT548A[‘medium’] PIT548A[‘high’]
PIT-548-B	Pressão do <i>manifold</i> de óleo mineral	Baixo Médio Alto	PIT548B[‘low’] PIT548B[‘medium’] PIT548B[‘high’]
TE-559-A	Temperatura do óleo mineral	Baixo Médio Alto	TE559A[‘low’] TE559A[‘medium’] TE559A[‘high’]
TE-559-B	Temperatura do óleo mineral	Baixo Médio Alto	TE559B[‘low’] TE559B[‘medium’] TE559B[‘high’]
PDIT-556	Pressão diferencial dos filtros de óleo mineral	Baixo Médio Alto	PDIT556[‘low’] PDIT556[‘medium’] PDIT556[‘high’]
PIT-562	Pressão de descarga das bombas de óleo mineral	Baixo Médio Alto	PIT562[‘low’] PIT562[‘medium’] PIT562[‘high’]
PIT-5124018	Pressão do <i>header</i> de água de refrigeração	Baixo Médio Alto	PIT5124018[‘low’] PIT5124018[‘medium’] PIT5124018[‘high’]
TIT-5124009	Temperatura do <i>header</i> de água de refrigeração	Baixo Médio Alto	TIT5124009[‘low’] TIT5124009[‘medium’] TIT5124009[‘high’]

Referência: Elaborado pelo Autor.

#### 4.3.1 Processo de modelagem do SIF

O processo de modelagem do SIF envolve as etapas de fuzzificação, criação de regras, criação do mecanismo de inferência fuzzy e desfuzzificação das saídas. Nesta fase, são estabelecidos os limites das funções de pertinência para a fuzzificação das entradas *crisp*. As regras fuzzy são determinadas para diagnosticar os modos de falha definidos na Seção 4.1. A desfuzzificação é realizada com o objetivo de diagnosticar o estado final do sistema avaliado, por meio da análise das entradas fuzzificadas em relação às regras

estabelecidas. Para a definição dos limites das funções de pertinência trapezoidais de entrada, é necessária a definição dos quatro parâmetros que compõem a Equação (2.5), sendo eles: “a”, “b”, “c” e “d”, que representam os quatro pontos que formam o trapézio. No plano cartesiano, esses pontos possuem as seguintes coordenadas (x, y): (a, 0); (b, 1); (c, 1); (d, 0), conforme ilustrado na Figura 9 para a função de pertinência trapezoidal. A definição desses pontos para cada variável é baseada nos limites operacionais de cada variável, que estão definidos na documentação de projeto do equipamento.

A formulação de regras fuzzy é uma etapa que depende dos modos de falha do sistema de óleo lubrificante mineral e das inter-relações entre os parâmetros medidos. Relações com operadores lógicos são estabelecidas entre diferentes conjuntos fuzzy de entrada, de modo a obter cada julgamento desejado pelo especialista no sistema. Dessa forma, o mecanismo de inferência fuzzy possui todos os elementos necessários para a obtenção das saídas do modelo.

As regras criadas foram baseadas no processamento de linguagem natural, uma vez que as entradas fuzzy foram definidas como leituras baixas, médias e altas dos sensores. A Tabela 6 lista cada regra criada para o SIF, relacionando as variáveis de entrada para obter o diagnóstico desejado com base na documentação FMECA. Adicionalmente, foram criadas regras que avaliam a divergência de leitura dos sensores que possuem leitura redundante, com o objetivo de identificar divergência de leitura entre esses instrumentos e evitar diagnósticos equivocados devido a falhas nos instrumentos de monitoramento.

A formulação das regras é feita por meio de operadores lógicos que atendem às relações estabelecidas entre os elementos dos conjuntos fuzzy. Esses operadores são definidos nas Equações (2.8)–(2.10). Ao relacionar os conjuntos, o sistema de inferência fuzzy realiza a operação de implicação, levando em consideração a relação de dependência representada pelas variáveis linguísticas “se” / “então”, definida pela Equação (2.11). Essas relações são expressas como distribuições de probabilidades fuzzy que representam a incerteza associada às conclusões em termos dos graus de pertinência, permitindo a modelagem do problema que tem característica complexa e com uma distribuição de probabilidade de falha associada.

Assim como na etapa de fuzzificação das entradas *crisp*, na etapa de desfuzzificação das saídas fuzzy, a parcela consequente também possui uma função de pertinência, a ser definida pela aplicação do SIF. Para este sistema, foram utilizadas funções triangulares que serviram como base para a classificação das falhas do sistema de óleo mineral do turbogerador. As saídas foram distribuídas de acordo com os limites apresentados na Tabela 7, em que cada faixa de valor de saída *crisp* do SIF está relacionada ao diagnóstico de uma determinada falha.

A escolha da função de pertinência triangular para representar a classificação de falhas se deu em virtude de sua similaridade com as saídas do SIF, tendo em vista que os

Tabela 6 – Conjunto de regras do SIF para diagnóstico de falhas do sistema de óleo mineral

Regra	Diagnóstico
Se: a pressão no sensor A do <i>manifold</i> de óleo lubrificante mineral está baixa e no sensor B está baixa e a descarga das bombas de óleo lubrificante mineral está baixa	Então verifique: falha nas bombas de óleo lubrificante mineral / auxiliares
Se: a pressão no sensor A do coletor de óleo lubrificante mineral está baixa e no sensor B está baixa e (a pressão na descarga das bombas de óleo lubrificante mineral está média ou alta)	Então verifique: afrouxamento de conexões / rompimento nas tubulações de óleo lubrificante mineral
Se: a pressão diferencial do filtro está alta	Então verifique: obstrução nos filtros
Se: a temperatura no sensor A do coletor de óleo lubrificante mineral está alta e no sensor B está alta e (a temperatura no coletor de água de resfriamento está baixa ou média) e (a pressão no coletor de água de resfriamento está média ou alta)	Então verifique: obstrução do trocador de calor / contaminação das placas ou travamento da válvula de controle de temperatura (TCV, do inglês: <i>Temperature Control Valve</i> )
Se: a pressão diferencial do tanque de óleo lubrificante mineral no sensor A está alta e no sensor B está alta	Então verifique: obstrução / falha no eliminador névoa de óleo mineral
Se: o nível do tanque de óleo mineral estiver baixo	Então verifique: verifique o nível do tanque de óleo mineral
Se: (o Sensor A tem valor baixo e (o Sensor B tem valor médio ou alto)) ou (o Sensor A tem valor alto e (o Sensor B tem valor baixo ou médio)) ou (o Sensor B tem valor baixo e (o Sensor A tem valor médio ou alto)) ou (o Sensor B tem valor alto ou (o Sensor A tem valor baixo ou médio))	Então verifique: medições divergentes nos sensores

Referência: Elaborado pelo Autor.

conjuntos de saída possuem alto grau de pertencimento à classe de falhas no valor central da função, diminuindo-o gradualmente à medida que se aproximam dos valores das classes vizinhas. O SIF foi projetado para classificar as falhas de forma individual, mesmo quando elas ocorrem simultaneamente. Por esse motivo, as classes de falhas não se intersectam, o que significa que as funções de pertinência da parcela consequente do SIF também não têm intersecção.

O processo de desfuzzificação ocorre pelo cálculo do centroide da função de pertinência de saída ativada, conforme descrito na Equação (2.18). No contexto da classificação de falhas, é importante que o programa seja capaz de lidar com a ocorrência de múltiplas falhas simultaneamente, a fim de evitar erros de diagnóstico. Para isso, ao identificar

Tabela 7 – Limites das saídas *crisp* de diagnóstico do sistema de óleo mineral

Saída do SIF	Faixas de saída <i>crisp</i>	Diagnóstico de falha
1	0 a 10	Falha na bomba principal / auxiliar de óleo
2	10 a 20	Vazamento de óleo mineral
3	20 a 30	Obstrução dos filtros de óleo mineral
4	30 a 40	Falha no trocador de calor ou na TCV
5	40 a 50	Falha no eliminador de névoa
6	50 a 60	Divergência de medição nos transmissores de pressão diferencial <i>tags</i> PDIT-555-A/B
7	60 a 70	Divergência de medição nos transmissores temperatura <i>tags</i> TE-559-A/B
8	70 a 80	Divergência de medição nos transmissores de pressão <i>tags</i> PIT-548-A/B
9	80 a 90	Baixo nível do tanque de óleo lubrificante mineral
10	90 a 100	Operação normal

Referência: Elaborado pelo Autor.

uma falha quando da avaliação do conjunto de regras, o algoritmo realiza a classificação individual de cada falha, retornando sua classificação correspondente.

Na modelagem do SIF, alterou-se a arquitetura mostrada na Figura 8 para prevenir erros de classificação em cenários de falhas simultâneas. Dessa maneira, criou-se uma rotina especial para avaliar essas falhas. Caso não se detecte nenhuma falha, o algoritmo segue com a análise do conjunto de regras fuzzy sem ativar a rotina, mantendo a arquitetura original do método Mamdani. Se houver falhas, cada regra é examinada individualmente para definir quais saídas serão ativadas, levando ao diagnóstico de falhas e à reestruturação da arquitetura do sistema de inferência fuzzy para tal diagnóstico.

### 4.3.2 Codificação

Para a criação do sistema de inferência fuzzy, um algoritmo foi desenvolvido em Python. A biblioteca “Scikit-fuzzy” foi utilizada nessa implementação, considerando que ela possui as funções necessárias para o desenvolvimento de aplicações em lógica fuzzy, para a linguagem de programação escolhida. A função “Antecedent” do módulo “Control” nessa biblioteca foi utilizada para criar os conjuntos antecedentes, que são as funções que são ativadas pelos valores de entrada de cada variável. Da mesma forma, a função “Consequent” foi utilizada para criar as associações consequentes do sistema de inferência fuzzy.

A função “Rule” do módulo “Control” foi empregada para estabelecer as regras a serem aplicadas aos pontos de dados antecedentes. Para aprimorar o método de classificação, foram desenvolvidas duas etapas de inferência fuzzy. Na etapa inicial, uma avaliação é conduzida para determinar se o sistema está operando em um estado saudável ou com falhas. Se uma falha for detectada, a etapa subsequente envolve a identificação do tipo específico de falha presente no sistema.

