

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

Monitoramento da Condição de  
Unidades Motogeradoras em Usinas  
Termelétricas usando Regras de Nelson

**Fernanda Mitchelly Vilas Boas Abreu**

**Itajubá, Novembro de 2023**

UNIVERSIDADE FEDERAL DE ITAJUBÁ  
PROGRAMA DE PÓS-GRADUAÇÃO EM  
ENGENHARIA ELÉTRICA

Fernanda Mitchelly Vilas Boas Abreu

Monitoramento da Condição de  
Unidades Motogeradoras em Usinas  
Termelétricas usando Regras de Nelson

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

Área de Concentração: Automação e Sistemas Elétricos Industriais

Orientador: Prof. Dr. Luiz Eduardo Borges da Silva  
Coorientador: Prof. Dr. Helcio Francisco Villa Nova

Itajubá  
2023

*Dedico este trabalho a meus pais, a meu irmão, a meu marido e,  
de maneira especial, a meu amado Vô Zé (in memoriam),  
que durante a trajetória do doutorado estiveram do meu lado  
me sustentando em todos os momentos.*

# Agradecimentos

Primeiramente, agradeço a Deus, pelas oportunidades únicas que ele me proporciona e por ter me fortalecido nesta trajetória.

Agradeço aos meus pais, José M. V. B. Pereira e Silvana V. B. Simões, por tamanha dedicação em sempre me ajudar, seja da forma que for e por nunca deixarem de estar do meu lado, me incentivando, apoiando e me fortalecendo para que eu nunca desistisse dos meus sonhos. Graças ao amor incondicional de vocês hoje cumpro mais essa missão. Meus sinceros agradecimentos por tudo. Eu amo muito vocês!

Agradeço ao meu irmão, Janderson P. V. Boas pelo apoio, companheirismo, amizade e pelas palavras de incentivo, força e motivação.

Agradeço ao meu esposo e companheiro de todas as horas Ramon Barrozo Abreu pelo apoio, cuidado, amor e compreensão para que este trabalho pudesse ser realizado.

Agradeço aos meus avôs, avós, tios, tias, primos e primas, especialmente, tio Beto, tia Lucimara e Goreti, e ao primo Lucas, que sempre preocuparam comigo e vibraram com minhas conquistas. Obrigada pelo carinho!

Agradeço aos Profs. Luiz Eduardo e Germano pela ajuda, disponibilidade e apoio prestado para o desenvolvimento deste trabalho.

Agradeço ao Prof. Hércio especialmente pela paciência, aconselhamentos e por todo o apoio prestado para o andamento deste trabalho.

Agradeço aos colegas de trabalho, Adriano, Bruno Gama, Bruno Guimarães, Cláudio, Tiago, Carlos Eduardo, Carlos Gustavo, Haylemar, Anelise, Ellyara, Gabriela e Cássia, pelo suporte e amparo nas atividades cotidianas.

Meu agradecimento especial ao amigo Frederico pela amizade, pela paciência, pela oportunidade de realizar meu estágio supervisionado ainda durante a graduação de Engenharia e agora, por todo o apoio que sempre presta a mim e aos meus trabalhos.

Agradeço aos amigos Mateus e Wilson pela ajuda, paciência e disponibilidade oferecidas a mim para realizar as simulações e escrita deste trabalho. Agradeço também as amigas Fabienne, Deise e Carol pela assistência e conselhos a mim prestados.

Agradeço as amigas da minha cidade natal, pela amizade, assistência e por sempre me motivarem.

Agradeço ao Instituto Gnarus, pelo apoio financeiro para o desenvolvimento deste trabalho.

Agradeço à ANEEL, que por meio de seu Programa de Pesquisa e Desenvolvi-

mento, pelo suporte a este trabalho.

Agradeço à Usina Termelétrica Rio Amazonas Energia S.A. RAESA, pelo apoio prestado para a realização deste trabalho.

Agradeço à empresa PS Soluções, em especial, ao Erik e Levy, pela confiança, ensinamentos e suporte a mim prestados.

Por fim, agradeço a todos que de alguma forma colaboraram na execução deste trabalho.

*“Ele (Deus) é o dono de tudo. Devo a Ele a oportunidade que tive de chegar onde cheguei. Muitas pessoas têm essa capacidade, mas não têm a oportunidade. Ele a deu pra mim, não sei porque. Só sei que não posso desperdiçá-la.”*

*Ayrton Senna*

# Resumo

A estrutura física das Usinas Termelétricas é formada por vários componentes, dentre eles se destacam os motores de combustão interna (MCI). Fundamentalmente, neste tipo de motor, como o próprio nome sugere, a energia é produzida através da queima do combustível no seu interior. Como essa geração de energia termelétrica se mantém constante durante o período de operação da usina, estes motores estão constantemente sujeitos a estresses, devido a diferentes fatores como por exemplo, número de partidas, carga média, variação de carga e temperatura ambiente. Conseqüentemente, isso ocasiona várias falhas como desgaste, vibração excessiva, aumento da temperatura, diminuição da eficiência energética, entre outras falhas. Devido a este contexto, sabe-se que esses motores podem não trabalhar em seu melhor rendimento e, conseqüentemente, existe a necessidade de um sistema de monitoramento contínuo para verificar as condições de funcionamento. Porém, na maioria das vezes, esses sistemas de monitoramento existentes apenas indicam se os parâmetros monitorados estão em não conformidade após a ocorrência de uma falha - não permitindo uma análise antecipada das condições de operação da máquina. Tendo conhecimento disso, neste trabalho, uma metodologia de análise preditiva de falhas no motor de combustão interna, baseada no Processo de Controle Estatístico e Regras de Nelson, é proposta de forma inédita para analisar, de maneira preditiva, as condições operacionais da máquina com base nos dados históricos do sistema supervisório da UTE. Com a finalidade de dar um apelo prático às análises realizadas neste trabalho, os dados operacionais utilizados são os históricos reais do ano de 2019, do motor de combustão interna modelo 18V46 (do fabricante Wärtsilä), que constituem a usina termelétrica em pauta. O mecanismo de análise é validado por meio de dois estudos de caso, sendo o primeiro uma comparação entre o grau de severidade da condição operacional da unidade geradora 5 e o evento de parada desta mesma unidade geradora no dia 01/08/19 e o segundo estudo de caso os apontamentos estatísticos do grau de severidade da unidade geradora 5, quando ela retorna da manutenção pós parada. Demonstra-se que os resultados obtidos com a metodologia proposta corresponderam adequadamente aos lançamentos do registro de turno, sendo eles a degradação de certos subsistemas da unidade motogeradora 5 até a ocorrência da sua parada em Agosto de 2019 - o que a torna uma ferramenta promissora tanto para a tomada de decisões sobre manutenções na planta de forma precoce, quanto para ajudar os operadores das máquinas a verificar se as máquinas que voltaram de manutenção estão em condições boas.

**Palavras-chaves:** Manutenção baseada em condição, análises de falhas, motores de combustão interna, regras de Nelson, controle estatístico de processo, grau de severidade.

# Abstract

The physical structure of Thermoelectric Power Plants is made up of several components, among which the internal combustion engines (MCI) stand out. Fundamentally, in this type of engine, as the name suggests, energy is produced by burning the fuel inside. As this generation of thermoelectric energy remains constant during the plant's operating period, these engines are constantly subject to stress, due to different factors such as number of starts, average load, load variation and ambient temperature. However, most of the time, these existing monitoring systems only indicate whether the monitored parameters are non-compliant after a failure has occurred – not allowing an early analysis of the machine's operating conditions. Knowing this, in this work, a methodology for early analysis of failures in the internal combustion engine, based on the Statistical Control Process and Nelson's Rules, is proposed in an unprecedented way to analyze, in a predictive manner, the operating conditions of the machine based on historical data from the UTE supervisory system. In order to give a practical appeal to the analyzes carried out in this work, the operational data used are the real records of the year 2019, of the internal combustion engine model 18V46 (from the manufacturer Wärtsilä), which constitute the thermoelectric plant in question. The analysis mechanism is validated through two case studies, the first being a comparison between the degree of severity of the operational condition of generating unit 5 and the shutdown event of this same generating unit on 08/01/19 and the second case study statistical notes on the degree of severity of generating unit 5, when it returns from post-shutdown maintenance. It is demonstrated that the results obtained with the proposed methodology adequately corresponded to the entries in the shift record, namely the degradation of certain subsystems of the motor generating unit 5 until its stop in August 2019 - which makes it a promising tool both for making early decisions about plant maintenance and for helping machine operators check whether machines that have returned from maintenance are in good condition.

**Key-words:** Condition Based Maintenance, failure analysis, internal combustion engines, Nelson rules, statistical process control, degree of severity.

# Lista de ilustrações

Figura 1 – Estrutura geral de uma típica UTE (1). . . . .	25
Figura 2 – Exemplo de uma casa de máquina (2). . . . .	26
Figura 3 – Exemplo das entradas de ar para refrigerar o ambiente da casa de máquinas (3). . . . .	26
Figura 4 – Exemplo de tubos de escape (4). . . . .	27
Figura 5 – Exemplo de disposição dos motogeradores dentro da casa de máquina (5). . . . .	27
Figura 6 – Exemplo de disposição dos radiadores (6). . . . .	28
Figura 7 – Exemplo de tanques (7). . . . .	29
Figura 8 – Exemplo de torres de escape (8). . . . .	29
Figura 9 – Exemplo de sala de tratamento de óleo (9). . . . .	30
Figura 10 – Exemplo de sala de controle (10). . . . .	31
Figura 11 – Modelo de UG convencional (11) . . . . .	31
Figura 12 – Modelo convencional de Diagrama de Controle. . . . .	40
Figura 13 – Dispersão dos pontos relativos à Linha Média (LM). . . . .	41
Figura 14 – Zona C do diagrama de controle. . . . .	42
Figura 15 – Zona B do diagrama de controle. . . . .	43
Figura 16 – Zona A do diagrama de controle. . . . .	44
Figura 17 – Exemplo de um típico histograma. . . . .	47
Figura 18 – Exemplos de resultados típicos de teste Q-Q Plot. . . . .	47
Figura 19 – Regra 1. . . . .	55
Figura 20 – Regra 2. . . . .	56
Figura 21 – Regra 3. . . . .	57
Figura 22 – Regra 4. . . . .	58
Figura 23 – Regra 5. . . . .	59
Figura 24 – Regra 6. . . . .	60
Figura 25 – Regra 7. . . . .	61
Figura 26 – Regra 8. . . . .	62
Figura 27 – Diagrama da unidade geradora dividida em 11 subsistemas. . . . .	67
Figura 28 – Diagrama do desenho do motor que ilustra os sensores do subsistema ar de admissão. . . . .	68
Figura 29 – Diagrama do desenho do motor que ilustra os sensores do subsistema de turbinas. . . . .	69
Figura 30 – Diagrama do esquemático interno do subsistema de óleo combustível. . . . .	70
Figura 31 – Diagrama do desenho do motor que ilustra os sensores do subsistema de cilindro. . . . .	72

Figura 32 – Diagrama do desenho do motor que ilustra os sensores do subsistema de mancais. . . . .	73
Figura 33 – Diagrama do esquemático geral do subsistema de óleo lubrificante. . . .	74
Figura 34 – Diagrama do esquemático interno do subsistema de água de arrefecimento. . . . .	75
Figura 35 – Diagrama do esquemático interno do subsistema de gases de exaustão. . . . .	77
Figura 36 – Diagrama do desenho do motor que ilustra os sensores do subsistema de gerador. . . . .	78
Figura 37 – Diagrama do esquemático geral do subsistema de gás natural. . . . .	79
Figura 38 – Diagrama do desenho do motor que ilustra os sensores do subsistema outros. . . . .	80
Figura 39 – Histograma da Potência Ativa do Gerador. . . . .	83
Figura 40 – Histograma da Temperatura de Saída do Óleo Lubrificante. . . . .	83
Figura 41 – Histograma da Temperatura do Cilindro B7 sensor 1. . . . .	84
Figura 42 – Histograma da Temperatura do Cilindro B4 sensor 2. . . . .	84
Figura 43 – Histograma da Temperatura do Cilindro A6 sensor 2. . . . .	85
Figura 44 – Gráfico Q-Q Plot da Potência Ativa do Gerador. . . . .	86
Figura 45 – Gráfico Q-Q Plot da Temperatura de Saída do Óleo Lubrificante. . . .	87
Figura 46 – Gráfico Q-Q Plot da Temperatura de revestimento do Cilindro B7 sensor 1. . . . .	87
Figura 47 – Gráfico Q-Q Plot da Temperatura de revestimento do Cilindro B4 sensor 2. . . . .	88
Figura 48 – Gráfico Q-Q Plot da Temperatura de revestimento do Cilindro A6 sensor 2. . . . .	88
Figura 49 – Diagrama em blocos da Normalização dos Dados. . . . .	91
Figura 50 – Histograma da potência ativa do gerador após ajuste contínuo via Distfit. . . . .	94
Figura 51 – Modelo de Diagrama de Controle. . . . .	96
Figura 52 – Zona C do diagrama de controle. . . . .	98
Figura 53 – Zona B do diagrama de controle. . . . .	99
Figura 54 – Zona A do diagrama de controle. . . . .	100
Figura 55 – Escala de cores das Regras de Nelson. . . . .	102
Figura 56 – Gráfico do comportamento de todas as variáveis do motor em um intervalo de tempo. . . . .	103
Figura 57 – Área selecionada do espectro da potência ativa do gerador do diagrama do mês de janeiro. . . . .	106
Figura 58 – Gráfico de barras do subsistema de Óleo Lubrificante, da primeira janela selecionada. . . . .	107
Figura 59 – Gráfico de barras do subsistema de Cilindros, da primeira janela selecionada. . . . .	107

Figura 60 – Área selecionada do espectro da potência ativa do gerador do diagrama do mês de fevereiro. . . . .	108
Figura 61 – Gráfico de barras do subsistema de Óleo Lubrificante, da segunda janela selecionada. . . . .	109
Figura 62 – Gráfico de barras do subsistema de Cilindros, da segunda janela selecionada. . . . .	109
Figura 63 – Área selecionada do espectro da potência ativa do gerador do diagrama do mês de Março. . . . .	111
Figura 64 – Gráfico de barras do subsistema de Óleo Lubrificante, da terceira janela selecionada. . . . .	111
Figura 65 – Gráfico de barras do subsistema de Cilindros, da terceira janela selecionada. . . . .	112
Figura 66 – Área selecionada do espectro da potência ativa do gerador do diagrama do mês de abril. . . . .	113
Figura 67 – Gráfico de barras do subsistema de Óleo Lubrificante, da quarta janela selecionada. . . . .	114
Figura 68 – Gráfico de barras do subsistema de Cilindros, da quarta janela selecionada. . . . .	114
Figura 69 – Área selecionada do espectro da potência ativa do gerador do diagrama do mês de Maio. . . . .	116
Figura 70 – Gráfico de barras do subsistema de Óleo Lubrificante, da quinta janela selecionada. . . . .	116
Figura 71 – Gráfico de barras do subsistema de Cilindros, da quinta janela selecionada. . . . .	117
Figura 72 – Área selecionada do espectro da potência ativa do gerador do diagrama do mês de junho. . . . .	118
Figura 73 – Gráfico de barras do subsistema de Óleo Lubrificante, da sexta janela selecionada. . . . .	119
Figura 74 – Gráfico de barras do subsistema de Cilindros, da sexta janela selecionada.	119
Figura 75 – Área selecionada do espectro da potência ativa do gerador do diagrama do mês de julho. . . . .	121
Figura 76 – Gráfico de barras do subsistema de Óleo Lubrificante, da sétima janela selecionada. . . . .	122
Figura 77 – Gráfico de barras do subsistema de Cilindros, da sétima janela selecionada. . . . .	122
Figura 78 – Área selecionada do espectro da potência ativa do gerador do diagrama do mês de agosto. . . . .	124
Figura 79 – Gráfico de barras do subsistema de Óleo Lubrificante, da oitavo janela selecionada. . . . .	124

Figura 80 – Gráfico de barras do subsistema de Cilindros, da oitava janela selecionada.	125
Figura 81 – Área selecionada do espectro da potência ativa do gerador do diagrama do mês de novembro. . . . .	128
Figura 82 – Gráfico de barras do subsistema de Óleo Lubrificante, da nona janela selecionada. . . . .	129
Figura 83 – Gráfico de barras do subsistema de Cilindros, da nona janela selecionada.	129
Figura 84 – Área selecionada do espectro da potência ativa do gerador do diagrama do mês de dezembro. . . . .	131
Figura 85 – Gráfico de barras do subsistema de Óleo Lubrificante, da décima janela selecionada. . . . .	132
Figura 86 – Gráfico de barras do subsistema de Cilindros, da nona janela selecionada.	132
Figura 87 – Casquilho do Cilindro B7 danificado. . . . .	163
Figura 88 – Sinais de deslocamento do casquilho na capa. . . . .	164
Figura 89 – Deslocamento do cilindro B7. . . . .	164
Figura 90 – Dano na lateral do casquilho do cilindro B7. . . . .	165
Figura 91 – Trava do casquilho do cilindro B7 danificada. . . . .	165
Figura 92 – Bucha da biela com defeito devido a decorrência da limalha. . . . .	166
Figura 93 – Presença de limalha no alojamento do filtro automático de óleo lubrificante. . . . .	166

# Lista de tabelas

Tabela 1	– Tabela que apresenta as <i>tags</i> e as descrições das variáveis que compõem o subsistema de ar de admissão. . . . .	68
Tabela 2	– Tabela que apresenta as <i>tags</i> e as descrições das variáveis que compõem o subsistema de turbinas. . . . .	69
Tabela 3	– Tabela que apresenta as <i>tags</i> e as descrições das variáveis que compõem o subsistema de óleo combustível. . . . .	70
Tabela 4	– Tabela que apresenta as <i>tags</i> e as descrições das variáveis que compõem o subsistema de cilindro. . . . .	71
Tabela 5	– Tabela que apresenta as <i>tags</i> e as descrições das variáveis que compõem o subsistema de mancais. . . . .	73
Tabela 6	– Tabela que apresenta as <i>tags</i> e as descrições das variáveis que compõem o subsistema de óleo lubrificante. . . . .	74
Tabela 7	– Tabela que apresenta as <i>tags</i> e as descrições das variáveis que compõem o subsistema de água de arrefecimento. . . . .	75
Tabela 8	– Tabela que apresenta as <i>tags</i> e as descrições das variáveis que compõem o subsistema de gases de exaustão. . . . .	76
Tabela 9	– Tabela que apresenta as <i>tags</i> e as descrições das variáveis que compõem o subsistema de gerador. . . . .	78
Tabela 10	– Tabela que apresenta as <i>tags</i> e as descrições das variáveis que compõem o subsistema de gás natural. . . . .	79
Tabela 11	– Tabela que apresenta as <i>tags</i> e as descrições das variáveis que compõem o subsistema de outros. . . . .	80
Tabela 12	– Tabela que apresenta os resultados dos testes KS para cada uma das variáveis selecionadas. . . . .	90
Tabela 13	– Tabela que apresenta o resultado do ajuste contínuo da distribuição normal aos dados da variável potência ativa do gerador via Distfit. . . . .	93
Tabela 14	– Resultados do ajuste discreto da distribuição binomial aos dados das variáveis temperatura de saída do óleo lubrificante e temperatura de revestimento dos cilindros B7 (sensor 1), B4 (sensor 2) e A6 (sensor 2) via Distfit. . . . .	94
Tabela 15	– Tabela que apresenta as escalas de cores com as respectivas regras de Nelson. . . . .	102
Tabela 16	– Tabela que apresenta os acontecimentos do sinistro do dia 01-ago-2019. . . . .	126

# Lista de abreviaturas e siglas

AD	Anderson-Darling
ANEEL	Agência Nacional de Energia Elétrica
CBM	“ <i>Condition-Based Maintenance</i> ”, Manutenção Baseada em Condições
CEP	Controle Estatístico de Processo
CSV	‘ <i>Comma Separated Values</i> ’, Valores Separados por Vírgulas
FDC	Função de Distribuição Cumulativa
GD	Gás-Diesel
HFO	“ <i>Heavy Fuel Oil</i> ”, Óleo Combustível Pesado
HT	Circuito de alta temperatura
i.i.d	Independente e identicamente distribuída
KS	Kolmogorov-Smirnov
KW	Kilowatt
LIC	Limite Inferior de Controle
LM	Linha Média
LSC	Limite Superior de Controle
LT	Circuito de baixa temperatura
MCI	Motor de Combustão Interna
MLE	“ <i>Maximum Likelihood Estimation</i> ”, Método de Máxima Verossimilhança
PDF	“ <i>Probability Density Function</i> ”, Função Densidade de Probabilidade
PLC	“ <i>Programmable Logic Controller</i> ”, Controlador Lógico Programável
PMF	“ <i>Probability Mass Function</i> ”, Função Massa de Probabilidade
Q-Q Plot	“ <i>Quantil-quantil</i> ”
RAESA	Rio Amazonas Energia S.A

RSS	“ <i>Residual Sum of Squares</i> ”, Soma Residual dos Quadrados
Regra 1	Regra de Nelson número 1
Regra 2	Regra de Nelson número 2
Regra 3	Regra de Nelson número 3
Regra 4	Regra de Nelson número 4
Regra 5	Regra de Nelson número 5
Regra 6	Regra de Nelson número 6
Regra 7	Regra de Nelson número 7
Regra 8	Regra de Nelson número 8
SCADA	“ <i>Supervisory Control and Data Acquisition</i> ”, Sistema de supervisão e aquisição de dados
SIMPREBAL	Sistema Inteligente de manutenção preditiva de Balbina
SW	Shapiro-Wilk
TCL	Teorema central do limite
UG	Unidade Motogeradora
UNIFEI	Universidade Federal de Itajubá
UTE	Usina Termelétrica
WOIS	“ <i>Wärtsilä Operator’s Interface System</i> ”, Sistema de Interface do Operador da Wärtsilä
ZONA A	Zona de controle A
ZONA B	Zona de controle B
ZONA C	Zona de controle C

# Lista de símbolos

$\alpha$	Nível de significância
$\mu$	Média populacional
$\mu_{Z_N}(w)$	Função característica de $Z_N$
$\sigma$	Desvio padrão populacional
$2\sigma$	2° Desvio padrão populacional
$3\sigma$	3° Desvio padrão populacional
$\sigma^2$	Variância populacional
$\Phi$	Representação da função distribuição cumulada da densidade normal
$\Phi(\xi_q)$	Q-ésimo quantil de uma distribuição normal
$\Phi(Z)$	Função densidade cumulativa da distribuição normal
$\Phi(z_{(n)})$	Probabilidade de assumir um valor no intervalo $(\frac{n-1}{n}, 1)$
$\Pi$	Produtório
$\Sigma$	Somatório
$A_{crit}^2$	Valor crítico tabelado de Anderson-Darling
$A_m^2$	Valor da estatística de teste de Anderson-Darling para um número pequeno de amostra
$A_i$	Zona A inferior
$A_n$	Sequência de números de André
$A_s$	Zona A superior
$A^2$	Estatística de teste de Anderson-Darling
$A_6$	Cilindro de número 6 do lado A do motor Wärtsilä 18V46
$a_i$	Coefficiente da tabela de Shapiro-Wilk
$B_i$	Zona B inferior
$B_s$	Zona B superior

$b$	Coefficiente de Shapiro-Wilk
$b_i$	Contagem normal dos dados ordenados
$B_6$	Cilindro de número 6 do lado B do motor Wärtsilä 18V46
$B_7$	Cilindro de número 7 do lado B do motor Wärtsilä 18V46
$C_i$	Zona C inferior
$C_s$	Zona C superior
$D_n$	Número que começa a sequência para baixo
$D_n$	Estatística de teste de Kolmogorov-Smirnov
$E[Z_N]$	Valor esperado de $Z_N$
$E[e^{jwZ_N}]$	Valor esperado de $e^{jwZ_N}$
$e^x$	Exponencial de x
$F$	Função densidade cumulativa da distribuição normal padrão
$F(x)$	Função de distribuição acumulada
$f(x_i)$	Valor previsto de $y_i$
$H_0$	Hipótese de rejeitar a distribuição normal
$H_1$	Hipótese que conclui distribuição normal
$k$	Número total de intervalo de classe
$\ln$	Representação de logaritmo neperiano
$m_k$	Função do histograma
$N$	Número total de elementos da população
$N$	Número total de amostra aleatória
$\mathcal{N}(0, 1)$	Processo para geração de uma variável aleatória gaussiana padrão
$n$	Número total de observações
$n$	Tamanho da sequência de números alterando em zig-zag
$n$	Frequência total de ocorrência em cada classe do histograma
$n$	Número de amostras

$n$	Número de repetições de um evento de Bernoulli
$n!$	Fatorial do tamanho da sequência $n$
$p$	Probabilidade dos eventos de Bernoulli ocorrer
$P(A)$	Probabilidade de uma medida estar na Zona A
$P(A_i)$	Probabilidade de um ponto estar na Zona A inferior
$P(A_s)$	Probabilidade de um ponto estar na Zona A superior
$P(B_i)$	Probabilidade de um ponto estar na Zona B inferior
$P(B_s)$	Probabilidade de um ponto estar na Zona B superior
$P(C)$	Probabilidade de uma medida estar na Zona C
$P(C_i)$	Probabilidade de um ponto estar na Zona C inferior
$P(C_s)$	Probabilidade de um ponto estar na Zona C superior
$P(E_i)$	Probabilidade de um ponto estar na Zona externa inferior
$P(E_s)$	Probabilidade de um ponto estar na Zona externa
$P_r[Z_N \leq Z]$	Probabilidade do evento $[Z_N \leq Z]$
$P(Regra1)$	Probabilidade de ocorrência da regra de Nelson de número 1
$P(Regra2)$	Probabilidade de ocorrência da regra de Nelson de número 2
$P(Regra3)$	Probabilidade de ocorrência da regra de Nelson de número 3
$P(Regra4)$	Probabilidade de ocorrência da regra de Nelson de número 4
$P(Regra5)$	Probabilidade de ocorrência da regra de Nelson de número 5
$P(Regra6)$	Probabilidade de ocorrência da regra de Nelson de número 6
$P(Regra7)$	Probabilidade de ocorrência da regra de Nelson de número 7
$P(Regra8)$	Probabilidade de ocorrência da regra de Nelson de número 8
$p_n$	Probabilidade de um número de sequência alternando em zig-zag
$q$	Quantil teórico de uma distribuição normal
$Região_{interna}$	Região Interna dos limites de controle
$R_p$	Estatística de teste de Ryan-Joiner

$S(x)$	Função de distribuição empírica
$S_N$	Soma das variáveis aleatórias
$s$	Desvio padrão amostral
$2s$	2º Desvio padrão amostral
$3s$	3º Desvio padrão amostral
$S^2$	Variância da amostra aleatória $y_i$
$s^2$	Variância amostral
$T_n$	Número de sequência alternando em zig-zag entre n!seqüências de tamanho n
$T_{14}$	Décima quarta posição da sequência dos números de André
$U_n$	Número que começa a sequência para CIMA
$var[Z_N]$	Estatística de teste de Shapiro-Wilk
$W$	Estatística de teste de Shapiro-Wilk
$W_{n;\alpha}$	Limiar de Shapiro-Wilk
$e^{-\frac{w^2}{2}}$	Função característica da gaussiana normalizada
$\bar{X}$	Média amostral
$x_i$	i-ésimo valor da variável a ser explicativa
$X_n$	N-ésima observação de uma amostra
$X_n - \mu$	Variável aleatória
$X_N$	N-ésimo valor de uma amostra aleatória independente e identicamente distribuída
$x$	Valores da população
$x_N$	N-ésimo valor da população
$x[n]$	Dados históricos reais fornecido pela UTE
$Y_i$	Dados ordenados de forma ascendente
$y_i$	Valores da amostra aleatória de uma população
$y_i$	i-ésimo valor da variável a ser prevista

$\hat{y}_i$	Valor previsto de $y_i$
$y_k$	Estatística de ordem da amostra aleatória observada
$y_{k+i}$	Valor da mediana
$z$	Z-score
$z$	Valores de uma amostra aleatória com distribuição normal
$z[n]$	Z-score dos dados históricos reais fornecido pela UTE
$z_{(n)}$	N-ésimo valor de uma amostra aleatória com distribuição normal
$Z_N$	Variável aleatória

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>24</b>
<b>1.1</b>	<b>Contextualização</b>	<b>24</b>
<b>1.2</b>	<b>Usina Termelétrica</b>	<b>25</b>
1.2.1	Motor de Combustão Interna (MCI)	31
<b>1.3</b>	<b>Estado da arte do monitoramento</b>	<b>32</b>
<b>1.4</b>	<b>Motivação e Objetivo central</b>	<b>34</b>
<b>1.5</b>	<b>Estrutura e contribuições do trabalho</b>	<b>35</b>
<b>2</b>	<b>FUNDAMENTOS TEÓRICOS</b>	<b>37</b>
<b>2.1</b>	<b>Estatística</b>	<b>37</b>
2.1.1	Média	37
2.1.1.1	Média Aritmética	37
2.1.2	Desvio Padrão	38
2.1.2.1	Desvio padrão populacional e amostral	38
2.1.3	Z-score	39
2.1.4	Diagrama de Controle	40
<b>2.2</b>	<b>Testes de normalidade</b>	<b>46</b>
2.2.1	Métodos visuais	46
2.2.2	Histograma	46
2.2.3	Quantil-Quantil (Q-Q Plot)	47
2.2.4	Testes Estatísticos	49
2.2.5	Teste de normalidade Anderson-Darling (AD)	49
2.2.6	Teste de normalidade Ryan-Joiner	50
2.2.7	Teste de normalidade Shapiro-Wilk (SW)	51
2.2.8	Teste de normalidade Kolmogorov-Smirnov (KS)	52
<b>2.3</b>	<b>Regras de Nelson</b>	<b>54</b>
2.3.1	Regra 1	54
2.3.2	Regra 2	56
2.3.3	Regra 3	56
2.3.4	Regra 4	57
2.3.5	Regra 5	58
2.3.6	Regra 6	60
2.3.7	Regra 7	61
2.3.8	Regra 8	62
<b>2.4</b>	<b>Técnica usada pela biblioteca Distfit</b>	<b>63</b>

<b>3</b>	<b>METODOLOGIA PROPOSTA</b>	<b>66</b>
<b>3.1</b>	<b>Divisão em subsistemas</b>	<b>66</b>
<b>3.2</b>	<b>Variáveis selecionadas por subsistemas</b>	<b>67</b>
3.2.1	Subsistema de Ar de Admissão	67
3.2.2	Subsistema de Turbinas	68
3.2.3	Subsistema de Óleo Combustível	70
3.2.4	Subsistema de Cilindro	70
3.2.5	Subsistema de Mancais	72
3.2.6	Subsistema de Óleo Lubrificante	73
3.2.7	Subsistema de Água de Arrefecimento	74
3.2.8	Subsistema de Gases de Exaustão	76
3.2.9	Subsistema de Gerador	77
3.2.10	Subsistema de Gás Natural	78
3.2.11	Subsistema Outros	79
<b>3.3</b>	<b>Base de dados de um sistema de monitoramento de UTEs</b>	<b>81</b>
<b>3.4</b>	<b>Aplicação do Teste de Normalidade</b>	<b>81</b>
3.4.1	Aplicação do Teste de Normalidade Visual	82
3.4.2	Aplicação do Teste de Normalidade Estatístico	89
<b>3.5</b>	<b>Normalização dos Dados</b>	<b>91</b>
<b>3.6</b>	<b>Cálculos estatísticos para as variáveis</b>	<b>95</b>
<b>3.7</b>	<b>Diagrama de Controle para as variáveis</b>	<b>96</b>
<b>3.8</b>	<b>Regras de Nelson aplicadas em MCI</b>	<b>100</b>
<b>3.9</b>	<b>Análise das Regras de Nelson aplicadas em MCI no tempo</b>	<b>101</b>
3.9.1	Gráficos de barras	101
<b>4</b>	<b>RESULTADOS NUMÉRICOS</b>	<b>104</b>
<b>4.1</b>	<b>Descrição do tratamento dos dados</b>	<b>104</b>
<b>4.2</b>	<b>Desempenho e validação do modelo estatístico por meio dos gráficos de barras</b>	<b>105</b>
4.2.1	Análise 1: janeiro 2019	105
4.2.2	Análise 2: fevereiro 2019	108
4.2.3	Análise 3: março 2019	110
4.2.4	Análise 4: abril 2019	113
4.2.5	Análise 5: maio 2019	115
4.2.6	Análise 6: junho 2019	118
4.2.7	Análise 7: julho 2019	121
4.2.8	Análise 8: agosto 2019	123
<b>4.3</b>	<b>Desempenho e validação do modelo estatístico após o retorno da UG 5</b>	<b>127</b>
4.3.1	Análise 9: novembro 2019	128

4.3.2	Análise 10: dezembro 2019 . . . . .	131
<b>5</b>	<b>CONCLUSÃO . . . . .</b>	<b>135</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>140</b>
	<b>APÊNDICES . . . . .</b>	<b>146</b>
	<b>APÊNDICE A – DESENVOLVIMENTO ANALÍTICO DO TEOREMA CENTRAL DO LIMITE . . . . .</b>	<b>147</b>
<b>A.1</b>	<b>Teorema Central do Limite . . . . .</b>	<b>147</b>
A.1.1	Demonstração que $E[Z_N] = 0$ . . . . .	148
A.1.2	Demonstração que $var[Z_N] = 1$ . . . . .	149
A.1.3	Demonstração que $Z_N \xrightarrow{\infty} \mathcal{N}(0, 1)$ . . . . .	151
	<b>APÊNDICE B – DISTRIBUIÇÕES ESTATÍSTICAS . . . . .</b>	<b>155</b>
<b>B.1</b>	<b>Tipos de Distribuições . . . . .</b>	<b>155</b>
<b>B.2</b>	<b>Aproximação da Distribuição Binomial pela Distribuição Normal . . . . .</b>	<b>157</b>
	<b>APÊNDICE C – SINISTRO DO DIA 01 DE AGOSTO DE 2019 . . . . .</b>	<b>159</b>
<b>C.1</b>	<b>Descrição do Evento . . . . .</b>	<b>159</b>
<b>C.2</b>	<b>Cronologia do Evento no WOIS . . . . .</b>	<b>159</b>
<b>C.3</b>	<b>Evidências Pós Evento . . . . .</b>	<b>162</b>
<b>C.4</b>	<b>Inspeção de Campo Pós Evento . . . . .</b>	<b>163</b>
	<b>ANEXOS . . . . .</b>	<b>167</b>

# 1 Introdução

## 1.1 Contextualização

A maior parte da energia elétrica produzida no Brasil provém das barragens de água que constituem as usinas hidrelétricas. Numericamente, este fato corresponde a uma porcentagem de aproximadamente 53% (12). Conseqüentemente, percebe-se a partir disso que o Brasil ainda possui uma grande dependência da usina hidrelétrica como fonte principal de sua geração de energia. No entanto, essa dependência vem se agravando com o passar dos anos, pois intervalos mais longos de altas temperaturas ou secas estão ocorrendo com mais frequência e com isso o volume de chuva está diminuindo, os reservatórios estão atingindo valores cada vez menores e conseqüentemente as hidrelétricas não estão conseguindo gerar de forma constante 100% da sua capacidade, deixando de atender às necessidades energéticas do país. Devido a este contexto, a busca por fontes de energia que complementem a geração hidrelétrica brasileira vem se intensificando. E uma das formas que o governo tem para suprir tal demanda é através do despacho das Usinas Termelétricas (UTE) (13). De acordo com o último relatório divulgado pelo site da ANEEL (Agência Nacional de Energia Elétrica) em Junho de 2023, este despacho das UTEs representam uma porcentagem de aproximadamente 24% da capacidade instalada total de geração de energia elétrica no Brasil (12). Dessa forma as UTEs têm um papel importante na matriz energética brasileira, pois são a segunda fonte de geração de energia elétrica mais utilizada no Brasil. Além disso, as UTEs têm a vantagem de serem capazes de operar de forma contínua e previsível, independentemente das condições climáticas. Isso as torna uma opção estratégica para garantir a estabilidade do suprimento de energia elétrica. No entanto, como essa geração de energia elétrica ocorre de forma constante no interior dos MCI, através da queima de combustível, durante todo o período de operação da usina, estes motores estão constantemente sujeitos a estresses (14), por causa de diferentes fatores, como por exemplo, número de partidas, carga média, variação de carga, pressões elevadas e temperatura ambiente (15, 16). Conseqüentemente, isso pode ocasionar uma série de problemas e impactos negativos nos MCI como desgaste acelerado dos seus componentes (pistões, anéis, válvulas e bronzinas), aquecimento demasiado, falhas mecânicas, vibração excessiva, consumo exagerado de combustível, diminuição da eficiência energética (17, 18), entre outros impactos. De acordo com esse contexto, sabe-se que esses motores podem não trabalhar em seu melhor desempenho e rendimento e, conseqüentemente, é essencial o monitoramento contínuo destes motores para garantir seu desempenho, confiabilidade e segurança. O monitoramento contínuo permite ainda detectar quaisquer problemas ou anomalias no funcionamento destes motores, possibili-

tando ações corretivas oportunas. Algumas práticas comuns de monitoramento constante incluem: monitoramento de parâmetros operacionais, análise de gases de escape, análise de lubrificante, monitoramento da temperatura, inspeção visual, sistemas de monitoramento eletrônico, entre outras práticas. Portanto, o monitoramento contínuo dos MCI ajuda a identificar problemas precocemente, permitindo a implementação de medidas de manutenção preventiva, reparos ou substituições de peças antes que ocorram falhas catastróficas. Isso contribui para o bom desempenho, prolongamento da vida útil do motor e redução de custos operacionais. Sendo assim, ainda no capítulo 1 será apresentado o estado da arte sobre monitoramento de ativos, porém, antes, são sumarizados dois dos principais conceitos relacionados ao tema UTE, objetivando facilitar o entendimento do leitor do que em seguida é apresentado.

## 1.2 Usina Termelétrica

A usina termelétrica, nomeada UTE, ou também chamada de termoelétrica, é uma instalação industrial que tem como objetivo gerar energia elétrica por meio da queima de vários tipos de combustíveis (19), como carvão mineral, gás natural, madeira, bagaço de plantas, óleo combustível, óleo diesel e outros produtos (20).

A estrutura geral de uma UTE é constituída de casas de máquinas, tanques, subestação elétrica, unidades motogeradoras, chaminés de exaustão, radiadores, sala de tratamento de óleo e sala de controle. Para melhor visualizar estas partes que compõem a instalação estrutural de uma UTE, a Figura 1 representa uma típica UTE.

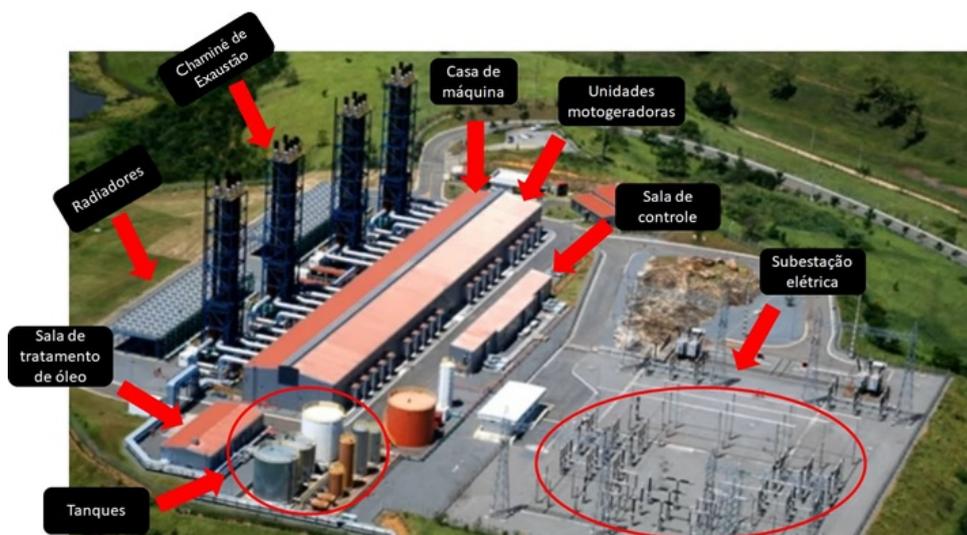


Figura 1 – Estrutura geral de uma típica UTE (1).