As funções “ControlSystem” e “ControlSystemSimulation” foram utilizadas para definir as relações entre as regras criadas e realizar o cálculo da saída fuzzy dos sistemas de inferência. A função “Compute” foi então utilizada para calcular a saída do sistema de inferência fuzzy dado um conjunto de entradas.

As funções “trapmf” e “trimf”, que também pertencem à biblioteca “scikit-fuzzy”, foram utilizadas para criar as funções de pertinência do modelo de inferência, onde os parâmetros para essas funções foram estabelecidos de acordo com os limites definidos das entradas e saídas.

Para aprimorar o desempenho do modelo de classificação e minimizar o processamento computacional, o primeiro passo é avaliar se o sistema está em um estado saudável ou com falhas. Se o sistema estiver com falhas, as falhas são classificadas com base na Tabela 7. Como várias falhas podem ocorrer simultaneamente, o algoritmo foi projetado para lidar com essa condição.

Um diagrama de fluxo que representa o algoritmo do sistema de inferência fuzzy é apresentado na Figura 13. O algoritmo começa adquirindo os dados do conjunto de dados e passando por uma etapa de limpeza de dados. Em seguida, o algoritmo cria as variáveis universo com base nas faixas de calibração dos sensores, seguido pela criação das funções de pertinência de entrada com base nos limites das variáveis de entrada. As regras são então criadas usando operações lógicas para estabelecer relações entre as variáveis do sistema, com base nos modos de falha definidos na FMECA. Em seguida, as associações de saída são criadas para facilitar o diagnóstico de falhas.

Durante a fase de inferência, o mecanismo do SIF processa iterativamente cada variável de entrada e regra, considerando suas interações e combinando os resultados para gerar a saída final. Se for detectada operação normal, nenhuma classificação é feita e o algoritmo continua a processar a próxima amostra. No entanto, se uma falha for detectada durante a fase de inferência, é realizada uma classificação mais detalhada da falha.

Antes de avaliar cada falha, verifica-se se há divergência de medição entre os sensores, levando em consideração que essa condição pode invalidar um diagnóstico. Caso haja divergência de medição entre os sensores que possuem redundância, as falhas que dependem dos dados desses sensores não são avaliadas e a divergência de medição é notificada. Os modos de falha que não são detectados por sensores redundantes não passam



por uma avaliação prévia e suas regras são julgadas apenas se o sistema estiver em um *loop* de falhas.

## 4.4 Avaliação

O objetivo principal de avaliar o desempenho do modelo de classificação de falhas é identificar a porcentagem de classificações corretas e incorretas feitas pelo algoritmo.

Os critérios de desempenho estabelecidos para este modelo foram a porcentagem de diagnósticos corretos e incorretos, conforme descrito abaixo:

- Verdadeiro Positivo (VP): porcentagem de diagnósticos de falhas realizados de forma correta pelo modelo;
- Verdadeiro Negativo (VN): porcentagem de diagnósticos de operações normais realizados de forma correta pelo modelo;
- Falso Positivo (FP): porcentagem de diagnósticos de falhas realizados de forma incorreta pelo modelo;
- Falso Negativo (FN): porcentagem de diagnósticos de operações normais realizados de forma incorreta pelo modelo;

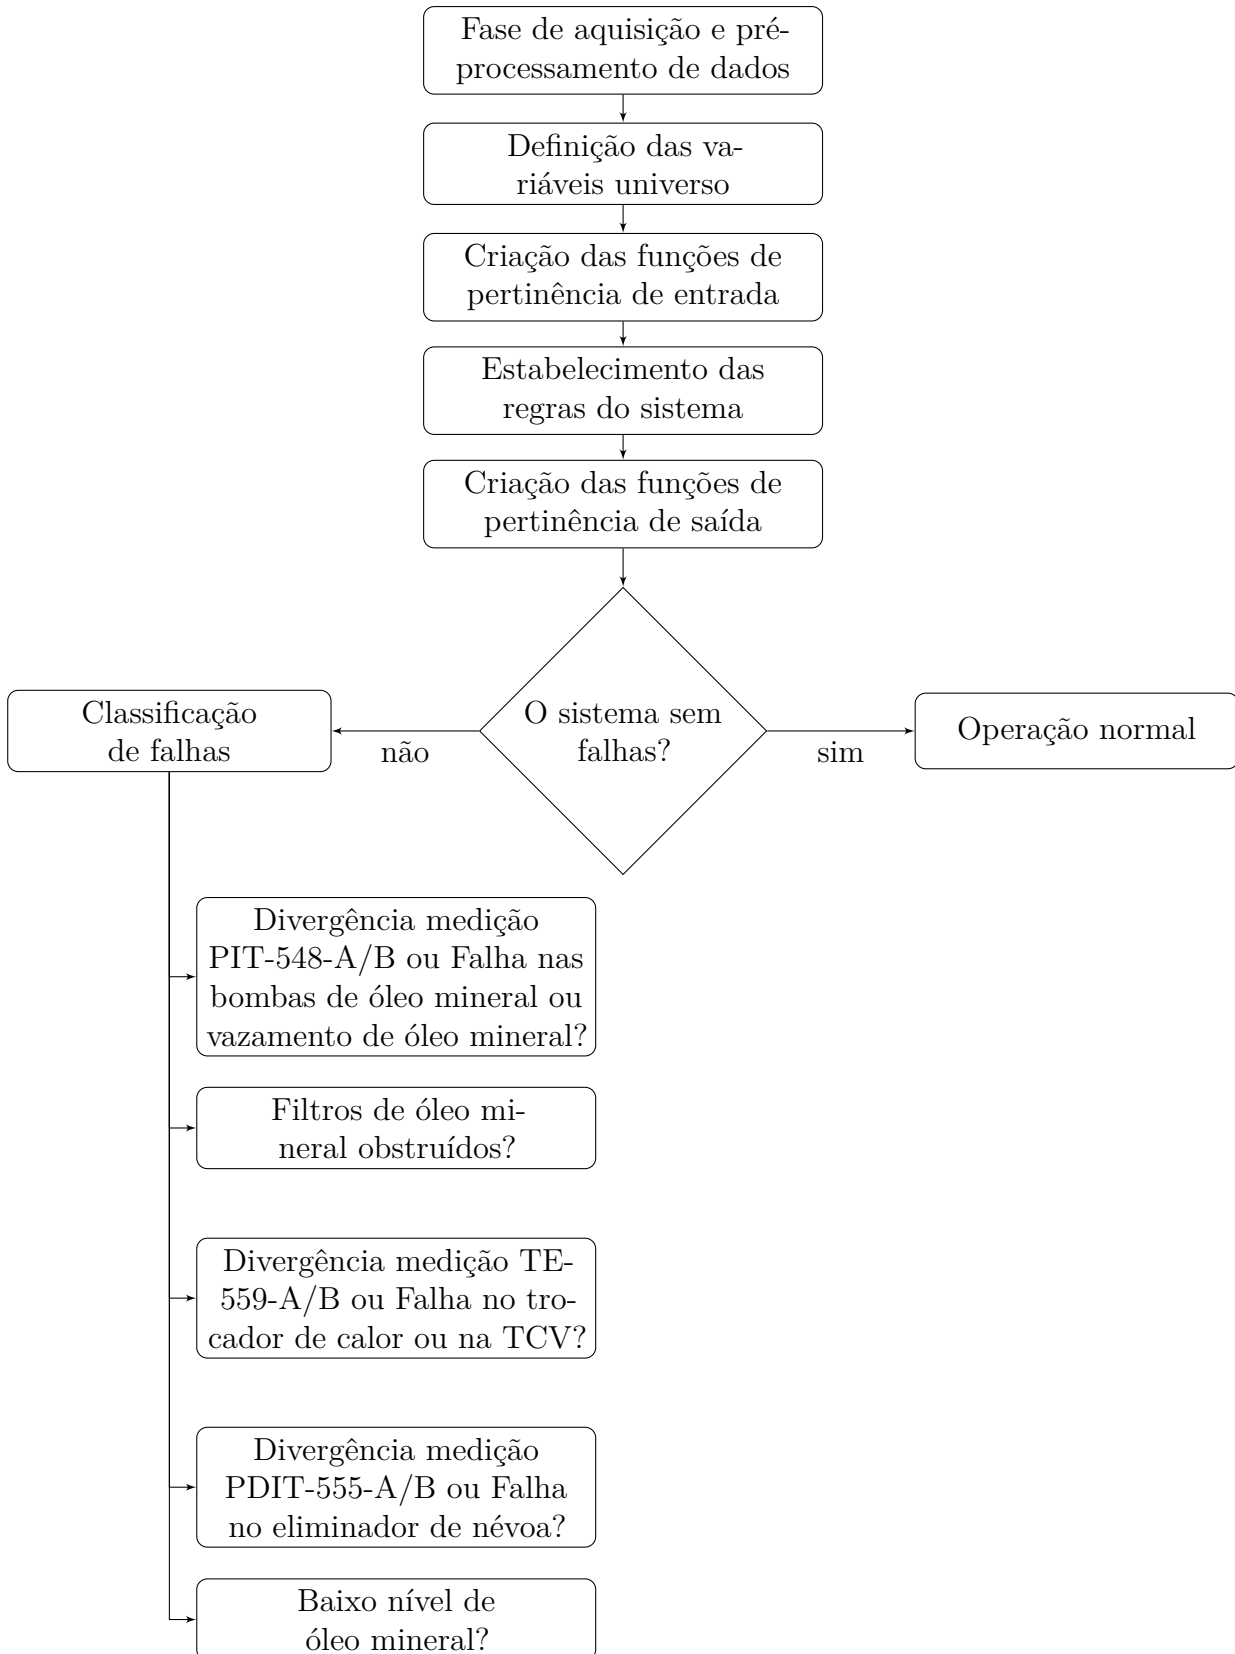
No contexto da classificação de falhas, a presença de um conjunto de dados desequilibrado é uma ocorrência prevalente. Essa disparidade decorre da expectativa de que as ocorrências de falhas de equipamentos sejam naturalmente superadas por instâncias de operação normal. Como consequência, depender apenas de métricas de desempenho convencionais de classificação - como acurácia, precisão, recall e score F1 - pode resultar em interpretações enganosas sobre a eficácia do modelo.

## 4.5 Considerações finais

Neste capítulo foi apresentada a metodologia aplicada no desenvolvimento da solução de diagnóstico de falhas para os turbogeradores do sistema de geração principal da plataforma tipo FPSO. A metodologia visou o atendimento das necessidades do cliente, o desenvolvimento de uma solução baseada no entendimento dos dados disponíveis e como empregá-los, e em uma modelagem que atendesse aos critérios de avaliação do modelo.

No próximo capítulo são apresentados os resultados da pesquisa que foram obtidos com base na fundamentação teórica, fundamentados nas referências bibliográficas e com a aplicação da metodologia aqui apresentada.

Figura 13 – Diagrama de fluxo do algoritmo empregado para o diagnóstico de falhas utilizando o SIF



Referência: Elaborado pelo Autor.

## 5 Resultados

Neste capítulo, são apresentados os resultados da pesquisa obtidos a partir da utilização da metodologia descrita no capítulo anterior. A apresentação dos resultados foi dividida em cinco seções, de forma a correlacionar com cada etapa desenvolvida na metodologia, bem como comentar os resultados obtidos.

A Seção 5.1 apresenta os dados de falhas que motivaram o início do estudo, onde foi identificada a necessidade da solução proposta para o negócio. Na Seção 5.2, estão os limites superior e inferior de cada variável, sendo estes os limites para as curvas de calibração dos instrumentos, bem como os limites operacionais de cada variável para os turbogeradores. Na Seção 5.3, são apresentados os parâmetros das funções de pertinência das parcelas antecedentes e consequentes do modelo fuzzy, bem como os resultados do modelo de inferência para os dados de entrada. Na Seção 5.4, estão os resultados das métricas de desempenho do modelo utilizado. Na Seção 5.5, são comentados os resultados obtidos no trabalho.

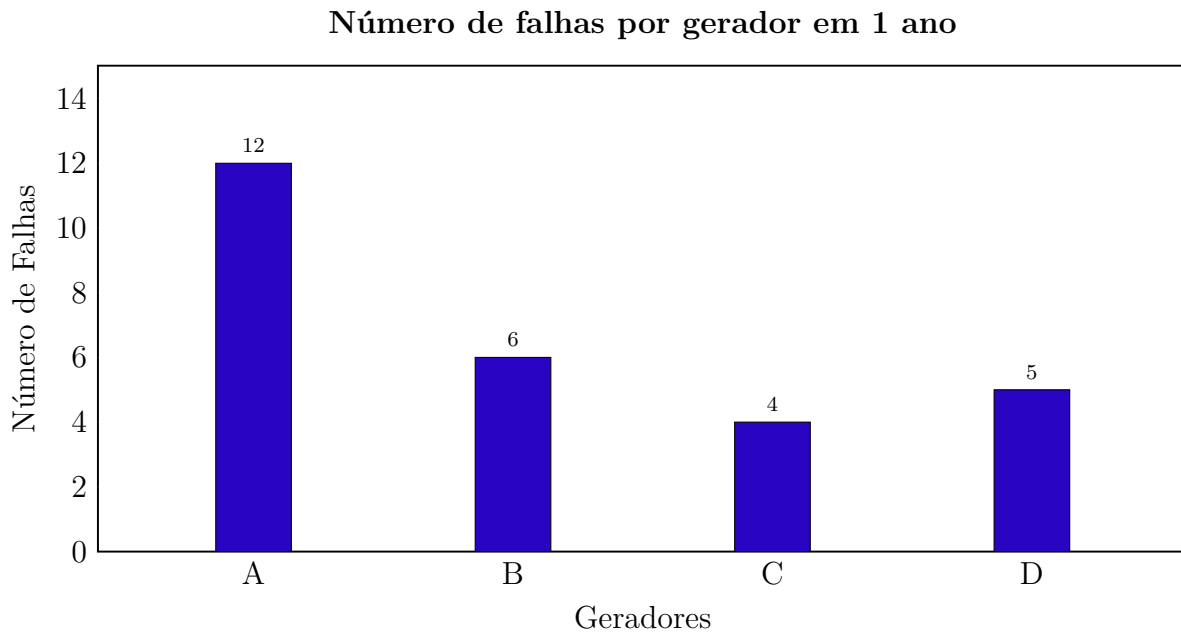
### 5.1 Entendimento do negócio

O estudo de caso apresentado nesta Tese iniciou-se com uma avaliação, na qual constatou-se que o sistema de geração principal de uma unidade de produção de óleo e gás, tipo FPSO, atualmente em produção, apresentou no período de 01/05/2020 a 01/05/2021, 27 paradas de seus geradores principais devido a falhas, sendo que 12 dessas paradas foram atribuídas ao gerador A, conforme ilustrado na Figura 14. Em uma avaliação dos dados de falhas desse equipamento no período, não se identificou qualquer anomalia que apontassem falhas atípicas para o equipamento.

Analisando os registros de manutenção do Gerador A, em um período compreendendo os anos de 2019 a 2022, identificaram-se 28 solicitações de manutenção para o sistema de lubrificação por óleo mineral desse equipamento, sendo o segundo sistema com mais solicitações de manutenção no período. Nos registros operacionais, houve 3 notificações de parada do equipamento por *trip* relacionadas a esse sistema no período.

O sistema de óleo lubrificante mineral influencia várias partes da máquina, como a PT, a caixa de engrenagens e o gerador, conforme citado na Seção 2.1.2 e ilustrado na Figura 5. Devido à sua importância para a operação do turbogerador e por conter registros dos principais problemas relatados pela equipe de operação e manutenção, além de ter causado paradas na máquina, o sistema em questão foi escolhido como objeto para o desenvolvimento do modelo de diagnóstico de falhas. Com o objetivo de ampliar a

Figura 14 – Falhas por gerador no período de 1 ano



Referência: Elaborado pelo Autor.

abrangência do modelo, o escopo do estudo foi estendido para incluir outros geradores do sistema.

Este estudo abrangeu um período de observação que compreendeu de 1<sup>o</sup> de janeiro de 2019 a 31 de dezembro de 2022. Os quatro turbogeradores que compõem o parque de geração principal da UEP analisada estão em operação desde fevereiro de 2018. No entanto, o primeiro ano de operação do sistema foi excluído da análise de diagnóstico de falhas, pois corresponde à fase de comissionamento do projeto, período em que as falhas referentes falhas montagem ou de projeto são mais evidentes (BILLINTON; ALLAN, 1992).

Além das partes afetadas pelos modos de falha definidos como detectáveis por monitoramento e listados na Tabela 3, foi identificada a necessidade de monitoramento do nível do tanque de óleo mineral. Embora não faça parte da matriz da FMECA, segundo avaliação especialista, é um monitoramento de importância para os equipamentos, como pode ser observado na Tabela 7, onde há um dos diagnósticos referentes ao modo de falha “Baixo nível do tanque de óleo lubrificante mineral”.

## 5.2 Entendimento dos dados

Nesta etapa, foi realizada uma correlação entre as partes afetadas dos equipamentos monitorados, seus modos de falha e os sensores utilizados para a detecção de cada um desses modos de falha, conforme apresentado na Tabela 8. A forma como as variáveis monitoradas por esses sensores se relacionam para a detecção dos modos de falha é definida nas regras estabelecidas na etapa de modelagem do sistema. No entanto, na etapa de

entendimento dos dados, é possível identificar o que cada variável monitora e correlacionar esse monitoramento ao modo de falha a ser detectado.

Tabela 8 – Matriz de correlação entre partes afetadas, modos de falha e meio de detecção

<b>Parte afetada</b>	<b>Modo de falha FMECA</b>	<b>Meio de detecção</b>
Bomba lubrificação principal	Desgaste interno	PIT-548-A/B PIT-562
Bomba lubrificação auxiliar	Desgaste interno	PIT-548-A/B PIT-562
Linhas de óleo mineral	Afrouxamento de conexões / rompimento	PIT-548-A/B PIT-562
Filtros de óleo mineral	Obstrução	PDIT-556 PIT-562
Trocadores de calor	Obstrução / contaminação das placas	TE-559-A/B TIT-5124009 PIT-5124018
TCV	Travamento / emperramento / perda de vedação	TE-559-A/B TIT-5124009 PIT-5124018
Vent do tanque de óleo mineral	Obstrução	PDIT-555-A/B
Sensores redundantes	Divergência de medições	PDIT-555-A/B PIT-548-A/B TE-559-A/B

Referência: Elaborado pelo Autor.

As relações das variáveis de processo com os modos de falha e partes afetadas podem ser feitas de forma direta, como o monitoramento do nível de óleo do tanque ou do diferencial de pressão dos filtros de óleo, por meio dos sensores de nível do tanque e de diferencial de pressão dos filtros, respectivamente. Também podem ser feitas de forma indireta, como no caso da obstrução dos permutadores de calor, em que se avalia a temperatura do óleo mineral, a temperatura da água de refrigeração e a pressão da água de refrigeração. Para a identificação da obstrução de um permutador de calor, é importante conhecer a temperatura do óleo na sua saída e a temperatura da água de resfriamento, levando em consideração a temperatura de referência do sistema. A pressão da água de resfriamento é importante para saber se há bombeamento de água no momento ou não.

Com o mapeamento dos meios de detecção dos modos de falhas, que corresponde aos sensores de monitoramento, e como eles se relacionam com cada parte afetada, a próxima etapa do processo é a aquisição e seleção de dados.

Conforme mencionado na Seção 4.2, a aquisição foi feita utilizando a biblioteca Python “pandaspi”, em que um total de 3.112.051 padrões de entrada por atributo foram adquiridos. Essa etapa resultou em uma massa total de dados 523 MB, sendo utilizado para sua coleta um computador com processador Intel Core i-10210U com CPU 1.6GHz e

memória RAM de 16 GB. A aquisição dos dados é realizada em blocos de dados para o conjunto de atributos.