A construção de uma UTE não começa necessariamente com a casa de máquinas, mas essa é uma parte crucial do processo. A casa de máquinas é feita com uma estrutura metálica, resultando em um galpão, onde os principais equipamentos da usina são ins-

talados, incluindo as turbinas, geradores, caldeiras, condensadores e outros componentes essenciais para a geração de energia, conforme Figura 2.



Figura 2 – Exemplo de uma casa de máquina (2).

Nas paredes das casas de máquinas das usinas termelétricas, geralmente estão localizadas as aberturas de admissão e exaustão de ar. Essas aberturas são essenciais para a operação eficiente dos motores, turbinas e outros equipamentos de geração de energia que podem estar presentes na casa de máquinas.

As tomadas de ar de admissão, permitem que o ar fresco seja introduzido na casa de máquinas para o processo de combustão ou resfriamento. Dependendo do tipo de usina termelétrica e dos equipamentos envolvidos, essas aberturas de admissão podem ser projetadas para direcionar o ar para caldeiras, fornalhas ou outros sistemas de geração de calor. A Figura 3 ilustra um exemplo das entradas de ar para refrigerar o ambiente da casa de máquinas.



Figura 3 – Exemplo das entradas de ar para refrigerar o ambiente da casa de máquinas (3).

Os tubos de escape dos motores, permitem a saída de gases de exaustão ou ar quente gerado durante o processo de geração de energia. Isso é fundamental para manter as temperaturas dentro da casa de máquinas sob controle e evitar o superaquecimento dos equipamentos, conforme mostra a Figura 4.



Figura 4 – Exemplo de tubos de escape (4).

Vale ressaltar que a localização e o tamanho dessas aberturas de admissão e exaustão são cuidadosamente projetados para atender às necessidades específicas da usina termelétrica, garantindo um suprimento adequado de ar fresco e a remoção eficiente de gases de exaustão. Além disso, sistemas de filtragem e controle de qualidade do ar podem ser implementados para garantir que o ar de admissão seja limpo e adequado para a operação dos equipamentos.

No interior da casa de máquinas de uma usina termelétrica estão dispostos os motogeradores. Essa disposição pode variar de acordo com o projeto específico e as necessidades de geração de energia. A configuração mais comum é dispor os motogeradores em paralelo, o que significa que eles operam em conjunto para gerar eletricidade, conforme ilustra a Figura 5.



Figura 5 – Exemplo de disposição dos motogeradores dentro da casa de máquina (5).

Nesse tipo de configuração, vários motogeradores são conectados a uma rede elétrica comum e são sincronizados para operar em fase. Isso permite que eles compartilhem a carga de forma equilibrada e forneçam energia de maneira eficiente e confiável. Se um dos motogeradores falhar ou precisar ser desligado para manutenção, os outros podem continuar a fornecer energia para a rede.

Seguindo a construção de uma UTE, são colocados os radiadores, cuja disposição pode ser localizada em regiões diferentes dependendo do *design* da UTE, podendo até serem colocados sobre a casa de máquinas (no telhado) da usina, conforme Figura 6, o que cria uma UTE bem compacta. Sua função é dissipar o calor gerado pelos motores, turbinas ou outros componentes que estão operando na usina termelétrica. O resfriamento é essencial para evitar o superaquecimento dos equipamentos, garantindo que eles funcionem dentro das faixas de temperatura seguras e eficientes, independentemente de a usina utilizar carvão, gás natural ou outra fonte de energia fóssil.



Figura 6 – Exemplo de disposição dos radiadores (6).

Em UTEs, são construídos diversos tipos de tanques para diferentes finalidades, dependendo do processo e das necessidades específicas da usina. Os dois tipos de tanques mais comuns encontrados nas UTEs são os tanques de armazenamento de combustível (tanques cinzas) e os tanques de água para combate a incêndio (tanques vermelhos), conforme mostra a Figura 7. Os tanques de armazenamento de combustível são usados para armazenar combustíveis, como diesel, gás natural ou óleo pesado (HFO). Esses tanques armazenam o combustível necessário para alimentar os motores ou turbinas utilizados na geração de eletricidade. A capacidade desses tanques pode variar amplamente dependendo do tamanho e do tipo da usina. Como mencionado anteriormente, as UTEs também mantêm tanques de água vermelhos para uso em sistemas de combate a incêndio. Essa água é essencial para proteger a instalação contra incêndios e garantir a segurança dos trabalhadores e dos ativos da usina.



Figura 7 – Exemplo de tanques (7).

Após a construção dos tanques, são construídas as torres de escape, onde ficam os escapamentos e silenciadores e por onde são liberado os gases de exaustão gerados durante o processo de geração de energia, conforme Figura 8. Essas estruturas são projetadas para direcionar os gases para cima e para longe da área da usina. A altura das chaminés pode variar para garantir uma dispersão adequada dos poluentes atmosféricos. Para reduzir o ruído gerado pelos gases de exaustão em sistemas de escape, os silenciadores ou dispositivos de controle de ruído estão instalados na saída das chaminés. Isso ajuda a minimizar o impacto sonoro da usina termelétrica nas áreas circundantes.



Figura 8 – Exemplo de torres de escape (8).

A construção da sala de tratamento de óleo em uma usina termelétrica é fundamental para garantir a qualidade e a eficácia dos sistemas de óleo que desempenham um papel crítico na operação da usina. O tratamento de óleo envolve várias etapas, incluindo

filtragem e remoção de água, que são realizadas na sala de tratamento de óleo para manter os sistemas de óleo em boas condições, conforme ilustrado na Figura 9.



Figura 9 – Exemplo de sala de tratamento de óleo (9).

E por fim, a sala de controle é construída para conter todos os equipamentos e instalações necessários para a operação e monitoramento das partes essenciais da planta. É o centro de comando da usina termelétrica, onde os operadores têm acesso a todos os dados e sistemas necessários para controlar e supervisionar todas as operações críticas da usina. A partir da sala de controle, os operadores podem monitorar o desempenho dos equipamentos, tomar decisões em tempo real, ajustar parâmetros operacionais e garantir que a usina esteja operando eficientemente e com segurança.

Os principais componentes encontrados na sala de controle incluem painéis de controle, monitores de computador, sistemas de controle e automação, sistemas de comunicação, sistemas de registro de dados, sistemas de alarme, sistemas de segurança e acesso restrito, e muito mais. Todos esses elementos trabalham em conjunto para permitir que os operadores gerenciem e controlem a usina termelétrica de maneira eficaz e confiável.

Essa concentração de equipamentos e tecnologia na sala de controle é essencial para garantir que a usina funcione de acordo com os padrões operacionais e de segurança, bem como para responder rapidamente a qualquer situação de emergência ou problema que possa surgir durante a operação da usina. A sala de controle desempenha um papel crítico na geração de energia elétrica a partir de fontes térmicas, como carvão, gás natural ou óleo, e na manutenção do fornecimento de eletricidade de forma eficiente e confiável, conforme mostra a Figura 10.



Figura 10 – Exemplo de sala de controle (10).

### 1.2.1 Motor de Combustão Interna (MCI)

A unidade motogeradora (UG) é basicamente um MCI acoplado a um gerador pelo mesmo eixo. Para melhor compreensão desta composição, a Figura 11 mostra um modelo de UG convencional.

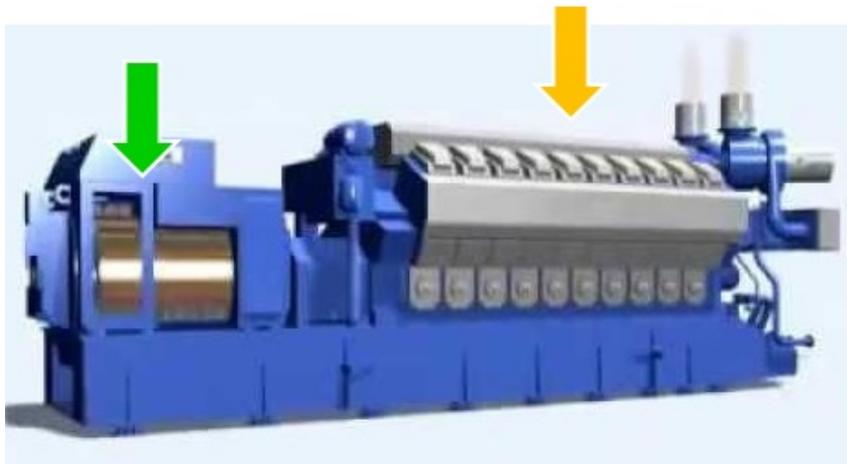


Figura 11 – Modelo de UG convencional (11)

Na Figura 11, a seta amarela indica a localização do MCI e a seta verde indica a localização do gerador. O MCI é uma máquina que tem como objetivo transformar a energia térmica, produzida pela queima de combustível, em energia mecânica. Neste tipo de motor, como o próprio nome sugere, a queima do combustível é feita no interior do mesmo (19).

Os principais tipos de MCI são os de pistão e os de êmbolo rotativo. O MCI de pistão é dividido em ciclo Otto (Gasolina) e ciclo Diesel (Óleo diesel). No ciclo Diesel, o funcionamento do motor é dividido em 4 ou 2 fases, também chamado de 4 tempos ou

2 tempos (19). Já o MCI de êmbolo rotativo é o Wankel (21). Neste trabalho, a ênfase é dada ao MCI de pistão que funciona em 4 tempos, pois o modelo de motor Wäertsilä 18V46 de 18 cilindros em configuração V de ignição por compressão, aqui empregado, segue este tipo de motor.

Os 4 tempos do funcionamento do MCI a pistão são admissão, compressão, combustão e escape. No primeiro tempo, denominado admissão, ocorre a entrada do ar através da válvula de admissão para dentro do cilindro, porém antes disso o ar admitido passa pela turbina que vai fazer a compressão deste ar. Em seguida passa por filtros e então é injetado para dentro do cilindro para fazer a combustão. Já no segundo tempo, denominado compressão, como o próprio nome sugere, ocorre a compressão do ar admitido no primeiro tempo por meio da subida do pistão. No final da compressão, o bico injetor injeta combustível na câmara de combustão, na qual se junta com o ar aquecido pela compressão. Vale ressaltar que, como o pistão subiu, nesta etapa, as válvulas de admissão e escape se fecham. Neste momento de funcionamento do motor ocorre o terceiro tempo, denominado combustão, ou seja, a mistura ar quente mais combustível se inflama gerando a combustão. Vale enfatizar também que como houve a queima de combustível, há a expansão dos gases, impulsionando o pistão a descer. No quarto e último tempo, denominado escape, o pistão sobe novamente e ocorre a liberação dos gases através da válvula de escape (19). Como este processo é cíclico, nesta etapa o processo começa novamente.

### 1.3 Estado da arte do monitoramento

Adquirir o conhecimento aprofundado do ambiente da usina termelétrica que está em operação, no que diz respeito aos níveis de estresse e desgaste a que as unidades motogeradoras se encontram, é uma prerrogativa importante para se obter informações sobre o monitoramento destes ativos - também, para melhor realizar o controle da manutenção, o que pode reduzir custos e postergar investimentos com itens de reposição. Diversas abordagens sobre implementação de sistemas de supervisão e controle com base nos recursos do ambiente onde estão inseridos e sobre tipos de manutenção já foram propostos na literatura científica. Por exemplo, em Bonaldi *et al.* (22), um sistema híbrido foi desenvolvido com a finalidade de prever falhas no sistema de arrefecimento (inversor, motor e carga) de UTE. Para o desenvolvimento do sistema em questão, foram utilizadas técnicas avançadas de processamento estatístico de sinais, como análise da assinatura elétrica, vibração e temperatura. Empregando as técnicas de sinais elétricos e vibracionais de forma conjunta, os diagnósticos de falhas no sistema de arrefecimento tornaram-se mais robustos e preditivos. Outro resultado importante deste trabalho é que o sistema desenvolvido pode ser empregado em qualquer unidade geradora e seus sistemas auxiliares, assim como na indústria em geral. Em Pellicel *et al.* (23), foi desenvolvido e instalado um sistema capaz de supervisionar e diagnosticar falhas precoces nas unidades turbogeradoras da usina ter-

melétrica, da cidade de Porto Velho, denominada TermoNorte, a partir das técnicas de sistemas inteligentes e estruturas de mineração de dados. Visando a melhora do desempenho do sistema originalmente proposto em (23), em (24) Pellicel *et al.* apresentam o progresso do sistema original com a instalação deste sistema em outras 4 máquinas e ainda incluem alguns resultados práticos obtidos pela utilização do sistema. A partir destas apresentações foram constatados que os processos estão adequados e que os desempenhos dos resultados observados são bem representativos. Em Fast *et al.* (25), foi apresentado um estudo com o objetivo de criar um sistema *online* para monitoramento e diagnóstico das condições operacionais das máquinas que compõem uma usina geradora na Suécia. Tal sistema foi fundamentado em modelo de rede neural que representa a interconexão de cada componente principal da usina a uma interface gráfica de usuário. Sendo assim, o modelo de rede neural foi incorporado em um servidor dirigente das informações da usina em questão, e a interface gráfica do usuário ficou disponível nos ambientes de trabalho que tinham conexão com este servidor. A rede neural implementada neste trabalho foi treinada com dados operacionais da usina, gerando resultados precisos de diagnósticos de falhas. Em Marcos (26), uma metodologia foi proposta com o objetivo de criar um sistema de monitoramento inteligente da condição de máquina da usina hidrelétrica de Balbina a partir de regras de produção usando funções de pertinência *fuzzy*. Tal metodologia foi integrada ao sistema inteligente de manutenção preditiva de Balbina (SIMPREBAL) já existente, usando os dados históricos desta própria usina hidrelétrica. O resultado desta integração foi uma maior confiabilidade nos registros de eventos de alertas, alarmes e *trips* do sistema SIMPREBAL, ou seja, em outras palavras, esta integração permitiu aos operadores uma maior confiabilidade de monitoramento da condição das máquinas que compõem esta usina. Em Audas (27), um esquema de banco de dados foi proposto a fim de resolver questões relacionadas com a grande carga de trabalho manual para reunir os dados da UTE baseados em planilha e também a dificuldade de realizar manutenção e rastreamento destes dados, pois estão espalhados em planilhas diferentes. Como resultado deste trabalho foi verificado que o banco de dados ajudou nas questões relacionadas aos dados distribuídos em planilha, porém este banco de dados ainda precisa ser incorporado com mais funções para se tornar mais robusto para a aplicação. Em Ribeiro *et al.* (28), um sistema de monitoramento em tempo real através de sensores foi apresentado com o objetivo de identificar falhas precoces na geração de energia das UTEs. O resultado deste trabalho foi que a geração de energia tornou-se mais confiável e segura, uma vez que os parâmetros para detecção de falhas nas condições operacionais das máquinas foram coletados em tempo real de forma mais ágil e eficiente por meio dos sensores. Em Samtani *et al.* (29), foi apresentado um estudo com o objetivo de avaliar e identificar as vulnerabilidades dos sistemas de supervisão e aquisição de dados habilitados para internet (SCADA), utilizando técnicas passivas e ativas de avaliação destas vulnerabilidades. Com os resultados das análises deste estudo, foi possível identificar a existência de muitos

sistemas SCADA vulneráveis a ataques cibernéticos. Em Mayadevi *et al.* (30), uma nova técnica foi proposta, capaz de prever falhas em uma usina que utiliza o SCADA como sistema supervisorio. No presente contexto sobre sistema supervisorio, ênfase especial é dada ao Sistema de Interface do Operador Wärtsilä (WOIS), discutido em profundidade em Tuomas e Wärtsilä (31, 32), pois este sistema supervisorio é o usado na UTE em pauta neste trabalho.

No sistema supervisorio WOIS, os operadores podem controlar e monitorar os geradores e sistemas relacionados através dos recursos do ambiente em que estão inseridos. Este controle é feito por meio de uma interface composta de janelas. Essas janelas são classificadas em três categorias: principal, processo e objeto. Na janela principal, o operador tem uma visão geral do conjunto de geradores e seus estados, além de acessar listas de alarmes, gráficos e relatórios. Na janela do processo, os operadores têm acesso as medições e símbolos gráficos que descrevem informações mais detalhadas sobre o próprio processo. Por fim, na janela de objetos, o operador tem acesso às informações detalhadas sobre medidas analógicas (31). Como resultado, os operadores podem acessar todos os dados importantes da planta por meio da interface gráfica do sistema supervisorio WOIS.

Ainda relacionado ao escopo deste trabalho, encontram-se as diferentes abordagens de manutenção, sendo elas manutenção corretiva, preventiva e preditiva. Uma revisão delas é apresentada em Bonaldi *et al.* (33). Ênfase especial é dada à manutenção preditiva, pois permite o monitoramento do comportamento operacional das unidades geradoras e tem a capacidade de prever uma possível falha antes do desligamento da unidade (33), assegurando assim, que ações adequadas possam ser executadas, evitando quebras e as consequentes perdas (34, 35). Ainda no contexto de manutenção, outra ênfase especial é dada à Manutenção Baseada em Condições (CBM, do inglês Condition-Based Maintenance). Este tipo de manutenção é baseado no monitoramento contínuo de certos parâmetros e na avaliação da condição que esses parâmetros se encontram, verificando portanto, se estão indicando sinais de redução de desempenho (36). Sabendo disso, insere-se neste contexto, o conceito de modelo estatístico baseado em Controle Estatístico de Processo (CEP) (37), pois neste trabalho, este conceito é considerado uma opção importante para monitorar a condição operativa dos motores de combustão interna da UTE e indicar tendências de falhas de médio e longo prazo, com base nas medidas coletadas dos ativos via sensores.

## 1.4 Motivação e Objetivo central

As UTEs desempenham um papel crucial na geração de energia elétrica brasileira, utilizando MCI para transformar a energia térmica, proveniente da queima do combustível, em energia mecânica, que aplicada ao gerador produz energia elétrica. No entanto, devido a essa geração de energia elétrica ser realizada de forma contínua e esses MCI estarem

constantemente sujeitos a estresses, é fundamental realizar o monitoramento constante desses motores para garantir que eles operem de maneira eficiente e confiável. Diante disso, existem na literatura diversos tipos de métodos que realizam o monitoramento dos ativos de forma preditiva, como por exemplo análise de assinatura elétrica, vibração e temperatura (22), e de forma inteligente, como mineração de dados (23), rede neural (25), funções de pertinência *fuzzy* (26), entre outros métodos. No entanto, esses métodos não incorporam uma avaliação estatística das condições operacionais da máquina. Com base nesses conhecimentos, este trabalho apresenta uma abordagem inovadora para a análise precoce de falhas no motor de combustão interna, baseada no Controle Estatístico de Processos e as Regras de Nelson. Com o objetivo de tornar essas análises mais aplicáveis na prática, foram utilizados os dados operacionais reais do motor de combustão interna modelo 18V46, fabricado pela Wärtsilä, no ano de 2019. Esses dados correspondem ao motor em operação em uma usina termelétrica. O método de análise foi validado por meio de dois estudos de caso. No primeiro estudo, foi realizada uma comparação entre a gravidade da condição operacional da unidade geradora 5 e um evento que resultou na parada dessa mesma unidade em 01/ago/2019. No segundo estudo, foram feitas anotações estatísticas sobre a gravidade da unidade geradora 5 ao retornar da manutenção após essa parada. Certifica-se que a metodologia proposta neste trabalho está alinhada com as etapas de tratamento de dados, abrangendo a degradação de subsistemas específicos da unidade motogeradora 5 até a ocorrência de sua parada em Agosto de 2019. Portanto, essa proposta se mostra uma ferramenta promissora, pois as análises dos meses anteriores aos eventos poderiam ter sido evitadas se a metodologia proposta estivesse sendo aplicada. Além disso, essa proposta permite ainda tanto o auxílio na tomada de decisões preditivas sobre manutenções na planta, como o auxílio aos operadores das máquinas para avaliar a condição das mesmas após retornarem de manutenção.

## 1.5 Estrutura e contribuições do trabalho

Para cumprir com os propósitos deste trabalho, o restante do mesmo está organizado da seguinte forma:

No Capítulo 2, inicialmente, são apresentados os conceitos de estatística e dos principais assuntos envolvidos nela como a média, o desvio padrão, o Z-score e o diagrama de controle. Em seguida são apresentados os conceitos fundamentais sobre teste de normalidade. Por fim, é feita uma descrição aprofundada sobre Regras de Nelson.

No Capítulo 3, inicialmente, descreve-se a divisão da unidade geradora em subsistemas, seguido pela apresentação das variáveis selecionadas para cada um deles. Posteriormente, são apresentados os dados históricos fornecidos pela UTE, seguidos pela descrição da aplicação do teste de normalidade aos dados. Em seguida, é detalhado o processo de

normalização dos dados, seguido dos cálculos estatísticos para as variáveis. Após essa etapa, é descrita a montagem do diagrama de controle para as variáveis. Também são apresentadas as Regras de Nelson aplicadas em motor de combustão interna. E por fim, apresenta-se a análise das Regras de Nelson aplicada em motor de combustão interna no tempo.

O Capítulo 4 traz a descrição do tratamento dos dados. Em seguida, apresenta o desempenho e validação do modelo estatístico por meio dos gráficos de barras. E por fim, apresenta o desempenho e validação do modelo estatístico após o retorno da UG 5.

Finalmente, o Capítulo 5 apresenta as principais conclusões do trabalho e algumas oportunidades para futuras pesquisas.

## 2 Fundamentos Teóricos

Neste capítulo são apresentados os fundamentos teóricos, objetivando facilitar o entendimento dos capítulos seguintes. Inicia-se com uma breve revisão sobre o conceito de estatística e em seguida descreve os principais assuntos envolvidos nela como a média, o desvio padrão, o Z-score e o diagrama de controle. Em seguida são apresentados os conceitos teóricos fundamentais sobre teste de normalidade. E por fim, é feita uma descrição aprofundada sobre Regras de Nelson.

### 2.1 Estatística

A estatística é um ramo da matemática utilizada para coletar, interpretar, analisar e apresentar os resultados dos dados numéricos. Sendo assim, a estatística é dividida em dois tipos: descritiva e analítica (ou inferência). Na estatística descritiva a função principal é apresentar os dados. Esta apresentação é dada através de gráficos, tabelas e medidas. Porém, neste tipo de estatística não há a preocupação de onde vêm os dados, ou seja, não se preocupa com a população que proveu estes dados. Na estatística analítica ou também chamada de inferência estatística este problema é solucionado, uma vez que é neste tipo de estatística que tem-se a função de inferir sobre a população a partir de dados conhecidos (38). Sabendo-se disso, as análises deste trabalho serão feitas com base na estatística descritiva, mais precisamente, pelas medidas. Sendo assim, as seções seguintes definem estas medidas de forma mais detalhada.

#### 2.1.1 Média

Média é uma das medidas de tendência central ou posição. Em outras palavras, a média é uma medida ou até mesmo um valor típico que indica a posição onde os dados estão se concentrando (39).

Há vários tipos de medidas de centralidade, porém as mais importantes são média aritmética, mediana e moda (39). Para este trabalho destaque especial é dado as médias aritméticas, conforme abordado na subseção seguinte.

##### 2.1.1.1 Média Aritmética

A média aritmética é a medida de centralidade mais conhecida e mais utilizada, uma vez que o seu cálculo é simples e sua interpretação é intuitiva. Sendo assim, o cálculo desta média pode ser feito de duas formas: populacional e amostral (39).

Seja  $x = (x_1, x_2, \dots, x_N)$  os valores de uma dada população, ou seja, todos os elementos que formam um conjunto, o cálculo da média populacional, designado por  $\mu$ , é dado pela divisão da soma destes valores pelo total de elementos desta população. Assim, algebricamente, a média populacional é dado por (40)

$$\mu = \left( \frac{x_1 + x_2 + \dots + x_N}{N} \right), \quad (2.1)$$

onde  $N$  é o número total de elementos desta população.

Retirando um subconjunto da população utilizada no cálculo anterior, determina-se a média amostral, ou também chamada de média simples, ou de forma simplificada média, cuja representação é dada por  $\bar{X}$ . Analogamente ao cálculo da média populacional, o cálculo da média amostral é feito somando-se todas as  $n$ -ésimas observações de uma dada amostra, dado por  $X_1 + X_2 + \dots + X_n$ , e dividindo-se esta soma pelo número de observações. Assim, algebricamente, a média amostral é dado por (38)

$$\bar{X} = \left( \frac{X_1 + X_2 + \dots + X_n}{n} \right), \quad (2.2)$$

onde  $n$  é o número total de observações.

Ressalta-se que além das medidas de centralidade dos dados, para este trabalho, destaque especial também é dado para as medidas de variação porque permitem informar as variabilidades dos dados. Sendo assim, a próxima subseção discorre sobre as definições destas medidas.

## 2.1.2 Desvio Padrão

Desvio padrão é uma das medidas de variação, ou também chamada de medida de dispersão. Em outras palavras, o desvio padrão é uma medida que indica o quão dispersos os dados estão em relação a média (39).

Há vários tipos de medidas de dispersão, dentre os quais podem ser citados amplitude, variância e desvio padrão (39). Para este trabalho ênfase particular é dada ao desvio padrão. Sendo assim, analogamente ao cálculo da média, o cálculo deste desvio pode ser feito de duas formas, sendo populacional e amostral (39), conforme abordado na subseção seguinte.

### 2.1.2.1 Desvio padrão populacional e amostral

Para o cálculo do desvio padrão populacional, inicialmente, considera-se que  $x = (x_1, x_2, \dots, x_N)$  são os valores de uma dada população. Em seguida, calcula-se a média populacional destes valores, conforme a equação (2.1). De posse desta média, realiza-se a soma dos quadrados dos desvios (entre  $x - \mu$ ). Após isto divide-se esta soma pelo número

de observações e assim, obtêm-se a variância populacional, cuja designação é dada por  $\sigma^2$ . Por definição sabe-se que a raiz quadrada da variância populacional é igual ao desvio padrão populacional (39). Sendo assim, algebricamente, este desvio é dado por

$$\sigma = \sqrt{\sigma^2} = \sqrt{\frac{1}{N} \sum_{i=1}^N (x - \mu)^2} \quad (2.3)$$

Para o cálculo do desvio padrão amostral, inicialmente, colhe-se um subconjunto da população, denominado amostra, dado por  $X = X_1 + X_2 + \dots + X_n$ . Em seguida, calcula-se a média amostral das observações desta amostra, conforme a equação (2.2). De posse desta média, realiza-se a soma dos quadrados dos desvios (entre  $X - \bar{X}$ ). Após isto divide-se esta soma pelo número que representa o tamanho da amostra (representado por  $n$ ) menos 1 e assim, obtêm-se a variância amostral, cuja designação é dada por  $s^2$ . Por definição análoga a variância populacional, sabe-se que a raiz quadrada da variância amostral é igual ao desvio padrão amostral (39). Sendo assim, algebricamente, este desvio é dado por

$$s = \sqrt{s^2} = \sqrt{\frac{1}{n} \sum_{i=1}^n (X - \bar{X})^2} \quad (2.4)$$

É importante notar que as medidas estatísticas conforme definido nas equações (2.1) e (2.3) são capazes de monitorar a tendência central e a dispersão das amostras. Além disso, à partir delas, é possível monitorar e calcular a variação dessas amostras em relação a média. Portanto, a próxima seção discorre como é realizado este cálculo.

### 2.1.3 Z-score

Z-score é um valor que representa o quanto uma medida está longe da média. Em outras palavras, o Z-score oferece o número de desvios padrão que esta amostra está acima ou abaixo da média (41).

Seja  $\mu$  a média populacional, conforme definida em (2.1) e  $\sigma$  o desvio padrão populacional, conforme definido em (2.3), o cálculo do Z-score é dado pela diferença entre os valores da população ( $x$ ) e a sua média dividida pelo desvio padrão populacional. Sendo assim, algebricamente, o Z-score, representado por  $z$ , é dado por (39)

$$z = \frac{x - \mu}{\sigma} \quad (2.5)$$

Vale ressaltar que o cálculo de Z-score também pode ser feito para amostras. Para isso deve-se trocar os valores da população por observações de uma dada amostra, a média populacional pela média amostral, conforme definido em (2.2) e o desvio populacional pelo

desvio amostral, conforme definido em (2.4). Em seguida disso, para resolvê-lo aplica-se a mesma equação dada por (2.5).

O Z-score pode ser colocado em uma distribuição normal, ou seja, o valor de  $z$  irá padronizar os dados em relação a média e desvio padrão e indicar o local que a medida se encontra nesta distribuição. Quanto menor o valor de  $z$ , mais perto estas medidas estão da média e quanto maior o valor de  $z$ , mais distante estas medidas estão da média (41).

### 2.1.4 Diagrama de Controle

O Diagrama de controle, ou carta de controle, são gráficos que tem como objetivo monitorar estatisticamente se o processo está sob controle, ou seja, verificar se o processo produtivo está dentro de limites plausíveis (42).

Para analisar estatisticamente um processo, o diagrama de controle delimita uma faixa nomeada limites de controle. Esta faixa é composta pelos limites superior e inferior de controle (representado por LSC e LIC, respectivamente) e também pela linha média (representada por LM). O cálculo destes limites é feito considerando de forma primordial uma distribuição normal com média  $\mu$  e desvio padrão  $\sigma$  (cujos cálculos foram detalhados nas subseções 2.1.1.1 e 2.1.2.1). Sendo assim, a  $LM = \mu$  e o  $LSC = \mu + 3\sigma$  e o  $LIC = \mu - 3\sigma$ , uma vez que o posicionamento da distribuição normal é centralizado em sua média, definindo LM, enquanto que o desvio padrão ( $\sigma$ ) determina os limites LSC e LIC respectivamente (43). Vale ressaltar que o valor de  $3\sigma$  acima ou abaixo da média foi definido segundo Shewhart (44). Objetivando o melhor entendimento destes limites a Figura 12 representa um modelo convencional do diagrama de controle.

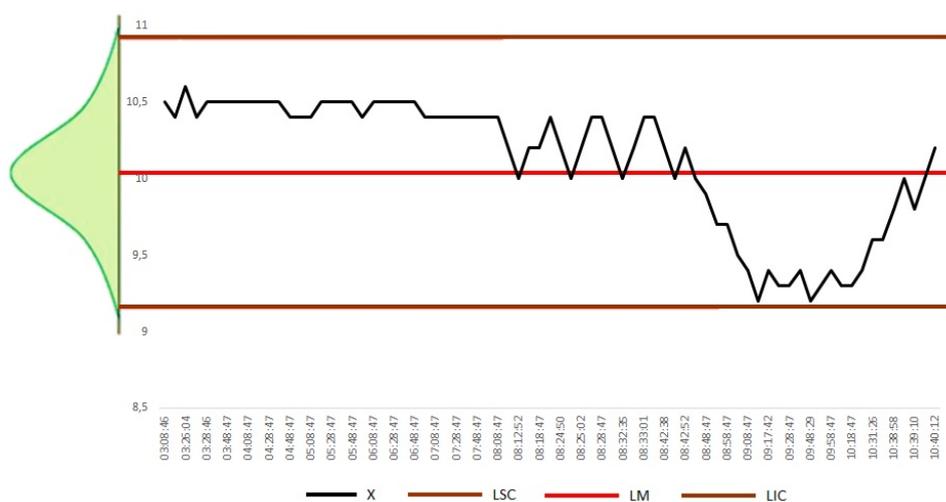


Figura 12 – Modelo convencional de Diagrama de Controle.

No diagrama da Figura 12, a curva preta (denominada X) caracteriza o comportamento de uma variável monitorada em um determinado processo. A linha vermelha (denominada LM) caracteriza a linha média, ou seja, caracteriza a média dos valores da

variável  $X$ . As linhas marrons representam os limites estatísticos superior e inferior (LSC e LIC, respectivamente) em que se espera que a variável oscile em casos extremos, ainda sob normalidade.

Para realizar os cálculos dos limites de controle, superior e inferior, conforme já mencionado anteriormente, foi considerado uma distância de 3 desvios padrão ( $3\sigma$ ) da média ( $\mu$ ) (44), com base nas probabilidades da distribuição normal. Sendo assim, o limite superior de controle (LSC) é dado por:

$$LSC = \mu + 3\sigma, \quad (2.6)$$

Já o limite inferior de controle (LIC) é dado por:

$$LIC = \mu - 3\sigma. \quad (2.7)$$

Logo, calculando a variação entre os dois limites de controle, é possível demonstrar que a região interna destes limites possuem distância de 6 desvios padrão ( $6\sigma$ ), dado por

$$\begin{aligned} Regi\tilde{a}o_{Interna} &= LSC - LIC, \\ &= \overbrace{(\mu + 3\sigma)} - \overbrace{(\mu - 3\sigma)}, \\ &= (\mu + 3\sigma - \mu + 3\sigma), \\ &= 6\sigma. \end{aligned} \quad (2.8)$$

Com base na distribuição normal considerada para os cálculos anteriores e no posicionamento da mesma para a construção do diagrama de controle da Figura 12, é esperado que, a dispersão dos valores da variável de controle esteja aproximadamente 50% de cada lado da linha média (LM) (45), conforme ilustrado na Figura 13.

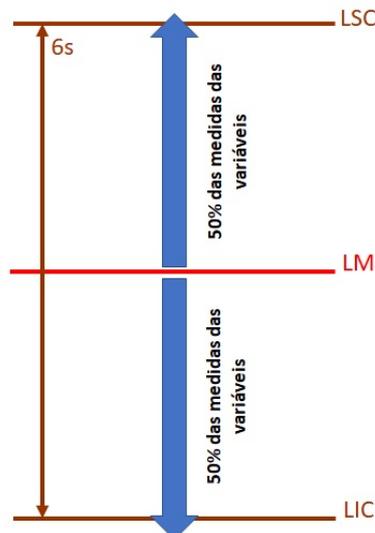


Figura 13 – Dispersão dos pontos relativos à Linha Média (LM).

Visando melhorar a identificação das várias regiões de análise dentro da faixa interna dos limites de controle da Figura 12, foram definidas algumas zonas de controle. Em cada uma dessas zonas, os valores das variáveis possuem uma probabilidade de ocorrência específica (45).

A primeira zona de controle definida foi a chamada Zona C. Esta zona está localizada dos dois lados da média (LM), e a uma distância de 1 desvio padrão ( $1\sigma$ ), ou seja, algebricamente a Zona C superior (representada por  $C_s$ ) é dada por (45)

$$C_s = \mu + 1\sigma, \quad (2.9)$$

E a Zona C inferior (representada por  $C_i$ ) é dada por (45)

$$C_i = \mu - 1\sigma. \quad (2.10)$$

Para melhor compreensão destas definições, a Figura 14 apresenta um exemplo didático que ilustra a localização da faixa da Zona C em um diagrama de controle da variável em análise.

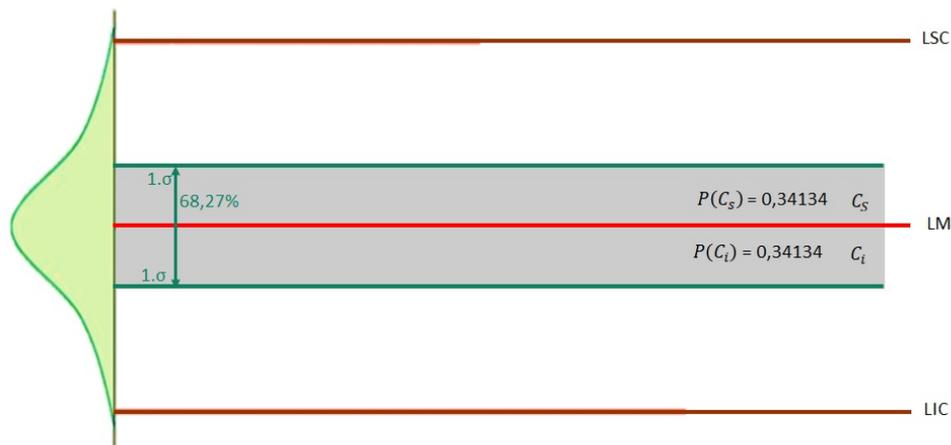


Figura 14 – Zona C do diagrama de controle.

Na Figura 14, a faixa limitada em cinza (Zona C superior e inferior) mostra a região de maior probabilidade de ocorrência dos valores da variável em análise, quando considerado a distribuição normal. Em outras palavras, a faixa cinza identifica que 68,27% (46) dos valores desta variável estarão a 1 desvio padrão da média. Consequentemente, a probabilidade de um valor da variável cair somente na Zona C superior (dada por  $C_s$ ) ou na Zona C inferior (dada por  $C_i$ ) é de 34,135% (45). Essa probabilidade é verificada ao calcular a divisão da probabilidade total da Zona C pelo algarismo 2 que representa as 2 regiões (superior e inferior). Algebricamente, estas probabilidades são dadas por

$$P(C_s) = P(C_i) = 0,6827/2 = 0,34135 \quad \text{ou} \quad 34,135\%. \quad (2.11)$$

A segunda zona de controle definida foi a chamada Zona B. Esta zona está localizada a uma distância entre 1 e 2 desvios padrão da média, porém na região superior e inferior da mesma. Assim sendo, algebricamente, a Zona B superior (representada por  $B_s$ ) é dada por (45)

$$\mu + 1\sigma < B_s < \mu + 2\sigma, \quad (2.12)$$

E a Zona B inferior (representada por  $B_i$ ) é dada por (45)

$$\mu - 2\sigma < B_i < \mu - 1\sigma. \quad (2.13)$$

Para melhor visualizar estas definições e as localizações dessas faixas, a Figura 15 ilustra didaticamente que a faixa da Zona B superior está localizada acima da Zona C superior e analogamente, a faixa da Zona B inferior está localizada abaixo da Zona C inferior.

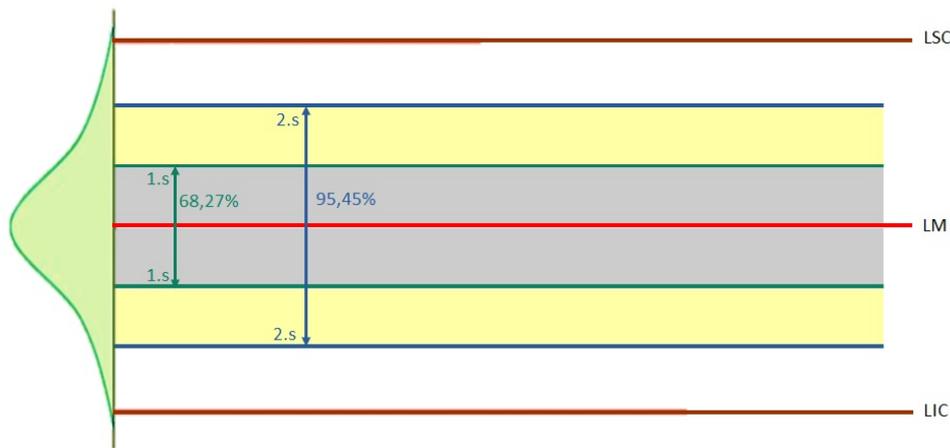


Figura 15 – Zona B do diagrama de controle.

Na Figura 15, a seta azul mostra que a probabilidade total de se encontrar um valor de qualquer variável em análise a até 2 desvios padrão de distância da média, em uma distribuição normal, é de 95,45% (46). Conseqüente, a faixa limitada em amarelo (Zona B superior e inferior) na Figura 15, identifica que a probabilidade de um desses valores caírem em uma destas faixas é de 13,591% (46). Essa probabilidade é verificada ao calcular a divisão da diferença entre a probabilidade total da Zona B e a probabilidade total da Zona C pelo algarismo 2 que representa as 2 regiões (superior e inferior). Algebricamente, estas probabilidades são dadas por:

$$\begin{aligned} P(B_s) = P(B_i) &= (0,9545 - 0,6827)/2 \\ &= 0,13591 \quad \text{ou} \quad 13,591\%. \end{aligned} \quad (2.14)$$

A Terceira e última zona de controle definida foi a chamada Zona A. Nesta zona os valores da variável de controle estão localizadas entre 2 e 3 desvios padrão de cada lado

da média. Sendo assim, algebricamente, a Zona A superior (representada por  $A_s$ ) é dada por (45)

$$\mu + 2\sigma < A_s < \mu + 3\sigma, \tag{2.15}$$

E a Zona A inferior (representada por  $A_i$ ) é dada por

$$\mu - 3\sigma < A_i < \mu - 2\sigma. \tag{2.16}$$

Para melhor compreender estas definições e as localizações dessas faixas, a Figura 16 mostra didaticamente que a faixa da Zona A superior está localizada acima da Zona B superior e analogamente, a faixa da Zona A inferior está localizada abaixo da Zona B inferior, conforme ilustrado na Figura 16.