Um total de 13 atributos, sendo eles as 11 variáveis de monitoramento da Tabela 4 e 2 sensores de chama da câmara de combustão da turbina, com período de amostragem de 60 segundos por variável, sendo o tempo de aquisição de cada bloco em torno de 20 segundos. Em seguida, foi executada a etapa de seleção de dados, na qual foram filtrados os valores indesejados e estimados os valores faltantes.

Os limites das variáveis “crisp” foram obtidos de acordo com as faixas de calibração dos instrumentos, conforme apresentado na Tabela 9, servindo como documentos de referência para a lista de instrumentos e o P&ID.

Tabela 9 – Variáveis de monitoramento do sistema de óleo mineral

Sensor	Descrição	Limite Inferior	Limite Superior
LIT-511	Nível do tanque de óleo mineral	143 mm	1113 mm
PDIT-555-A	Pressão diferencial do tanque de óleo mineral	-10 mbar	10 mbar
PDIT-555-B	Pressão diferencial do tanque de óleo mineral	-10 mbar	10 mbar
PIT-548-A	Pressão do <i>manifold</i> de óleo mineral	0 bar	2.5 bar
PIT-548-B	Pressão do <i>manifold</i> de óleo mineral	0 bar	2.5 bar
TE-559-A	Temperatura do óleo mineral	-50 °C	130 °C
TE-559-B	Temperatura do óleo mineral	-50 °C	130 °C
PDIT-556	Pressão diferencial dos filtros de óleo mineral	0 bar	4 bar
PIT-562	Pressão de descarga das bombas de óleo mineral	0 bar	10 bar
PIT-5124018	Pressão do <i>header</i> de água de refrigeração	0 kPa	800 kPa
TIT-5124009	Temperatura do <i>header</i> de água de refrigeração	-20 °C	80 °C

Referência: Elaborado pelo Autor.

Foi realizado o levantamento dos limites de alarme e *trip* de cada variável, conforme

descrito na Seção 4.3. Nem todos os limites das variáveis têm necessariamente algum efeito direto de alarme ou *trip* sobre o sistema, portanto, foi atribuído o valor do fim da escala de calibração do instrumento indicado na Tabela 9, ou esses valores foram reajustados após rodadas do modelo, a fim de estabelecer os limites das entradas *crisp*, conforme apresentado na Tabela 10.

Tabela 10 – Limites das entradas *crisp* do sistema de óleo lubrificante mineral

Variável	Muito Baixo	Baixo	Alto	Muito Alto
LIT-511	540 mm	724 mm	774 mm	887 mm
PDIT-555-A	-1.0 mbar	0 mbar	3.9 mbar	4.9 mbar
PDIT-555-B	-1.0 mbar	0 mbar	3.9 mbar	4.9 mbar
PIT-548-A	0.9 bar	1.4 bar	1.7 bar	2.5 bar
PIT-548-B	0.9 bar	1.4 bar	1.7 bar	2.5 bar
TE-559-A	0 °C	20 °C	65 °C	70 °C
TE-559-A	0°C	20 °C	65 °C	70 °C
PDIT-556	-1 bar	0 bar	1 bar	2 bar
PIT-562	0 bar	5 bar	7.3 bar	9 bar
PIT-5124018	0 kPa	427 kPa	487 kPa	634 kPa
TIT-5124009	0 °C	20 °C	45 °C	60 °C

Referência: Elaborado pelo Autor.

Com os limites operacionais estabelecidos para cada variável a próxima etapa a ser realizada é a de preparação dos dados para carregamento no modelo, em que as funções de pertinência de entrada podem ser criadas para cada variável de acordo com os limites operacionais estabelecidos.

### 5.3 Preparação dos dados e modelagem

Para o carregamento dos dados de entrada no SIF, é necessário definir as funções de pertinência de cada variável de entrada. Os parâmetros dessas funções de pertinência foram definidos com base nos limites operacionais estabelecidos para os turbogeradores, conforme documentação de projeto. Os parâmetros das funções de pertinência trapezoidais da parcela antecedente do SIF são apresentados na Tabela 11.

Com os dados dos sensores de monitoramento pré-processados e as funções de pertinência da parcela antecedente criadas, foi realizada uma avaliação para o diagnóstico de falhas do sistema de óleo mineral dos quatro turbogeradores, com base nos limites especificados na Tabela 11. O processo de fuzzificação das entradas dentro do componente do controlador fuzzy é estabelecido.

A definição dos parâmetros da parcela consequente do SIF é feita com base na Tabela 7, a fim de correlacionar o valor de saída *crisp* com o diagnóstico correspondente à saída classificada do SIF. Os parâmetros das funções de pertinência triangulares são apresentados na Tabela 12.

Tabela 11 – Parâmetros das funções de pertinência trapezoidais da parcela antecedente

Variável Fuzzy	Parâmetros funções de pertinência trapezoidais			
	“a”	“b”	“c”	“d”
LIT511[‘low’]	0	143	540	724
LIT511[‘medium’]	540	724	774	887
LIT511[‘high’]	774	887	1113	1113
TIT558A[‘low’]	-50	-50	-50	20
TIT558A[‘medium’]	-50	20	80	90
TIT558A[‘high’]	80	90	130	130
PDIT555A[‘low’]	-10,0	-10,0	-1,0	0,0
PDIT555A[‘medium’]	-1,0	0,0	3,9	4,9
PDIT555A[‘high’]	3,9	4,9	10,0	10,0
PDIT555B[‘low’]	-10,0	-10,0	-1,0	0,0
PDIT555B[‘medium’]	-1,0	0,0	3,9	4,9
PDIT555B[‘high’]	3,9	4,9	10,0	10,0
PIT548A[‘low’]	-1	0	9	14
PIT548A[‘medium’]	9	14	17	25
PIT548A[‘high’]	17	25	30	30
PIT548B[‘low’]	-1	0	9	14
PIT548B[‘medium’]	9	14	17	25
PIT548B[‘high’]	17	25	30	30
TE559A[‘low’]	-50	-50	0	20
TE559A[‘medium’]	0	20	65	70
TE559A[‘high’]	65	70	130	130
TE559B[‘low’]	-50	-50	0	20
TE559B[‘medium’]	0	20	65	70
TE559B[‘high’]	65	70	130	130
PDIT556[‘low’]	-1,0	-1,0	-0,5	0,0
PDIT556[‘medium’]	-0,5	0,0	1,0	2,0
PDIT556[‘high’]	1,0	2,0	4,0	4,0
PIT562[‘low’]	-4,0	0,0	0,0	5,0
PIT562[‘medium’]	0,0	5,0	7,3	9,0
PIT562[‘high’]	7,3	9,0	10,0	10,0
PIT5124018[‘low’]	0,00	0,00	0,00	426,59
PIT5124018[‘medium’]	0,00	426,59	487,00	634,00
PIT5124018[‘high’]	487,00	634,00	800,00	800,00
TIT5124009[‘low’]	0	0	0	20
TIT5124009[‘medium’]	0	20	45	60
TIT5124009[‘high’]	45	60	80	80

Referência: Elaborado pelo Autor.

A Figura 15 ilustra as funções de pertinência definidas para as saídas fuzzy, que representam as consequências das avaliações das regras fuzzy. Os números das saídas indicam cada diagnóstico mapeado na Tabela 7.

Ao especificar as saídas do controlador fuzzy de acordo com os parâmetros definidos



Tabela 12 – Parâmetros das funções de pertinência triangulares da parcela consequente

Variável fuzzy	Parâmetros funções de pertinência triangulares		
	“a”	“b”	“c”
Falha na bomba principal / auxiliar de óleo	0	5	10
Vazamento de óleo mineral	10	15	20
Obstrução dos filtros de óleo mineral	20	25	30
Falha no trocador de calor ou na válvula de controle de temperatura	30	35	40
Falha no eliminador de névoa	40	45	50
Divergência de medição nos transmissores de pressão diferencial <i>tags</i> PDIT-555-A/B	50	55	60
Divergência de medição nos transmissores temperatura <i>tags</i> TE-559-A/B	60	65	70
Divergência de medição nos transmissores de pressão <i>tags</i> PIT-548-A/B	70	75	80
Baixo nível do tanque de óleo lubrificante mineral	80	85	90
Operação normal	90	95	100

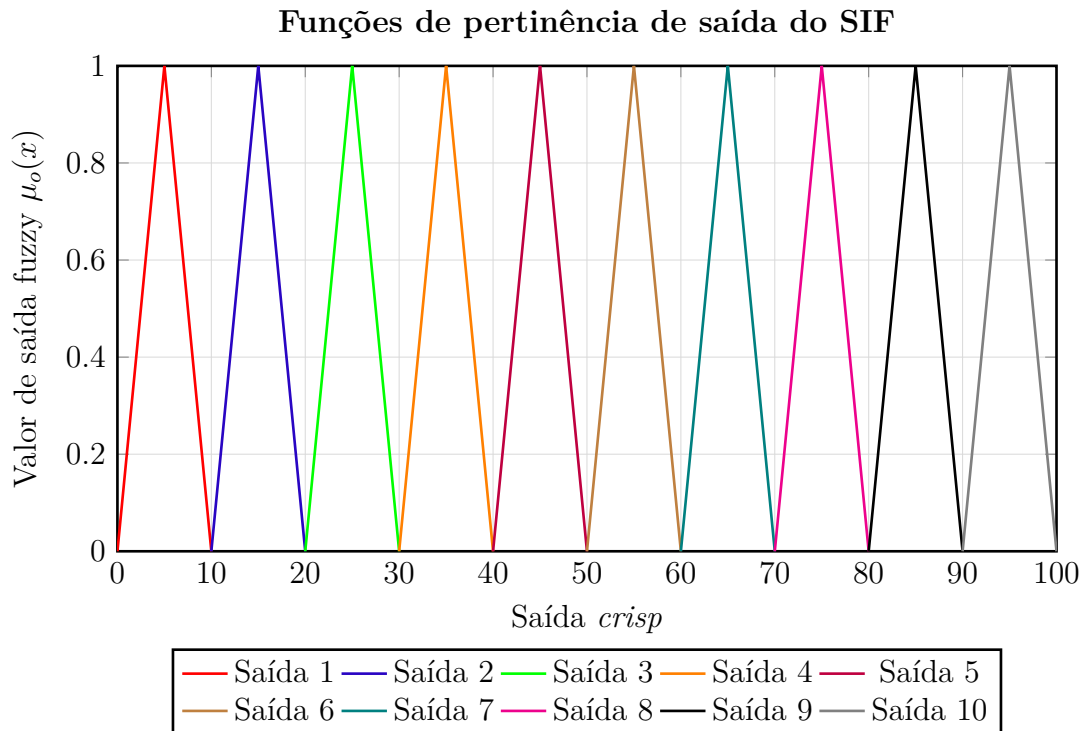
Referência: Elaborado pelo Autor.

na Tabela 12 e utilizar definições de regras com base no conhecimento do especialista, utilizando as relações definidas nas Equações (2.8)–(2.10) para operacionalizar o modelo baseado nas regras definidas na Tabela 6, o modelo está preparado para a execução dos modelos de inferência definidos pela Equação (2.11), utilizando os dados coletados. Isso resulta em saídas que classificam eventos com base na saída do modelo, que são defuzzificadas com base no método centroide definido na Equação (2.18). O tempo de execução do código desenvolvido para essa aplicação, utilizando-se o mesmo computador para a coleta de dados do servidor da Seção 5.2, foi de pouco menos de 1 segundo.