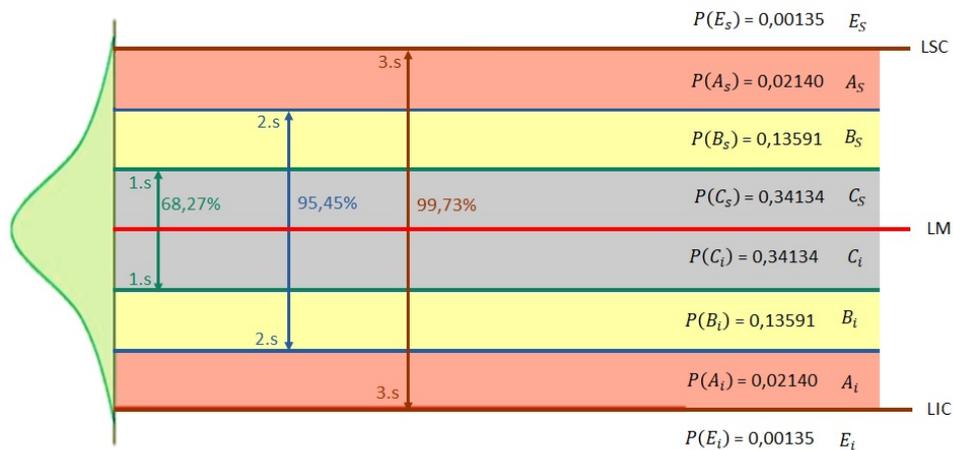


Figura 16 – Zona A do diagrama de controle.

Na Figura 16, a seta marrom mostra que a probabilidade total dos valores de uma variável estarem dentro dos limites de controle, em uma distribuição normal, é de 99,73% (46). Conseqüente, as faixas em vermelho mostram que a probabilidade de um valor da variável em análise cair na faixa superior ou inferior da Zona A é de 2,140% (46). Essa probabilidade é verificada ao calcular a divisão da diferença entre a probabilidade total entre os limites de controle e a probabilidade total da Zona B pelo algarismo 2 que representa as 2 regiões (superior e inferior). Algebricamente, estas probabilidades são dadas por:

$$\begin{aligned} P(A_s) = P(A_i) &= (0,9973 - 0,9545)/2 \\ &= 0,02140 \quad \text{ou} \quad 2,140\%. \end{aligned} \tag{2.17}$$

Além das zonas e das probabilidades descritas anteriormente, ainda existem as probabilidades de um ou mais valores da variável em análise caírem fora dos limites de controle. Essas probabilidades (representadas por  $E_s$  e  $E_i$ ) de ocorrência não são nula, mais precisamente, elas tem o valor de 0,135% (46) para cada um dos limites, conforme ilustrado

na Figura 16. Essas probabilidades são verificadas ao calcular a divisão da diferença entre a probabilidade total de ocorrer anormalidade em um valor da variável (que é 1 ou 100%) e a probabilidade total entre os limites de controle pelo algarismo 2 que representa as 2 regiões (superior e inferior). Algebricamente, estas probabilidades são dadas por:

$$\begin{aligned} P(E_s) = P(E_I) &= (1 - 0,9973)/2 \\ &= 0,00135 \quad \text{ou} \quad 0,135\%. \end{aligned} \quad (2.18)$$

Devido a estas probabilidades, por definição, quando um dos valores da variável for feito fora dos limites de controle, pode-se concluir que há algum tipo de anormalidade, mas esta anormalidade pode ser momentânea e não necessariamente causar defeito no processo (47). No entanto, ela pode contribuir para o nível de desgaste da máquina.

É importante notar que a aplicação do diagrama de controle conforme definido na Figura 12 é capaz de apresentar quando os pontos que compõem os valores da variável (representados pela linha preta) estão distribuídos de forma aleatória dentro da faixa dos limites de controle, ou seja, entre o LSC e LIC, concluindo que o processo em análise está "sob controle". Agora, caso um ou mais destes pontos estejam localizados fora da faixa de controle, ou seja, além do LSC ou além do LIC, pode-se concluir que o processo em questão está "fora de controle", desde que, a permanência deste ponto fora dos limites ultrapasse o produto do tempo que o processo em análise funcionou com a probabilidade do ponto cair fora dos limites.

Vale ressaltar que as variações no processo podem ser divididas em dois grupos, um causas normais e o outro causas especiais (48). As causas normais são aquelas que não podem ser evitadas, ou seja, ocorre de forma corriqueira, não altera os parâmetros estatísticos de processo (sendo média e desvio padrão) e conseqüentemente mantém uma distribuição normal. Já as causas especiais são aquelas que quando ocorrem são claramente identificáveis e devem ser corrigidas, pois elas alteram os parâmetros estatísticos do processo (48).

Existem na literatura dois tipos de carta de controle, cujos nomes são carta de controle para variáveis e carta de controle para atributos (47). A carta de controle para variáveis, cujo o próprio nome sugere, são aquelas criadas para controlar variável, ou seja, controlam processos que assumem diferentes valores contínuos (representado por medidas). Já a carta de controle para atributos, cujo o próprio nome também sugere, são aquelas criadas para controlar atributos, ou seja, controlam processos que assumem algum tipo de carácter qualitativo, por exemplo, conforme ou não-conforme, adequado ou não-adequado, entre outros (47). Neste trabalho, destaque especial é dada a carta de controle para variáveis, pois se enquadram nas análises em questão.

Como já citado anteriormente é fundamental que a distribuição das medidas de um sistema de supervisão em UTEs sigam uma distribuição normal para se realizar a

construção dos diagramas de controle. Existem na literatura vários métodos que verificam a normalidade dos dados, sendo assim, a próxima seção descreverá detalhadamente os fundamentos teóricos dos principais tipos destes métodos.

## 2.2 Testes de normalidade

A avaliação da normalidade dos dados pode ser realizada de duas formas, visual ou estatística (49), conforme abordado nas subseções seguintes.

### 2.2.1 Métodos visuais

Os métodos visuais são métodos que mostram graficamente a forma que os dados são distribuídos. Porém, este tipo de avaliação de normalidade não garante se os dados realmente seguem uma distribuição normal uma vez que não testam o nível de significância entre a distribuição normal e a distribuição da amostra em questão (49).

Na literatura, existem vários métodos visuais que avaliam a normalidade dos dados, no entanto, os principais são histograma e gráfico de quantil-quantil (Q-Q Plot) (49). Para melhor entendimento destes métodos, as próximas subseções abordarão mais detalhadamente cada um deles.

### 2.2.2 Histograma

Os histogramas são gráficos formados por barras, cuja disposição é dada no eixo x e y, e representam as formas que os dados estão distribuídos (50). A verificação de normalidade dos dados com este método é realizada através da verificação visual se as barras seguem uma forma de sino. Caso as barras do histograma tiverem a forma próxima do sino da distribuição normal, os dados tem indício de serem normais (50).

No eixo x destes gráficos, estão localizadas as classes na qual os dados foram divididos e representam a base da barra. No eixo y, estão localizadas as frequências na qual os dados apareceram em cada uma destas classes e representam as alturas das barras (49). Para melhor entendimento deste gráfico, a Figura 17 ilustra um típico histograma.

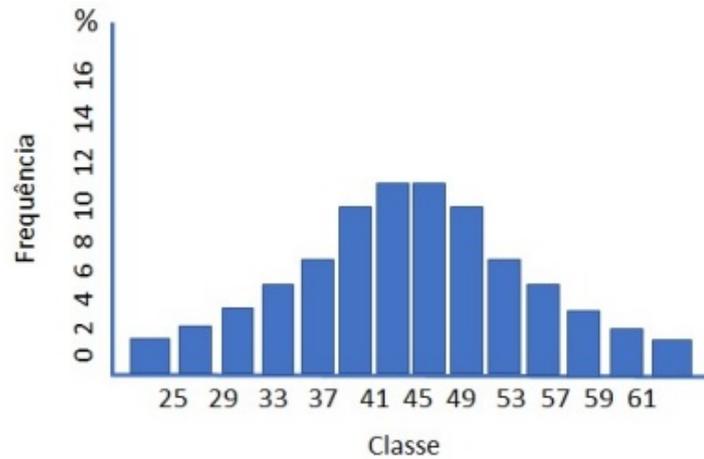


Figura 17 – Exemplo de um típico histograma (51).

Seja  $n$  a frequência total de ocorrência em cada classe e  $k$  o número total de intervalos de classe, algebricamente, o histograma (representado pela função  $m_i$ ) é dado por (52)

$$n = \sum_{i=1}^k m_i \tag{2.19}$$

### 2.2.3 Quantil-Quantil (Q-Q Plot)

Quantil-Quantil, ou também chamado Q-Q Plot, é um método gráfico que dispõe basicamente uma comparação entre os quantis teóricos de uma distribuição normal e os quantis dos dados em análise (49). Neste gráfico, o eixo x representa os quantis dos dados em análise, e o eixo y os quantis de uma distribuição normal (50). Para melhor compreensão do teste Q-Q Plot, a Figura 18 apresenta os típicos resultados de análise do gráfico Q-Q Plot.

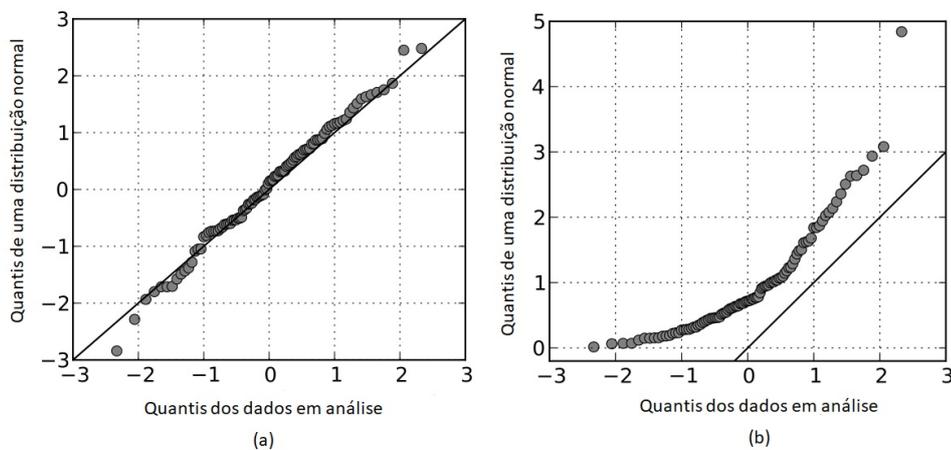


Figura 18 – Exemplo de resultados típicos de teste Q-Q Plot (53).

Na Figura 18, a análise de normalidade via Q-Q Plot é verificada quando os pontos, que representam os dados em análise, estão ou não concentrando em torno da reta de

referência apresentada pela linha diagonal no gráfico. No caso da letra (a) da Figura 18, os dados tem uma boa aderência à distribuição normal, pois os dados em questão estão próximos da reta de referência. Já no caso (b) da Figura 18, os dados não tem uma boa aderência à distribuição normal, pois os dados em questão não estão próximos da reta de referência, concluindo que os mesmos não seguem uma distribuição normal (49).

Seja  $z = (z_{(1)}, z_{(2)}, \dots, z_{(n)})$  os valores de uma amostra aleatória com distribuição normal de média ( $\mu$ ) zero e desvio padrão ( $\sigma$ ) 1, ou seja,  $\mathcal{N}(0, 1)$ , os quantis da amostra são as ordenações amostrais, dado por

$$z_{(1)} \leq z_{(2)} \leq \dots \leq z_{(n)}. \quad (2.20)$$

Dada uma função distribuição cumulativa da densidade normal (representada por  $\Phi$ ) e um  $q$ -ésimo quantil de uma distribuição normal (representado por  $\Phi(\xi_q)$ ), aplicando a noção de quantil, o cálculo dos quantis teóricos da distribuição normal é dado por (54)

$$\Phi(\xi_q) = q. \quad (2.21)$$

Adotando o primeiro valor das ordenações amostrais  $z_{(1)}$  e substituindo este valor na equação (2.21), obtêm-se a probabilidade de assumir um valor no intervalo  $(0, \frac{1}{n})$ . Algebricamente, têm-se (54)

$$\Phi(z_{(1)}) = \left(0, \frac{1}{n}\right), \quad (2.22)$$

em que  $n$  é o número total de amostras.

Analogamente, se adotar o segundo valor das ordenações amostrais  $z_{(2)}$  e substituindo este valor na equação (2.21), obtêm-se a probabilidade de assumir um valor no intervalo  $(\frac{1}{n}, \frac{2}{n})$ . Algebricamente, têm-se (54)

$$\Phi(z_{(2)}) = \left(\frac{1}{n}, \frac{2}{n}\right). \quad (2.23)$$

Analogamente, continuando as adoções dos valores de ordenações amostrais e realizando os cálculos da (2.21), obtêm-se  $\Phi(z_{(n)})$ , que é a probabilidade de assumir um valor no intervalo  $(\frac{n-1}{n}, 1)$ . Conseqüentemente, espera-se que o quantil teórico da distribuição seja definido como o inverso da função distribuição acumulada normal padrão. Especificamente, o quantil teórico corresponde ao quantil empírico  $z_{(i)}$ . Algebricamente, isso é dado por (54)

$$\xi_q = q \approx \frac{i - 0,5}{n}, \quad (2.24)$$

em que  $i = 1, 2, 3, \dots, n$  e  $n$  é a quantidade total de amostra.

A decisão a favor (hipótese  $H_0$ ) ou não (hipótese  $H_1$ ) da normalidade dos dados é tomada levando-se em consideração o valor quantil teórico  $\Phi_q$ . Neste caso, a regra de decisão a respeito da normalidade, é dada por

$$\begin{aligned}\xi_q &= z_{(n)}, & (H_0) \\ \xi_q &\neq z_{(n)}, & (H_1)\end{aligned}\tag{2.25}$$

Em palavras, deverá decidir pela hipótese  $H_0$  sempre que o quantil teórico da distribuição normal  $\xi_q$  for igual ao quantil da amostra  $z_{(n)}$ , concluindo que a amostra é próxima da reta de referência, conforme (a) da Figura 18, assumindo que a amostra segue uma distribuição normal, e deverá decidir pela rejeição de  $H_0$  caso contrário (50).

É importante notar que embora os métodos gráficos, conforme definidos anteriormente sejam capazes de monitorar a normalidade dos dados, eles não garantem essa normalidade e ainda dependem da interpretação visual da pessoa que está realizando a análise. Sendo assim, para amenizar o efeito de interpretação visual e aumentar a confiabilidade das decisões e a garantia sobre a normalidade dos dados, o mais indicado é fazer testes com aderência à distribuição normal (50), ou seja, fazer teste estatístico de normalidade, cuja descrição detalhada é feita na próxima subseção.

## 2.2.4 Testes Estatísticos

Os testes estatísticos são testes que avaliam a normalidade dos dados com base na aderência da distribuição normal (50). A realização destes testes é baseada na hipótese nula (representada por  $H_0$ ), ou seja, é aquela hipótese em que as variáveis aleatórias se aderem a uma distribuição normal. Sendo assim, nestes testes testa-se a possibilidade de uma amostra retirada de uma população ter uma distribuição normal. Caso isso seja verdadeiro, a hipótese  $H_0$  é mantida e conclui-se que os dados são normais. Caso contrário, a hipótese  $H_0$  é descartada e conclui-se que os dados são anormais (50).

Na literatura, existem vários testes estatístico de aderência que avaliam a normalidade dos dados, no entanto, os principais são Anderson-Darling (AD), Ryan-Joiner, Shapiro-Wilk (SW), Kolmogorov-Smirnov (KS), entre outros (49). Sendo assim, para melhor entendimento destes testes, as próximas subseções abordarão mais detalhadamente cada um deles.

## 2.2.5 Teste de normalidade Anderson-Darling (AD)

O teste de Anderson-Darling (AD) é um teste que avalia a normalidade dos dados de uma população através da comparação entre uma função de distribuição cumulativa (FDC) dos valores dos dados de uma população testada com a FDC da distribuição normal (55).

Seja  $N$  o tamanho da amostra retirada de uma dada população, o cálculo da estatística de teste de Anderson-Darling, designado por  $A^2$ , é dado por (55)

$$A^2 = -(N + S),\tag{2.26}$$

Como  $S$  é igual a (55)

$$S = \sum_{i=1}^n \frac{(2_i - 1)}{N} [\ln F(Y_i) + \ln 1 - F(Y_{N+1-i})], \quad (2.27)$$

em que  $F$  é FDC da distribuição normal padrão (representada por  $\Phi\left(\frac{Y_i - \bar{x}}{s}\right)$ , onde  $\bar{x}$  é média e  $s$  é o desvio padrão),  $Y_i$  são dados ordenados de forma ascendente,  $N$  como já foi mencionado é o tamanho da amostra e  $i$  é a  $i$ -ésima amostra dos dados ordenados de forma ascendente (55, 56).

Substituindo a equação (2.27) em (2.26) e tirando a raiz quadrada da diferença, finalmente, calcula-se a estatística de teste  $A$ .

Destaque especial aqui é dado às amostras com tamanho pequeno, pois quando isso ocorre, a equação (2.27) pode ser alterada. Resultando em (55)

$$A_m^2 = A^2 \left(1 + \frac{0,75}{N} + \frac{0,75}{N}\right), \quad (2.28)$$

A decisão a favor (hipótese  $H_0$ ) ou não (hipótese  $H_1$ ) da normalidade dos dados é tomada levando em consideração um valor crítico tabelado  $A_{crit}^2$  (obtido na tabela de (57)) (56). Neste caso, a regra de decisão a respeito da normalidade, a um nível de significância  $\alpha$ , é dada por

$$\begin{aligned} A &\leq A_{crit}^2, & (H_0) \\ A &> A_{crit}^2, & (H_1) \end{aligned} \quad (2.29)$$

Em palavras, deverá decidir pela hipótese  $H_0$  sempre que a estatística de teste  $A$  for menor ou igual ao limiar de decisão crítico  $A_{crit}^2$ , a um nível de significância  $\alpha$ , concluindo que a amostra aleatória segue uma distribuição normal, e deverá decidir pela rejeição de  $H_0$  caso contrário.

## 2.2.6 Teste de normalidade Ryan-Joiner

O teste de Ryan-Joiner é um teste que avalia a normalidade de uma amostra retirada de uma população através da correlação entre os valores da amostra testada com os escores dos valores da amostra normal (55).

Seja  $Y_i = (Y_1, Y_2, \dots, Y_n)$  os valores de observações ordenadas e  $b_i$  as contagens normais destes dados ordenados, o cálculo da estatística de teste de Ryan-Joiner, designado por  $R_p$ , é dado por (58)

$$R_p = \frac{\sum(Y_i - \bar{Y})b_i}{\sqrt{s^2(n-1) \sum b_i^2}}, \quad (2.30)$$

em que  $\bar{Y}$  é a média amostral da amostra  $Y_i$  e  $s^2$  é a variância da amostra.

Como  $Y_i$  já foi definida anteriormente, a média amostral  $\bar{Y}$  é calcula por

$$\bar{Y} = \left( \frac{Y_1 + Y_2 + \dots + Y_n}{n} \right), \quad (2.31)$$

em que  $n$  é o número total de observações ordenadas.

Após o cálculo da média, é realizado o cálculo da variância da amostra  $s^2$  de acordo com

$$s^2 = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (2.32)$$

Realizando também a contagem normal dos dados ordenados  $Y_i$  de acordo com

$$b_i = \sum_{i=1}^n Y_i \quad (2.33)$$

Substituindo as equações (2.31), (2.32) e (2.33) em (2.30) e fazendo a divisão, finalmente, calcula-se a estatística de teste  $R_p$ . A decisão a favor (hipótese  $H_0$ ) ou não (hipótese  $H_1$ ) da normalidade dos dados é tomada em relação a 1 (55). Neste caso, a regra de decisão a respeito da normalidade, a um nível de significância  $\alpha$ , é dada por

$$\begin{aligned} R_p &\geq 1, & (H_0) \\ R_p &< 1, & (H_1) \end{aligned} \quad (2.34)$$

Em palavras, deverá decidir pela hipótese  $H_0$  sempre que a estatística de teste  $R_p$  for maior ou igual 1, a um nível de significância  $\alpha$ , concluindo que amostra aleatória segue uma distribuição normal, e deverá decidir pela rejeição de  $H_0$  caso contrário.

### 2.2.7 Teste de normalidade Shapiro-Wilk (SW)

O teste de Shapiro-Wilk (SW) é um teste que avalia a normalidade de uma amostra retirada de uma população através da correlação entre os valores da amostra testada com os valores da amostra normal (59).

Seja  $y_i = (y_1, y_2, \dots, y_n)$  os valores de uma amostra aleatória de tamanho  $n$  retirados de uma dada população, o cálculo da estatística de teste de Shapiro-Wilk, designado por  $W$ , é dado por (60)

$$W = \left( \frac{b^2}{S^2} \right), \quad (2.35)$$

em que  $b$  é o coeficiente de Shapiro-Wilk que precisa ser determinado e  $S^2$  é o desvio quadrado ou também chamado variância da amostra aleatória  $y_i$ .

Como o tamanho da amostra é conhecido, o coeficiente  $b$  é determinado com base no número que esse tamanho assume, ou seja, se  $n$  é par ( $n = 2k$ ),  $b$  é dado por (59)

$$b = \sum_{i=1}^k a_{n-i+1}(y_{n-i+1} - y_i), \quad (2.36)$$

em que  $a_i$  é obtido na tabela de Shapiro-Wilk (61).

Agora, se  $n$  é ímpar ( $n = 2k + 1$ ), o cálculo de  $b$  é igual a equação (2.36), pois quando  $n = 2k + 1$  o valor de  $a_{k+1} = 0$ . Portanto,  $b$  dado por (59)

$$b = a_n(y_n - y_1) + \dots + a_{k+2}(y_{k+2} - y_k), \quad (2.37)$$

em que como  $y_{k+1}$  é o valor da mediana, ela não entra no cálculo (62).

Para realizar o cálculo de  $S^2$ , primeiramente, ordena-se a amostra  $y_i$ , como  $y_1 \leq y_2 \leq \dots \leq y_n$ . Em seguida, calcula-se a variância. Sendo assim, a variância desta amostra é dada por (59, 60)

$$S^2 = \sum_{i=1}^n (y_i - \bar{y})^2, \quad (2.38)$$

$$S^2 = \sum_{i=1}^n y_i^2 - \left( \frac{\overbrace{\sum_{i=1}^n y_i}^{\text{Média}}}{n} \right)^2$$

Substituindo as equações (2.36), (2.37) e (2.38) em (2.35) e fazendo a divisão, finalmente, calcula-se a estatística de teste  $W$ . A decisão a favor (hipótese  $H_0$ ) ou não (hipótese  $H_1$ ) da normalidade dos dados é tomada levando em consideração um valor tabelado  $W_{n,\alpha}$  (obtido na tabela de Shapiro-Wilk (61)) (59). Neste caso, a regra de decisão a respeito da normalidade, a um nível de significância  $\alpha$ , é dada por

$$\begin{aligned} W &\geq W_{n,\alpha}, & (H_0) \\ W &< W_{n,\alpha}, & (H_1) \end{aligned} \quad (2.39)$$

Em palavras, deverá decidir pela hipótese  $H_0$  sempre que a estatística de teste  $W$  for maior ou igual ao limiar de decisão  $W_{n,\alpha}$ , a um nível de significância  $\alpha$ , concluindo que amostra aleatória segue uma distribuição normal, e deverá decidir pela rejeição de  $H_0$  caso contrário.

## 2.2.8 Teste de normalidade Kolmogorov-Smirnov (KS)

O teste de Kolmogorov-Smirnov (KS) é um teste que avalia a normalidade dos dados amostrais através da comparação entre uma função de distribuição cumulativa (FDC) dos valores dos dados amostrais com a FDC da distribuição normal (63).

Seja  $x = (x_1, x_2, \dots, x_n)$  os valores de uma amostra aleatória retirados de uma dada população e  $y_k = (y_1, y_2, \dots, y_n)$  as estatísticas de ordem da amostra aleatória observada, o cálculo da estatística de teste de Kolmogorov-Smirnov, designado por  $D_n$ , é dado por (60, 63)

$$D_n = \sup_x [|F(x) - S(x)|], \quad (2.40)$$

em que  $F(x)$  é a função de distribuição acumulada e  $S(x)$  é alguma função de distribuição empírica e que deve ser definida.

Considerando as estatísticas de ordem da amostra aleatória observada sem repetições,  $y_k$ , a função de distribuição empírica  $S(x)$  é definida, algebricamente, por (63)

$$S(x) = \begin{cases} 0, & \text{para } x < y_1; \\ \frac{k}{n}, & \text{para } y_k \leq x < y_{k+1}, k = 1, 2, 3, \dots, n-1 \\ 1, & \text{para } x \geq y_n \end{cases} \quad (2.41)$$

em que  $k$  é igual a  $1, 2, 3, \dots, n-1$  e  $n$  é números de observações amostrais.

Substituindo a equação (2.41) em (2.40), finalmente, calcula-se a estatística de teste  $D_n$ .

A decisão a favor (hipótese  $H_0$ ) ou não (hipótese  $H_1$ ) da normalidade dos dados é tomada levando em consideração alguma função de distribuição empírica  $S(x)$  (63). Neste caso, a regra de decisão a respeito da normalidade, a um nível de significância  $\alpha$ , é dada por

$$\begin{aligned} F(x) &\neq S(x), & (H_0) \\ F(x) &= S(x), & (H_1) \end{aligned} \quad (2.42)$$

Em palavras, deverá decidir pela hipótese  $H_0$  sempre que a função de distribuição acumulada  $F(x)$  for diferente da função de distribuição empírica  $S(x)$ , a um nível de significância  $\alpha$ , concluindo que amostra aleatória segue uma distribuição normal, e deverá decidir pela rejeição de  $H_0$  caso contrário.

Segundo o que já foi citado anteriormente, para realizar a construção dos diagramas de controle, é necessário que as medidas das UTEs sigam uma distribuição normal. Devido a isso, são realizados testes de normalidade nestes dados, de acordo com as técnicas descritas nesta seção, para assegurar que estes dados são normais. Após isto, com a posse da normalidade destes dados, o diagrama de controle é construído conforme definido na Figura 12. É importante notar que, este diagrama é capaz de monitorar o comportamento estatístico de um determinado processo. Porém, na prática, é necessário interpretar estes gráficos para determinar se há alguma causa especial ocorrendo ou não. Devido a isso, a próxima seção discorre sobre um método específico capaz de interpretar estes gráficos, cujo nomeação é dada por Regras de Nelson.

## 2.3 Regras de Nelson

As regras de Nelson são métodos criados para interpretar os comportamentos estatísticos dos processos apresentados pelo diagrama de controle. Em outras palavras, as regras de Nelson servem como fonte de interpretação e detecção de condições anormais de um processo (47).

A primeira vez que as regras de controle de processo foram proposta na literatura foi na década de 20, por Walter Shewhart (47). Em 1984, uma atualização destas regras foi feita por Lloyd S Nelson, o que resultou na publicação de um artigo no *Journal of Quality Technology*, na edição daquele ano (44). Nesta publicação, Nelson apresentou 8 regras (critérios) capazes de indicar posições dos pontos que informam condições fora de controle de processo, cuja descrição são (44):

- Regra 1: Um ponto além da Zona A;
- Regra 2: 9 pontos de um mesmo lado da média;
- Regra 3: Seis pontos consecutivos aumentando ou diminuindo continuamente;
- Regra 4: Quatorze pontos consecutivos, alternando para cima e para baixo;
- Regra 5: Dois de três pontos consecutivos na Zona A ou além;
- Regra 6: Quatro de cinco pontos consecutivos na Zona B ou além;
- Regra 7: Quinze pontos consecutivos na Zona C (acima e abaixo linha central);
- Regra 8: Oito pontos consecutivos em ambos os lados da linha central sem nenhum nas Zonas C.

À partir das descrições anteriores é possível interpretar as posições que os pontos ocupam nas zonas que compõem o diagrama de controle, conforme descrito na seção 2.1.4. Em cada uma dessas zonas, esses pontos possuem uma probabilidade específica de ocorrência, conforme também detalhado na seção 2.1.4. Sendo assim, cada uma das 8 regras também são sustentadas com uma probabilidade estatística particular. Portanto, nas subseções seguintes, serão descritas detalhadamente tanto a probabilidade da ocorrência da regra 1, também chamada, regra básica, quanto as probabilidades de ocorrência das demais 7 regras de Nelson, também chamadas de regras complementares, que detectam anormalidade.

### 2.3.1 Regra 1

Conforme descrito anteriormente a regra de número 1 é a regra conhecida como regra básica e tem como definição um ponto além da Zona A (44). Objetivando facilitar

o entendimento desta regra, a Figura 19 mostra, a título de ilustração, o comportamento que os pontos seguem perante a definição da regra 1.

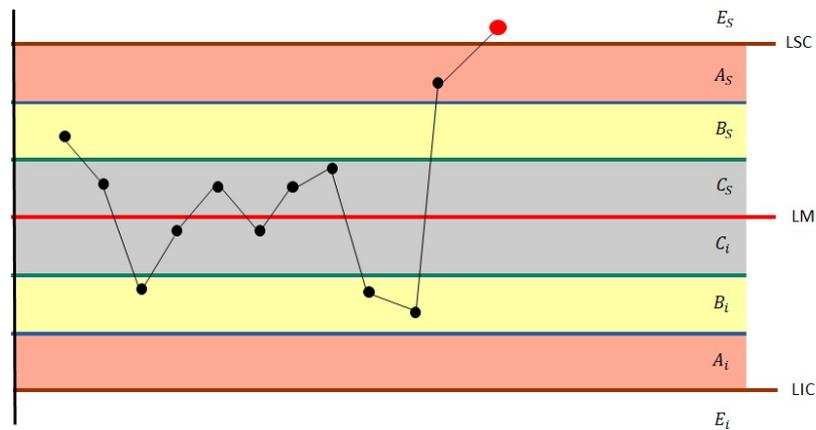


Figura 19 – Regra 1.

De acordo com a descrição da regra e com a Figura 19, ao identificar o primeiro ponto fora dos limites (superior ou inferior) pode-se concluir que a variável em análise pode estar operando de forma anormal. A probabilidade que sustenta essa afirmação não é nula, mais especificamente, é de 0,27% (45). Essa probabilidade é verificada, matematicamente, ao calcular a probabilidade de um ponto estar localizado na região externa acima da Zona A superior (chamado  $E_s$ ) ou na região externa abaixo da Zona A inferior (chamado  $E_i$ ). Como a probabilidade de um ponto cair em uma destas duas faixas é igual a 0,00135 (ou 0,135%), conforme descrito na seção 2.1.4. Algebricamente, como  $P(E_s) = P(E_i)$ , a probabilidade da regra 1 ocorrer é dada por

$$\begin{aligned} P(\text{Regra1}) &= 2 * P(E_s) \\ P(\text{Regra1}) &= 2 * 0,135\% \\ P(\text{Regra1}) &= 0,27\% \end{aligned} \tag{2.43}$$

Portanto, pode-se concluir perante a probabilidade de ocorrência da regra 1 que, se um determinado processo funciona a cada 24h de forma contínua, sua operação fora dos limites de controle é dita normal até aproximadamente 4 minutos. Fora disso, já é indicado anormalidade.

As regras de Nelson são utilizadas para identificar condições anormais de operação. No entanto, além da regra 1, tem-se também as regras que são capazes de identificar anormalidades com os pontos ainda dentro dos limites de controle (47). Assim sendo, a indicação de anormalidade pode ser feita nas demais 7 formas citadas anteriormente, da regra 2 a regra 8, conforme abordado nas subseções seguintes.

### 2.3.2 Regra 2

A segunda regra de Nelson que indica anormalidade estatística é nomeada Regra 2 e tem como definição 9 pontos de um mesmo lado da média (44). Objetivando facilitar o entendimento desta regra, a Figura 20 mostra, a título de ilustração, o comportamento que os pontos seguem perante a definição da regra 2.

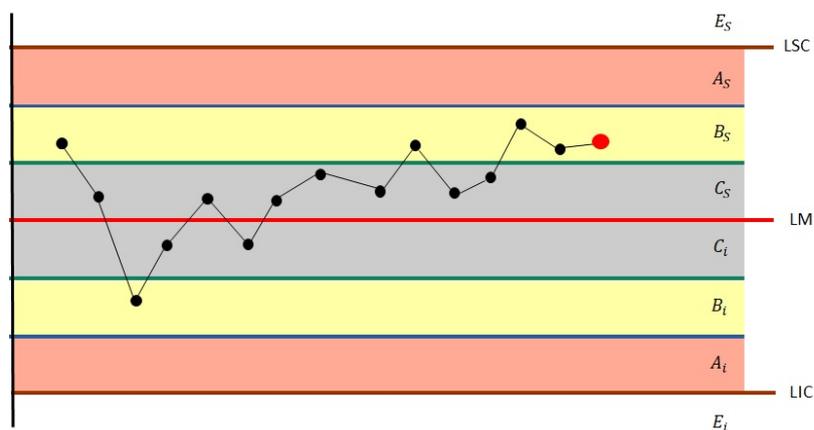


Figura 20 – Regra 2.

De acordo com a descrição da regra e com a Figura 20, estatisticamente, é possível identificar que as ocorrências de nove pontos consecutivos na Zona C ou além, é uma evidência de que a média da distribuição foi alterada indicando anormalidade. A probabilidade que sustenta essa informação é de 0,391%. Essa probabilidade é verificada, matematicamente, ao calcular a probabilidade de nove pontos estarem localizados ou na Zona C ou na Zona B ou Zona A ou na Zona externa tanto superior quanto inferior, respectivamente (chamados de  $C_s$ ,  $B_s$ ,  $A_s$ ,  $E_s$  para a parte superior e  $C_i$ ,  $B_i$ ,  $A_i$ ,  $E_i$  para a parte inferior, respectivamente). Como a probabilidade de nove pontos caírem em uma destas quatro faixas superior ou inferior é igual e com valor de 0,5 (ou 50%) (45) para cada região, conforme descrito na seção 2.1.4. Algebricamente, como  $P(C_s) = P(C_i)$ ,  $P(B_s) = P(B_i)$ ,  $P(A_s) = P(A_i)$  e  $P(E_s) = P(E_i)$ , a probabilidade da regra 2 ocorrer é dada por (45)

$$\begin{aligned}
 P(\text{Regra2}) &= 2 * [P(C_s) \text{ ou } P(B_s) \text{ ou } P(A_s) \text{ ou } P(E_s)]^9 \\
 P(\text{Regra2}) &= 2 * (0,5)^9 * 100 \\
 P(\text{Regra2}) &= 0,391\%
 \end{aligned}
 \tag{2.44}$$

### 2.3.3 Regra 3

A terceira regra de Nelson que indica anormalidade estatística é nomeada Regra 3 e tem como definição seis pontos consecutivos aumentando ou diminuindo continuamente (44). Objetivando facilitar o entendimento desta regra, a Figura 21 mostra, a título de ilustração, o comportamento que os pontos seguem perante a definição da regra 3.

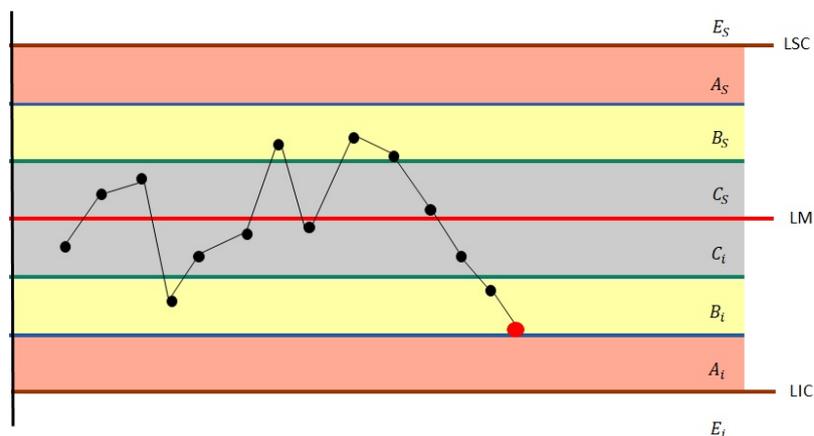


Figura 21 – Regra 3.

De acordo com a descrição da regra e com a Figura 21, a ocorrência de seis pontos consecutivos aumentando ou diminuindo continuamente indica que a média da distribuição foi deslocada para essa nova direção. Conseqüentemente, os pontos passam a seguir uma tendência sempre crescente (ou decrescente) indicando outra situação de anormalidade. A probabilidade que sustenta essa informação é de 0,278%. Essa probabilidade é verificada matematicamente ao calcular a probabilidade entre todas as combinações possíveis de seis pontos consecutivos seguir uma tendência aumentando ou diminuindo. Em outras palavras, calcula-se o fatorial de 6, e obtêm-se um total de 720 combinações de seis pontos consecutivos. No entanto, destas 720 combinações apenas 1 seqüência de 6 pontos consecutivos seguem um padrão aumentando e apenas 1 seqüência de 6 pontos consecutivos seguem um padrão diminuindo. Portanto, algebricamente, a probabilidade da regra 3 ocorrer é dada por (45)

$$\begin{aligned}
 P(\text{Regra3}) &= (1 + 1)/6! \\
 P(\text{Regra3}) &= 2/(6 * 5 * 4 * 3 * 2 * 1) \\
 P(\text{Regra3}) &= 2/(720) * 100 \\
 P(\text{Regra3}) &= 0,278\%
 \end{aligned}
 \tag{2.45}$$

### 2.3.4 Regra 4

A quarta regra de Nelson que indica anormalidade estatística é nomeada Regra 4 e tem como definição quatorze pontos consecutivos, alternando para cima e para baixo (44). Objetivando facilitar o entendimento desta regra, a Figura 22 mostra, a título de ilustração, o comportamento que os pontos seguem perante a definição da regra 4.

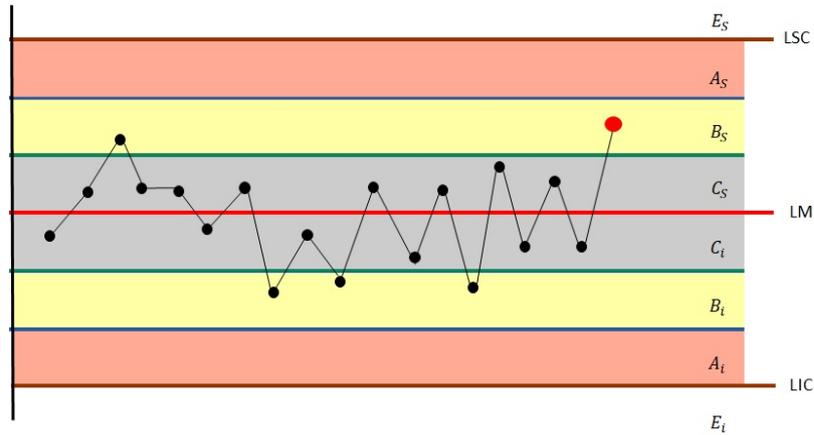


Figura 22 – Regra 4.

De acordo com a descrição da regra e com a Figura 22, a situação de anormalidade ocorre quando há uma sequência de 14 pontos consecutivos da variável se alternando em zig-zag, para cima e para baixo, independente da zona. A probabilidade que sustenta essa informação é de 0,457%. Essa probabilidade é verificada empregando o algoritmo de Entringer (64). Neste algoritmo adota-se que o número de sequência alternando em zig-zag entre as  $n!$  sequências que tem tamanho  $n$  (sendo  $n$  números inteiros) é representado por  $T_n$  e calculado por  $T_n = 2A_n$ , onde  $A_n$  é a sequência dos números de André (65)(66). Dentro desta sequência, o número que começa a sequência para cima é chamado  $U_n$  e o número que começa a sequência para baixo é chamado  $D_n$  (45). Assim sendo, considerando que existe simetria entre essas alterações de sequência para cima e para baixo pode-se compreender que  $D_n = U_n = A_n$  e que  $T_n = U_n + D_n = 2A_n$  (45). Conseqüentemente, a probabilidade de um número de sequência alternando em zig-zag entre as  $n!$  sequências é dada por  $p_n = T_n/n!$  (45). Portanto, como na regra 4 o tamanho da sequência de pontos é 14, tem-se  $n=14$ , e segundo a tabela 3 do artigo (45) a décima quarta posição da sequência dos números de André ( $T_{14}$ )(65)(66) é igual a 398721962. Sendo assim, algebricamente, a probabilidade da regra 4 ocorrer é dado por (45)

$$\begin{aligned}
 P(\text{Regra4}) &= T_{14}/14! \\
 P(\text{Regra4}) &= 398721962/(14!) * 100 \\
 P(\text{Regra4}) &= 0,457\%
 \end{aligned}
 \tag{2.46}$$

Portanto, conclui-se que o acionamento desta regra não pode ser explicada simplesmente como ruído de uma distribuição normal. Vale investigar esta situação, porque ela pode indicar a influência de algum fator externo cíclico na variável monitorada.

### 2.3.5 Regra 5

A quinta regra de Nelson que indica anormalidade estatística é nomeada Regra 5 e tem como definição dois de três pontos consecutivos na Zona A ou além (44). Objeti-



### 2.3.6 Regra 6

A sexta regra de Nelson que indica anormalidade estatística é nomeada Regra 6 e tem como definição quatro de cinco pontos consecutivos na Zona B ou além (44). Objetivando facilitar o entendimento desta regra, a Figura 24 mostra, a título de ilustração, o comportamento que os pontos seguem perante a definição da regra 6.

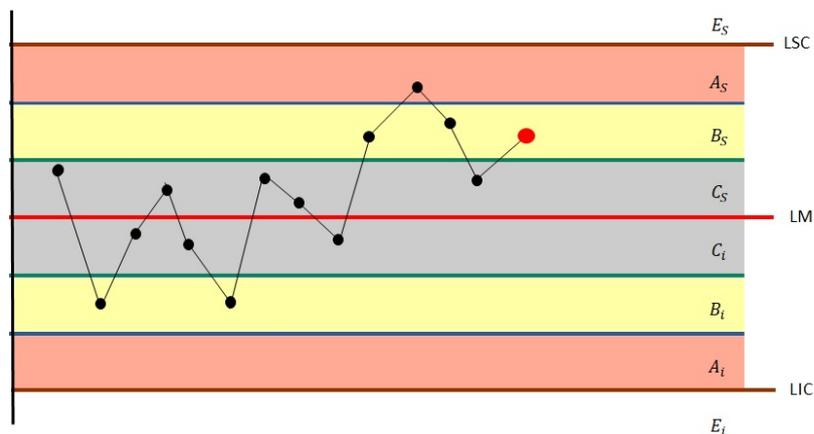


Figura 24 – Regra 6.

De acordo com a descrição da regra e com a Figura 24, se o quarto ponto, em 5 pontos consecutivos, estiverem na Zona B ou além é indício de anormalidade, porque a probabilidade desta situação ocorrer é baixa, uma vez que considerou nenhuma modificação na distribuição. De forma estatística, é mais provável que a média real da variável tenha se deslocado para o lado onde as medidas estão tendendo, e este deslocamento indica uma operação em condição diferente da condição de controle considerada normal. A probabilidade que sustenta essa informação é de 0,553%. Essa probabilidade é verificada, matematicamente, ao calcular a combinação do quarto ponto em 5 pontos consecutivos, a probabilidade do quarto ponto estar localizado ou na Zona B ou na Zona A ou na Zona Externa tanto superior quanto inferior, respectivamente (chamado  $B_s$ ,  $A_s$  e  $E_s$  para região superior e  $B_i$ ,  $A_i$  e  $E_i$  para região inferior, respectivamente) e também a probabilidade do quarto ponto não estar em nenhuma das zonas citadas anteriormente. Além disso, é preciso calcular ainda a probabilidade do quinto ponto estar localizado ou na Zona B ou na Zona A ou na Zona Externa tanto superior quanto inferior, respectivamente. Portanto, algebricamente, a probabilidade da regra 6 ocorrer é dada por (45)

$$\begin{aligned}
P(\text{Regra6}) &= 2 * \binom{5}{4} * [P(B_s \text{ ou } A_s \text{ ou } E_s)]^4 * \\
& * [1 - P(B_s \text{ ou } A_s \text{ ou } E_s)] + \\
& + 2 * [P(B_s \text{ ou } A_s \text{ ou } E_s)]^5 \\
& = 2 * \left( \frac{5!}{4! * (5 - 4)!} \right) * [0,13591 + 0,02140 + 0,00135]^4 * \\
& * [1 - (0,13591 + 0,02140 + 0,00135)] + \\
& + [0,13591 + 0,02140 + 0,00135]^5 \\
& = 2 * 5 * (0,15866)^4 * 0,84134 + 2 * (0,15866)^5 * 100 \\
P(\text{Regra6}) &= 0,553\%.
\end{aligned} \tag{2.48}$$

### 2.3.7 Regra 7

A sétima regra de Nelson que indica anormalidade estatística é nomeada Regra 7 e tem como definição quinze pontos consecutivos na Zona C (acima ou abaixo da linha central) (44). Objetivando facilitar o entendimento desta regra, a Figura 25 mostra, a título de ilustração, o comportamento que os pontos seguem perante a definição da regra 7.

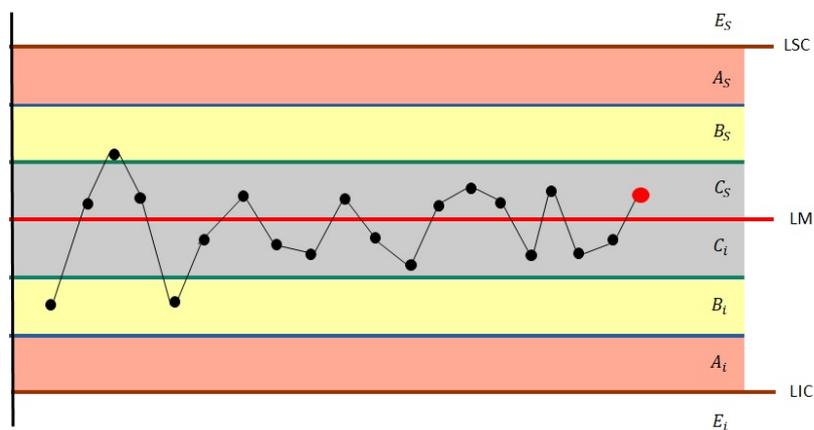


Figura 25 – Regra 7.

De acordo com a descrição da regra e com a Figura 25, estatisticamente, é possível identificar que a ocorrência do décimo quinto ponto consecutivo dentro das zonas C indica anormalidade. Portanto, como a variável segue uma distribuição normal, espera-se que a probabilidade desta regra ocorrer seja referente aos 68,27% dos pontos caírem nesta zona, conforme descrito na seção 2.1.4. A probabilidade que sustenta essa informação é de 0,326%. Essa probabilidade é verificada, matematicamente, ao calcular a probabilidade de quinze pontos consecutivos estarem localizados na Zona C superior (chamado  $C_s$ ) ou na Zona C inferior (chamado  $C_i$ ). Como a probabilidade de quinze pontos caírem em uma

destas duas faixas da Zona C é igual e de valor 0,34134 (ou 34,134%), conforme também descrito na seção 2.1.4. Algebricamente, como  $P(C_s) = P(C_i)$ , a probabilidade da regra 7 ocorrer é dada por (45)

$$\begin{aligned} P(\text{Regra7}) &= [P(C_s) \text{ ou } P(C_i)]^{15} \\ P(\text{Regra7}) &= (0,34134 + 0,34134)^{15} \\ P(\text{Regra7}) &= (0,6827)^{15} * 100 \\ P(\text{Regra7}) &= 0,326\% \end{aligned} \quad (2.49)$$

Portanto, conclui-se que o acionamento desta regra indica uma anormalidade devido à diminuição do desvio padrão da distribuição da variável aleatória analisada. Vale ressaltar que esta diminuição deve ser investigada, porque pode ser indício de falhas no sensor utilizado para a medição, por exemplo.

### 2.3.8 Regra 8

A oitava regra de Nelson que indica anormalidade estatística é nomeada Regra 8 e tem como definição oito pontos consecutivos em ambos os lados da linha média sem nenhum nas Zonas C (44). Objetivando facilitar o entendimento desta regra, a Figura 26 mostra, a título de ilustração, o comportamento que os pontos seguem perante a definição da regra 8.

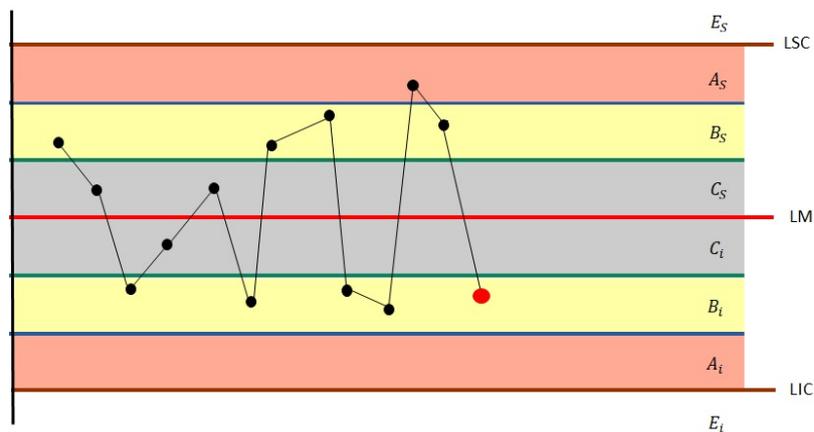


Figura 26 – Regra 8.

De acordo com a descrição da regra e com a Figura 26, a ocorrência de oito pontos consecutivos fora das zonas C é indício de anormalidade, uma vez que, a variável segue uma distribuição normal, espera-se que 68,27% dos valores desta variável caiam nesta zona. Confirmando, portanto, esta anomalia. A probabilidade que sustenta essa informação é de 0,010%. Essa probabilidade é verificada, matematicamente, ao calcular a probabilidade de oito pontos consecutivos estarem localizados ou na Zona B ou na Zona A ou na Zona externa tanto superior quanto inferior, respectivamente (chamados de  $B_s$ ,  $A_s$ ,  $E_s$  para a

parte superior e  $B_i$ ,  $A_i$ ,  $E_i$  para a parte inferior, respectivamente). Como já mencionado na subseção 2.1.4, a probabilidade de ocorrência de um ponto fora da Zona B superior (chamado  $P(B_s)$ ) ou inferior (chamado  $P(B_i)$ ) é igual e de valor 0,00135 (ou 0,135%). A probabilidade de ocorrência de um ponto na Zona A superior (chamado  $P(A_s)$ ) ou inferior (chamado  $P(A_i)$ ) é igual e de valor 0,02140 (ou 2,140%). Já a ocorrência de um ponto na Zona externa superior (chamado  $P(E_s)$ ) ou inferior (chamado  $P(E_i)$ ) é igual e de valor 0,13591 (ou 13,591%). Portanto, algebricamente, como  $P(B_s) = P(B_i)$ ,  $P(A_s) = P(A_i)$  e  $P(E_s) = P(E_i)$ , a probabilidade da regra 8 ocorrer é dada por (45)

$$\begin{aligned}
 P(\text{Regra8}) &= [2 * (P(B_s) \text{ ou } P(A_s) \text{ ou } P(E_s))]^8 \\
 P(\text{Regra8}) &= [2 * (0,13591 + 0,02140 + 0,00135)]^8 \\
 P(\text{Regra8}) &= [2 * (0,15866)]^8 \tag{2.50} \\
 P(\text{Regra8}) &= [0,31732]^8 * 100 \\
 P(\text{Regra8}) &= 0,010\%
 \end{aligned}$$

Portanto, conclui-se que o acionamento desta regra indica que as medidas estão mais afastadas, aumentando portanto a banda da distribuição normal da variável aleatória monitorada e, conseqüentemente, gerando um aumento no desvio padrão da mesma.

Sendo assim, conclui-se que as regras de Nelson conforme regra 1, indicam que se um ou mais pontos estão fora dos limites de controle, sejam estes superior ou inferior, por um período maior que o produto do tempo que o processo em análise funcionou com a probabilidade da regra 1 ocorrer, o processo está fora de controle. Já com as demais 7 regras conclui-se que pode haver anormalidade com os pontos ainda dentro dos limites de controle. Para todas essas regras, caso seja feito de fato o diagnóstico de anormalidade, medidas de ajustes no processo em questão devem ser tomadas (47).

Vale ressaltar que as 8 regras descritas anteriormente são baseadas na média e desvio padrão utilizados para construir o gráfico de controle, conforme descrito na seção 2.1.4. Ressalta-se também que o número de regras utilizadas para detecção de anormalidade pode ser alterado de acordo com o processo analisado em questão (46).

## 2.4 Técnica usada pela biblioteca Distfit

DistFit é uma biblioteca em Python que permite ajustar distribuições estatísticas aos dados e realizar o ajuste de parâmetros. Essa biblioteca é útil para identificar a distribuição que melhor se ajusta aos dados observados, permitindo uma melhor compreensão das características da distribuição subjacente (67).

Ao utilizar a biblioteca DistFit, é possível realizar o ajuste de diferentes distribuições estatísticas, como a distribuição normal, distribuição exponencial, distribuição de

Poisson, entre outras. A biblioteca utiliza o método de máxima verossimilhança (Maximum Likelihood Estimation, MLE) para estimar os parâmetros da distribuição (67).

O método de máxima verossimilhança é uma técnica estatística amplamente utilizada para estimar os parâmetros desconhecidos de uma distribuição de probabilidade com base nos dados observados. O objetivo principal desta técnica é encontrar os valores dos parâmetros que maximizem a verossimilhança dos dados observados, ou seja, a probabilidade de obter os dados que foram observados (68).

Em termos simples, a ideia por trás do método de máxima verossimilhança é encontrar os valores dos parâmetros que tornem os dados observados mais prováveis de acordo com a distribuição proposta, na qual neste caso é a distribuição normal. Isso envolve a construção de uma função de verossimilhança, que é uma função que descreve a probabilidade dos dados observados para diferentes valores dos parâmetros. Em seguida, os valores dos parâmetros são estimados maximizando essa função de verossimilhança.

O processo de aplicação do método de máxima verossimilhança envolve os seguintes passos:

- 1: Formulação da função de verossimilhança: É necessário definir a função de verossimilhança, que descreve a probabilidade dos dados observados em termos dos parâmetros desconhecidos da distribuição. A função de verossimilhança é construída a partir da distribuição de probabilidade assumida para os dados.
- 2: Maximização da função de verossimilhança: O próximo passo é encontrar os valores dos parâmetros que maximizam a função de verossimilhança. Isso geralmente envolve a otimização numérica, como o uso de algoritmos de otimização, para encontrar os valores dos parâmetros que maximizam a função.
- 3: Estimação dos parâmetros: Uma vez que os valores dos parâmetros que maximizam a função de verossimilhança tenham sido encontrados, esses valores são considerados as estimativas dos parâmetros desconhecidos da distribuição.

Matematicamente, o método de máxima verossimilhança pode ser expresso da seguinte forma:

Suponha que tenha um conjunto de observações independentes e identicamente distribuídas (i.i.d.)  $X_1, X_2, \dots, X_n$ , onde cada  $X_i$  segue uma distribuição de probabilidade parametrizada por um vetor de parâmetros desconhecidos  $\theta$ . A função de densidade de probabilidade (ou função de massa, no caso discreto) para cada  $X_i$  é denotada por  $f(x; \theta)$  ou  $f(x_1, x_2, \dots, x_n; \theta)$ .

A função de verossimilhança  $L(\theta; x_1, x_2, \dots, x_n)$  é definida como a probabilidade (ou função de massa) conjunta dos dados observados  $x_1, x_2, \dots, x_n$  como uma função dos

parâmetros  $\theta$ . Para observações independentes e identicamente distribuídas, a função de verossimilhança é o produto das funções de densidade de probabilidade (ou funções de massa) individuais:

$$L(\theta; x_1, x_2, \dots, x_n) = f(x_1; \theta) * f(x_2; \theta) * \dots * f(x_n; \theta) \quad (2.51)$$

O estimador de máxima verossimilhança  $\hat{\theta}_{MLE}$  é definido como o valor do vetor de parâmetros  $\theta$  que maximiza a função de verossimilhança, ou seja:

$$\hat{\theta}_{MLE} = \arg \max_{\theta} L(\theta; x_1, x_2, \dots, x_n) \quad (2.52)$$

A máxima verossimilhança pode ser aplicada a uma ampla variedade de distribuições estatísticas, como a distribuição normal, exponencial, de Poisson, entre outras. O método é conhecido por ter boas propriedades estatísticas, como eficiência assintótica e consistência, desde que as suposições sobre a distribuição sejam atendidas.

No contexto da biblioteca DistFit, se ela utiliza o método de máxima verossimilhança para estimar os parâmetros da distribuição, isso significa que ela utiliza essa abordagem para ajustar diferentes distribuições aos dados observados e encontrar os valores dos parâmetros que melhor se ajustam aos dados.

Vale ressaltar que os fundamentos teóricos para o entendimento dos demais capítulos deste trabalho estão concluídos. Portanto, o próximo capítulo discorre sobre a metodologia aplicada para a análise precoce de anormalidades no MCI de uma UTE no Brasil.

## 3 Metodologia Proposta

O capítulo apresenta a metodologia proposta para auxiliar os operadores de UTE no gerenciamento dos seus ativos, dado que a base de dados é grande e constituída de centenas de variáveis por unidade de geração. Existem na literatura diversos tipos de métodos que realizam o monitoramento dos ativos de forma inteligente, como por exemplo mineração de dados (23), rede neural (25), funções de pertinência *fuzzy* (26), entre outros métodos. Porém, não se encontrou trabalhos aplicando Regras de Nelson no monitoramento de ativos. Sendo assim, no capítulo 3 é apresentado de forma inédita um gerenciamento estatístico de motores de combustão interna baseada nas Regras de Nelson. Especificamente, para realizar esta análise é preciso que os dados sejam normais, conforme já citado anteriormente. Portanto, na seção 3.1, é apresentado a descrição de como foi feita a divisão da unidade geradora para as análises deste trabalho. Em seguida, são descritas as variáveis selecionadas por estes subsistemas. Posteriormente, é detalhado sobre a base de dados destas variáveis. Na seção 3.4, é abordado a aplicação dos testes de normalidade a fim de avaliar se estes dados seguem uma distribuição normal. Em seguida, na seção 3.5, é apresentado o procedimento de normalização dos dados caso esses dados não sejam normais. Posteriormente, são apresentados os cálculos estatísticos realizados nas medidas destas variáveis. Após isto, é descrito a montagem do diagrama de controle para estas variáveis. Em seguida, é apresentada a descrição das Regras de Nelson aplicadas em MCI. Por fim, na seção 3.9 é apresentada a forma como essas Regras de Nelson aplicadas em MCI são analisadas no tempo, através de gráficos de barras.

### 3.1 Divisão em subsistemas

A técnica utilizada para iniciar o desenvolvimento analítico de um modelo estatístico da condição sob monitoramento foi a divisão do sistema de geração (motor, gerador e sistemas periféricos semelhante a um Wäertsilä 18V46 (32)) em subsistemas.

Para melhor compreensão desta forma de divisão em subsistemas, a Figura 27 apresenta um exemplo didático de uma unidade geradora em processo de divisão. Neste exemplo, a unidade geradora a ser dividida é representada por um polígono. Já os 11 subsistemas definidos por Ar de Admissão, Turbinas, Óleo Combustível, Cilindros, Mancais de Rolamento, Óleo Lubrificante, Água de Arrefecimento, Gerador, Gás Natural, Gases de Exaustão e Outros são definidos pelos retângulos de cantos arredondados.



Figura 27 – Diagrama da unidade geradora dividida em 11 subsistemas.

No diagrama ilustrado na Figura 27, 10 dos 11 subsistemas ilustrados já são existentes e foram criados pela Wärtsilä, apenas o subsistema “outros” que foi proposto neste trabalho. Cada um dos 11 subsistemas possui sensores que medem variáveis específicas, como por exemplo, temperatura, pressão, vazão, entre outras. Conseqüentemente, após a divisão da unidade geradora, o próximo passo é selecionar as variáveis correspondentes a cada um desses 11 subsistemas, conforme abordado na seção seguinte.

## 3.2 Variáveis selecionadas por subsistemas

De acordo com o manual da fornecedora dos motores (18V46) que são utilizados na UTE em questão (32), os subsistemas envolvidos na geração de eletricidade contam com sensores instalados em regiões pontuais (de cada subsistema) com o objetivo de medir variáveis específicas de operação deste motor. Com base nestas informações e na tabela de dados disponibilizada pelo próprio sistema de supervisão da planta, medições de campo, sistemas de monitoramento de condição *online* ou relatórios da equipe de manutenção da UTE, nas próximas subseções, serão especificadas as variáveis selecionadas para cada subsistema envolvido na geração elétrica.

### 3.2.1 Subsistema de Ar de Admissão

O subsistema de "Ar de Admissão" foi o primeiro subsistema a ter as variáveis selecionadas. Nele, foram agrupadas a temperatura de admissão no compressor, proveniente da turbina A, bem como a temperatura saída e a pressão de saída do ar de admissão e o número de rotações do compressor de admissão. A principal função deste subsistema é admitir a quantidade adequada de ar no cilindro para o processo de combustão (69).

Para melhor compreensão das variáveis selecionadas para o subsistema de ar de

admissão, a Tabela 1 apresenta as *tags* que representam as variáveis deste subsistema e as suas descrições e a Figura 28 apresenta um desenho do motor 18V46GD com os sensores deste subsistema por meio de diagrama (70).

Tabela 1 – Tabela que apresenta as *tags* e as descrições das variáveis que compõem o subsistema de ar de admissão.

Tag	Descrição
SNB051T001PV	Temperatura Entrada Compressor Turbina A
SNB051T002PV	Temperatura Saída Ar Admissão TE601
SNB051P002PV	Pressão Saída Ar Admissão PT601
SOB051S001PV	Número de Rotações Compressor Admissão

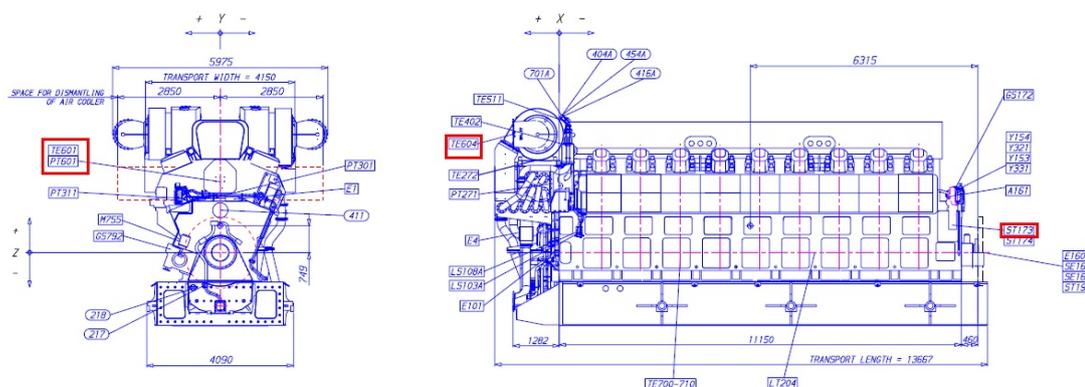


Figura 28 – Diagrama do desenho do motor que ilustra os sensores do subsistema ar de admissão (70).

Neste diagrama, o sensor denominado TE604 faz a medida da temperatura no compressor de admissão da turbina A. Já os sensores denominados TE601 e PT601 fazem as medidas da temperatura e da pressão de saída do ar de admissão. Por fim, o sensor denominado ST173 faz a medida do número de rotações do compressor de admissão.

### 3.2.2 Subsistema de Turbinas

O segundo subsistema a ter as variáveis selecionadas, foi o subsistema de "Turbinas". Nele, foram associadas as temperaturas de entrada e saída da turbina A e B, bem como o número de rotações de ambas. A principal função deste subsistema é fornecer ao motor uma maior potência de explosão em cada cilindro, uma vez que, este sistema comprime o ar (aumenta a sua pressão) antes de entrar na válvula de admissão, o que resulta em uma maior massa de ar na câmara de combustão (sem a necessidade do aumento de volume), e conseqüentemente, quanto mais ar na câmara de combustão, mais combustível pode ser injetado, resultando em maior potência (71).

Para melhor compreensão das variáveis selecionadas para o subsistema de turbinas, a Tabela 2 apresenta as *tags* que representam as variáveis deste subsistema e as suas

descrições e a Figura 29 apresenta um desenho do motor 18V46GD com os sensores deste subsistema por meio de diagrama (70).

Tabela 2 – Tabela que apresenta as tags e as descrições das variáveis que compõem o subsistema de turbinas.

Tag	Descrição
SNA051T055PV	Temperatura Entrada Turbina A
NHA051T001PV	Temperatura Saída Turbina A
SNA051T056PV	Temperatura Entrada Turbina B
NHA051T002PV	Temperatura Saída Turbina B
SOB051S002PV	Número de Rotações Turbina A
SOB051S003PV	Número de Rotações Turbina B

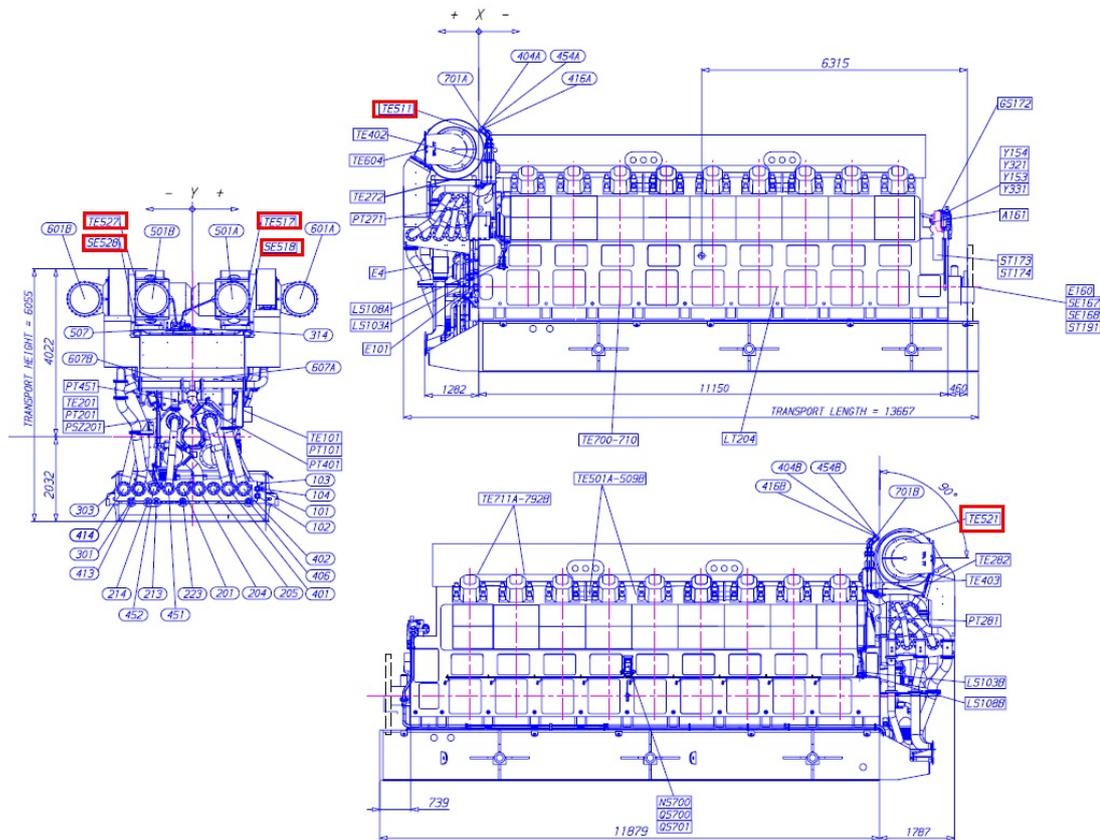


Figura 29 – Diagrama do desenho do motor que ilustra os sensores do subsistema de turbinas (70).

Neste diagrama, os sensores denominados TE511 e TE521 fazem as medidas das temperaturas de entrada das turbinas A e B, respectivamente. Já os sensores TE517 e TE527 fazem as medidas das temperaturas de saída das turbinas A e B, respectivamente. Por fim, os sensores SE518 e SE528 fazem as medidas dos números de rotações das turbinas A e B, respectivamente.

### 3.2.3 Subsistema de Óleo Combustível

O terceiro subsistema a ter as variáveis selecionadas, foi o subsistema de "Óleo Combustível". Nele, foram agrupadas a temperatura e a pressão de entrada do óleo combustível. A principal função deste subsistema é dosar de forma apropriada o combustível e transferir as suas pequenas partículas para dentro da câmara de combustão para que o processo de combustão ocorra perfeitamente (69).

Para melhor compreensão das variáveis selecionadas para o subsistema de óleo combustível, a Tabela 3 apresenta as *tags* que representam as variáveis deste subsistema e as suas descrições e a Figura 30 apresenta um esquemático interno convencional deste subsistema por meio de diagrama (32).

Tabela 3 – Tabela que apresenta as *tags* e as descrições das variáveis que compõem o subsistema de óleo combustível.

Tag	Descrição
SPA051T002PV	Temperatura de Entrada do Óleo Combustível
SPA051P004PV	Pressão de Entrada do Óleo Combustível

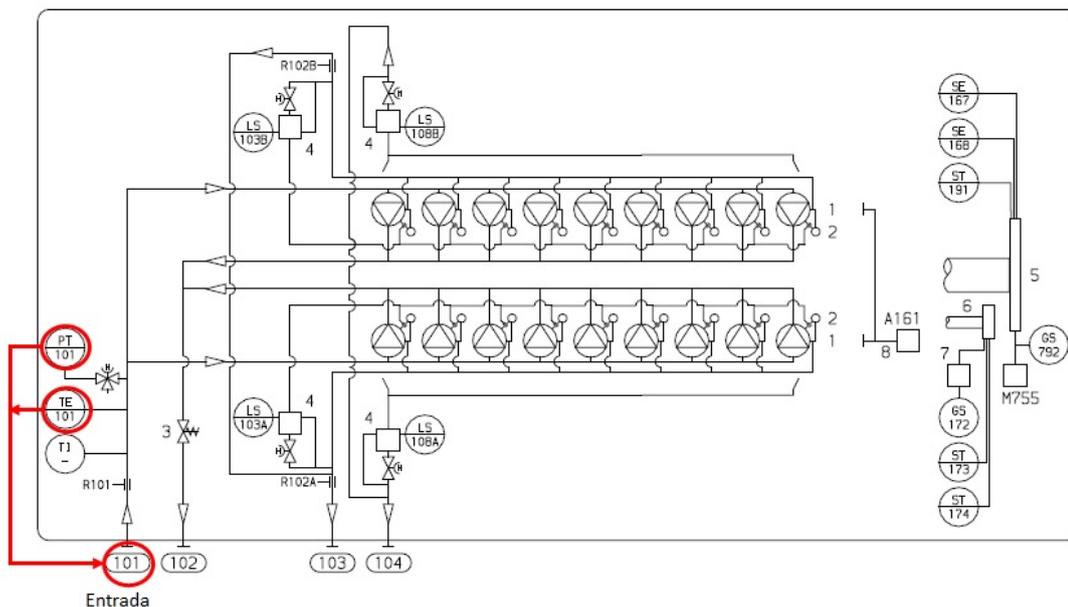


Figura 30 – Diagrama do esquemático interno do subsistema de óleo combustível (32).

Neste diagrama, a conexão do tubo denominada 101 representa a entrada do óleo combustível e interliga os sensores que fazem as medidas da temperatura e pressão de entrada do óleo combustível (representadas por TE101 e PT101, respectivamente).

### 3.2.4 Subsistema de Cilindro

No quarto subsistema, denominado de "Cilindros", as variáveis selecionadas foram as temperaturas de entrada dos cilindros tanto do lado A quanto do lado B. O

funcionamento adequado deste subsistema permite que a combustão sob altas pressões e temperaturas ocorra perfeitamente, dado que é no interior deste subsistema que este processo ocorre (72).

Para melhor compreensão das variáveis selecionadas para o subsistema de cilindro, a Tabela 4 apresenta as *tags* que representam as variáveis deste subsistema e as suas descrições e a Figura 31 apresenta um desenho do motor 18V46 com os sensores deste subsistema por meio de diagrama (70).

Tabela 4 – Tabela que apresenta as *tags* e as descrições das variáveis que compõem o subsistema de cilindro.

Tag	Descrição
SOC051T012PV	Temperatura 1 da Camisa do Cilindro A1
SOC051T013PV	Temperatura 2 da Camisa do Cilindro A1
SOC051T015PV	Temperatura 1 da Camisa do Cilindro A2
SOC051T016PV	Temperatura 2 da Camisa do Cilindro A2
SOC051T018PV	Temperatura 1 da Camisa do Cilindro A3
SOC051T019PV	Temperatura 2 da Camisa do Cilindro A3
SOC051T021PV	Temperatura 1 da Camisa do Cilindro A4
SOC051T022PV	Temperatura 2 da Camisa do Cilindro A4
SOC051T024PV	Temperatura 1 da Camisa do Cilindro A5
SOC051T025PV	Temperatura 2 da Camisa do Cilindro A5
SOC051T027PV	Temperatura 1 da Camisa do Cilindro A6
SOC051T028PV	Temperatura 2 da Camisa do Cilindro A6
SOC051T030PV	Temperatura 1 da Camisa do Cilindro A7
SOC051T031PV	Temperatura 2 da Camisa do Cilindro A7
SOC051T033PV	Temperatura 1 da Camisa do Cilindro A8
SOC051T034PV	Temperatura 2 da Camisa do Cilindro A8
SOC051T036PV	Temperatura 1 da Camisa do Cilindro A9
SOC051T037PV	Temperatura 2 da Camisa do Cilindro A9
SOC051T039PV	Temperatura 1 da Camisa do Cilindro B1
SOC051T040PV	Temperatura 2 da Camisa do Cilindro B1
SOC051T042PV	Temperatura 1 da Camisa do Cilindro B2
SOC051T043PV	Temperatura 2 da Camisa do Cilindro B2
SOC051T045PV	Temperatura 1 da Camisa do Cilindro B3
SOC051T046PV	Temperatura 2 da Camisa do Cilindro B3
SOC051T048PV	Temperatura 1 da Camisa do Cilindro B4
SOC051T049PV	Temperatura 2 da Camisa do Cilindro B4
SOC051T051PV	Temperatura 1 da Camisa do Cilindro B5
SOC051T052PV	Temperatura 2 da Camisa do Cilindro B5
SOC051T054PV	Temperatura 1 da Camisa do Cilindro B6
SOC051T055PV	Temperatura 2 da Camisa do Cilindro B6
SOC051T057PV	Temperatura 1 da Camisa do Cilindro B7
SOC051T058PV	Temperatura 2 da Camisa do Cilindro B7
SOC051T060PV	Temperatura 1 da Camisa do Cilindro B8
SOC051T061PV	Temperatura 2 da Camisa do Cilindro B8
SOC051T063PV	Temperatura 1 da Camisa do Cilindro B9
SOC051T064PV	Temperatura 2 da Camisa do Cilindro B9

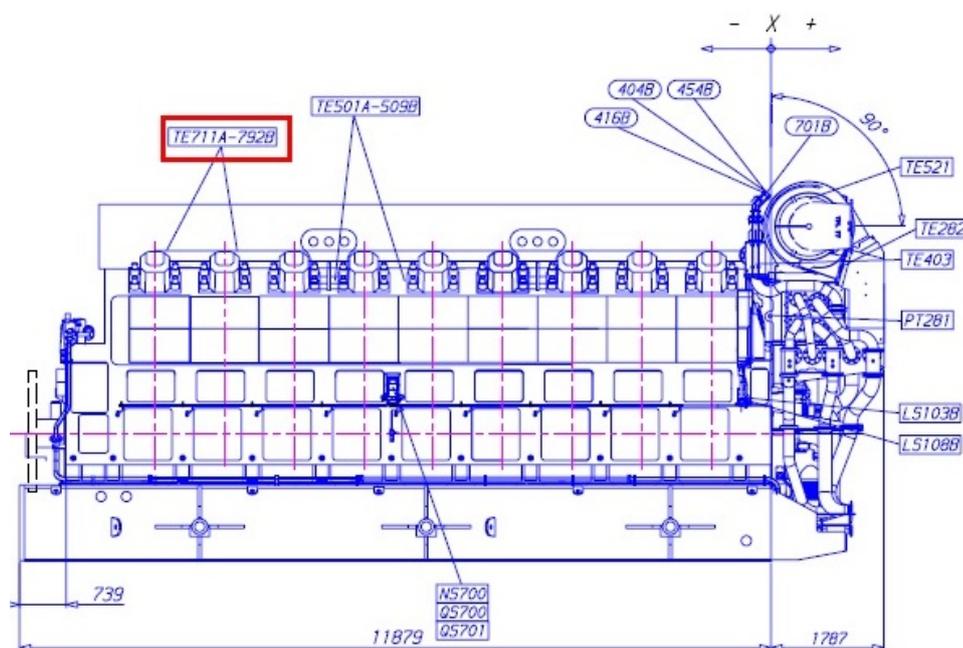


Figura 31 – Diagrama do desenho do motor que ilustra os sensores do subsistema de cilindro (70).

Neste diagrama, os sensores denominados TE711A, TE712A, TE721A, TE722A, TE731A, TE732A, TE741A, TE742A, TE751A, TE752A, TE761A, TE762A, TE771A, TE772A, TE781A, TE782A e TE791A, TE792A fazem as medidas das temperaturas de entrada dos cilindros do lado A. Já os sensores TE711B, TE712B, TE721B, TE722B, TE731B, TE732B, TE741B, TE742B, TE751B, TE752B, TE761B, TE762B, TE771B, TE772B, TE781B, TE782B e TE791B, TE792B fazem as medidas das temperaturas de entrada dos cilindros do lado B.

### 3.2.5 Subsistema de Mancais

O quinto subsistema a ter as variáveis selecionadas, foi o subsistema de "Mancais de Rolamento". Nele, foram associadas as temperaturas de saída dos 10 mancais, bem como o número de rotações do mancal e a temperatura do mancal de escora. A principal função deste subsistema é fornecer apoio as partes móveis, bem como reduzir o atrito entre elas (73).

Para melhor compreensão das variáveis selecionadas para o subsistema de mancais, a Tabela 5 apresenta as *tags* que representam as variáveis deste subsistema e as suas descrições e a Figura 32 apresenta um desenho do motor 18V46 com os sensores deste subsistema por meio de diagrama (70).

Tabela 5 – Tabela que apresenta as tags e as descrições das variáveis que compõem o subsistema de mancais.