Este estudo utilizou dados operacionais de um sistema de geração principal real instalado em uma plataforma FPSO. Ao longo de três anos, os dados abrangeram o funcionamento de quatro turbogeradores, totalizando um total de 40.456.663 padrões de entrada, conforme ilustrado na Tabela 13, o que apresenta uma visão abrangente dos resultados obtidos com a classificação de falhas pelo modelo. Esta tabela apresenta o número de saídas que classificaram um valor defeituoso, que foi de 8.665.

Após uma avaliação das saídas do modelo, constatou-se que as 8.665 classificações realizadas representam 31 estados de falhas. Esses estados correspondem a situações em

Figura 15 – Funções de saída do SIF para classificação de falhas



que os geradores do sistema transitaram do estado operacional para o estado de falha. É importante mencionar que algumas das classificações foram atribuídas à mesma falha.

Dentre as falhas classificadas, o modelo obteve sucesso na classificação de 23 falhas de forma correta. No entanto, ocorreram 8 casos em que as falhas foram classificadas erroneamente como falhas ou como falhas classificadas em uma classe diferente.

Tabela 13 – Avaliação do período e resultados

Período de Avaliação	1º Janeiro 2019 a 31 Dezembro 2022
Geradores Avaliados	A/B/C/D
Nº total de padrões de entrada	40.456.663
Nº de padrões de entrada por atributo	3.112.051
Nº de atributos	13
Nº de saídas com valores defeituosos	8.665
Nº de falhas não detectadas	1
Nº de falhas detectadas	31
Nº de diagnósticos corretos	23
Nº de diagnósticos incorretos	8

Referência: Elaborado pelo Autor.

## 5.4 Avaliação

O desempenho geral do modelo em termos de classificação correta é apresentado na Tabela 14, onde todas as métricas de desempenho definidas para o modelo são calculadas com base na quantidade de classificações realizadas pelo modelo, que é comparada com o REM, sendo esta a principal fonte de informação atualmente utilizada para registrar todos os eventos relacionados às máquinas. Dessa maneira, as 8.665 classificações foram avaliadas em termos dos critérios de desempenho estabelecidos para o modelo.

Além de serem o principal insumo para o modelo de classificação de falhas, os dados de monitoramento da planta de geração foram utilizados neste estudo para avaliar a precisão do modelo nas classificações de saída para aqueles eventos em que informações sobre falhas ocorridas não foram alimentadas no REM, como nos casos em que o modelo detectou falha e o operador não as reportou.

Tabela 14 – Critério de desempenho do SIF

Critério	Percentual
VP	98,35%
VN	99,99%
FP	1,65%
FN	0,01%

Referência: Elaborado pelo Autor.

Nem todas as falhas mapeadas pelo modelo ocorreram no sistema durante o período de avaliação, pois nem todas as falhas que foram mapeadas para serem classificadas pelo modelo ocorreram durante a observação. Dessa forma, essas métricas estão relacionadas às seguintes falhas:

- Obstrução dos filtros de óleo mineral: 5 eventos;
- Falha no trocador de calor ou na TCV: 12 eventos;
- Falha no eliminador de névoa: 6 eventos;
- Divergência de medição nos transmissores de temperatura tags TE-559-A/B: 5 eventos;
- Baixo nível do tanque de óleo lubrificante mineral: 2 eventos.

## 5.5 Considerações

Ao analisar o REM foi possível identificar que houve 5 registros de máquinas em estado de serviço que foram forçadas a sair de operação durante um período de necessidade, ou seja, que entraram em falha sem que ficassem disponíveis para o sistema. Em 4 casos, o

modelo conseguiu diagnosticar com sucesso as falhas, e em um caso, o modelo classificou a falha como um caso operacional normal. Nesses casos, um sistema de diagnóstico de falhas poderia reduzir o tempo de inatividade da máquina, aumentando, conseqüentemente, a disponibilidade geral de produção da plataforma.

A classe classificada incorretamente foi “Vazamento de óleo lubrificante mineral”, e essa classe é mais adequada para vazamentos significativos, uma vez que pequenos vazamentos podem não gerar uma perda de pressão no sistema que possa resultar na detecção de falhas com base nas regras atualmente estabelecidas. Em qualquer caso, a não detecção foi considerada uma classificação incorreta.

Das falhas identificadas pelo modelo, 26 delas não foram relatadas pelos operadores no REM. Uma possibilidade é ajustar a saída do modelo para o mesmo formato da REM, o que permitiria evitar o seu preenchimento manual pelos operadores do sistema de geração. Com a utilização do programa desenvolvido aqui, seria possível preencher automaticamente e em tempo real os eventos de falhas ocorridos nas máquinas, sem depender da intervenção humana para essa tarefa.

Após uma análise crítica das 26 falhas detectadas pelo modelo, mas que não foram registradas pelos operadores, constatou-se que 7 dessas falhas foram classificadas de forma incorreta. A seguir, encontra-se a descrição dessas falhas:

- Falha no trocador de calor ou na TCV: 1 evento;
- Divergência de medição nos transmissores de temperatura tags TE-559-A/B: 5 eventos;
- Baixo nível do tanque de óleo lubrificante mineral: 1 evento.

A classificação incorreta ocorreu no caso da classe “Falha no trocador de calor ou TCV”, que ocorreu logo após um desligamento externo que não foi detectado pelo modelo. Nesse caso, a incorporação ao modelo de sinais externos ao equipamento para a identificação desse tipo de evento irá evitar esse tipo de erro do modelo.

A classificação do modelo para a falha “Divergência de medição nos transmissores temperatura tags TE-559-A/B” foi considerada imprecisa, pois não foi detectada nenhuma divergência perceptível entre os sensores de temperatura do *header* de óleo mineral. Essa discrepância surgiu a partir do intervalo temporal nas respostas dos sensores de temperatura quando há flutuações abruptas na temperatura do óleo lubrificante. Essa discrepância transitória de valores é um fenômeno que pode ser considerado ao se refinar o modelo, em que um atraso para o diagnóstico de falha de divergência de medição para esses sensores pode ser avaliado.

Embora essa característica represente um desafio para o diagnóstico de falhas, ela pode ser potencialmente aproveitada como uma vantagem em um futuro algoritmo de previsão. Em certos cenários, essa discrepância temporária ocorre aproximadamente dois minutos antes de os trocadores de calor do óleo lubrificante mineral experimentarem temperaturas elevadas.

No caso da classificação incorreta da falha “Nível baixo do tanque de óleo lubrificante mineral”, isso ocorreu durante um evento térmico que derreteu os cabos do sensor. O evento foi observado pelos operadores em 28 de fevereiro de 2022, às 14h32, mas o modelo estava relatando problemas com o nível de óleo lubrificante mineral desde 28 de fevereiro de 2022, às 10h21, com relatos de problemas às 11h26 de obstrução dos filtros de óleo lubrificante mineral e vários relatos de nível baixo do tanque de óleo lubrificante mineral e obstrução dos filtros de óleo lubrificante mineral até que a máquina fosse parada manualmente devido a um evento térmico causado pelo superaquecimento no rolamento da bomba de óleo lubrificante mineral. O modelo não detectou falhas na bomba de óleo lubrificante mineral, pois ela continuou bombeando e sua pressão de descarga, bem como as pressões do sistema estavam normais.

As consequências do evento térmico ocorrido em 28 de fevereiro de 2022, poderiam ter sido mitigadas com o uso do diagnóstico de falhas proposto, pois teria dado um aviso antecipado para o operador do gerador verificar o que estava acontecendo com a máquina, tornando o problema visível para o operador durante o momento de verificação, evitando uma escalada de danos.

Em se tratando do desempenho computacional do modelo empregado, pode-se constatar que o mesmo foi satisfatório, considerando que para acessar o servidor e processar a saída do sistema com o diagnóstico de falha tem-se um tempo total de aproximadamente 21 segundos, sendo esse menor que o período de amostragem adotado que foi de 60 segundos.



## 6 Considerações Finais

Neste trabalho, um sistema de inferência fuzzy foi desenvolvido e utilizado para realizar o diagnóstico de falhas em um sistema de geração de energia de turbogeradores composto por quatro máquinas do mesmo modelo que compõem o sistema de geração principal de uma plataforma de produção de óleo e gás tipo FPSO. O sistema de lubrificação de óleo mineral destes geradores foi o escolhido para o estudo tendo em vista a quantidade de requisições de manutenções de para esse sistema, por esse sistema ter gerado paradas de máquina e por ser um sistema que tem interface com diversas partes do turbogerador.

Os resultados obtidos demonstram que o modelo classificou com sucesso as falhas relatadas pelos operadores em 4 de 5 casos. O modelo alcançou um bom desempenho de classificação, com uma taxa de 98,35% de diagnósticos corretos de falhas considerando todas as falhas identificadas pelo modelo num período de observação de três anos. Alguns eventos classificados pelo modelo não foram relatados no REM pelos operadores. Isso destaca o potencial do modelo para automatizar o processo de registros operacionais.