Tag	Descrição
SOC051T002PV	Temperatura do Mancal 1
SOC051T003PV	Temperatura do Mancal 2
SOC051T004PV	Temperatura do Mancal 3
SOC051T005PV	Temperatura do Mancal 4
SOC051T006PV	Temperatura do Mancal 5
SOC051T007PV	Temperatura do Mancal 6
SOC051T008PV	Temperatura do Mancal 7
SOC051T009PV	Temperatura do Mancal 8
SOC051T010PV	Temperatura do Mancal 9
SOC051T011PV	Temperatura do Mancal 10
SOC051T001PV	Temperatura do Mancal de Escora
SOB051S006PV	Número de Rotações Mancal

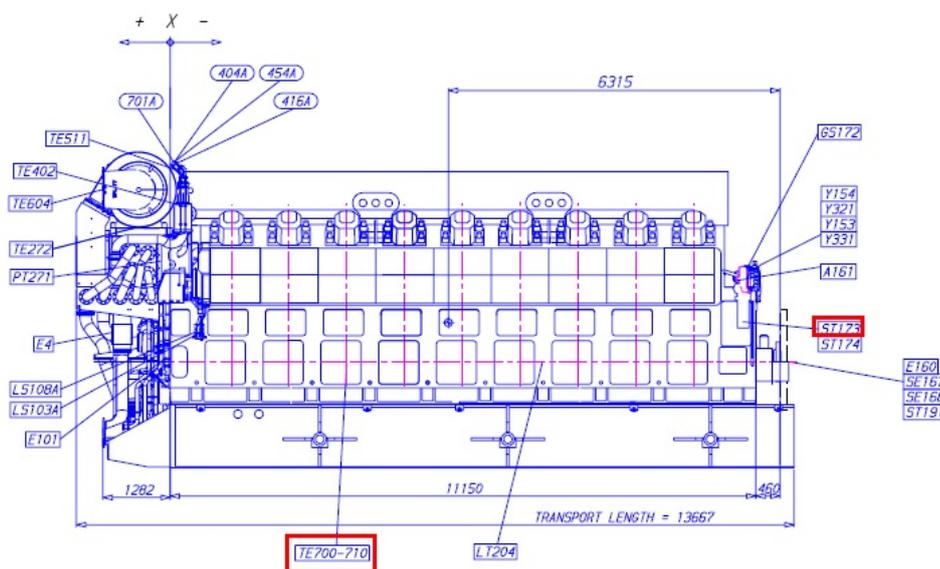


Figura 32 – Diagrama do desenho do motor que ilustra os sensores do subsistema de mancais (70).

Neste diagrama, os sensores denominados TE700 a TE710 fazem as medidas das temperaturas de saída dos 10 mancais e da temperatura do mancal de escora. Já o sensor ST173 mede o número de rotações do mancal.

### 3.2.6 Subsistema de Óleo Lubrificante

O sexto subsistema a ter as variáveis selecionadas, foi o subsistema de "Óleo Lubrificante". Nele, foram agrupadas a temperatura e pressão de entrada, bem como as temperaturas de saída e as pressões de entrada do óleo lubrificante das turbinas A e B. A principal função deste subsistema é a lubrificação das peças que compõem o motor, como por exemplo pistões, rolamentos, etc. Além desta função, este subsistema também

é responsável pela remoção de calor e pela limpeza no interior do motor (32).

Para melhor compreensão das variáveis selecionadas para o subsistema de óleo lubrificante, a Tabela 6 apresenta as tags que representam as variáveis deste subsistema e as suas descrições e a Figura 33 apresenta um esquemático geral deste subsistema por meio de diagrama (32).

Tabela 6 – Tabela que apresenta as tags e as descrições das variáveis que compõem o subsistema de óleo lubrificante.

Tag	Descrição
SQA051T003PV	Temperatura de Entrada do Óleo Lubrificante
SQA051T006PV	Temperatura de Saída do Óleo Lubrificante na Turbina A
SQA051T007PV	Temperatura de Saída do Óleo Lubrificante na Turbina B
SQA051P008PV	Pressão de Entrada do Óleo Lubrificante
SQA051P010PV	Pressão de Entrada do Óleo Lubrificante na Turbina A
SQA051P011PV	Pressão de Entrada do Óleo Lubrificante na Turbina B

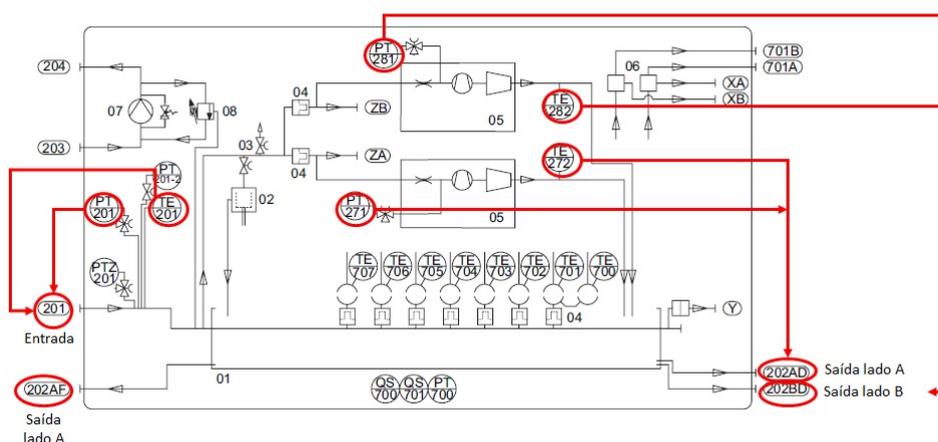


Figura 33 – Diagrama do esquemático geral do subsistema de óleo lubrificante (32).

Neste diagrama, a conexão do tubo denominada 201 representa a entrada do óleo lubrificante e interliga os sensores que fazem as medidas da temperatura e pressão de entrada do óleo lubrificante (representados por TE201 e PT201, respectivamente). As conexões dos tubos denominadas 202AF/AD e 202BD representam as saídas do óleo lubrificante do lado A e do lado B, respectivamente. Os sensores denominados TE272 e TE282 são responsáveis pelas medidas das temperaturas de saída do óleo lubrificante na turbina A e B, respectivamente. E por fim, sensores denominados PT271 e PT281 são responsáveis pelas medidas das pressões de entrada do óleo lubrificante na turbina A e B, respectivamente.

### 3.2.7 Subsistema de Água de Arrefecimento

O sétimo subsistema a ter as variáveis selecionadas, foi o subsistema de "Água de Arrefecimento". Nele, foram associadas as temperaturas de entrada e saída da água de

arrefecimento fria, bem como as temperaturas de saída da água de arrefecimento quente e as pressões de entrada para água quente e fria. A principal função deste subsistema, como o próprio nome sugere, é garantir que a temperatura interna do motor esteja dentro dos limites ótimos de funcionamento. O resfriamento para manter esta temperatura é feito por um sistema de água fresca na qual é tratada em 2 circuitos fechados, denominados circuito de alta temperatura (HT) e circuito de baixa temperatura (LT) (32).

Para melhor compreensão das variáveis selecionadas para o subsistema de água de arrefecimento, a Tabela 7 apresenta as tags que representam as variáveis deste subsistema e as suas descrições e a Figura 34 apresenta um esquemático interno convencional deste subsistema por meio de diagrama (74).

Tabela 7 – Tabela que apresenta as tags e as descrições das variáveis que compõem o subsistema de água de arrefecimento.

Tag	Descrição
QEA051T101PV	Temperatura de Entrada Água LT CAC Interno Sensor T101
QEA051T102PV	Temperatura de Entrada Água LT CAC Interno Sensor T102
QEA051T105PV	Temperatura de Saída Água LT CAC Externo Sensor T105
QEA051T106PV	Temperatura de Saída Água LT CAC Externo Sensor T106
QEA051T107PV	Temperatura de Entrada Água LT Jaqueta Sensor T107
QEA051T108PV	Temperatura de Saída Água LT Jaqueta Sensor T108
QEA051T109PV	Temperatura de Saída Água LT Pré-aquecedor Sensor T109
QEA051T120PV	Temperatura de Saída Água LT Pós-radiadores Sensor T120
SVH051T013PV	Temperatura de Saída Água HT Banco A
SVH051T014PV	Temperatura de Saída Água HT Banco B
SVL051P003PV	Pressão Entrada Água LT
SVH051P003PV	Pressão Entrada Água HT

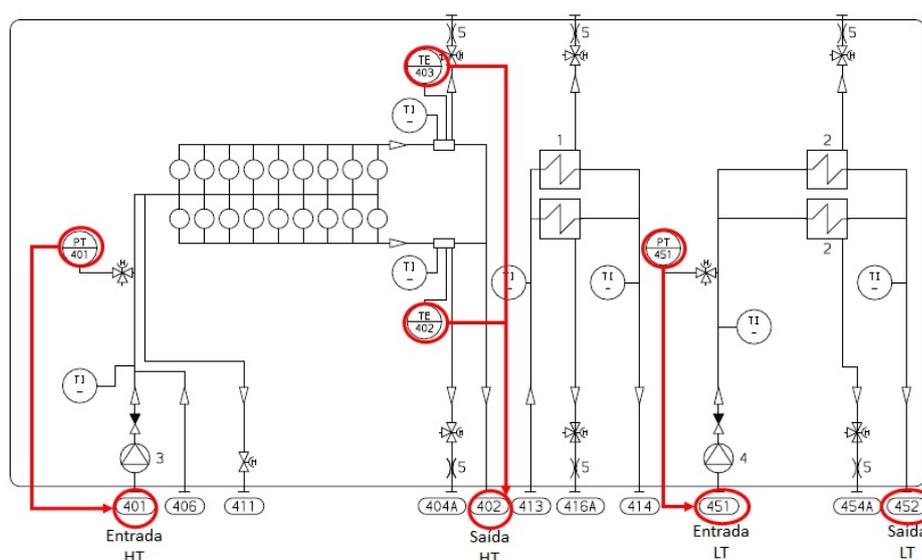


Figura 34 – Diagrama do esquemático interno do subsistema de água de arrefecimento (74).

Neste diagrama, a conexão do tubo denominada 401 representa a entrada da água quente (HT) e interliga o instrumento elétrico (nomeado sensor) que faz a medida da pressão de entrada (representada por PT401) para esta água quente. A conexão do tubo denominada 402 representa a saída da água quente (HT) e interliga os sensores que fazem as medidas das temperaturas de saída para esta água quente do lado A e B (representada por TE402 lado A e TE403 lado B). Já a conexão do tubo denominada 451 representa a entrada da água fria (LT) e interliga os sensores que fazem as medidas da temperatura e pressão de entrada (representada por PT451) para esta água fria. Por fim, a conexão do tubo denominada 452 representa a saída da água fria (LT) e interliga os sensores que fazem as medidas da temperatura e pressão de saída para esta água fria.

### 3.2.8 Subsistema de Gases de Exaustão

O oitavo subsistema a ter as variáveis selecionadas, foi o subsistema de "Gases de Exaustão". Nele, foram associadas as temperaturas dos gases em cada um dos 18 cilindros do motor. A principal função deste subsistema é conduzir os gases provenientes da combustão para a ambiente externo (69).

Para melhor compreensão das variáveis selecionadas para o subsistema de gases de exaustão, a Tabela 8 apresenta as *tags* que representam as variáveis deste subsistema e as suas descrições e a Figura 35 apresenta um esquemático interno convencional deste subsistema por meio de diagrama (75).

Tabela 8 – Tabela que apresenta as *tags* e as descrições das variáveis que compõem o subsistema de gases de exaustão.

Tag	Descrição
SNA051T019PV	Temperatura dos Gases de Exaustão no Cilindro A1
SNA051T021PV	Temperatura dos Gases de Exaustão no Cilindro A2
SNA051T023PV	Temperatura dos Gases de Exaustão no Cilindro A3
SNA051T025PV	Temperatura dos Gases de Exaustão no Cilindro A4
SNA051T027PV	Temperatura dos Gases de Exaustão no Cilindro A5
SNA051T029PV	Temperatura dos Gases de Exaustão no Cilindro A6
SNA051T031PV	Temperatura dos Gases de Exaustão no Cilindro A7
SNA051T033PV	Temperatura dos Gases de Exaustão no Cilindro A8
SNA051T035PV	Temperatura dos Gases de Exaustão no Cilindro A9
SNA051T037PV	Temperatura dos Gases de Exaustão no Cilindro B1
SNA051T039PV	Temperatura dos Gases de Exaustão no Cilindro B2
SNA051T041PV	Temperatura dos Gases de Exaustão no Cilindro B3
SNA051T043PV	Temperatura dos Gases de Exaustão no Cilindro B4
SNA051T045PV	Temperatura dos Gases de Exaustão no Cilindro B5
SNA051T047PV	Temperatura dos Gases de Exaustão no Cilindro B6
SNA051T049PV	Temperatura dos Gases de Exaustão no Cilindro B7
SNA051T051PV	Temperatura dos Gases de Exaustão no Cilindro B8
SNA051T053PV	Temperatura dos Gases de Exaustão no Cilindro B9

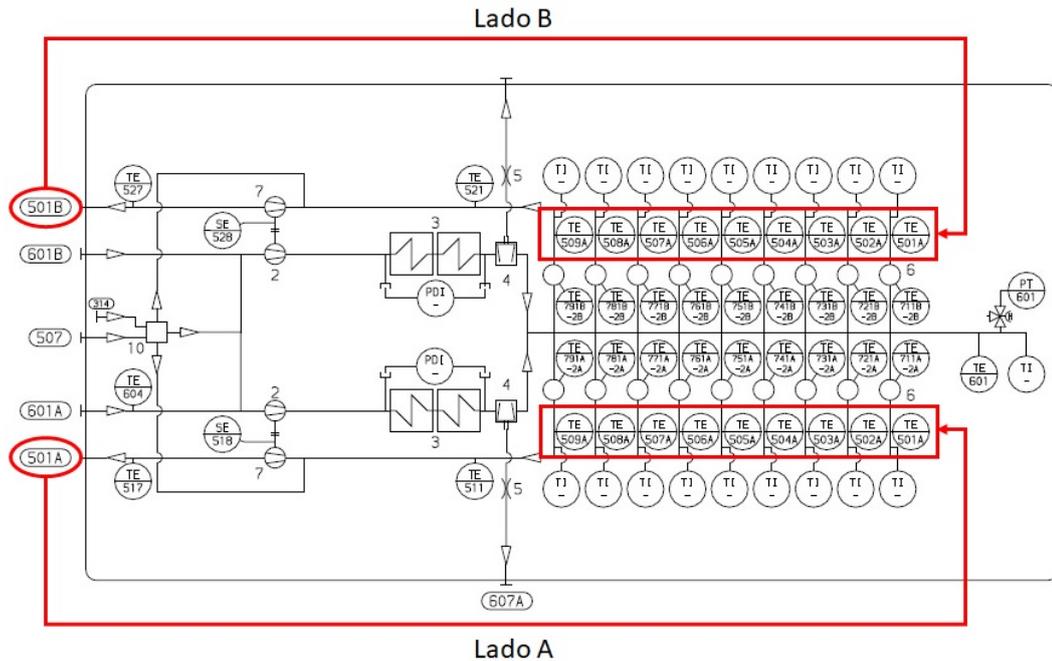


Figura 35 – Diagrama do esquemático interno do subsistema de gases de exaustão (75).

Neste diagrama, a conexão do tubo denominada 501A representa a saída dos gases de exaustão do lado A do motor e interliga os sensores denominados TE501A a TE509A que faz as medidas das temperaturas dos gases em cada um dos 9 cilindros do lado A. Já a conexão do tubo denominada 501B representa a saída dos de gases de exaustão do lado B do motor e interliga os sensores denominados TE501B a TE509B que faz as medidas das temperaturas dos gases nos demais 9 cilindros do lado B. Vale ressaltar que o motor 18V46 é configurado em formato V com 18 cilindros, dispostos em 9 cilindros no lado A e 9 no lado B. Devido a isso, os gases de exaustão também estão dispostas nos lados A e B.

### 3.2.9 Subsistema de Gerador

No nono subsistema, denominado de "Gerador", as variáveis selecionadas foram as temperaturas dos enrolamentos nas fases e nas extremidades do gerador. A função principal deste subsistema é gerar energia elétrica, ou seja, neste trabalho, ele transformar a energia mecânica produzida pelo acionamento do motor em energia elétrica (72).

Para melhor compreensão das variáveis selecionadas para o subsistema de gerador, a Tabela 9 apresenta as tags que representam as variáveis deste subsistema e as suas descrições e a Figura 36 apresenta um desenho do motor 18V46 com os sensores deste subsistema por meio de diagrama (70).

Tabela 9 – Tabela que apresenta as *tags* e as descrições das variáveis que compõem o subsistema de gerador.

Tag	Descrição
BAG051T001PV	Temperatura Gerador Enrolamento Fase U
BAG051T002PV	Temperatura Gerador Enrolamento Fase V
BAG051T003PV	Temperatura Gerador Enrolamento Fase W
BAG051T004PV	Temperatura Gerador Rolamento extremidade D
BAG051T005PV	Temperatura Gerador Rolamento extremidade ND

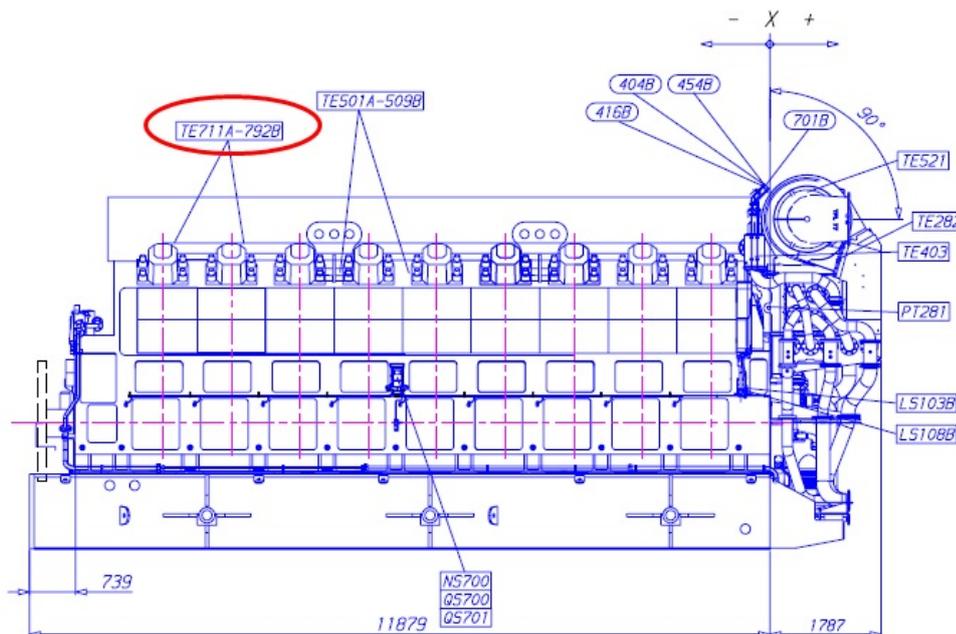


Figura 36 – Diagrama do desenho do motor que ilustra os sensores do subsistema de gerador (70).

Neste diagrama, o círculo vermelho denominado TE711A-TE792B engloba os sensores denominados TE751 a TE755 que fazem as medidas das temperaturas dos enrolamentos nas fases e nas extremidades do gerador.

### 3.2.10 Subsistema de Gás Natural

No décimo subsistema, denominado de "Gás Natural", as variáveis selecionadas foram as pressões de entrada e saída nas válvulas de gás, bem como a vazão e a temperatura de entrada do mesmo. A principal função deste subsistema também é manter o motor em operação, uma vez que ele é utilizado como combustível no processo de combustão (76).

Para melhor compreensão das variáveis selecionadas para o subsistema de gás natural, a Tabela 10 apresenta as *tags* que representam as variáveis deste subsistema e as suas descrições e a Figura 37 apresenta um esquemático interno convencional deste subsistema por meio de diagrama (32).

Tabela 10 – Tabela que apresenta as *tags* e as descrições das variáveis que compõem o subsistema de gás natural.

Tag	Descrição
ZCA051P101PV	Pressão de Entrada do Gás
ZCA051P102PV	Pressão de Saída do Gás
ZCA051Q101PV	Vazão de Entrada do Gás
ZCA051T001PV	Temperatura de Saída do Gás

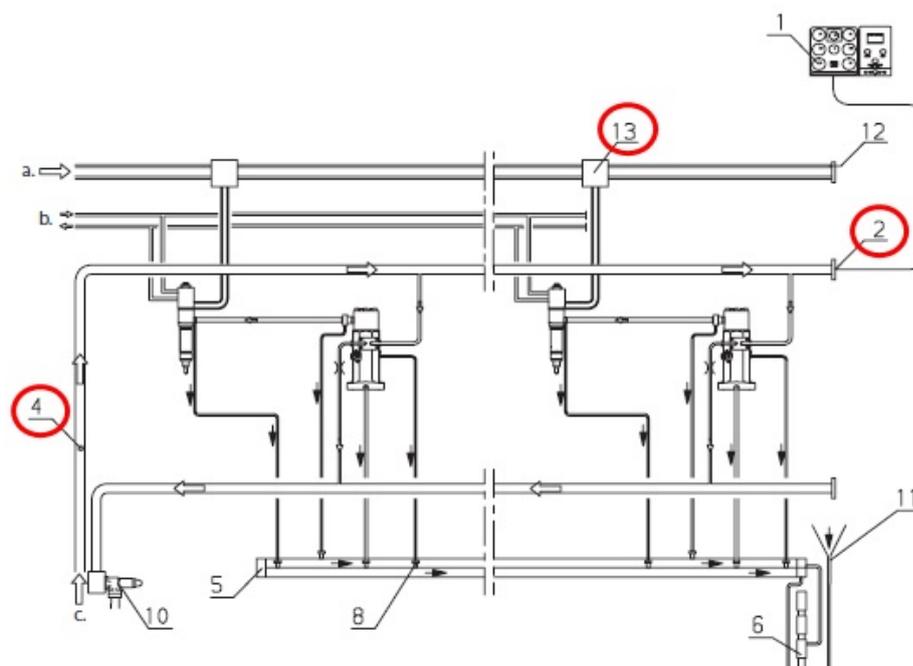


Figura 37 – Diagrama do esquemático geral do subsistema de gás natural (32).

Neste diagrama, o sensor indicado pelo número 2 mede as pressões de entrada e saída nas válvulas de gás. Já os sensores de número 4 e 13 medem a temperatura e a vazão de entrada do gás, respectivamente. Vale ressaltar que a entrada denominada "a" que é responsável pela entrada de gás natural.

### 3.2.11 Subsistema Outros

E por fim, no último subsistema, denominado "Outros", as variáveis selecionadas foram algumas variáveis de interesse que não foram previamente inseridas em outros subsistemas, como a vibração de torção do eixo, a pressão do ar de partida e do ar de controle, os modos de operação dos combustíveis, a porcentagem do gás combustível, a potência ativa do gerador, a temperatura ambiente externa e a umidade absoluta. A principal função deste subsistema é garantir a análise de todas as variáveis de operação presentes neste modelo de motor.

Para melhor compreensão das variáveis selecionadas para o subsistema outros, a Tabela 11 apresenta as *tags* que representam as variáveis deste subsistema e as suas

descrições e a Figura 38 apresenta um desenho do motor 18V46 com os sensores deste subsistema por meio de diagrama (70).

Tabela 11 – Tabela que apresenta as *tags* e as descrições das variáveis que compõem o subsistema de outros.

Tag	Descrição
STA051P003PV	Pressão Entrada do Ar de Partida
STA0511P005PV	Pressão de Entrada da Ar de Controle
SAE051L001PV	Vibração de Torsão do Eixo
CFC051MODEINF	Modo de Operação (GD/HFO)
CFC051FSPV	% de Gás Combustível
BAE051UP01PV	Potência ativa no gerador
BAG051UP01AV	Valor definido de potência ativa atual no PLC ( <i>Programmable Logic Controller</i> )
NGA901T001PV	Temperatura Ambiente Externa
NGA901E001PV	Umidade absoluta

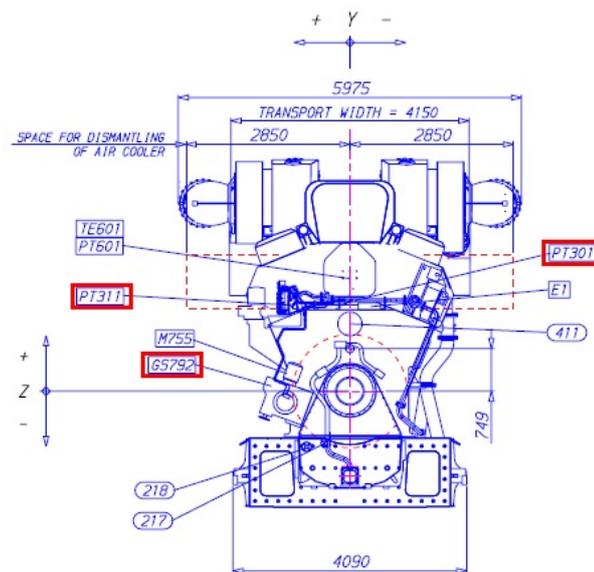


Figura 38 – Diagrama do desenho do motor que ilustra os sensores do subsistema outros (70).

Neste diagrama, os sensores denominados PT301 e PT311 fazem as medidas das pressões de ar de partida e de controle. Já o sensor denominado GS792 faz a medida da vibração de torção do eixo.

Vale ressaltar que tanto no subsistema "Outros" quanto nos outros 10 subsistemas do modelo estatístico, uma nova variável pode ser incluída no futuro, se necessário. Sendo assim, de posse das variáveis que constituem cada subsistema, o próximo passo é apresentar a base de dados destas variáveis. Para isso, a subseção 3.3 descreve a base de dados de um sistema de monitoramento de UTEs.

### 3.3 Base de dados de um sistema de monitoramento de UTEs

A base de dados de um sistema de monitoramento de uma UTE específica, que trabalha com dois tipos de combustíveis, sendo gás e Óleo Combustível Pesado (*Heavy Fuel Oil*, HFO), foi disponibilizada para acesso e tem formato de tabelas. Em cada uma destas tabelas estão dispostos uma grande quantidade de medidas (em gás e HFO) das variáveis por unidade geradora que foram realizadas por sensores. Em outros termos, cada tabela representa uma variável de uma unidade geradora e comporta a grande quantidade de dados (em gás e HFO) medidos por sensores de cada uma destas variáveis em específico relacionadas ao funcionamento da usina como, por exemplo, a potência do motor, a temperatura, a pressão, a velocidade do gerador, entre outras, totalizando 113 variáveis. Todas essas medidas realizadas por sensores são feitas em períodos não constante, pois o sistema utiliza uma “banda morta” de 10 minutos dentro da qual as medidas podem variar sem que sejam gerados um registro de leitura diferente, ou seja, enquanto a medida de entrada permanecer dentro da “banda morta”, não ocorre gravação de novos registros. Assim, só são gravados em disco os registros de medidas quando elas saem de dentro desta banda. Porém, caso não haja nenhum registro novo após 10 minutos, o sistema grava por padrão um registro com o valor atual da medida. Conseqüentemente, devido a esta situação, sabe-se que as variáveis medidas possuem tamanhos de arquivos diferentes, entretanto, nada se sabe sobre a distribuição que essas variáveis seguem. Porém, como já mencionado na subseção 2.1.4, é fundamental que estes dados sigam uma distribuição normal, uma vez que o diagrama de controle é construído com este tipo de distribuição e as análises deste trabalho são realizadas a partir deste diagrama. Sendo assim, de acordo com a seção 2.2, existem na literatura vários métodos que são capazes de avaliar se os dados seguem ou não uma distribuição normal, também conhecida como distribuição gaussiana (49). Portanto, na seção 3.4 será descrito detalhadamente a aplicação destes principais métodos de teste de normalidade nos dados fornecidos pela UTE RAESA, a fim de avaliar se estes dados seguem ou não uma distribuição normal.

### 3.4 Aplicação do Teste de Normalidade

Tendo a base de dados fornecida pela UTE RAESA, o primeiro passo realizado para aplicar o teste de normalidade, foi selecionar o conjunto de dados dos três primeiros meses do motor 5, na qual tem a mesma base de dados e *timestamp*. A partir disso, com estes arquivos nas mesmas quantidades de medidas, foram selecionadas as medidas feitas em gás. Após isto, nestes dados foi aplicado o primeiro teste de normalidade, sendo ele visual, denominado histograma. A partir destes resultados, foi verificado que algumas variáveis se comportavam como variáveis discretas e outras como variáveis contínuas. Também a partir destes resultados, foi verificado na variável potência que o motor 5 desta UTE trabalhava

grande parte de operação na potência de 16800kW, porém, tinha momentos em que ele trabalhava na potência de 16600kW, 16850kW e até 17000kW. Sendo assim, a partir deste ponto em diante foram utilizados os dados gerados no ponto de operação do motor 5 em 16800kW, pois é a potência que este motor mais trabalhou, e foram selecionados 5 variáveis deste mesmo motor para realizar a aplicação dos testes de normalidade e provar se estes dados seguem ou não uma distribuição Gaussiana. Vale ressaltar que foram escolhidas somente 5 variáveis para apresentar os resultados dos testes de normalidade, pois apresentar os resultados dos testes de todas as variáveis que compõem o motor 5 não ficaria prático. As 5 variáveis selecionadas foram: potência ativa do gerador, temperatura de saída do óleo lubrificante, temperatura de revestimento do cilindro B7 (sensor 1), temperatura de revestimento do cilindro B4 (sensor 2) e temperatura de revestimento do cilindro A6 (sensor 2), pois correspondem as variáveis que apresentaram problemas segundo o diário de turno fornecido pela UTE. A aplicação do teste de normalidade nestas variáveis foi realizada por meio de duas formas, visual e estatística, conforme abordado nas subseções 3.4.1 e 3.4.2.

### 3.4.1 Aplicação do Teste de Normalidade Visual

A aplicação do Teste de Normalidade Visual foi feita de duas formas através do histograma e do gráfico Q-Q Plot. Para realizar a primeira forma deste tipo de teste, ou seja, para gerar o histograma, inicialmente, foram selecionadas os dados em gás das 5 variáveis do motor 5 escolhidas para testar a normalidade. Em seguida, estes dados foram divididos em classes na qual demonstram valores assumidos pelas variáveis em pauta e em frequências na qual esses mesmos dados apareciam em cada uma destas classes, formando as barras que caracterizam o histograma de cada uma dessas variáveis, conforme ilustrado nas Figuras 39, 40, 41, 42 e 43. Vale ressaltar que, conforme já foi supramencionado, foram utilizados os dados gerados no ponto de operação em 16800kW para a realização dos testes de normalidade, pois é a potência que este motor mais trabalhou.

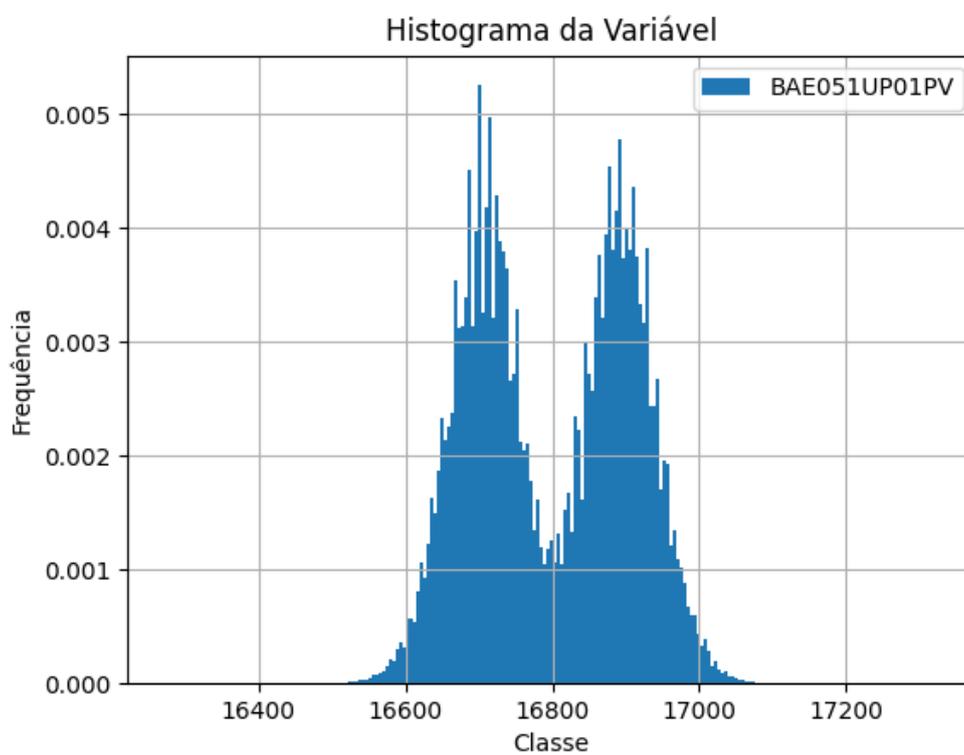


Figura 39 – Histograma da Potência Ativa do Gerador.

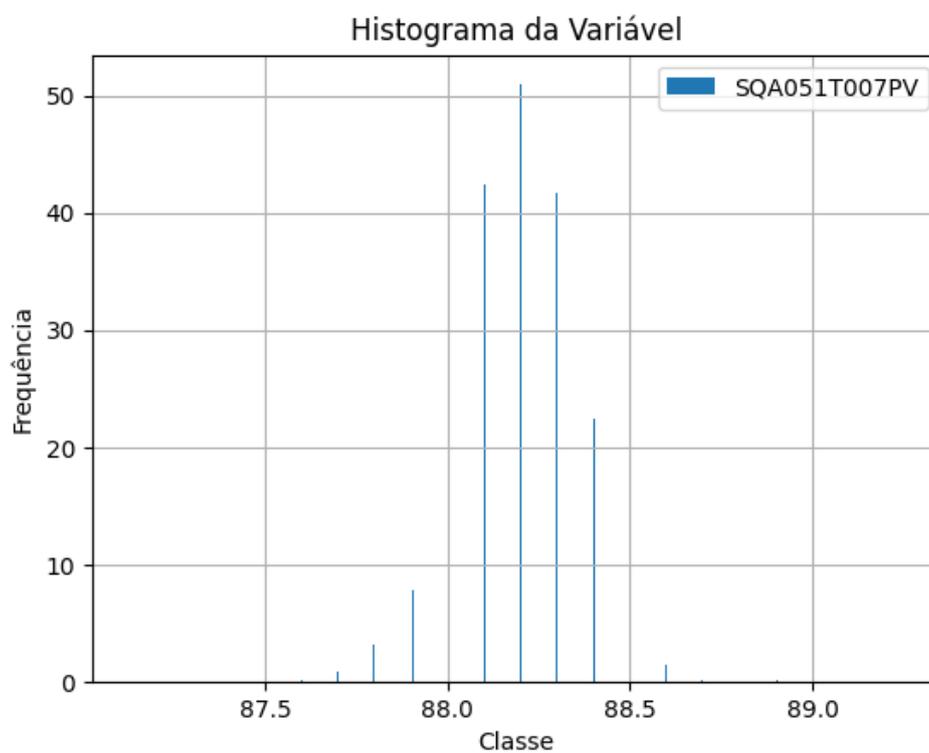


Figura 40 – Histograma da Temperatura de Saída do Óleo Lubrificante.

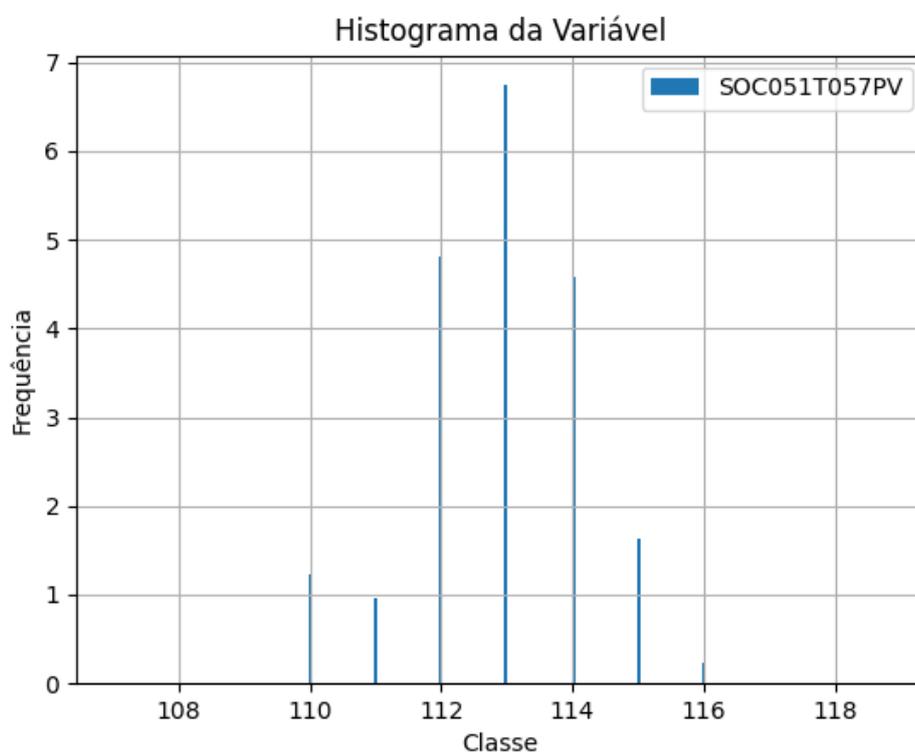


Figura 41 – Histograma da Temperatura do Cilindro B7 sensor 1.

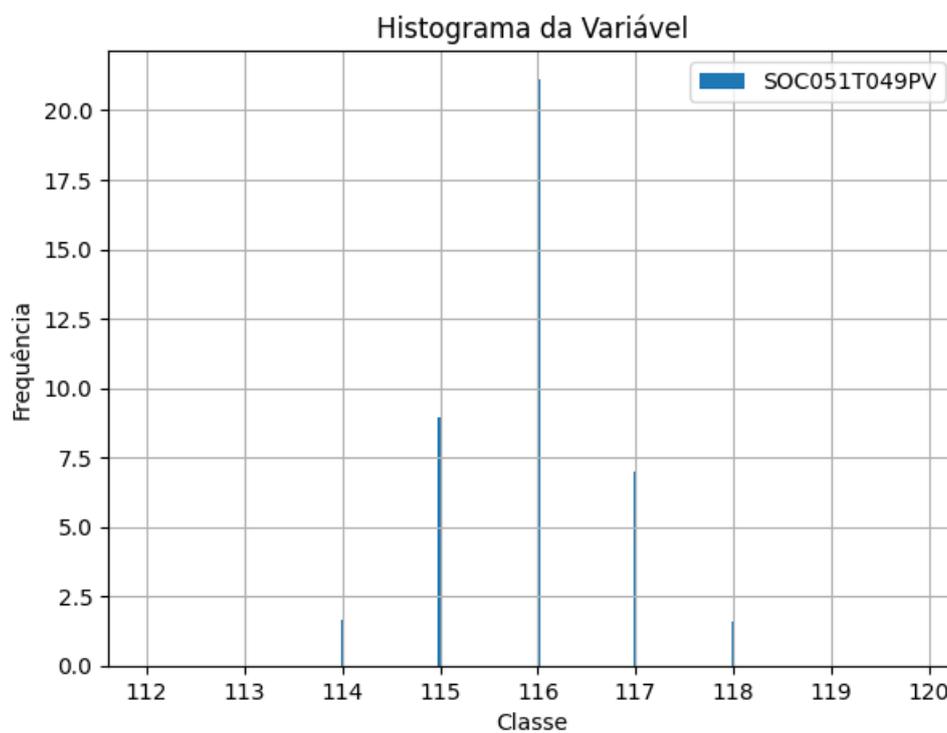


Figura 42 – Histograma da Temperatura do Cilindro B4 sensor 2.