Em muitos casos, as equipes de operação e manutenção fazem o registro de falhas manualmente, o que pode levar a erros devido a informações preenchidas incorretamente, informações faltantes ou até mesmo a ausência de registros de ocorrências. O sistema de diagnóstico de falhas proposto neste trabalho realiza a classificação de falhas que ocorreram nos equipamentos, fornecendo a data e a hora dos eventos, tornando desnecessário o preenchimento manual do REM. Dessa forma, dados de confiabilidade mais precisos das máquinas são fornecidos à engenharia de manutenção para que possa traçar as melhores estratégias de prevenção de falhas.

A criação das variáveis universo para este modelo foi baseada na faixa de calibração dos instrumentos, pois essa é a faixa onde são obtidas leituras válidas para os sensores. Isso garante que o modelo tenha informações corretas sobre as variáveis de leitura, o que melhora a precisão do modelo.

A essência do diagnóstico eficaz de falhas usando o SIF depende do mapeamento de todos os possíveis modos de falha dentro do sistema e do estabelecimento de relações entre as variáveis de processo e seus limites operacionais. Alcançar essa simbiose exige um estabelecimento abrangente de regras dentro do modelo, onde o conhecimento especializado desempenha um papel fundamental. Um conjunto formado por dez regras foi estabelecido para este modelo, com o objetivo de diagnosticar e classificar falhas no equipamento avaliado, por meio de relações lógicas entre os conjuntos formados pelas pelos sinais de entrada na sua forma fuzzificada.

A utilização da FMECA como ferramenta fundamental para codificar os modos de

falha de acordo com a norma ISO 14224:2006 e padronizar o conhecimento especializado faz com que o conjunto de partes afetadas e modos de falhas permaneçam os mesmos independente do fabricante do equipamento, padronizando assim a saída do modelo criado.

No comparativo entre técnicas de diagnóstico, destacou-se como vantagem do SIF sobre a rede ANFIS os seguintes pontos: não se faz necessário a formação de conjunto de dados de treinamento e teste; em geral, apresenta menor custo computacional; e apresentou maior percentual de acerto no diagnóstico de falhas. Cabe ressaltar que a disponibilidade de dados de falha para modelos que requerem dados de treinamento e teste nem sempre é de fácil obtenção, principalmente em sistemas reais e em operação, tendo em vista que por vezes não existe a possibilidade de execução de testes ou ensaios para se levar esses sistemas ao limite de falha. Dessa maneira, a escolha de um modelo que não requeira dados para treinamento e testes deve ser considerada nesses casos.

## 6.1 Trabalhos futuros

O SIF não requer um conjunto de dados de treinamento ou de uma etapa de treinamento; por outro lado, ele depende fortemente da definição correta dos limites operacionais das variáveis. Consequentemente, é necessária a criação de regras que representem o comportamento real do sistema e os critérios de classificação na parte consequente do modelo. Portanto, nos casos em que as regras a serem geradas para o sistema de inferência fuzzy não forem explícitas, outros modelos devem ser avaliados.

Como dados reais foram usados neste trabalho e nem todos os modos de falha que o modelo classifica puderam ser verificados, sugere-se como trabalho futuro simular os outros modos de falha não verificados com os dados atuais.

O processo de criação de regras do modelo proposto baseou-se no conhecimento prévio do sistema, ou seja, de conhecimento especialista, porém as mesmas foram definidas de não assistida e definida pelo projetista do SIF. Um processo de automatização de criação de regras, sendo avaliada a possibilidade de substituição do conhecimento especialista por esse processo ou apenas a automação do processo de criação de regras ainda utilizando suas diretrizes é uma avaliação a ser futura a ser realizada.

A metodologia empregada para a classificação de falhas de sistemas baseado na coleta de dados de supervisor e na identificação dos modos de falha definidos na FMECA como passíveis de serem identificados por monitoramento, pode ser expandida para outros sistemas dos turbogeradores e até mesmo para outros equipamentos da mesma planta de processo ou outras plantas. Dessa maneira, sugere-se a aplicação desse modelo em outros ambientes para sua validação.

Embora a aplicação do SIF tenha apresentado um bom desempenho na classificação



de falhas, a utilização outras técnicas complementares com teste comparativo entre a taxa de acerto entre os diagnósticos realizados entre os sistemas.

Outro ponto a ser avaliado é o tempo de resposta com a aquisição de dados diretamente do supervisor do meio produtivo para a aplicação e a segurança da interação da aplicação com o meio produtivo, de modo a reduzir o tempo de acesso ao servidor do historiador de dados que atualmente é de 20 segundos.



# Publicações

Castro, P.F.; Lira, G.R.S.d.; Vilar, P.B.; Costa, E.G.d.; Carvalho, F.B.S. **Fuzzy Inference System Development for Turbogenerator Failure Diagnosis on Floating Production Offloading and Storage Platform.** *Energies* 2024, 17, 392. <https://doi.org/10.3390/en17020392>

Castro, P.F.; Costa, E.G.d.; Lira, G.R.S.d. **Modelo ANFIS para Diagnóstico de Falhas em Turbogenerator.** Seminário Petrobras de Confiabilidade 2022, 2022.



# Referências Bibliográficas

- BAGUA, H. et al. Gas turbine monitoring using fuzzy control approaches: Comparison between fuzzy type 1 and 2. In: IEEE. **2018 International Conference on Applied Smart Systems (ICASS)**. Medea: IEEE, 2018. P. 1–6.
- BARBOSA, V. R. N. et al. Estimation of Metal Oxide Surge Arresters' Useful Life Based on Time Series Forecasts. **IEEE Transactions on Power Delivery**, v. 37, n. 2, p. 842–850, 2022.
- BENOUIOUA, D. et al. Diagnosis of fuel cells using instantaneous frequencies and envelopes extracted from stack voltage signal. **International Journal of Hydrogen Energy**, v. 47, n. 16, p. 9706–9718, 2022. ISSN 0360-3199.
- BIDE, Z. et al. A new method of diagnosing turbogenerator's vibration fault based on fuzzy clustering analysis and wavelet packets transform. In: IEEE. **ICEMS'2001. Proceedings of the Fifth International Conference on Electrical Machines and Systems (IEEE Cat. No. 01EX501)**. Shenyang: IEEE, 2001. v. 1, p. 339–342.
- BILLINTON, R.; ALLAN, R. N. **Reliability Evaluation of Engineering Systems**. 2. ed. Nova Iorque: Plenum Press, 1992. P. 5, 163–167. ISBN 0-306-44063-6.
- BORGOVINI, R.; PEMBERTON, S.; ROSSI, M. **Failure Mode, Effects and Criticality Analysis (FMECA)**. Nova York: Reliability Analysis Center IIT Research Center, 1993. P. 134.
- BRANCO FILHO, G. **A Organização, o Planejamento e o Controle da Manutenção**. Edição: Paulo André Pitanga Marques. 1ª. Rio de Janeiro: Ciência Moderna, 2008. v. I, p. 16. ISBN 978-85-7393-680-3.
- BRITO, L. C. et al. An explainable artificial intelligence approach for unsupervised fault detection and diagnosis in rotating machinery. **Mechanical Systems and Signal Processing**, v. 163, p. 108105, 2022. ISSN 0888-3270.
- CASTRO, P. F.; RODRIGUEZ, Y. P. M.; CARVALHO, F. B. S. Application of Generation Adequacy Analysis for Reliability Evaluation of a Floating Production Storage and Offloading Platform Power System. **Energies**, v. 15, n. 15, 2022. ISSN 1996-1073.
- CASTRO, P. F.; SIMÕES FILHO, S. Estudo de Confiabilidade de um Sistema de Suprimento de Energia Elétrica. **8º Simpósio Internacional de Confiabilidade**, 2010.
- CASTRO, P. F. de. **Análise de Confiabilidade do Sistema Elétrico de uma Plataforma de Produção de Petróleo e Gás**. 2020. F. 94. Diss. (Mestrado) – Universidade Federal da Paraíba, João Pessoa.

CHOI, J.; O'KEEFE, K.; BARUAH, P. Nonlinear system diagnosis using neural networks and fuzzy logic. In: IEEE. [1992 Proceedings] **IEEE International Conference on Fuzzy Systems**. São Diego: IEEE, 1992. P. 813–820.

DAO, P. B. Condition monitoring and fault diagnosis of wind turbines based on structural break detection in SCADA data. **Renewable Energy**, v. 185, p. 641–654, 2022. ISSN 0960-1481.

EBRAHIMI, M. 7 - Gas turbine power plant. In: EBRAHIMI, M. (Ed.). **Power Generation Technologies**. Londres: Academic Press, 2023. P. 266, 299, 312. ISBN 978-0-323-95370-2.

ELSHENAWY, L. M. et al. Unsupervised machine learning techniques for fault detection and diagnosis in nuclear power plants. **Progress in Nuclear Energy**, v. 142, p. 103990, 2021. ISSN 0149-1970.

FELIPE, T. A.; MELO, F. C.; FREITAS, L. C. G. Design and Development of an Online Smart Monitoring and Diagnosis System for Photovoltaic Distributed Generation. **Energies**, v. 14, n. 24, 2021. ISSN 1996-1073.

FOROUHARI, S.; ABU-SIADA, A. Application of adaptive neuro fuzzy inference system to support power transformer life estimation and asset management decision. **IEEE Transactions on Dielectrics and Electrical Insulation**, v. 25, n. 3, p. 845–852, 2018.

GAO, W. et al. A Newly Designed Diagnostic Method for Mechanical Faults of High-Voltage Circuit Breakers via SSAE and IELM. **IEEE Transactions on Instrumentation and Measurement**, v. 70, p. 1–13, 2021.

GUAN, J. et al. A Reliability Evaluation Method for Independent Small Offshore Electric Systems. **Energies**, v. 14, n. 11, 2021. ISSN 1996-1073.

GUERRERO, A. C.; GUILLÉN, A.; GÓMEZ, J. A process to develop a quantitative FMECA analysis of critical systems in an offshore wind turbine. In: IEEE. **2013 International Conference on Renewable Energy Research and Applications (ICRERA)**. Madrid: IEEE, 2013. P. 590–594.

HOODA, D. S.; RAICH, V. **Fuzzy Logic Models and Fuzzy Control: An Introduction**. Oxford: Alpha Science International Ltd, 2017. P. 32. ISBN 978-1-78332-326-5.

HUAYING, W.; GUANGJIAN, W. Application of Wavelet Transform and Fuzzy Theory for Turbo-Generator Fault Mode Classification. In: IEEE. **2007 8th International Conference on Electronic Measurement and Instruments**. Xian: IEEE, 2007. P. 3-442-3-445.

INTERNATIONAL ELECTROTECHNICAL COMMISSION. **Failure Modes and effects analysis**. 3. ed. Genebra, 2018. P. 195. ISBN 978-2-8322-5915-3.

INTERNATIONAL ELECTROTECHNICAL COMMISSION. **Risk management – Risk assessment techniques**. 2. ed. Genebra, 2019. P. 37. ISBN 978-2-8322-6989-3.

ISO CENTRAL SECRETARY. **ISO 14224:2006**. en. Genebra, 2006. Petroleum, petrochemical and natural gas industries – Collection and exchange of reliability and maintenance data for equipment.

ISPIRLI, M. M. et al. Application and Comparative Analysis of Fuzzy Inference System for Transformer Fault Diagnosis with Dissolved Gases in Oil. In: IEEE. **2021 3rd International Conference on High Voltage Engineering and Power Systems (ICHVEPS)**. Bandungue: IEEE, 2021. P. 187–190.

KARI, T. et al. An integrated method of ANFIS and Dempster-Shafer theory for fault diagnosis of power transformer. **IEEE Transactions on Dielectrics and Electrical Insulation**, v. 25, n. 1, p. 360–371, 2018.

KARNAVAS, Y. L.; CHASIOTIS, I. D.; VRANGAS, A. Fault diagnosis of squirrel-cage induction motor broken bars based on a model identification method with subtractive clustering. In: IEEE. **2017 IEEE 11th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)**. Tinos: IEEE, 2017. P. 304–310.

KLIR, G. J.; YUAN, B. **Fuzzy sets and Fuzzy logic: theory and applications**. Nova Jersey: Prentice Hall PTR, 1995. P. 11, 14. ISBN 0-13-101171-5.

LAWDER, D. **World Bank Sees Lower 2024 Oil Price, but Middle East War Could Cause Spike**. Edição: Christian Schmollinger e Louise Heavens. 2023. Disponível em: <<<https://www.oedigital.com/news/509118-world-bank-sees-lower-2024-oil-price-but-middle-east-war-could-cause-spike>>>. Acesso em: 16 jan. 2024.

LEE, G.-H.; AKPUDO, U. E.; HUR, J.-W. FMECA and MFCC-Based Early Wear Detection in Gear Pumps in Cost-Aware Monitoring Systems. **Electronics**, v. 10, n. 23, 2021. ISSN 2079-9292.

LI, X.; ZHANG, W. Deep Learning-Based Partial Domain Adaptation Method on Intelligent Machinery Fault Diagnostics. **IEEE Transactions on Industrial Electronics**, v. 68, n. 5, p. 4351–4361, 2021.

LI, Z.; LI, Z. et al. An Intelligent Diagnosis Method for Machine Fault Based on Federated Learning. **Applied Sciences**, v. 11, n. 24, 2021. ISSN 2076-3417.

LIU, H.; MA, R. et al. Machinery Fault Diagnosis Based on Deep Learning for Time Series Analysis and Knowledge Graphs. **J. Signal Process. Syst.**, USA, v. 93, n. 12, p. 1433–1455, 2021. ISSN 1939-8018.

LIU, H.; LIU, Z. et al. A Novel Imbalanced Data Classification Method Based on Weakly Supervised Learning for Fault Diagnosis. **IEEE Transactions on Industrial Informatics**, v. 18, n. 3, p. 1583–1593, 2022.

LORA, E. E. S.; NASCIMENTO, M. A. R. do. **Geração termelétrica: planejamento, projeto e operação**. Edição: Vera Barros. 1. ed. Rio de Janeiro: Interciência, 2004. v. I, p. 145–148, 323, 342, 362–382, 386–387. ISBN 85-7193-105-4.

MA, G. et al. Multiclass Classification With Fuzzy-Feature Observations: Theory and Algorithms. **IEEE Transactions on Cybernetics**, v. 54, n. 2, p. 1048–1061, 2024.

MENEZES, D. Q. F. de et al. Modeling of Spiral Wound Membranes for Gas Separations—Part II: Data Reconciliation for Online Monitoring. **Processes**, v. 8, n. 9, 2020. ISSN 2227-9717.

MISHRA, M. et al. Intelligent Computing in Electrical Utility Industry 4.0: Concept, Key Technologies, Applications and Future Directions. **IEEE Access**, v. 10, p. 100312–100336, 2022.

MOHAMMADPOOR, M.; TORABI, F. Big Data analytics in oil and gas industry: An emerging trend. **Petroleum**, v. 6, n. 4, p. 321–328, 2020. SI: Artificial Intelligence (AI), Knowledge-based Systems (KBS), and Machine Learning (ML). ISSN 2405-6561.

MOUSAVI, M. et al. A New Fault Diagnosis Approach for Heavy-Duty Gas Turbines. **IEEE/ASME Transactions on Mechatronics**, p. 1–11, 2022.

OFFSHORE ENGINEER MAGAZINE. **Petrobras Orders Giant \$2.9B FPSO from Keppel**. 2023. Disponível em: <<<https://www.oedigital.com/news/498726-petrobras-orders-giant-2-9b-fpso-from-keppel>>>. Acesso em: 10 jan. 2024.

OUELLET, V. et al. Improve performance and robustness of knowledge-based FUZZY LOGIC habitat models. **Environmental Modelling & Software**, Elsevier, v. 144, p. 105138, 2021.

PANG, B.; NAZARI, M.; TANG, G. Recursive variational mode extraction and its application in rolling bearing fault diagnosis. **Mechanical Systems and Signal Processing**, v. 165, p. 108321, 2022. ISSN 0888-3270.

PARE, V. **New Petrobras FPSO Contracts in October**. 2019. Disponível em: <<<https://brazilenergyinsight.com/2019/09/23/new-petrobras-fpso-contracts-in-october/>>>. Acesso em: 02 mai. 2022.

PARE, V. **Petrobras enters in direct negotiations with Seatrium for the construction of FPSOs P-84 and P-85**. 2024. Disponível em: <<<https://brazilenergyinsight.com/2024/01/27/petrobras-enters-in-direct-negotiations-with-seatrium-for-the-construction-of-fpsos-p-84-and-p-85/>>>. Acesso em: 19 mai. 2024.

PEI, M. et al. A Fuzzy Logic-based Method for Proton Exchange Membrane Fuel Cell Fault Diagnosis. In: IEEE. **2020 International Conference on Sensing, Measurement Data Analytics in the era of Artificial Intelligence (ICSMD)**. Xian: IEEE, 2020. P. 1–6.



PETROBRAS. **FPSOs: o sistema definitivo e mais moderno de produção de petróleo**. 2023. Disponível em:

<<<https://www.petrobras.com.br/quem-somos/exploracao-e-producao#fppo>>>.

Acesso em: 10 jan. 2024.

RIBEIRO, A. **Produção nacional de petróleo cresce 3,9% em maio**. 2024.

Disponível em: <<<https://diariodocomercio.com.br/economia/producao-nacional-petroleo-cresce-maio/#gref>>>. Acesso em: 15 jul. 2024.

SHUTENKO, O.; PONOMARENKO, S. Development of a Multiple Regression Model for Early Diagnosis of Transformer Oil Condition. **Arabian Journal for Science and Engineering**, 2022. ISSN 2191-4281.

SUNDARAM, K. M. et al. Deep Learning for Fault Diagnostics in Bearings, Insulators, PV Panels, Power Lines, and Electric Vehicle Applications—The State-of-the-Art Approaches. **IEEE Access**, v. 9, p. 41246–41260, 2021.

SUPARTA, W.; ALHASA, K. M. **Modeling of Tropospheric Delays Using ANFIS**. Switzerland: SpringerNature, 2016. v. 1. 124 p. (SpringerBriefs in Meteorology). ISBN 978-3-319-28437-8.

TANSCHAIT, R. Sistemas Fuzzy. In: IEEE. **VI Simpósio Brasileiro de Automação Inteligente**. Bauru: IEEE, 2003. P. 17.

TANSCHAIT, R. Sistemas fuzzy. **Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro**, p. 338–353, 2004.

TRAN, M.-Q.; ELSISI, M.; LIU, M.-K. Effective feature selection with fuzzy entropy and similarity classifier for chatter vibration diagnosis. **Measurement**, v. 184, p. 109962, 2021. ISSN 0263-2241.

VOLLET, C. et al. FPSO Electrical Network Optimization for Significant Savings: Where Lies the Cost? In: IEEE. **2017 Petroleum and Chemical Industry Conference Europe (PCIC Europe)**. Viena: IEEE, 2017. P. 1–9.

WANG, H. et al. Intelligent Diagnosis of Rotating Machinery Based on Optimized Adaptive Learning Dictionary and 1DCNN. **Applied Sciences**, v. 11, n. 23, p. 11325, 2021.

WOODHOUSE, J. **ISO 55000 Asset management – What to Do and why?** 1<sup>a</sup>. Genebra: International Organization for Standardization, 2016. P. 19. ISBN 978-92-67-10653-3.

XU, G. et al. Data-driven fault diagnostics and prognostics for predictive maintenance: A brief overview. In: IEEE. **2019 IEEE 15th international conference on automation science and engineering (CASE)**. Vancouver: IEEE, 2019. P. 103–108.

YAMASSAKI, V. M. **Combinando modelos de Machine Learning com Lógica Fuzzy — Parte 1**. 2020. Disponível em:

<<<https://medium.com/creditas-tech/combinando-modelos-de-machine-learning-com-l%C3%B3gica-fuzzy-parte-1-b5a9f0761a5d>>>. Acesso em: 07 dez. 2021.

YAN, B. et al. Enhanced Component Analytical Solution for Performance Adaptation and Diagnostics of Gas Turbines. **Energies**, v. 14, n. 14, 2021. ISSN 1996-1073.