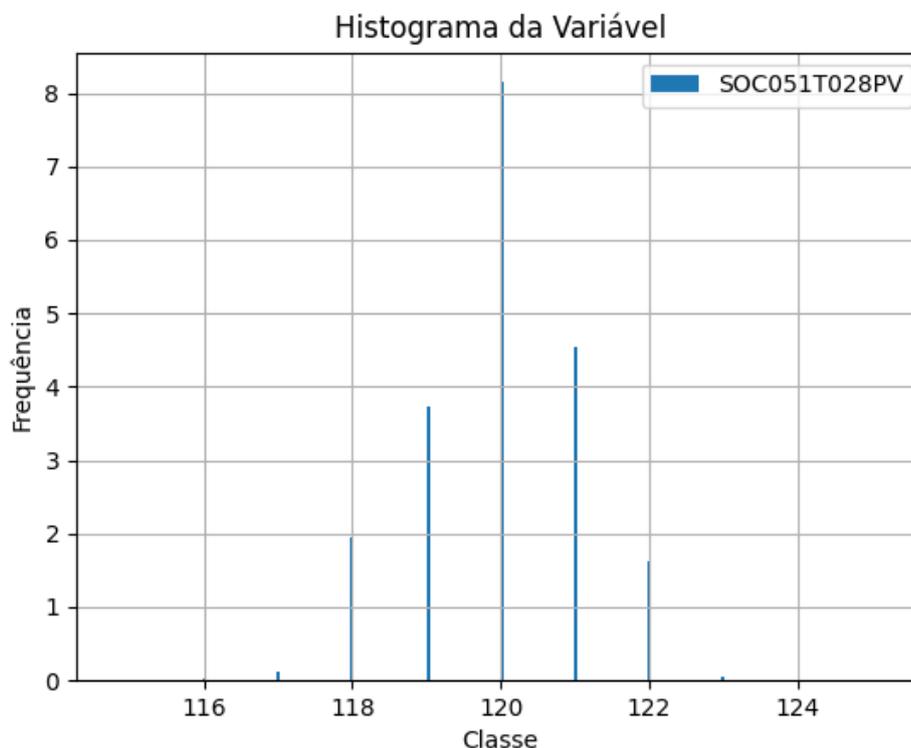


Figura 43 – Histograma da Temperatura do Cilindro A6 sensor 2.

Na Figura 39, percebe-se que os dados da potência ativa do gerador do motor 5, trabalhando em gás, se comportam como variável contínua, por assumirem valores inteiros e fracionários em um intervalo específico, na qual estes valores são representados por várias barras. Observa-se também, nesta Figura, que estes dados não seguem uma distribuição normal, uma vez que as barras deste histograma estão bem distantes do formato de um sino que caracteriza uma distribuição normal.

Nas Figuras 40, 41, 42 e 43, percebe-se que os dados da temperatura de saída do óleo lubrificante, da temperatura de revestimento do cilindro B7 (sensor 1), da temperatura de revestimento do cilindro B4 (sensor 2) e da temperatura de revestimento do cilindro A6 (sensor 2), todos do motor trabalhando em gás, se comportam como variáveis discretas por assumirem apenas valores inteiros e finitos, na qual são representados por barras em valores específicos. Nota-se também, nestas Figuras, que estes dados não seguem uma distribuição normal, uma vez que este tipo de distribuição é contínua e as barras destes histogramas são discretas o que significa que estão ainda mais distantes do formato de um sino que representa uma distribuição normal.

Para realizar a segunda forma de Teste de Normalidade Visual, foi inicialmente utilizado o mesmo procedimento da primeira forma, ou seja, selecionou-se as tabelas que contém os dados em gás das 5 variáveis do motor 5 escolhidas para testar a normalidade. Em seguida, gerou-se os quantis destes dados e comparou-se com os quantis teóricos de

uma distribuição normal, formando os gráficos Quantil- Quantil, também chamado de Q-Q Plot, de cada uma dessas variáveis, conforme ilustrado nas Figuras 44, 45, 46, 47 e 48. Vale ressaltar que, conforme já foi supramencionado, foram utilizados os dados gerados no ponto de operação do motor em 16800kW para a realização dos testes de normalidade, pois é a potência que este motor mais trabalhou.

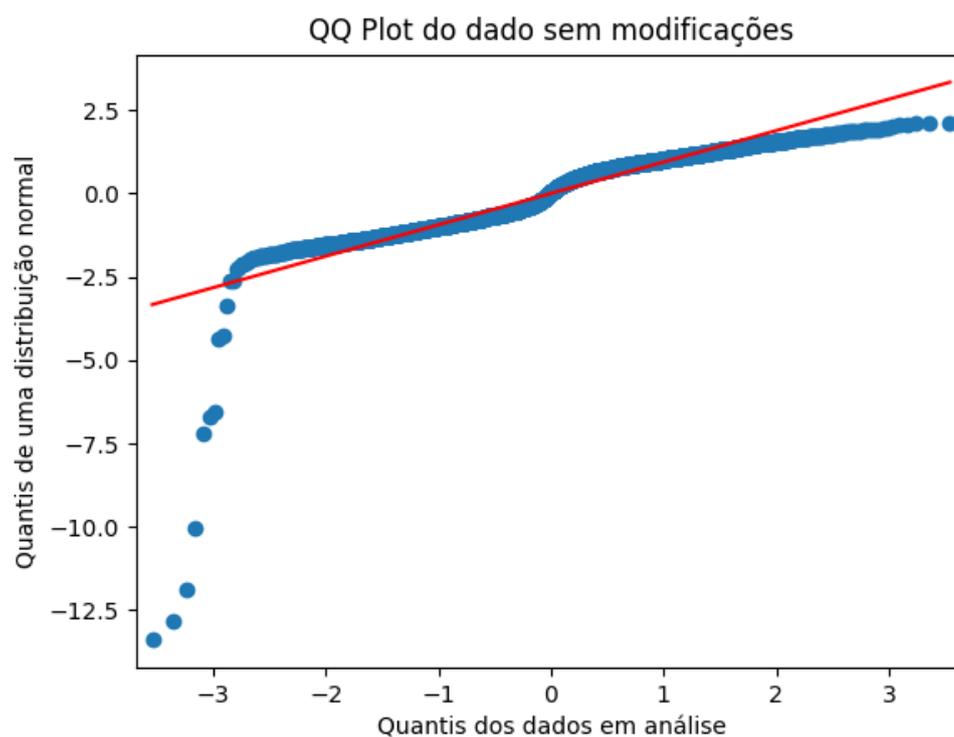


Figura 44 – Gráfico Q-Q Plot da Potência Ativa do Gerador.

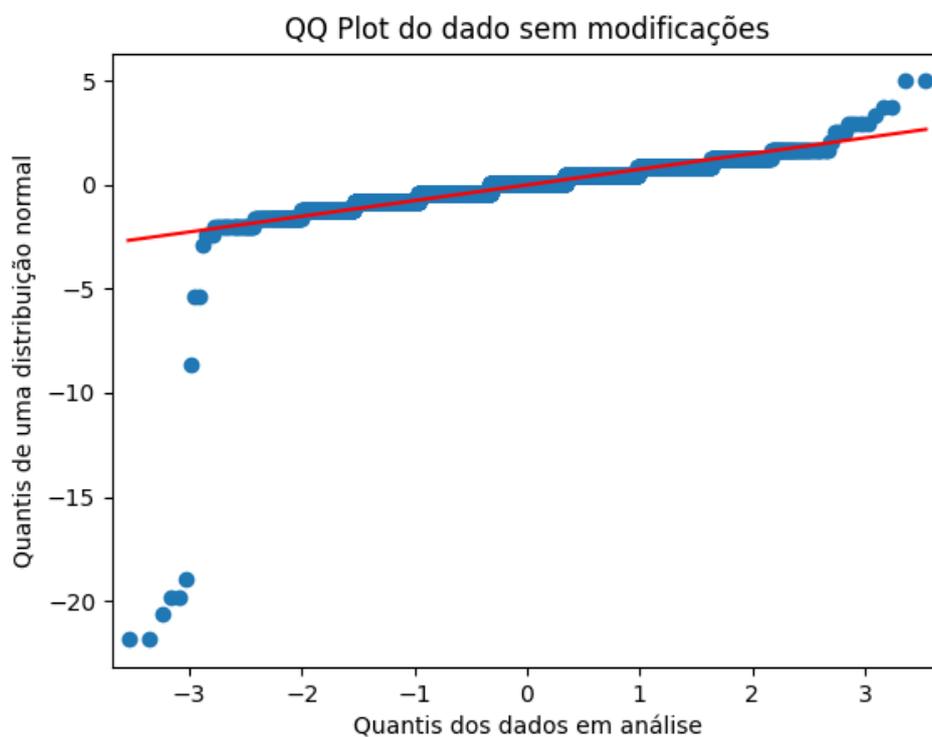


Figura 45 – Gráfico Q-Q Plot da Temperatura de Saída do Óleo Lubrificante.

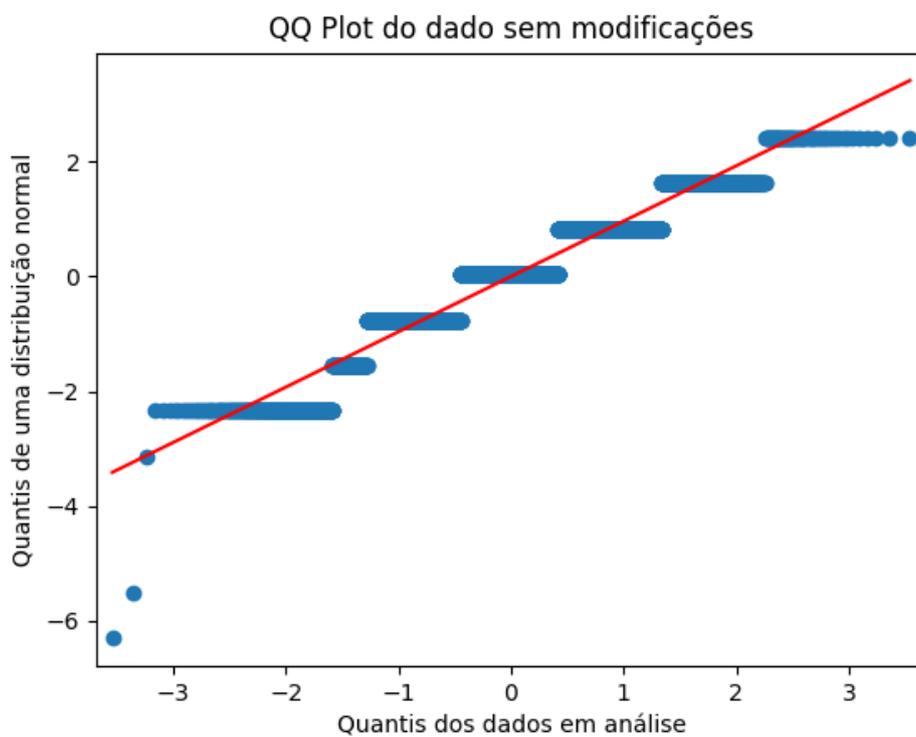


Figura 46 – Gráfico Q-Q Plot da Temperatura de revestimento do Cilindro B7 sensor 1.

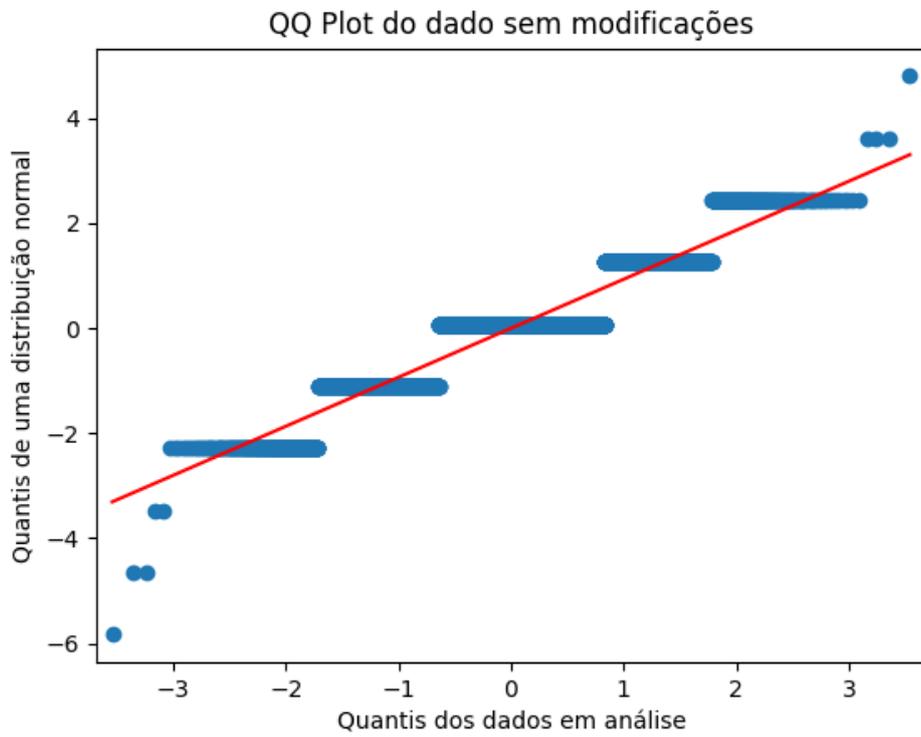


Figura 47 – Gráfico Q-Q Plot da Temperatura de revestimento do Cilindro B4 sensor 2.

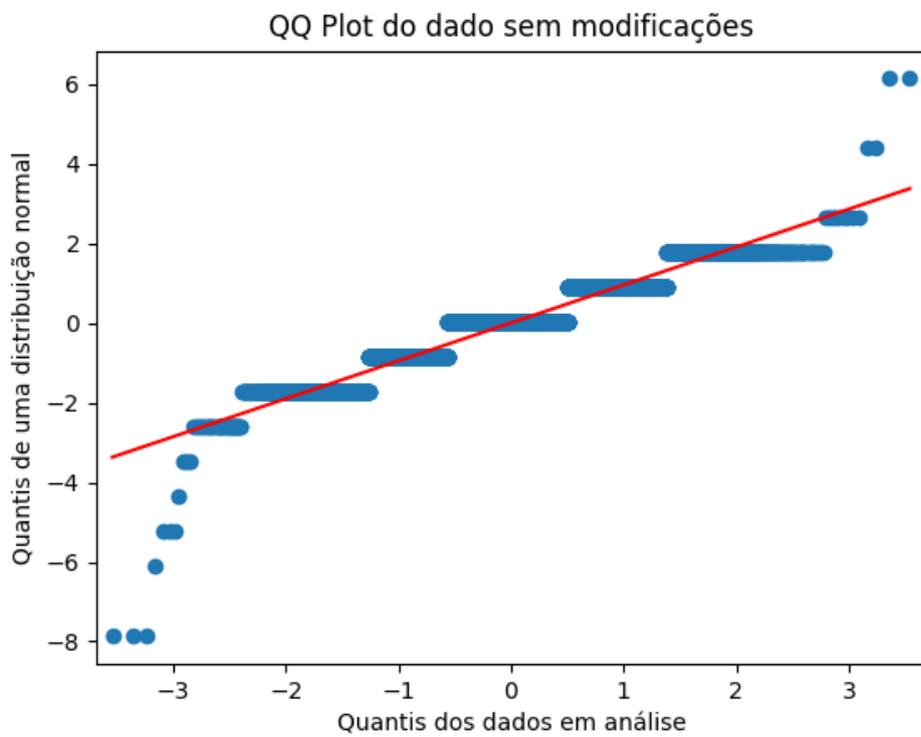


Figura 48 – Gráfico Q-Q Plot da Temperatura de revestimento do Cilindro A6 sensor 2.

Por meio da Figura 44, nota-se que os dados da potência ativa do gerador do motor, trabalhando em gás, não tem uma boa aderência à distribuição normal, pois os dados em questão não estão próximos da reta de referência (reta vermelha), concluindo que esta variável não segue uma distribuição normal.

Nas Figuras 45, 46, 47 e 48, percebe-se que os dados da temperatura de saída do óleo lubrificante, da temperatura de revestimento do cilindro B7 (sensor 1), da temperatura de revestimento do cilindro B4 (sensor 2) e da temperatura de revestimento do cilindro A6 (sensor 2), todos do motor 5 trabalhando em gás, possuem quantis em lugares específicos devido a característica de variáveis discretas. Conseqüentemente, nota-se também, nestas Figuras, que estes dados não tem uma boa aderência à distribuição normal, uma vez que os quantis discretos destes gráficos Q-Q Plot não estão próximos da reta de referência (reta vermelha), concluindo que estas variáveis também não seguem uma distribuição normal.

### 3.4.2 Aplicação do Teste de Normalidade Estatístico

Neste trabalho, além dos testes visuais, foi realizado também, a aplicação do Teste de Normalidade Estatístico através do Teste de Kolmogorov Smirnov (KS) (63), uma vez que este tipo de teste cobre a deficiência dos testes visuais, na qual é a garantia da normalidade dos dados por possuírem aderência a distribuição normal. Para melhor entendimento da aplicação deste teste, ele foi realizado em etapas, cuja descrições são:

1. Acesso à Base de Dados: foram selecionadas as mesmas 5 variáveis do motor 5 trabalhando em gás, utilizadas para realizar o teste de normalidade visual. Vale ressaltar que, também neste tipo de teste, esses dados foram gerados do ponto de operação do motor em 16800kW, pois é a potência que este motor mais trabalhou;
2. Formulação de hipóteses: foi formulado as hipóteses nula ( $H_0$ ) e alternativa ( $H_1$ ). A hipótese nula afirma que os dados seguem uma distribuição normal, enquanto a hipótese alternativa afirma que os dados não seguem uma distribuição normal;
3. Definição do nível de significância: Antes de realizar o teste KS, é necessário definir o nível de significância (geralmente denotado por  $\alpha$ ), que determina o limiar para rejeitar  $H_0$ . Neste trabalho, o valor definido para o nível de significância foi 0.05, o que significa que há uma probabilidade de 5% de rejeitar erroneamente  $H_0$  quando ela é verdadeira;
4. Realização do teste: O teste de normalidade KS foi aplicado nos dados das 5 variáveis do motor 5 selecionadas. O teste gera uma estatística de teste e um valor-p, que indica a probabilidade de obter a estatística de teste observada, assumindo que a

hipótese nula é verdadeira. Com base no valor-p, é possível tomar uma decisão em relação à hipótese nula;

5. Interpretação dos resultados: Com base no valor-p e no nível de significância escolhido, pode-se tomar uma decisão sobre os resultados. Se o valor-p for maior que o nível de significância de 5%, não há evidências suficiente para rejeitar  $H_0$ , o que significa que as variáveis podem ser consideradas aproximadamente normais. Caso contrário, se o valor-p for menor que o nível de significância, há evidências para rejeitar  $H_0$ , sugerindo que as variáveis não seguem uma distribuição normal.

Seguindo as descrições anteriores, foi aplicado o teste KS nas 5 variáveis escolhidas do motor 5 que trabalha em gás. Os resultados destes testes são mostrados na Tabela 12.

Tabela 12 – Tabela que apresenta os resultados dos testes KS para cada uma das variáveis selecionadas.

Variáveis selecionadas	Valor p para a Distribuição Normal
Potência Ativa do Gerador	$9.9198 \times 10^{-36}$
Temperatura de Saída do Óleo Lubrificante	$2.9096 \times 10^{-108}$
Temperatura de revestimento do Cilindro B7 sensor 1	$1.7769 \times 10^{-153}$
Temperatura de revestimento do Cilindro B4 sensor 2	$8.2235 \times 10^{-103}$
Temperatura de revestimento do Cilindro A6 sensor 2	$5.2582 \times 10^{-08}$

Sabendo-se que a variável potência ativa do gerador se comporta como variável contínua, observa-se na Tabela 12 que o valor de p (para a distribuição normal) do teste KS para esta variável é igual a  $9.9198 \times 10^{-36}$ . Consequentemente, este valor é menor que o nível de significância  $\alpha$ , ou seja,  $9.9198 \times 10^{-36} < 0.05$ . Portanto, pode-se concluir que, há evidências para rejeitar  $H_0$ , sugerindo que a variável potência ativa do gerador não segue uma distribuição normal.

Sabendo-se também que as variáveis temperatura de saída do óleo lubrificante, temperatura de revestimento do cilindro B7 (sensor 1), temperatura de revestimento do cilindro B4 (sensor 2) e temperatura de revestimento do cilindro A6 (sensor 2) se comportam como variáveis discretas, nota-se na Tabela 12 que os valores de p (para a distribuição normal) dos testes KS para estas variáveis são  $2.9096 \times 10^{-108}$ ,  $1.7769 \times 10^{-153}$ ,  $8.2235 \times 10^{-103}$  e  $5.2582 \times 10^{-08}$ . Consequentemente, estes valores são bem menores que o nível de significância  $\alpha$ , ou seja,  $2.9096 \times 10^{-108}$ ,  $1.7769 \times 10^{-153}$ ,  $8.2235 \times 10^{-103}$  e  $5.2582 \times 10^{-08} < 0.05$ . Portanto, pode-se concluir também que, há evidências para rejeitar  $H_0$ , sugerindo que tanto a variável temperatura de saída do óleo lubrificante quanto as variáveis de temperatura de revestimento dos cilindros B7 (sensor 1), B4 (sensor 2) e A6 (sensor 2) não seguem uma distribuição normal.

A partir dos resultados dos testes de normalidade visuais e estatísticos realizados nesta subseção, foi certificado qual tipo de classificação melhor se adaptava as medidas de

cada variável analisada e concluiu-se que uma variável se comportava com característica contínua e as outras com características discretas, no entanto, nenhuma delas seguiam uma distribuição normal. Devido a isso, foi necessário realizar uma manipulação nos dados, uma vez que a proposta deste trabalho de monitorar a condição operacional de unidades motogeradoras a partir das variáveis que a compõem via regras de Nelson dependem deste tipo de distribuição.

### 3.5 Normalização dos Dados

Conforme foi demonstrado na seção 3.4, algumas variáveis da base de dados fornecidas pela UTE RAESA possuem características discretas e outras possuem características contínuas, porém, nenhuma delas seguem uma distribuição Gaussiana. Sabendo-se disso, nesta seção, será realizado uma manipulação nestes dados, denominado normalização dos dados, com o objetivo de transformar tanto os dados contínuos quanto os dados discretos em normais. Para melhor compreensão desta manipulação dos dados, a Figura 49 apresenta um diagrama em blocos do processo de normalização de uma variável em geral.

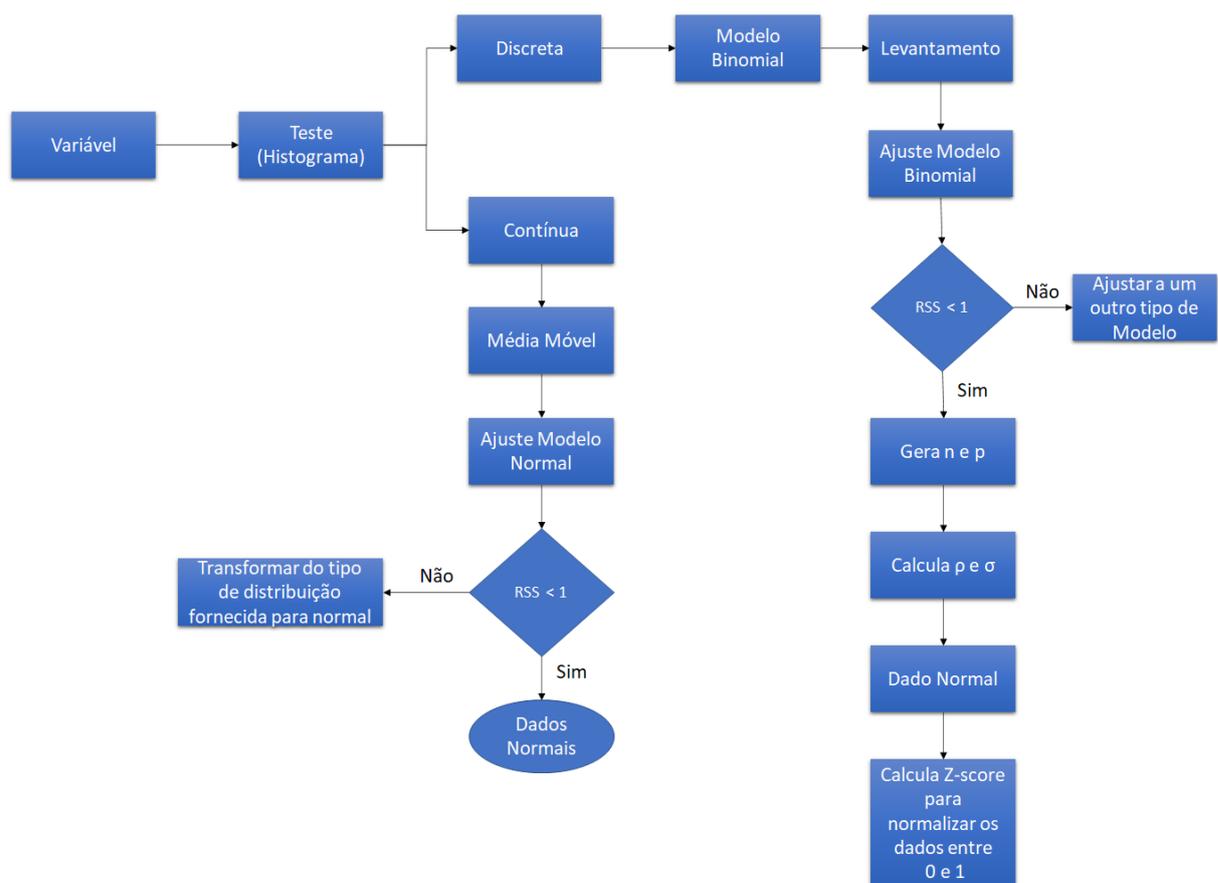


Figura 49 – Diagrama em blocos da Normalização dos Dados.

Neste diagrama, o bloco Teste (histograma) permite realizar a classificação da variável em discreta ou contínua. Após a classificação, se a variável é contínua, aplica-se uma média móvel <sup>1</sup>(77) nestes dados, conforme ilustrado pelo bloco denominado média móvel, com a finalidade de suavizar a equiparação do *timestemp* destes dados com os dados da potência ativa do gerador. Após isto, um ajuste do modelo normal a estes dados é aplicado via um pacote do *software* Python, denominado Distfit, para distribuições paramétricas, através da técnica de máxima verossimilhança para estimar os parâmetros desta distribuição (68), conforme descreve a seção 2.4. A avaliação da qualidade deste ajuste é feita a partir do cálculo da Soma Residual dos Quadrados (*Residual Sum of Squares*, RSS) (67). Esse cálculo é realizado por meio da diferença entre o dado real da variável em questão e a estimativa deste dado, conforme mostra a fórmula 3.1 (67).

$$RSS = \sum_{i=1}^n (y_i - f(x_i))^2 \quad (3.1)$$

onde  $y_i$  é o  $i$ -ésimo valor da variável a ser prevista,  $x_i$  é o  $i$ -ésimo valor da variável a ser explicada e  $f(x_i)$  é o valor previsto de  $y_i$  (também denominado de  $\hat{y}_i$ ).

Por fim, após realizado o cálculo de RSS, é verificada a condição de normalidade dos dados através da condição  $RSS < 1$ , representada pelo losango do diagrama em blocos. Caso essa condição seja verdadeira, significa que os dados são considerados normais. Caso contrário, significa que os dados precisam ser transformados do tipo de distribuição que o Distfit apontou para distribuição normal. Vale ressaltar que este valor numérico 1 é alternativo e foi considerado como métrica de verificação de normalidade para este trabalho. Vale ressaltar também que quanto menor o valor de RSS mais próximo está o ajuste do modelo normal aos dados da variável em questão.

Agora, se após a classificação, a variável for discreta, aplica-se um modelo binomial (68), conforme ilustrado pelo bloco denominado modelo binomial, com a finalidade de ajustar os dados discretos a um modelo de distribuição discreta que possa ser transformada ou ajustada a uma distribuição normal. Após isto, os dados são transformados em formatos de experimento de *Bernoulli*, ou seja, são colocados em formato de caso de sucesso e caso de insucesso, através do bloco denominado levantamento. Em seguida, é aplicado um ajuste do modelo binomial a estes dados, através da técnica de máxima verossimilhança para estimar os parâmetros desta distribuição, conforme descreve a seção 2.4, via um pacote do *software* Python, denominado Distfit, no entanto, agora para distribuições discretas. A avaliação da qualidade deste ajuste é feita a partir do cálculo da RSS (67). Esse cálculo é realizado pela mesma fórmula 3.1 descrita anteriormente (67). Após realizado o cálculo de RSS, é verificada a condição de ajuste dos dados a distri-

<sup>1</sup> A média móvel é uma técnica estatística utilizada para analisar dados sequenciais, como séries temporais. Ela é calculada através da média dos valores de um conjunto de dados em um determinado intervalo de tempo, onde esse intervalo se desloca ao longo da série.

buição binomial através da condição  $RSS < 1$ , representada pelo losango do diagrama em blocos. Caso essa condição seja verdadeira, significa que os dados se adequaram ao modelo binomial proposto. Caso contrário, significa que os dados precisam ser ajustados a um outro tipo de modelo discreto. Vale ressaltar que este valor numérico 1 também é alternativo e foi utilizado como métrica de verificação de normalidade para este trabalho. Vale ressaltar também que quanto menor o valor de RSS mais próximo está o ajuste do modelo binomial aos dados da variável discreta em análise. Tendo os dados adequados a distribuição binomial, eles podem ser aproximados de uma distribuição normal, pois segundo o teorema central do limite (TCL), definido no Apêndice A, todas as vezes que ocorrer a soma de várias variáveis aleatórias, a sua distribuição aproxima da normal (68). Como os dados são binomiais (ver Apêndice B), gera-se os parâmetros  $n$  e  $p$  (denominados, respectivamente, por número de repetições de um experimento e a probabilidade deste experimento ocorrer), através do bloco denominado "Gera  $n$  e  $p$ ". Após isto, realiza-se a aproximação da distribuição binomial pela normal (através do cálculo dos parâmetros que caracterizam uma variável aleatória, como média e desvio padrão, dado por  $\mu = n * p$  e  $\sigma = \sqrt{n * p * (1 - p)}$  (68), conforme mostra o bloco denominado "Cálculo de  $\mu$  e  $\sigma$ ". Vale ressaltar que, para a distribuição binomial, a aproximação para normal tem pouco erro quando  $np > 5$  e  $n(1 - p) > 5$  (68) (ver Apêndice B.2). Em seguida deste cálculo, o bloco denominado "Bloco Normal", demonstra que neste momento da manipulação dos dados, os dados seguem uma distribuição normal. Por fim, é realizado o cálculo de Z-score neste dados com o objetivo de normalizar os valores entre 0 e 1, ou seja, em outras palavras, mapear os dados em uma distribuição normal com média igual a zero e desvio padrão igual a 1. Vale ressaltar que os dados utilizados no processo de normalização dos dados desta subseção foram retirados do motor 5 trabalhando em gás e com o ponto de operação em 16800kW, pois é a potência que esse motor mais trabalhou.

Objetivando validar a normalização do dado contínuo selecionado, denominado potência ativa do gerador, a Tabela 13 mostra, a título de ilustração, o resultado da aplicação do pacote Distfit nesta variável contínua.

Tabela 13 – Tabela que apresenta o resultado do ajuste contínuo da distribuição normal aos dados da variável potência ativa do gerador via Distfit.

Variável selecionada	Distribuição	RSS	Loc	Scale
Potência Ativa do Gerador	Normal	0.0115695	16798.598	31.694

Na Tabela 13 percebe-se a excelente aderência entre o resultado teórico e simulado do valor de RSS para a distribuição normal, pois teoricamente, quanto menor o valor de RSS, mais os dados se aproximam de uma distribuição normal. E como o valor de RSS para esta variável é de aproximadamente 0.0116, pode-se concluir que esta variável segue uma distribuição normal.

Como complemento do resultado do ajuste contínuo via Distfit apresentado na

Tabela 13, foi aplicado o teste de normalidade visual nesta variável, através do histograma, cujo resultado é mostrado na Figura 50.

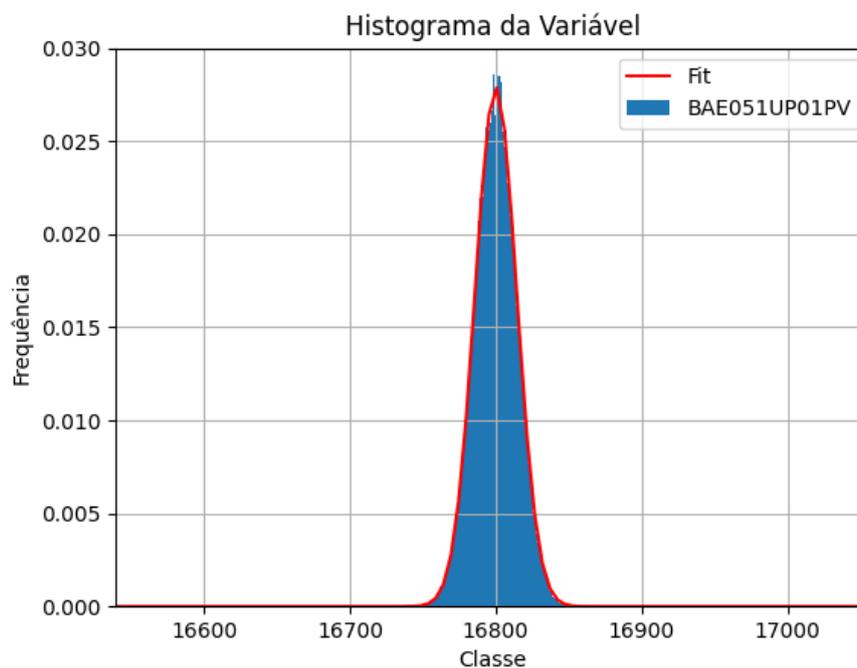


Figura 50 – Histograma da potência ativa do gerador após ajuste contínuo via Distfit.

O resultado mostrado na Figura 50 confirma, de modo geral, a conclusão obtida por meio da Tabela 13.

Agora objetivando validar o modelo binomial nos dados discretos selecionados do motor, que opera em gás e no ponto de operação de 16800kW, denominadas temperatura de saída do óleo lubrificante, temperatura de revestimento do cilindro B7 (sensor 1), temperatura de revestimento do cilindro B4 (sensor 2) e temperatura de revestimento do cilindro A6 (sensor 2), a Tabela 14 mostra, a título de ilustração, os resultados da aplicação do pacote Distfit nestas variáveis discretas.

Tabela 14 – Resultados do ajuste discreto da distribuição binomial aos dados das variáveis temperatura de saída do óleo lubrificante e temperatura de revestimento dos cilindros B7 (sensor 1), B4 (sensor 2) e A6 (sensor 2) via Distfit.

Variável selecionada	Distribuição	RSS	n	p
Temperatura de Saída do Óleo Lubrificante	Binomial	0.164	10	0.975281
Temperatura de revestimento do cilindro B7 (sensor 1)	Binomial	0.0209	11	0.53676
Temperatura de revestimento do cilindro B4 (sensor 2)	Binomial	0.0847	9	0.44969
Temperatura de revestimento do cilindro A6 (sensor 2)	Binomial	0.0502	10	0.44567

Observa-se na Tabela 14, a excelente aderência entre os resultados teóricos e simulados do valor de RSS para a distribuição binomial, pois teoricamente, quanto menor

o valor de RSS, mais os dados se aproximam de uma distribuição binomial. E como os valores de RSS para estas variáveis são de aproximadamente 0.164, 0.0209, 0.0847 e 0.0502, respectivamente, ou seja, esses valores são menores do que a condição  $RSS < 1$ , pode-se concluir que estas variáveis seguem uma distribuição binomial e, conseqüentemente, estes dados podem ser aproximados para distribuição normal, segundo TCL (ver Apêndice A), através do cálculo da média e desvio padrão. Vale ressaltar que esses cálculos são realizados a partir dos parâmetro  $n$  e  $p$  fornecidos por esta distribuição binomial. Vale ressaltar também que quanto maior o valor de  $n$  relativo ao valor de  $p$ , para estes cálculos, melhor a aproximação da normal aos dados.

De posse das normalidades das variáveis, o próximo passo é apresentar os processos estatísticos aplicados nestas variáveis para a criação do modelo estatístico. Para isso, a seção 3.6 descreve os cálculos estatísticos realizados para todas as variáveis.

### 3.6 Cálculos estatísticos para as variáveis

Para realizar o cálculo estatístico do parâmetro denominado média (representada por  $\bar{x}$ ), inicialmente, seleciona-se os conjuntos de dados históricos reais, em gás e com ponto de operação em 16800kW, de cada variável que a UTE enviou representados por  $x[n]$ . Então, a média desses conjuntos de dados é dada por

$$\bar{x} = \left( \frac{1}{N} \sum_{n=1}^N x[n] \right), \quad (3.2)$$

onde  $N$  é o número total de amostras de cada variável monitorada.

Para realizar o cálculo estatístico do parâmetro denominado desvio padrão (representado por  $s$ ), inicialmente, da mesma forma que para o cálculo da média, seleciona-se os conjuntos de dados históricos reais, em gás e com ponto de operação em 16800kW, de cada variável que a UTE enviou representados por  $x[n]$ . Então, o desvio padrão desses conjuntos de dados é dada por

$$s = \sqrt{\frac{\sum_{n=1}^N (x[n] - \bar{x})^2}{N - 1}}, \quad (3.3)$$

onde  $N$  é o número total de amostras de cada variável monitorada e  $\bar{x}$  é a média dessas amostras.

De posse dos dados históricos reais  $x[n]$ , em gás e com ponto de operação em 16800KW, e destas duas métricas explicadas anteriormente, denominada média ( $\bar{x}$ ) e desvio padrão ( $s$ ), destaque especial é dado a normalização dos dados reais através de Z-score (78), porque a partir dele é possível analisar a tendência das regras de Nelson no

tempo. Algebricamente, Z-score, nomeado  $z[n]$ , é dado por

$$z[n] = \frac{x[n] - \bar{x}}{s} \quad (3.4)$$

É importante salientar que a aplicação dos cálculos estatísticos anteriores são realizados para todas as variáveis descritas na subseção 3.2. Sendo assim, estes cálculos permitem a construção de um gráfico, chamado de diagrama de controle, o qual permite o monitoramento do comportamento das variáveis medidas das unidades geradoras. A seção 3.7 discute como são elaborados estes diagramas de controle à partir de dados históricos reais das unidades geradoras da UTE.

### 3.7 Diagrama de Controle para as variáveis

Para a elaboração do diagrama de controle, primeiramente, foram considerados e coletados os dados históricos reais da potência ativa do gerador, em gás e com ponto de operação em 16800kW, fornecidos pela UTE, pois elas fornecem boas indicações sobre o nível de carga do motor de combustão. Em seguida, foi aplicado e verificado através dos testes de normalidade que estes dados se comportam como contínuos e não seguem uma distribuição normal. Sendo assim, foi realizado uma manipulação nestes dados via Distfit, denominada normalização dos dados, para que os mesmos ficassem ajustados a uma distribuição normal. De posse desta distribuição, dois parâmetros que a caracterizam, sendo média ( $\bar{x}$ ) e desvio padrão ( $s$ ), foram calculados para cada uma das variáveis, conforme apresentado na seção 3.6. Consequentemente, a partir destes parâmetros, posiciona-se a distribuição normal centrada em sua média, determinando como o próprio nome sugere, a posição da linha média (LM), enquanto que o desvio padrão ( $s$ ) determina os limites superior e inferior de controle (LSC e LIC, respectivamente) das variações de cada variável monitorada (43), conforme ilustrado na Figura 51.

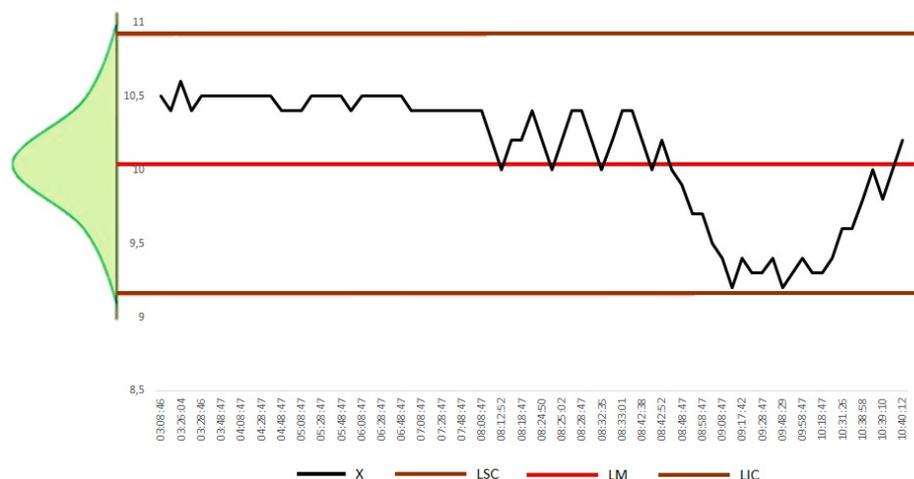


Figura 51 – Modelo de Diagrama de Controle.