YANG, J.; YIN, S. et al. A novel convolutional neural network with interference suppression for the fault diagnosis of mechanical rotating components. **Neural Computing and Applications**, 2022.

YANG, P.; WANG, Q.-m. Fault diagnosis system for turbo-generator set based on fuzzy neural network. In: IEEE. **16th International Conference on Artificial Reality and Telexistence–Workshops (ICAT’06)**. Hangzhou: IEEE, 2006. P. 228–231.

YANG, P.; ZHANG, Z. Fault Diagnosis System for Turbo-Generator Set Based on Self-Organized Fuzzy Neural Network. In: IEEE. **2008 Second International Conference on Future Generation Communication and Networking Symposia**. Hinan: IEEE, 2008. v. 4, p. 78–84.

ZHANG, J. et al. Lifetime Extension Approach Based on the Levenberg–Marquardt Neural Network and Power Routing of DC–DC Converters. **IEEE Transactions on Power Electronics**, v. 38, n. 8, p. 10280–10291, 2023.

ZHOU, K. et al. Deep graph feature learning-based diagnosis approach for rotating machinery using multi-sensor data. **Journal of Intelligent Manufacturing**, p. 1–10, 2022.

# Anexos



# ANEXO A – Lista de cargas do sistema de distribuição de energia elétrica do FPSO

## A.1 Sistema de distribuição do *topside*

As principais cargas do sistema de distribuição *topside* são:

- Sistema 13,8 kV
  - Compressores Principais C-UC-1231001A/B/C. Utilizados na compressão do gás de processo (1º estágio de compressão);
  - Compressores de Exportação C-UC-1231002A/B/C. Utilizados na compressão do gás de processo para exportação via gasoduto ou como 2º estágio de compressão para o compressor de injeção (3º estágio de compressão);
  - Compressores de Injeção de Gás C-UC-1252001A/B. Utilizados para compressão do gás que será injetado no reservatório;
  - Compressores de Recuperação de Vapor C-UC-1225001A/B. Utilizados para a compressão de gás dos separadores de baixa pressão;
  - Bombas *Feed* da Unidade de Remoção de Sulfato M-B-UT-1251001. Utilizadas no sistema de injeção de água;
  - Bombas Principais de Injeção de Água M-B-1251002A/B. Utilizadas para a injeção de água no reservatório;
  - Transformadores do *Topside* 13,8 kV / 4,16 kV - 10 MVA Ar Natural (AN) / 12,5 MVA Ar Forçada (AF): TF-5143001A/B. Utilizados para a distribuição de energia elétrica para o painel de alimentação de bombas do *topside*;
  - Transformadores do *Topside* 13,8 kV / 480 V / 480 V - 3150-1575-1575 kVA (AN) / 3938-1969-1969 kVA (AF): TF-5143002A/B. Utilizados para a distribuição de energia elétrica para os centro de controle de motores (CCM) do *topside*;
  - Transformador de *Topside* 13,8 kV / 690 V / 690 V: TF-P-1233005A/B. Utilizados para a alimentação dos aquecedores de gás de regeneração P-1233005A/B.
- Sistema 4,16 kV
  - Bombas de Captação de Água Salgada: M-B-5111001A/B/C/D/E. Utilizadas para fornecerem água principalmente para injeção de água e resfriamento;

- Bombas *Booster* de Injeção de Água: M-B-1251001-01A/B/C. Utilizadas em conjunto com as Bombas Principais de Injeção de Água;
  - Compressores de Gás Recuperado do Flare: M-C-UC-5412001-01A/B. Utilizado no sistema de processamento de gás;
  - Bombas do Separador de Teste. Utilizada no separador de teste no sistema de tratamento de petróleo;
  - Bombas de Circulação de Água de Resfriamento de Área Classificada. Utilizadas para circulação de água doce para resfriamento de equipamentos em área classificada e troca de calor com a água salgada captada para injeção e resfriamento;
  - Bombas de Circulação de Água de Resfriamento Área Não Classificada. Utilizadas para circulação de água doce para resfriamento de equipamentos em área não classificada (incluindo gerador e sistema de óleo mineral das turbinas dos geradores) e troca de calor com a água salgada captada de injeção e resfriamento;
  - Bombas de Transferência de Óleo: M-B-1223503A/B/C. Utilizadas no sistema de tratamento de petróleo para a transferência do petróleo para os tanques de carga.
- Sistema 690 V
    - Painel PN-P-1233005A/B que alimentam dos aquecedores de gás de regeneração P-1233005A/B.
- Sistema 480 V
    - Bombas de Vácuo M-B-Z-UT-1251002A/B. Utilizada na desaeradora para remoção de oxigênio da água de injeção;
    - Ar Condicionados Módulo Elétrico PN-AC-5252002A/B. Ar condicionado do módulo de painéis elétricos;
    - Compressores de Gás de Regeneração M-UC-1233001A/B. Utilizado no sistema de tratamento de gás;
    - Painéis CDC do *Topside*. Alimentam cargas e painéis CCM de do *topside*.
    - Painéis CCM do *Topside*. Alimentam diversas cargas do processo;
    - Painéis CCM Compressores de CO2 PN-CO2-1254001A/B-1. Auxiliares do sistema de compressão de CO2;
    - Unidade de Geração de Nitrogênio Z-5241001. Utilizada na produção de nitrogênio para serviços e selagem;

- Bombas de Circulação Água de Quente CF-B-5125001AB/C. Utilizadas no sistema de água quente para o processo;
- Unidade Hidráulica de Potência (HPU, do inglês: *Hydraulic Power Unit*) dos Poços UH-1210001. Unidade hidráulica utilizada para o controle dos poços conectados à plataforma.

## A.2 Sistema de distribuição do casco

As principais cargas do sistema de distribuição do casco são:

- Sistema 4,16 kV
  - *Power Packs* da unidade hidráulica de potência (HPU) do sistema de transferência de petróleo (sistema de *Offloading*) M-UH-1223501A/B/C/D/E/F. Unidade hidráulica de acionamento das bombas de carga, lastro e deslastro;
  - Bombas *Butterworth* TF-CF-B-5271502A/B. Utilizadas na limpeza dos tanques de carga.
- Sistema 480 V
  - Transformadores do Casco 13,8 kV / 480 V / 480 V - 4500-2250-2250 kVA (AN) / 5625-2813-2813 kVA (AF): TF-5143501 A/B. Utilizados para a distribuição de energia elétrica para o casco CDC do casco;
  - Painel CDC Essencial. Painel que alimenta cargas essenciais, UPS-5265501A e os CCM essenciais da plataforma. Nesse painel ficam as cargas para garantia da habitabilidade e sistemas de emergência. Esse também é o painel de gerador de emergência GE-5261501.
  - Painéis CCM Essenciais do Casco PN-5148502 / PN-5148503. Esses painéis são alimentados pelo CDC PN-5148501.
  - Transformadores - Cargas Essenciais 480 V / 220 V TF-5148501A/B. Transformadores para alimentação de cargas essenciais em 220 V.
  - Sistema de Energia Ininterrupta UPS-5265501A/B. Sistema que alimenta as cargas de emergência, sistemas de segurança, CLP (Controlador Lógico Programável) de diversos sistemas, todas as remotas e supervisorio. As cargas das sistema de energia ininterrupta (UPS, do inglês: *Uninterruptible Power Supply*) ficam tanto no casco quando no *topside* na tensão de 220V;
  - Painéis CCM dos Auxiliares dos Turbogeneradores PN-TG-5147001-01-01/02. Alimentam os auxiliares dos quatro turbogeneradores;

- Painéis CCM dos Compressores de Ar PN-C-UC-5134501A/B/C. Alimentam os inversores de frequência dos motores de cada um dos compressores e outras cargas dos compressores de Ar;
- Bombas de Captação de Água Salgada para Resfriamento M-B-501A/B. Utilizadas na captação de água salgada para resfriamento;
- Bomba de Circulação de Água de Resfriamento M-B-503A/B. Utilizada na circulação de água doce para resfriamento dos equipamentos do casco e troca de calor com a água salgada captada pela B-501A/B;
- Ar Condicionado 3º piso Módulo 17 PN-AC-001A/B. Alimenta o ar condicionado da sala de painéis de automação no Módulo 17.
- Bomba de Captação de Emergência M-B-5111501. Bomba de captação de água salgada utilizada para resfriamento na partida do primeiro gerador principal.
- Painel CDC Normais PN-5143504. Painel que alimenta cargas normais (cargas de utilidades e de serviços.), UPS-5265501B, os CCM PN-5143505 e PN-5143506. Esse também é o painel de gerador auxiliar GE-5262501.
- Painel CDC Normais PN-3501. Painel que alimenta cargas normais, os CCM PN-5143502 e PN-5143503.
- Painéis CCM Normais do Casco PN-5143502 / PN-5143503 / PN-5143505 / PN-5143506. Painéis que alimentam diversas cargas normais do casco.
- Transformadores Normais 480 V / 220V TF-5143503A/B / TF-5143504A/B. Transformadores para alimentação de cargas normais em 220 V.
- Sopradores do Sistema de Gás Inerte M-VT-IG-5241501A/B. Sopradores de gás inerte do gerador de gás inerte para os tanques de carga;
- Bomba de Água Salgada do Gerador de Gás Inerte (GGI) M-B-5241502A/B. Bomba de captação de água salgada para resfriamento do Gerador de Gás Inerte;
- Bombas de Serviços Gerais CF-M-B-5336502A/B. Bomba de captação de água salgada para resfriamento, água para destilação e eletrocloradoras. Também pode ser utilizada em caso de emergência para esgotamento da praça de máquinas.
- Bombas de Lastro M-B-5335501A/B. Utilizadas para lastramento da plataforma com água salgada.
- Unidades Eletrocloradoras PN-UE-5121501 / PN-UE-5121502. Utilizadas para a produção de hipoclorito para dosagem na água de captação para controle da vida marinha nas tubulações.



- HPU Sistema de Offloading de Vante e Ré PN-UH-1223504A-A/B e PN-UH-1223504/B-A/B. Unidade hidráulica para movimentação do carretel do mangote de offloading, SDV e guinchos do sistema.