No diagrama da Figura 51, a curva preta (denominada X) caracteriza o comportamento de cada uma das variáveis monitoradas. A linha vermelha (denominada LM) caracteriza a linha do meio, ou seja, caracteriza a média das medidas de cada variável X. As linhas marrons representam os limites estatísticos superior e inferior (LSC e LIC respectivamente) em que se espera que a variável oscile em casos extremos, ainda sob normalidade.

Para realizar os cálculos dos limites de controle, superior e inferior, considerou-se uma distância de 3 desvios padrão (3s) da média ( $\bar{x}$ ) com base na probabilidade da distribuição normal (44). Sendo assim, o limite superior de controle (LSC) é dado por

$$LSC = \bar{x} + 3s, \quad (3.5)$$

Já o limite inferior de controle (LIC) é dado por

$$LIC = \bar{x} - 3s, \quad (3.6)$$

Logo, calculando a variação entre os dois limites de controle, é possível demonstrar que a região interna destes limites possuem distância de 6 desvios padrão (6s), dado por

$$Região_{Interna} = LSC - LIC, \quad (3.7)$$

Visando melhorar a identificação das várias regiões de análise dentro da faixa interna dos limites de controle da Figura 51, foram definidas algumas zonas de controle. Em cada uma dessas zonas, as medidas das variáveis possuem uma probabilidade de ocorrência específica.

A primeira zona de controle definida foi a chamada Zona C. Esta zona está localizada dos dois lados da média (LM), e a uma distância de 1 desvio padrão (1s), ou seja, algebricamente a Zona C superior é dada por

$$ZonaC_{superior} = \bar{x} + 1s, \quad (3.8)$$

E a Zona C inferior é dada por

$$ZonaC_{inferior} = \bar{x} - 1s. \quad (3.9)$$

Para melhor compreensão destas definições, a Figura 52 apresenta um exemplo didático que ilustra a localização da faixa da Zona C em um diagrama de controle.

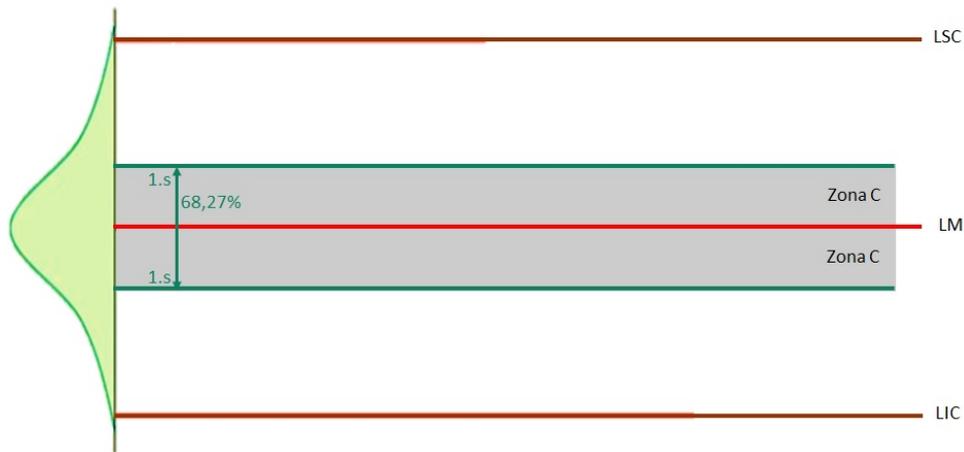


Figura 52 – Zona C do diagrama de controle.

Na Figura 52, a faixa limitada em cinza (Zona C superior e inferior) mostra a região de maior probabilidade de ocorrência das medidas de cada variável monitorada, quando considerado a distribuição normal. Em outras palavras, a faixa cinza identifica que 68,27% (46) dessas medidas estarão a 1 desvio padrão da média. Vale ressaltar que para a análise deste trabalho esta faixa da Zona C é caracterizada como região de normalidade.

A segunda zona de controle definida foi a chamada Zona B. Esta zona está localizada a uma distância entre 1 e 2 desvio padrão da média, porém na região superior e inferior da mesma. Assim sendo, algebricamente, a Zona B superior é dada por

$$\bar{x} + 1s < ZonaB_{superior} < \bar{x} + 2s, \quad (3.10)$$

E a Zona B inferior é dada por

$$\bar{x} - 2s < ZonaB_{inferior} < \bar{x} - 1s \quad (3.11)$$

Para melhor visualizar estas definições e as localizações dessas faixas, a Figura 53 ilustra didaticamente que a faixa da Zona B superior está localizada acima da Zona C superior e analogamente, a faixa da Zona B inferior está localizada abaixo da Zona C inferior.

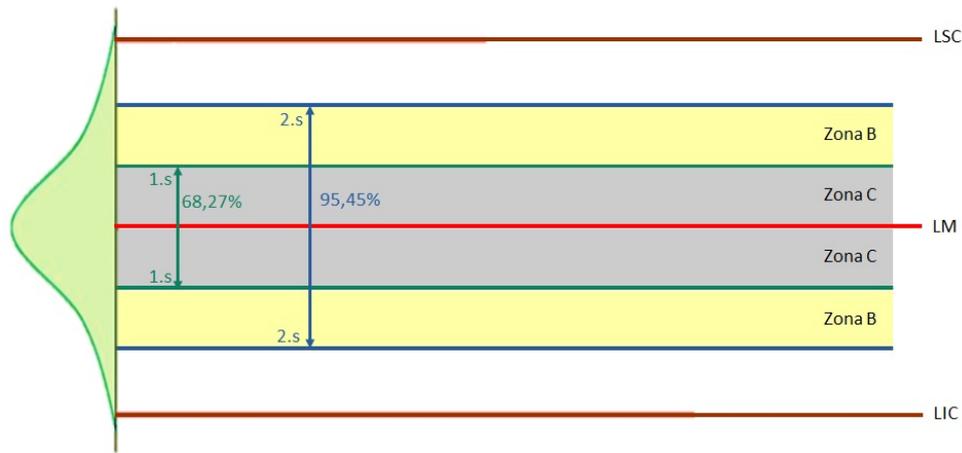


Figura 53 – Zona B do diagrama de controle.

Na Figura 53, a seta azul mostra que a probabilidade total de se encontrar uma medida de qualquer variável monitorada a até 2 desvios padrão de distância da média, em uma distribuição normal, é de 95,45% (46). Conseqüente, a faixa limitada em amarelo (Zona B superior e inferior) na Figura 53, identifica que a probabilidade de uma dessas medidas caírem nesta faixa é de 27,18% (95,45% - 68,27%) (46).

A Terceira e última zona de controle definida foi a chamada Zona A. Nesta zona as medidas das variáveis de controle estão localizadas entre 2 e 3 desvios padrão de cada lado da média. Sendo assim, algebricamente, a Zona A superior é dada por

$$\bar{x} + 2s < ZonaA_{superior} < \bar{x} + 3s \quad (3.12)$$

E a Zona A inferior é dada por

$$\bar{x} - 3s < ZonaA_{inferior} < \bar{x} - 2s \quad (3.13)$$

Para melhor compreender estas definições e as localizações dessas faixas, a Figura 54 mostra didaticamente que a faixa da Zona A superior está localizada acima da Zona B superior e analogamente, a faixa da Zona A inferior está localizada abaixo da Zona B inferior.

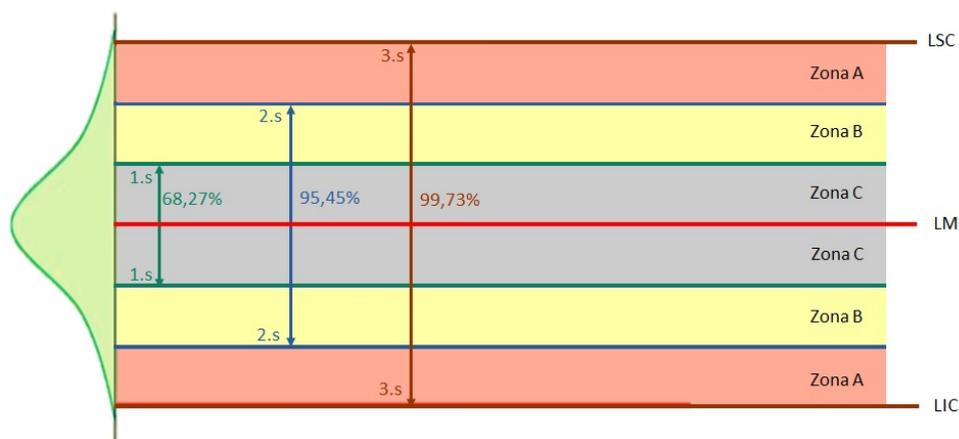


Figura 54 – Zona A do diagrama de controle.

Na Figura 54, a seta marrom mostra que a probabilidade total das medidas de uma variável monitorada estarem dentro dos limites de controle, em uma distribuição normal, é de 99,73% (46). Conseqüente, as faixas em vermelho mostram que a probabilidade de uma dessas medidas caírem na faixa superior ou inferior da Zona A é de 4,28% (99,73% - 95,45%) (46).

Além das zonas e das probabilidades descritas anteriormente, ainda existe a probabilidade de uma ou mais medidas das variáveis monitoradas caírem fora dos limites de controle. Essa probabilidade de ocorrência não é nula, mais precisamente, ela tem o valor de 0,27% (46). Devido a isso, por definição, sempre que uma dessas medidas forem feitas fora dos limites de controle, pode ser que aconteça algum tipo de anormalidade (47).

É importante notar que a aplicação do diagrama de controle conforme definido na Figura 51 é capaz de monitorar o comportamento estatístico das variáveis da UTE em questão. Porém, na prática, é necessário que os operadores das máquinas possam interpretar estes gráficos, para determinar e tomar decisão sobre a presença ou não de uma causa especial no MCI. Sendo assim, a seção 3.8 descreve sobre um método específico de interpretar estes gráficos, denominado regras de Nelson, no entanto, aplicada em MCI.

### 3.8 Regras de Nelson aplicadas em MCI

Comumente, a avaliação da estabilidade estatística de um processo é feita por meio da aplicação do método de Nelson nos diagramas de controle, o qual é conhecido como regras de Nelson. Tais regras relacionam as posições dos pontos e as zonas associados as cartas de controle. Cada sequência de pontos em uma determinada região do diagrama de controle equivale a uma regra de Nelson, sendo o menor valor desta sequência (no caso 1) na Zona A, o ponto em que define a regra 1, denominada regra básica, enquanto que os demais valores desta sequência em posições específicas do diagrama, os pontos em que definem as outras 7 regras propostas por Nelson. Sendo assim, a quantidade total de

regras que Nelson apresentou na literatura para controlar um processo foi de 8 regras e suas definições se encontram na seção 2.3.

Baseado nas definições das regras de Nelson supramencionadas é possível perceber que qualquer processo que gere pontos ou medidas pode ser avaliado de forma inteligente. No entanto, não se encontrou na literatura, um estudo que aplicasse o método de Nelson para monitorar a condição operacional de motores de combustão interna que compõem as UTEs. Sendo assim, este trabalho apresenta de forma inédita esta nova forma de aplicar as regras de Nelson, ou seja, em MCI.

Do ponto de vista do conceito das regras de Nelson, vale ressaltar que, para este trabalho, as definições teóricas das regras não mudam, são mantidas as mesmas definições descritas na seção 2.3. O que diferencia neste trabalho é apenas a aplicação e a interpretação das regras perante esta nova aplicação, ou seja, antes as regras eram aplicadas para controlar um processo de qualidade e agora elas são utilizadas para controlar a condição operacional de um motor de combustão interna de uma UTE no Brasil. Consequentemente, a regra 6 (da subseção 2.3.6) sofreu modificação de interpretação, porque quando aplicada para controlar um processo ela era considerada condição de anormalidade e agora, que é aplicada para monitorar a condição operacional de um MCI, ela é considerada condição normal, pois quanto mais próximo da média as medidas estiverem mais estável está a condição operacional do MCI da UTE em questão.

Como apelo prático, neste trabalho, a avaliação e a análise desta nova forma de aplicar as regras de Nelson, ou seja, em MCI, são realizadas no tempo, conforme mostrado na seção 3.9.

## 3.9 Análise das Regras de Nelson aplicadas em MCI no tempo

A análise das regras de Nelson aplicadas em MCI no tempo, como o próprio nome sugere, é a forma pela qual as regras de Nelson aplicadas em MCI supramencionadas na seção 3.8 podem ser analisadas no tempo. Esta análise é feita através dos gráficos de barras, conforme abordado na subseção seguinte.

### 3.9.1 Gráficos de barras

O gráfico de barras é a forma que as regras de Nelson aplicadas em MCI podem ser analisadas no tempo. Neste tipo de análise, seleciona-se a área de interesse que quer analisar no diagrama de controle da potência ativa do gerador e então o acionamento das regras começa a ser avaliado para cada variável monitorada e, em seguida é calculada sua quantidade de vezes de ativação neste intervalo selecionado. O resultado acumulado destas ativações é apresentado em um gráfico em forma de barras empilhadas, utilizando cores diferentes, que indicam progressivamente o desvio de cada variável de seu valor de

referência. As regras foram ordenadas conforme seu grau de severidade, criando-se uma escala de cores, que indica desde uma situação normal até uma situação fora do intervalo de 3 desvios padrão (baseado em uma distribuição normal), conforme mostra a Figura 55 e a Tabela 15.

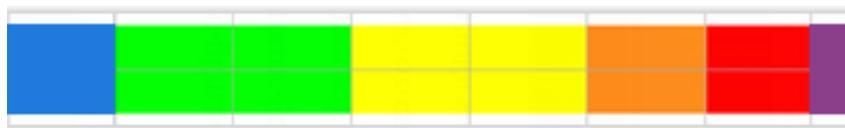


Figura 55 – Escala de cores das Regras de Nelson.

Tabela 15 – Tabela que apresenta as escalas de cores com as respectivas regras de Nelson.

Regras	Cor	Desvio	Descrição
7	Azul	$< 1\sigma$	Quinze pontos consecutivos na Zona C (acima ou abaixo linha central)
8	Verde	$> 1\sigma$	Oito pontos consecutivos em ambos os lados da linha central sem nenhum nas Zona C
6	Amarela	Entre $1\sigma$ e $3\sigma$	Quatro de cinco pontos consecutivos na Zona B ou além
5	Laranja	Entre $2\sigma$ e $3\sigma$	Dois de três pontos consecutivos na Zona A ou além
1	Vermelha	$> 3\sigma$	Um ponto além da Zona A
3	Roxa	- x -	Seis pontos consecutivos aumentando ou diminuindo continuamente

A partir da Figura 55 e da Tabela 15, percebe-se que a escala de cores inicia-se em azul, representando uma situação normal, e avança para verde, amarela, laranja e vermelho representando situações como satisfatória, atenção, insatisfatória e inadequado, respectivamente. Existe ainda a cor roxa, que indica situação de mudança rápida no valor da variável, seja para mais ou para menos, independente do valor absoluto que ela assuma. Vale ressaltar que as regras de número 2 e 4 não foram utilizadas na aplicação deste trabalho, pois não apresentaram grande utilidade nos testes práticos.

Com isso, a análise e a interpretação de um intervalo de dados passou a ser instintiva e rápida, bastando observar onde a barra chegou nos níveis de cores. Consequentemente, caso esta barra tenha chegado nos níveis de cores mais quentes (laranja e vermelho), pode-se concluir que a variável está em uma situação "insatisfatória" e "inadequada". Agora, caso esta barra tenha chegado no nível de cor amarela, pode-se concluir que a variável se encontra em uma situação de "atenção". E por fim, caso esta barra tenha chegado nos níveis de cores azul e verde, pode-se concluir que a variável está em operação "normal"

e “satisfatória ou bom”. Estas duas cores são na maioria das vezes complementares, ou seja, sua soma é constante, formando um patamar horizontal fixo no gráfico.

Para melhor assimilação desta forma de análise no tempo, através dos níveis de cores, a Figura 56 apresenta um gráfico de barras empilhadas convencional, que reflete o comportamento de todas as variáveis do motor em um intervalo de tempo, perante o acionamento das regras de Nelson.

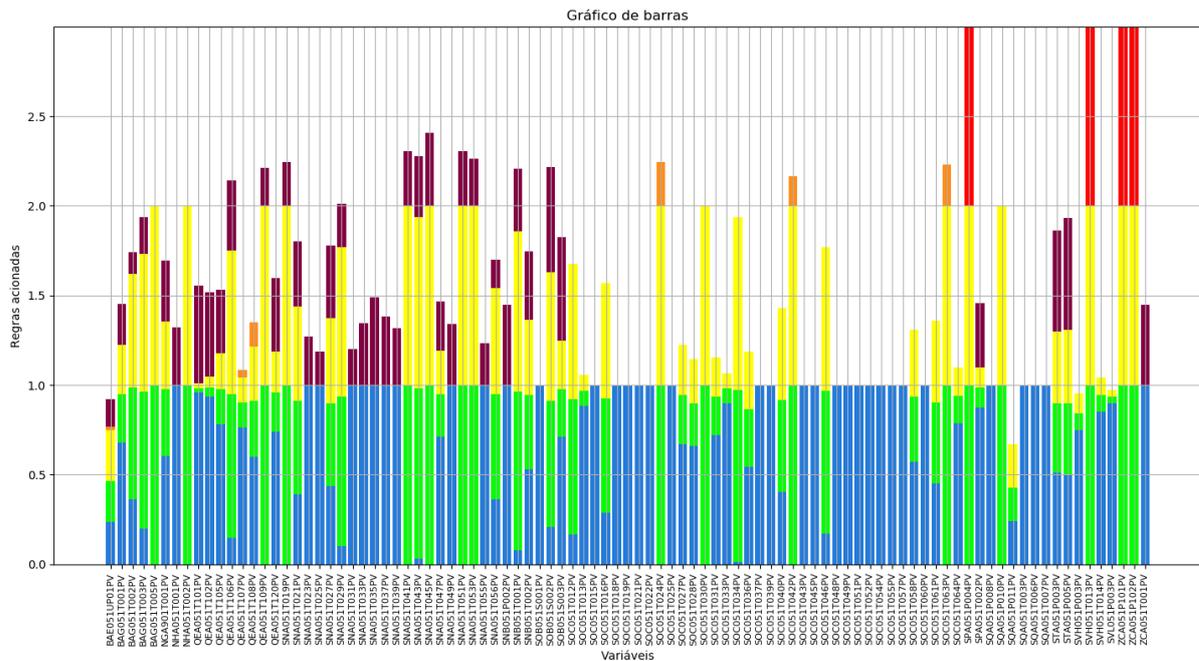


Figura 56 – Gráfico do comportamento de todas as variáveis do motor em um intervalo de tempo.

No gráfico ilustrado pela Figura 56, o eixo x indica as variáveis e o eixo y indica o total de vezes que cada regra foi acionada na região de seleção. Sendo assim, fica evidente que a maioria das variáveis está na faixa normal (azul ou verde), delimitando uma linha horizontal no gráfico. Somente algumas variáveis superam este patamar, apresentando um sinal de atenção(amarelo). Além disso, nota-se que poucas entraram nas faixas de estresse (laranja). Por fim, não mais do que 4 variáveis chegaram na Zona Vermelha, fora dos Limites de Controle.

## 4 Resultados Numéricos

Neste capítulo é feito um estudo sobre o tratamento dos dados da UTE RA-ESA e uma análise do desempenho do modelo estatístico aqui proposto. Inicialmente é apresentada a descrição do tratamento dos dados fornecidos pela UTE. Em seguida, são apresentados os resultados obtidos por estes tratamentos de dados, mostrando por meio dos gráficos de barras empilhadas os acionamentos das regras de Nelson nos subsistemas de óleo lubrificante e cilindros. E a última seção do capítulo traz os resultados dos tratamentos dos dados após o retorno do motor em análise, mostrando também por meio dos gráficos de barras empilhadas os acionamentos das regras de Nelson para esta situação nos subsistemas de óleo lubrificante e cilindros.

### 4.1 Descrição do tratamento dos dados

Para os resultados numéricos aqui apresentados, foram monitorados os subsistemas de óleo lubrificante e os subsistemas de cilindros. No subsistema de óleo lubrificante, destaque especial foi dado a temperatura de saída do óleo lubrificante representada pela variável, SQA051T007PV. E no subsistema de cilindro, destaque especial foi dado aos cilindros B7 (sensor 1), B4 (sensor 2) e A6 (sensor 2) representados, respectivamente, pelas variáveis, SOC051T057PV, SOC051T049PV e SOC051T028PV.

O diagrama de controle foi obtido por meio do tratamento dos dados históricos reais da potência ativa do gerador fornecidos pela UTE. Porém, primeiramente, foram calculados os parâmetros estatísticos como média, desvio padrão, LIC, LSC e as Zonas A, B e C desta variável monitorada. Após esses cálculos, o modelo estatístico simula a curva de cada parâmetro e gera o diagrama de controle específico desta variável. Vale ressaltar que essas etapas também se aplicam às outras 112 variáveis monitoradas, gerando um diagrama para cada uma delas.

De posse desses 112 diagramas de controle, cada janela de tempo móvel foi selecionada a partir do diagrama de controle da potência ativa do gerador porque é mais fácil de visualizar quando a geradora está ou não gerando energia. No entanto, os gráficos de barras foram obtidos por meio do tratamento dos dados históricos reais modificados e específicos de cada variável nas respectivas janelas de tempo móveis selecionadas em cada mês de análise estatística de falha no MCI.

Para esta análise, em cada uma dessas janelas de tempo selecionada, foi gerado um gráfico de barras empilhadas específico para cada mês. Estes gráficos de barras empilhadas apontam o acumulado das regras de Nelson que foram acionadas para cada variável nesta

janela. De posse destes apontamentos estatísticos, foi possível correlacionar estes desvios estatísticos com o grau de severidade da condição operacional da UG e verificar se o modelo estatístico proposto é capaz de realizar apontamentos precoce de falha no MCI, uma vez que é de conhecimento geral que ocorreu um evento de parada da UG no dia 01-ago-2019.

Em termos de parâmetros utilizados nos tratamentos dos dados, considerou-se os dados históricos modificados da potência ativa do gerador e das outras 112 variáveis monitoradas da unidade geradora 5, nos meses de janeiro, fevereiro, março, abril, maio, junho, julho, agosto, novembro e dezembro de 2019. Vale ressaltar que os meses de setembro e outubro de 2019 não foram utilizados na análise deste trabalho, porque a UG 5 estava parada nestes meses para realizar manutenção corretiva devido ao sinistro do dia 01-ago-2019. Considerou-se também, conforme já mencionado, uma janela de tempo móvel para cada mês em análise. Em termos de parâmetros utilizados na análise de validação do modelo estatístico considerou-se, conforme já mencionado, o evento ocorrido no dia 01-ago-2019 às 14h41 na UG 5. Neste evento, houve um desligamento, um alarme de detector de névoa, um deslocamento de biela e também foi verificado que o cilindro B7 estava travado.

## 4.2 Desempenho e validação do modelo estatístico por meio dos gráficos de barras

Para verificar o desempenho e a validação do modelo estatístico, primeiramente, foi selecionada 1 janela de tempo para cada mês no gráfico da potência ativa do gerador da UG 5 destes respectivos meses. Após isto, foram gerados gráficos de barras empilhadas para cada uma delas para os subsistemas de óleo lubrificante e cilindros. E, por fim, os resultados estatísticos destas análises foram correlacionados com o grau de severidade da condição operacional da UG 5 e com o sinistro do dia 01-ago-2019, verificando a validação do modelo, conforme detalhado nas subseções seguintes.

### 4.2.1 Análise 1: janeiro 2019

A primeira análise foi realizada na janela de tempo do mês de janeiro iniciada às 23:55:52 do dia 13-jan-2019 e finalizada às 06:01:02 do dia 15-jan-2019. Esta janela está indicada no diagrama da potência ativa do gerador do mês de janeiro, conforme mostra Figura 57.

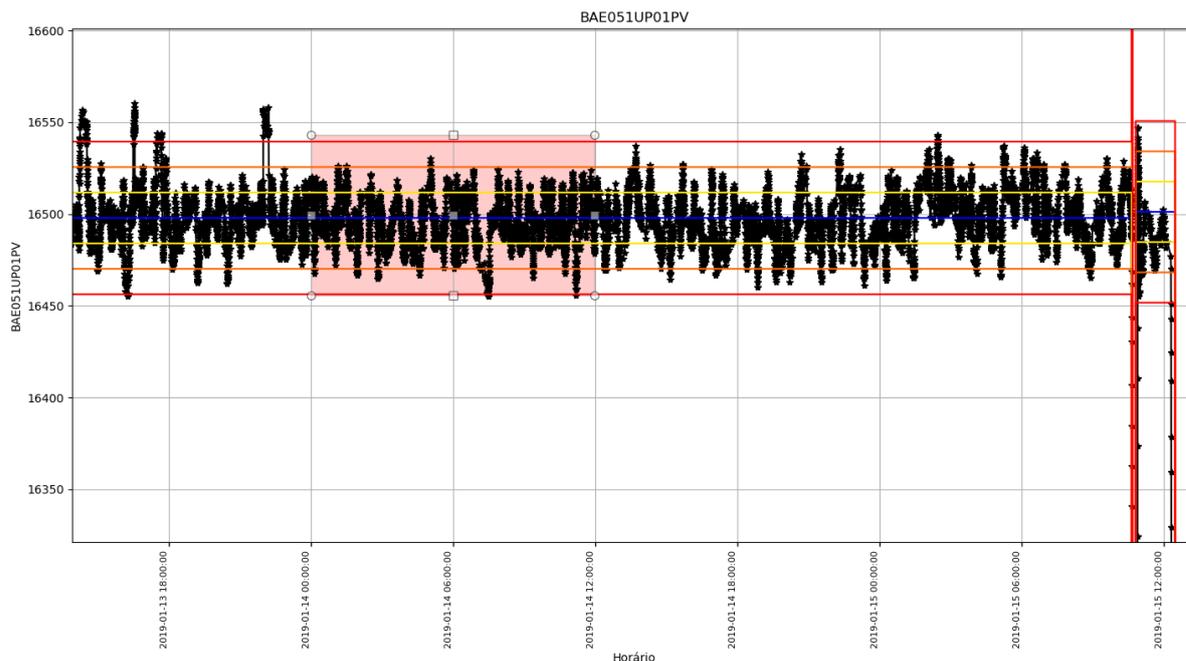


Figura 57 – Área selecionada do espectro da potência ativa do gerador do diagrama do mês de janeiro.

Na janela da Figura 57, foram gerados os gráficos de barras empilhadas para os subsistemas de óleo lubrificante e cilindros, conforme apresentados nas Figuras 58 e 59.

A partir das regras previamente definidas na seção 2.3 e na escala de cores dessas regras representadas na Figura 55 e na Tabela 15, pode-se deduzir que a regra 7 é uma indicação de normalidade estatística para a aplicação deste trabalho em questão, ou seja, indica normalidade no monitoramento da condição operacional das unidades geradoras (pois os dados selecionados da potência ativa do gerador estão dentro da zona C do diagrama de controle, região mais próxima da linha que representa a média), enquanto que a regra 1 indica uma condição extrema quando o período de permanência do ponto fora dos limites de controle inferior e superior (LIC / LSC) for maior que o produto do tempo que o processo em análise funcionou com a probabilidade da regra 1 ocorrer. Pode-se deduzir também que a regra 8 confirma a condição extrema da regra 1 (pois os dados selecionados da potência ativa do gerador não estão dentro da zona C do diagrama de controle). A regra 5, por sua vez, indica uma probabilidade de levar à condição extrema (uma vez que os dados selecionados da potência ativa do gerador estão na zona A do diagrama de controle). Já a regra 3, apenas indica uma mudança rápida no valor da variável, para mais ou para menos, independentemente do seu valor absoluto.

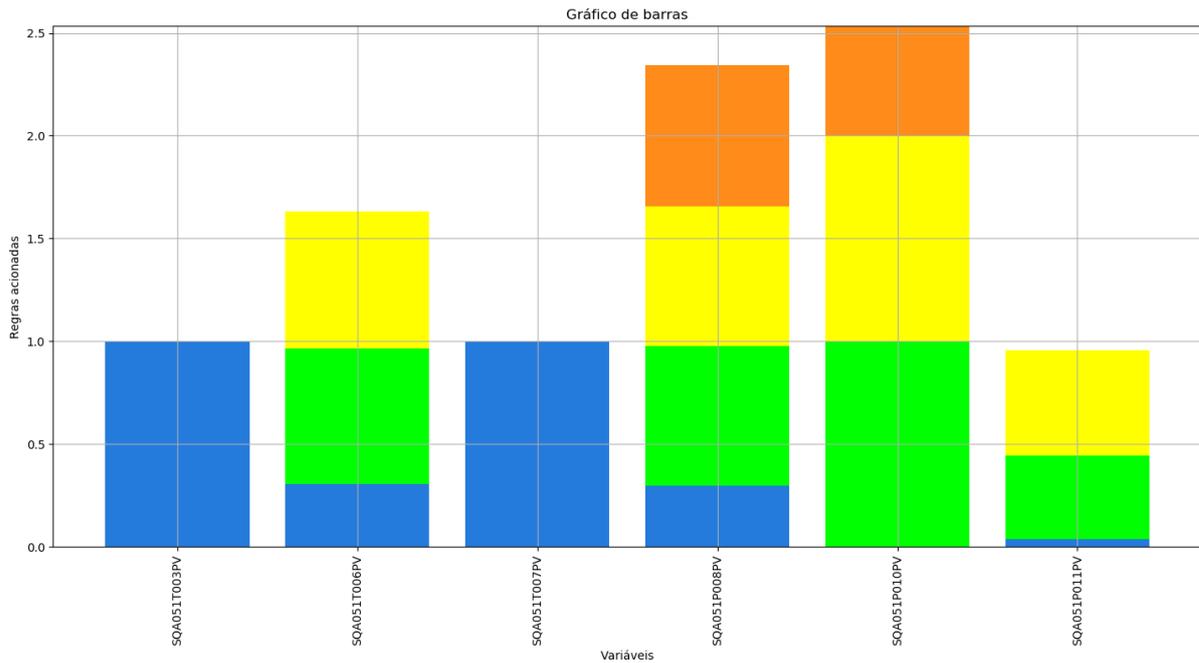


Figura 58 – Gráfico de barras do subsistema de Óleo Lubrificante, da primeira janela selecionada (Azul → R7, Verde → R8, Amarela → R6, Laranja → R5, Vermelha → R1).

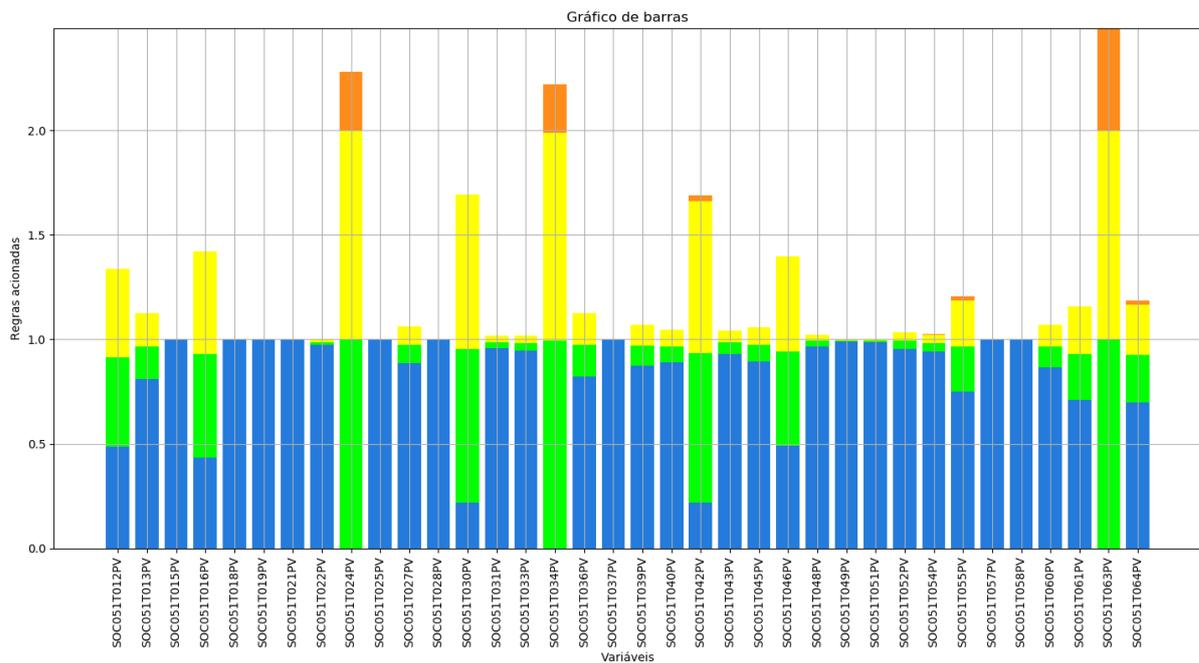


Figura 59 – Gráfico de barras do subsistema de Cilindros, da primeira janela selecionada (Azul → R7, Verde → R8, Amarela → R6, Laranja → R5, Vermelha → R1).

Em relação ao subsistema de óleo lubrificante (Figura 58), de acordo com a análise dos gráficos de barras empilhadas, fica evidente que duas variáveis deste subsistema, sendo uma delas a temperatura de saída do óleo lubrificante (cujo sensor é identificado pela tag

SQA051T007PV), estão operando na faixa normal (azul 1.0 e verde 0.0), delimitando uma linha horizontal no gráfico. Somente algumas variáveis superam este patamar, apresentando um sinal de atenção (amarelo). Além disso, nota-se que poucas entraram nas faixas de estresse (laranja). Por fim, nenhuma das variáveis que compõem este subsistema chegaram na Zona Vermelha (Inadequação), fora dos Limites de Controle.

Em relação ao subsistema do cilindro (Figura 59), de acordo com a análise dos gráficos de barras empilhadas, fica claro que a maioria das variáveis estão operando na faixa normal (azul ou verde), delimitando uma linha horizontal no gráfico. Destaque especial desta operação em faixa normal é dado a temperatura de revestimento dos cilindros B7 (azul 1.0 e verde 0.0), B4 (azul 0.99 e verde 0.01) e A6 (azul 1.0 e verde 0.0) (cujo sensores são identificados, respectivamente, pelas tags SOC051T057PV, SOC051T049PV e SOC051T028PV). Fica claro também que, somente algumas variáveis superam este patamar, apresentando um sinal de atenção (amarelo). Além disso, percebe-se também que poucas entraram nas faixas de estresse (laranja). Por fim, nenhuma das variáveis que compõem este subsistema chegaram na Zona Vermelha (Inadequação), fora dos Limites de Controle.

#### 4.2.2 Análise 2: fevereiro 2019

A segunda análise foi realizada na janela de tempo do mês de fevereiro iniciada às 00:03:51 do dia 25-fev-2019 e finalizada às 00:03:00 do dia 28-fev-2019. Esta janela está indicada no diagrama da potência ativa do gerador do mês de fevereiro, conforme mostra Figura 60.

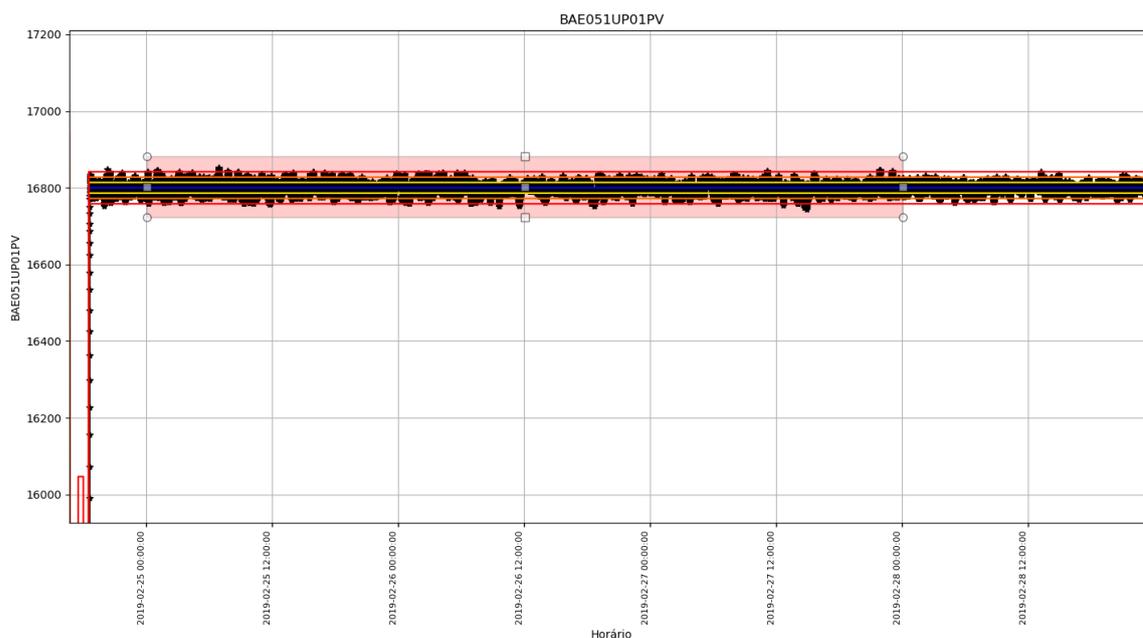


Figura 60 – Área selecionada do espectro da potência ativa do gerador do diagrama do mês de fevereiro.

Na janela da Figura 60, foram gerados os gráficos de barras empilhadas para os subsistemas de óleo lubrificante e cilindros, conforme apresentados nas Figuras 61 e 62.

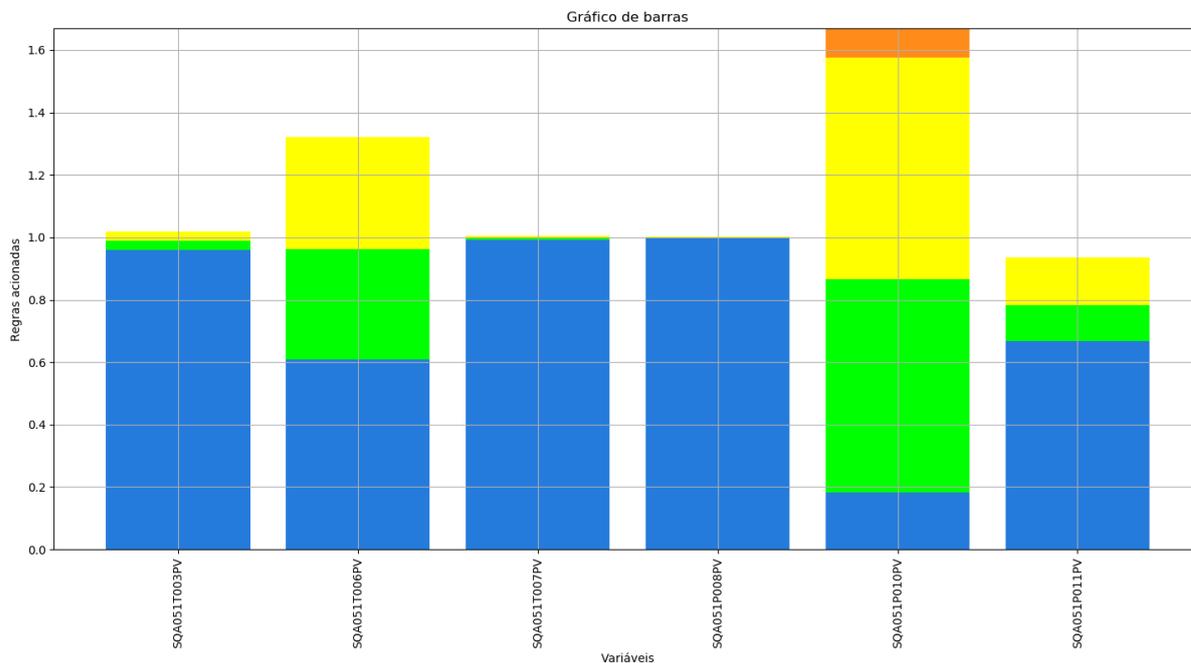


Figura 61 – Gráfico de barras do subsistema de Óleo Lubrificante, da segunda janela selecionada (Azul → R7, Verde → R8, Amarela → R6, Laranja → R5, Vermelha → R1).

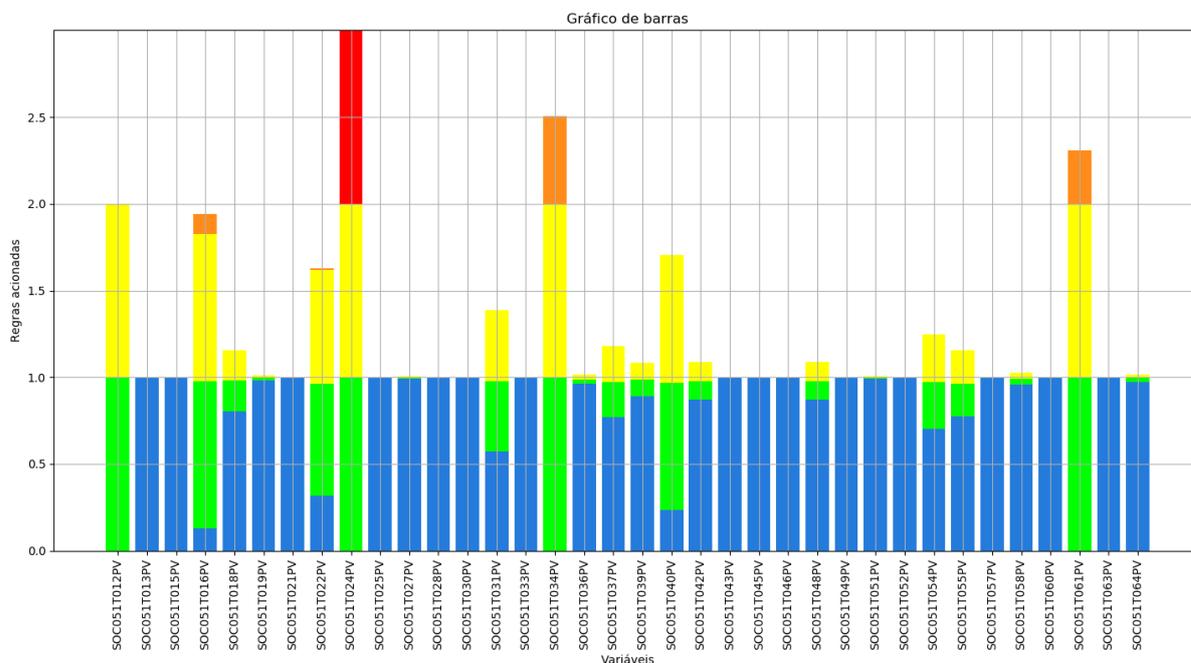


Figura 62 – Gráfico de barras do subsistema de Cilindros, da segunda janela selecionada (Azul → R7, Verde → R8, Amarela → R6, Laranja → R5, Vermelha → R1).

Em relação ao subsistema de óleo lubrificante (Figura 61), de acordo com a análise dos gráficos de barras empilhadas, fica evidente que duas variáveis deste subsistema, sendo uma delas a temperatura de saída do óleo lubrificante (cujo sensor é identificado pela tag SQA051T007PV), estão operando na faixa normal (azul 0.99 e verde 0.01), delimitando uma linha horizontal no gráfico. Fica evidente também que a maioria das variáveis superam este patamar, apresentando um sinal de atenção (amarelo). Além disso, nota-se que apenas uma variável deste subsistema entra na faixa de estresse (laranja). Por fim, nenhuma das variáveis que compõem este subsistema chegou na Zona Vermelha (Inadequação), fora dos Limites de Controle.

Em relação ao subsistema do cilindro (Figura 62), de acordo com a análise dos gráficos de barras empilhadas, fica claro que a maioria das variáveis estão operando na faixa normal (azul ou verde), delimitando uma linha horizontal no gráfico. Destaque especial desta operação em faixa normal é dado a temperatura de revestimento dos cilindros B7 (azul 1.0 e verde 0.0), B4 (azul 1.0 e verde 0.0) e A6 (azul 1.0 e verde 0.0) (cujo sensores são identificados, respectivamente, pelas tags SOC051T057PV, SOC051T049PV e SOC051T028PV). Fica claro também que, somente algumas variáveis superam este patamar, apresentando um sinal de atenção (amarelo). Além disso, nota-se também que poucas entraram nas faixas de estresse (laranja). Por fim, apenas uma variável deste subsistema chega na Zona Vermelha (Inadequação), fora dos Limites de Controle, devido a problema na válvula de segurança do cabeçote do cilindro A5, segundo informações do diário de turno fornecido pela usina.

### 4.2.3 Análise 3: março 2019

A terceira análise foi realizada na janela de tempo do mês de março iniciada às 12:49:12 do dia 01-mar-2019 e finalizada às 21:21:39 do dia 01-mar-2019. Esta janela está indicada no diagrama da potência ativa do gerador do mês de março, conforme mostra Figura 63.

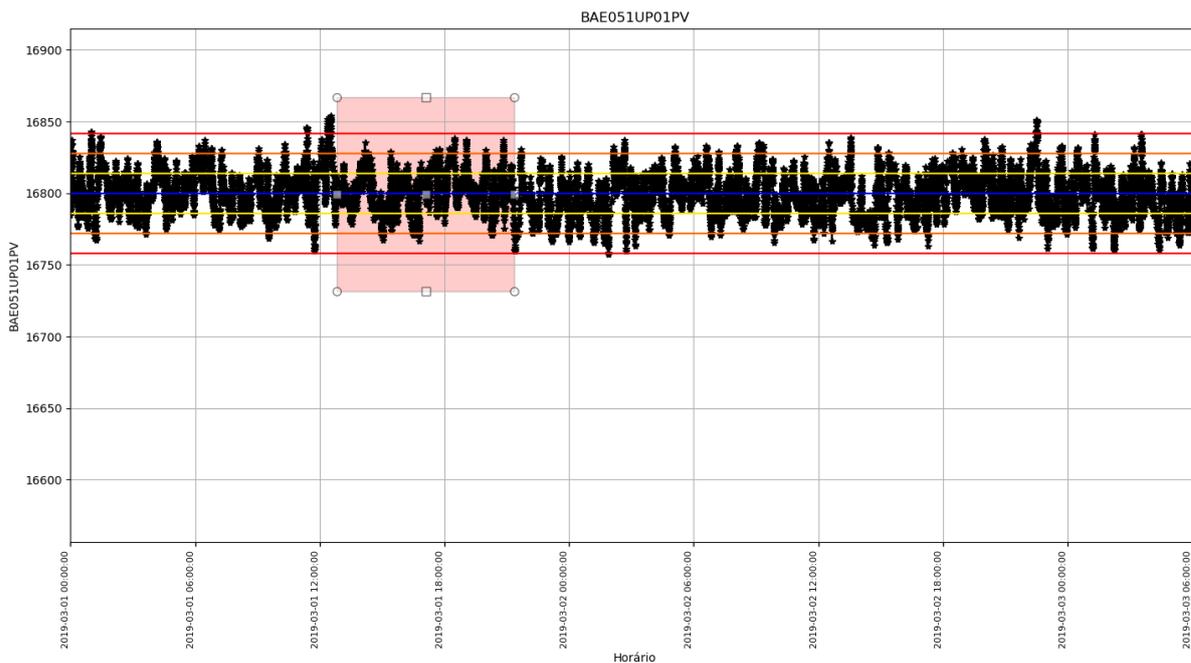


Figura 63 – Área selecionada do espectro da potência ativa do gerador do diagrama do mês de março.

Na janela da Figura 63, foram gerados os gráficos de barras empilhadas para os subsistemas de óleo lubrificante e cilindros, conforme apresentados nas Figuras 64 e 65.

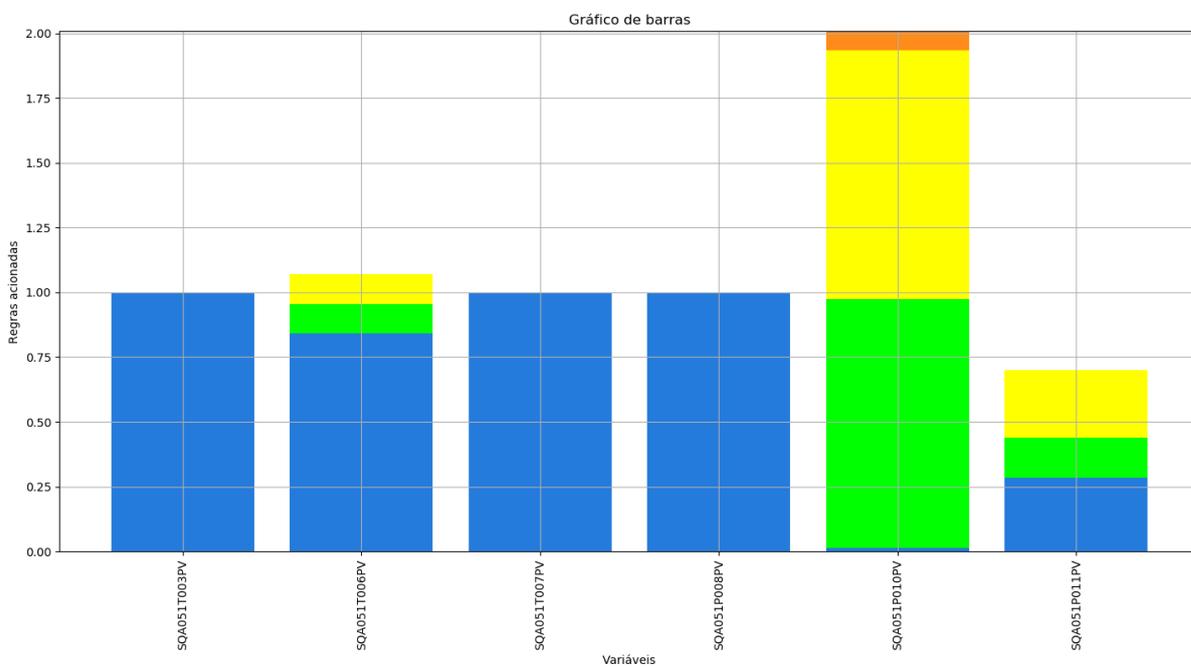


Figura 64 – Gráfico de barras do subsistema de Óleo Lubrificante, da terceira janela selecionada (Azul -> R7, Verde -> R8, Amarela -> R6, Laranja -> R5, Vermelha -> R1).

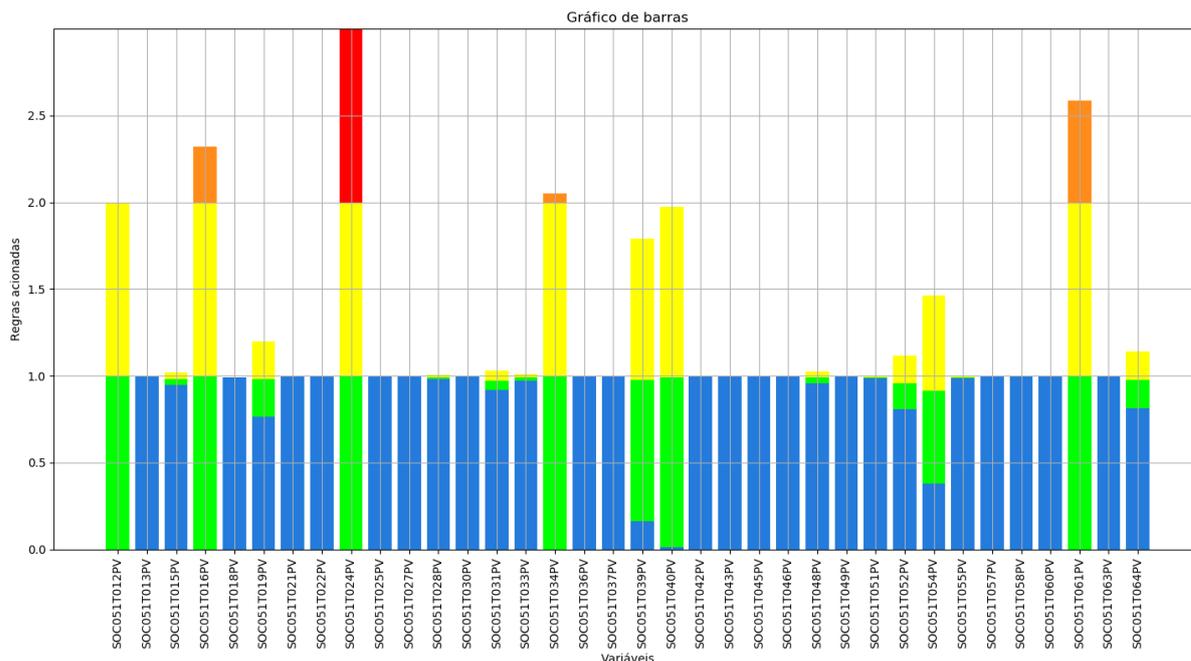


Figura 65 – Gráfico de barras do subsistema de Cilindros, da terceira janela selecionada (Azul → R7, Verde → R8, Amarela → R6, Laranja → R5, Vermelha → R1).

Em relação ao subsistema de óleo lubrificante (Figura 64), de acordo com a análise dos gráficos de barras empilhadas, fica evidente que três variáveis deste subsistema, sendo uma delas a temperatura de saída do óleo lubrificante (cujo sensor é identificado pela tag SQA051T007PV), estão operando na faixa normal (azul 1.0 e verde 0.0), delimitando uma linha horizontal no gráfico. Somente algumas variáveis superam este patamar, apresentando um sinal de atenção (amarelo). Além disso, nota-se que apenas uma variável deste subsistema entra na faixa de estresse (laranja). Por fim, nenhuma das variáveis que compõem este subsistema chegou na Zona Vermelha (Inadequação), fora dos Limites de Controle.

Em relação ao subsistema do cilindro (Figura 65), de acordo com a análise dos gráficos de barras empilhadas, fica claro que a maioria das variáveis estão operando na faixa normal (azul ou verde), delimitando uma linha horizontal no gráfico. Destaque especial desta operação em faixa normal é dado a temperatura de revestimento dos cilindros B7 (azul 1.0 e verde 0.0), B4 (azul 1.0 e verde 0.0) e A6 (azul 0.99 e verde 0.01) (cujo sensores são identificados, respectivamente, pelas tags SOC051T057PV, SOC051T049PV e SOC051T028PV). Fica claro também que, somente algumas variáveis superam este patamar, apresentando um sinal de atenção (amarelo). Além disso, nota-se também que poucas entraram nas faixas de estresse (laranja). Por fim, apenas uma variável deste subsistema chega na Zona Vermelha (Inadequação), fora dos Limites de Controle, devido a problema na válvula de segurança do cabeçote do cilindro A5.

#### 4.2.4 Análise 4: abril 2019

A quarta análise foi realizada na janela de tempo do mês de abril iniciada às 18:57:28 do dia 12-abr-2019 e finalizada às 04:36:54 do dia 14-abr-2019. Esta janela está indicada no diagrama da potência ativa do gerador do mês de abril, conforme mostra Figura 66.

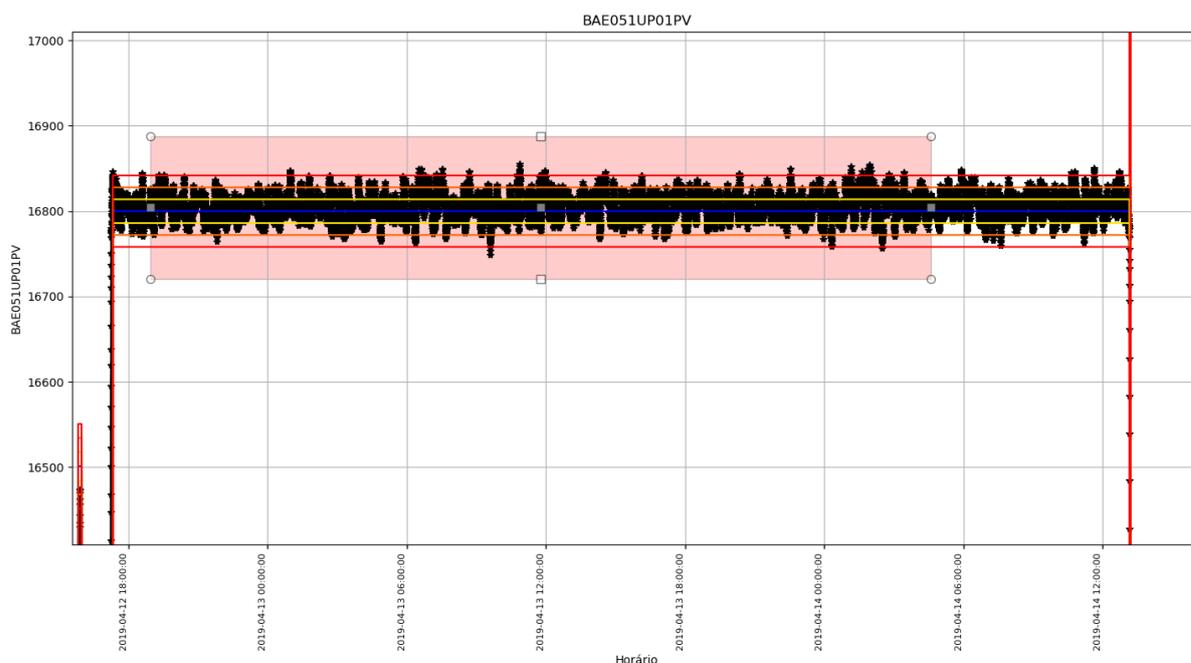


Figura 66 – Área selecionada do espectro da potência ativa do gerador do diagrama do mês de abril.

Na janela da Figura 66, foram gerados os gráficos de barras empilhadas para os subsistemas de óleo lubrificante e cilindros, conforme apresentados nas Figuras 67 e 68.

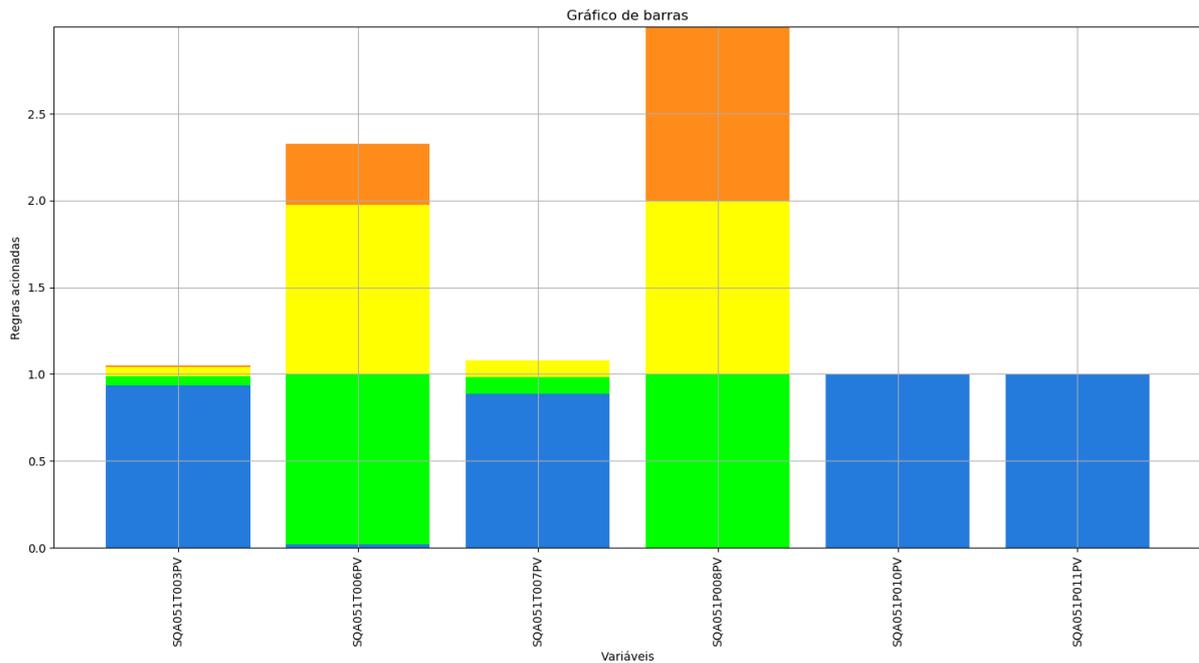


Figura 67 – Gráfico de barras do subsistema de Óleo Lubrificante, da quarta janela selecionada (Azul → R7, Verde → R8, Amarela → R6, Laranja → R5, Vermelha → R1).

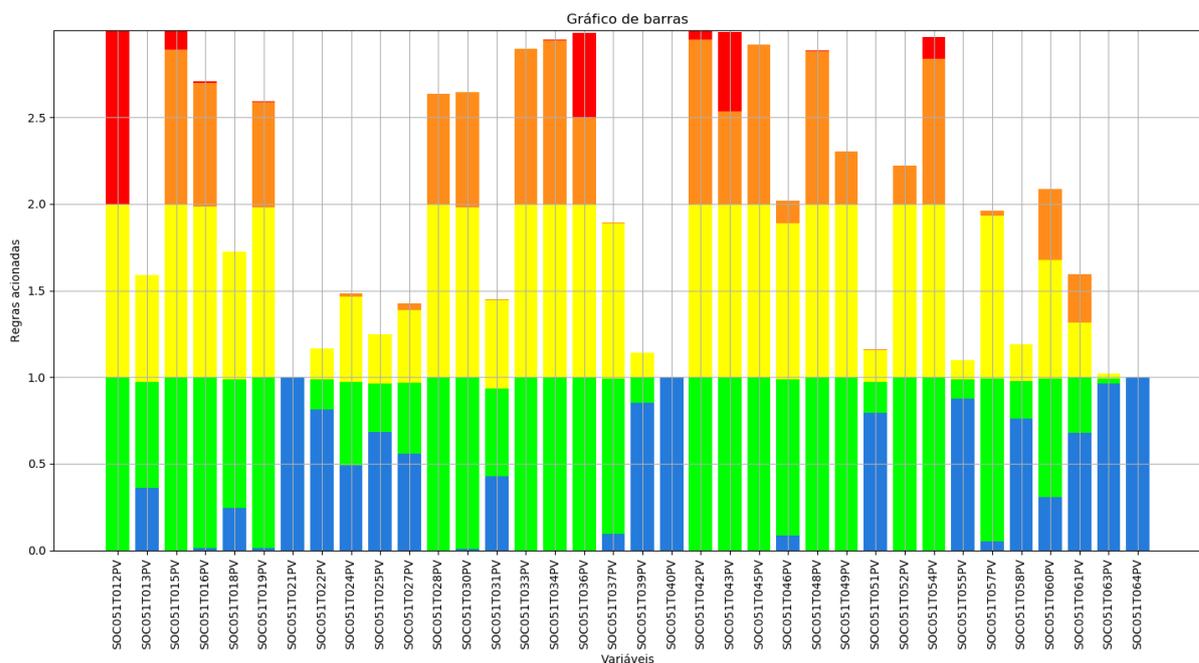


Figura 68 – Gráfico de barras do subsistema de Cilindros, da quarta janela selecionada (Azul → R7, Verde → R8, Amarela → R6, Laranja → R5, Vermelha → R1).

Em relação ao subsistema de óleo lubrificante (Figura 67), de acordo com a análise dos gráficos de barras empilhadas, fica evidente que duas variáveis deste subsistema estão operando na faixa normal (azul ou verde), delimitando uma linha horizontal no gráfico.

Somente uma variável supera este patamar, apresentando um sinal de atenção (amarelo 0.1), sendo ela a temperatura de saída do óleo lubrificante (cujo sensor é identificado pela tag SQA051T007PV). Além disso, nota-se que a maioria das variáveis deste subsistema entram na faixa de estresse (laranja). Por fim, nenhuma das variáveis que compõem este subsistema chegaram na Zona Vermelha (Inadequação), fora dos Limites de Controle. Vale ressaltar que a temperatura de saída do óleo lubrificante saiu da faixa normal (azul 1.0 e verde 0.0) do mês de Março, mostrada pela Figura 64, e passou a atuar em situação de atenção no mês de Abril, mostrada pela faixa amarela (0.1) da Figura 67.

Em relação ao subsistema do cilindro (Figura 68), de acordo com a análise dos gráficos de barras empilhadas, fica claro que poucas variáveis estão operando na faixa normal (azul ou verde), delimitando uma linha horizontal no gráfico. Fica claro também que, somente algumas variáveis superaram este patamar, apresentando um sinal de atenção (amarelo). Além disso, nota-se também que a maioria das variáveis deste subsistema estraram nas faixas de estresse (laranja), como destaque a temperatura de revestimento dos cilindros B7 (laranja 0.03), B4 (laranja 0.3) e A6 (laranja 0.63) (cujo sensores são identificados, respectivamente, pelas tags SOC051T057PV, SOC051T049PV e SOC051T028PV). Por fim, algumas variáveis deste subsistema chegaram na Zona Vermelha (Inadequação), fora dos Limites de Controle. Vale ressaltar que a temperatura de revestimento dos cilindros B7 (azul 1.0 e verde 0.0), B4 (azul 1.0 e verde 0.0) e A6 (azul 0.99 e verde 0.01) saíram da faixa normal do mês de Março, mostrada pela Figura 65, e passaram a atuar em situação de estresse no mês de Abril, mostrada pelas faixas laranjas B7 (laranja 0.03), B4 (laranja 0.3) e A6 (laranja 0.63) da Figura 68.

Vale destacar ainda que a partir dos resultados apresentados nos gráficos de barras empilhadas nesta janela, no subsistema de cilindros, percebe-se que o modelo estatístico aponta alterações estatísticas também em outros cilindros, como por exemplo, os cilindros A1 (sensor 1), A2 (ambos os sensores), A3 (sensor 2), B2 (ambos os sensores), entre outros.

#### 4.2.5 Análise 5: maio 2019

A quinta análise foi realizada na janela de tempo do mês de maio iniciada às 00:07:06 do dia 17-mai-2019 e finalizada às 00:07:12 do dia 20-mai-2019. Esta janela está indicada no diagrama da potência ativa do gerador do mês de maio, conforme mostra Figura 69.

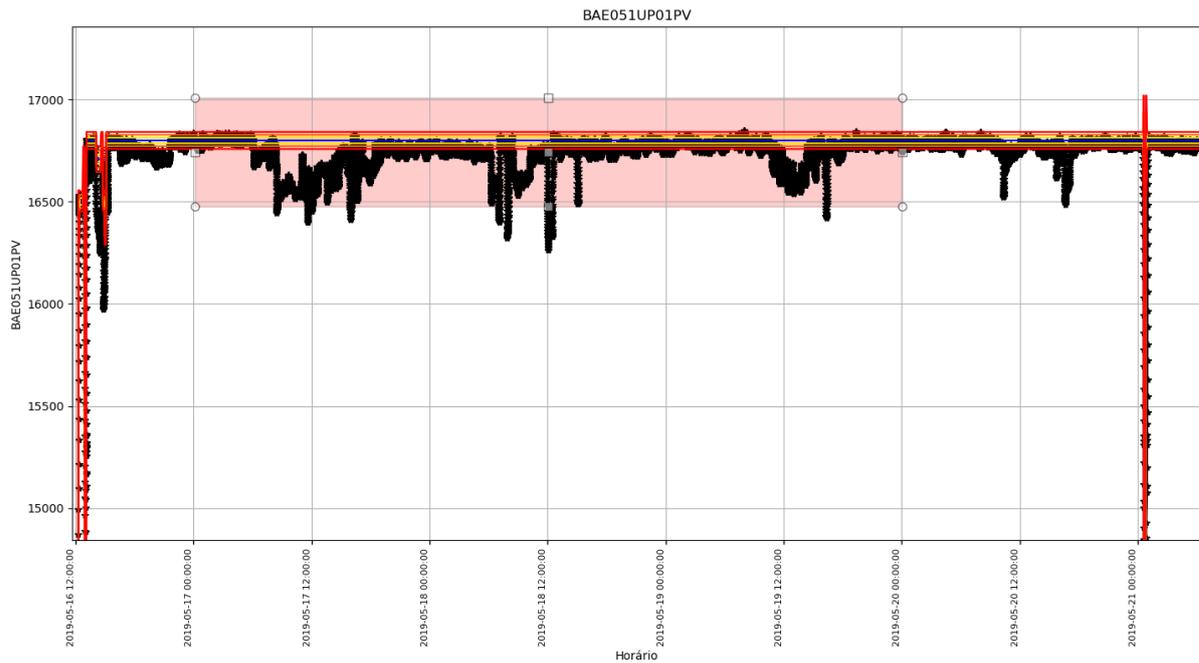


Figura 69 – Área selecionada do espectro da potência ativa do gerador do diagrama do mês de maio.

Na janela da Figura 69, foram gerados os gráficos de barras empilhadas para os subsistemas de óleo lubrificante e cilindros, conforme apresentados nas Figuras 70 e 71.

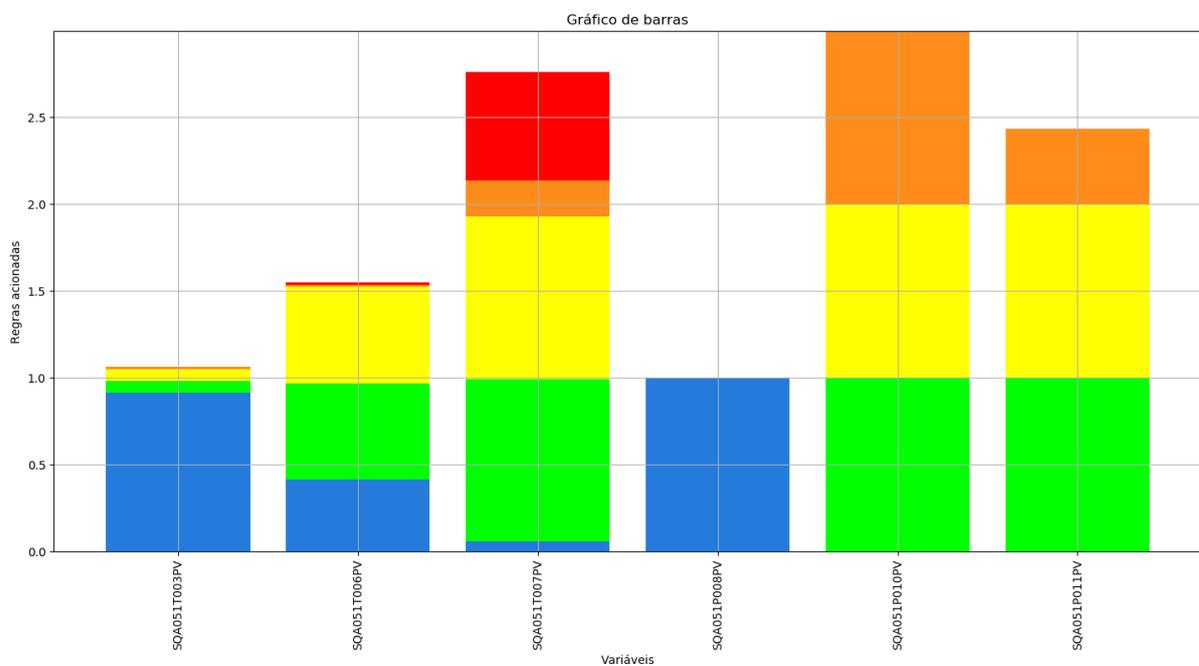


Figura 70 – Gráfico de barras do subsistema de Óleo Lubrificante, da quinta janela selecionada (Azul → R7, Verde → R8, Amarela → R6, Laranja → R5, Vermelha → R1).

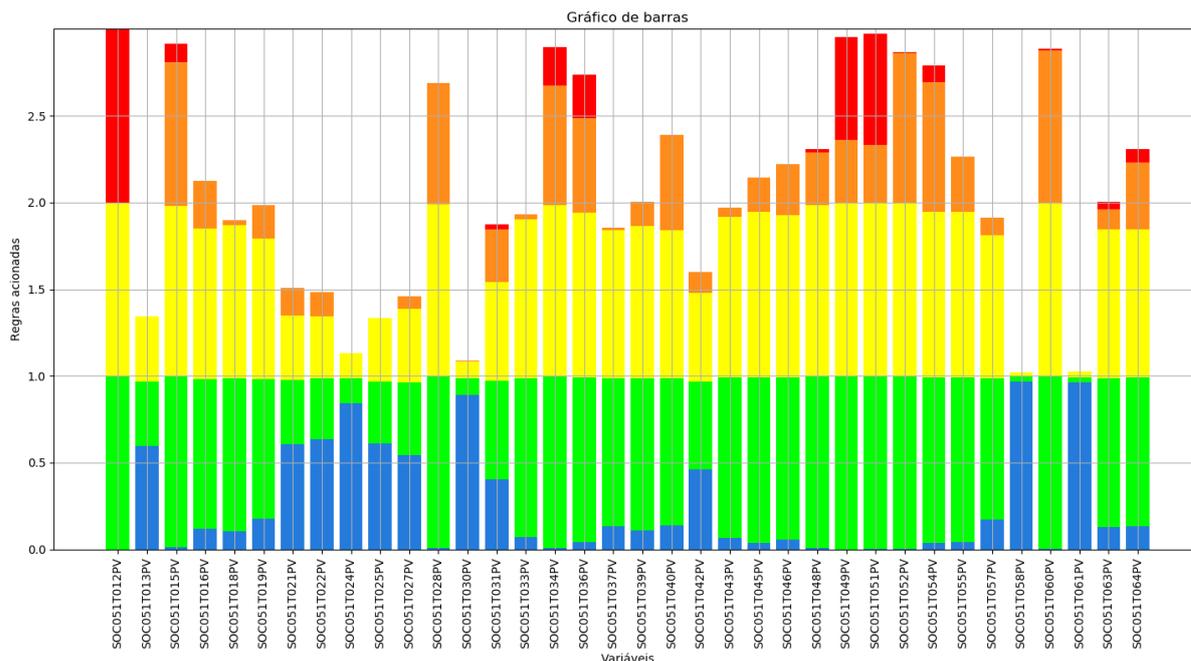


Figura 71 – Gráfico de barras do subsistema de Cilindros, da quinta janela selecionada (Azul → R7, Verde → R8, Amarela → R6, Laranja → R5, Vermelha → R1).

Em relação ao subsistema de óleo lubrificante (Figura 70), de acordo com a análise dos gráficos de barras empilhadas, fica evidente que apenas uma variável deste subsistema está operando na faixa normal (azul ou verde), delimitando uma linha horizontal no gráfico. Nenhuma variável supera este patamar, apresentando um sinal de atenção (amarelo). Além disso, nota-se que algumas variáveis deste subsistema entram na faixa de estresse (laranja). Por fim, duas variáveis que compõem este subsistema, sendo uma delas a temperatura de saída do óleo lubrificante (cujo sensor é identificado pela tag SQA051T007PV) (vermelho 0.5) chegaram na Zona Vermelha, fora dos Limites de Controle, indicando que estão operando em situação de inadequação. Vale ressaltar que a temperatura de saída do óleo lubrificante saiu da faixa de atenção (amarelo 0.1) do mês de Abril, mostrada pela Figura 67, e passou a atuar em situação de inadequação no mês de Maio, mostrada pela Zona Vermelha (0.5) da Figura 70.

Em relação ao subsistema do cilindro (Figura 71), de acordo com a análise dos gráficos de barras empilhadas, fica claro que nenhuma variável está operando na faixa normal (azul ou verde). Fica claro também que, somente algumas variáveis superaram este patamar, apresentando um sinal de atenção (amarelo). Além disso, nota-se também que a maioria das variáveis entraram nas faixas de estresse (laranja), como destaque a temperatura de revestimento dos cilindros B7 (laranja 0.1) e A6 (laranja 0.7) (cujo sensores são identificados, respectivamente, pelas tags SOC051T057PV e SOC051T028PV). Por fim, algumas variáveis deste subsistema chegaram na Zona Vermelha (Inadequação), fora dos Limites de Controle. Destaque especial é dado a temperatura de revestimento do cilindro

B4 (vermelho 0.6) (cujo sensor é identificado pela tag SOC051T049PV). Vale ressaltar que a situação de estresse (laranja) da temperatura de revestimento dos cilindros B7 (laranja 0.1) e A6 (laranja 0.7) (cujo sensores são identificados, respectivamente, pelas tags SOC051T057PV e SOC051T028PV), mostradas no mês de Maio, pela Figura 71, estão um pouco maiores do que as situações de estresse B7 (laranja 0.03) e A6 (laranja 0.63), mostradas no mês de Abril, pela Figura 68. Vale ressaltar também que a temperatura de revestimento do cilindro B4 (cujo sensor é identificado pela tag SOC051T049PV) saiu da faixa de estresse (laranja 0.3) do mês de Abril, mostrada pela Figura 68, e passou a atuar na situação de inadequação no mês de Maio, mostrada pela Zona Vermelha (0.6) da Figura 71.

Vale destacar também que a partir dos resultados apresentados nos gráficos de barras empilhadas nesta janela, no subsistema de cilindros, percebe-se que o modelo estatístico aponta alterações estatísticas também em outros cilindros, como por exemplo, os cilindros A1 (sensor 1), A2 (sensor 1), A3 (sensor 2), B5 (sensor 1), entre outros.

#### 4.2.6 Análise 6: junho 2019

A sexta análise foi realizada na janela de tempo do mês de junho iniciada às 19:10:39 do dia 03-jun-2019 e finalizada às 10:38:34 do dia 09-jun-2019. Esta janela está indicada no diagrama da potência ativa do gerador do mês de junho, conforme mostra Figura 72.

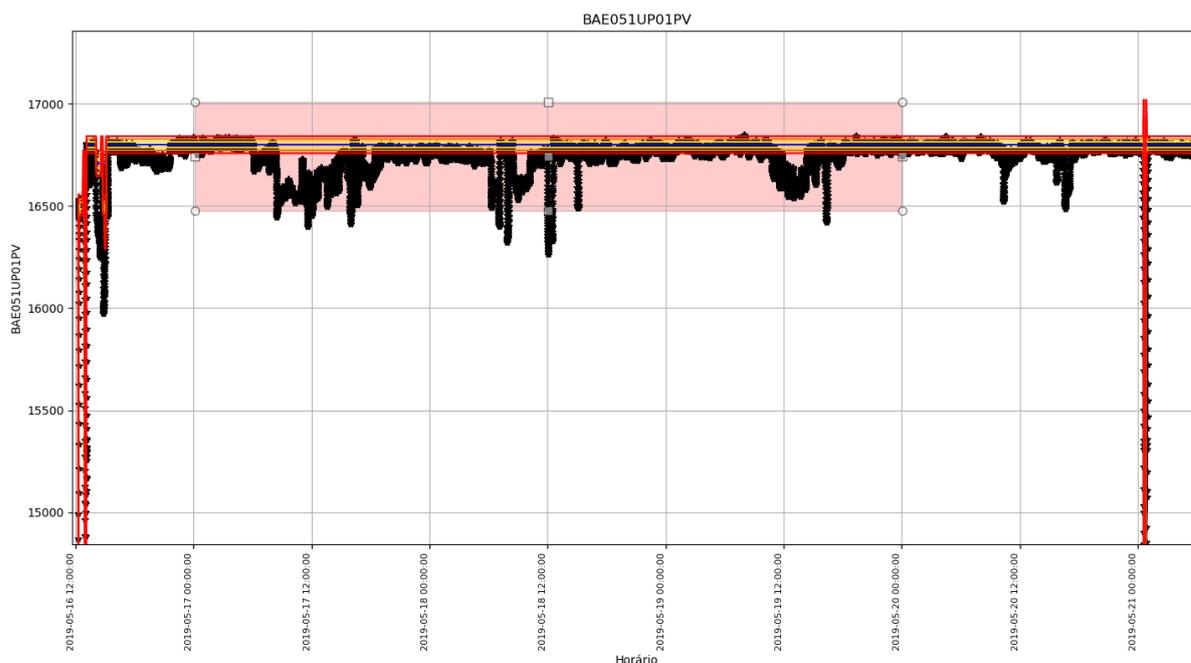


Figura 72 – Área selecionada do espectro da potência ativa do gerador do diagrama do mês de junho.

Na janela da Figura 72, foram gerados os gráficos de barras empilhadas para os subsistemas de óleo lubrificante e cilindros, conforme apresentados nas Figuras 73 e 74.

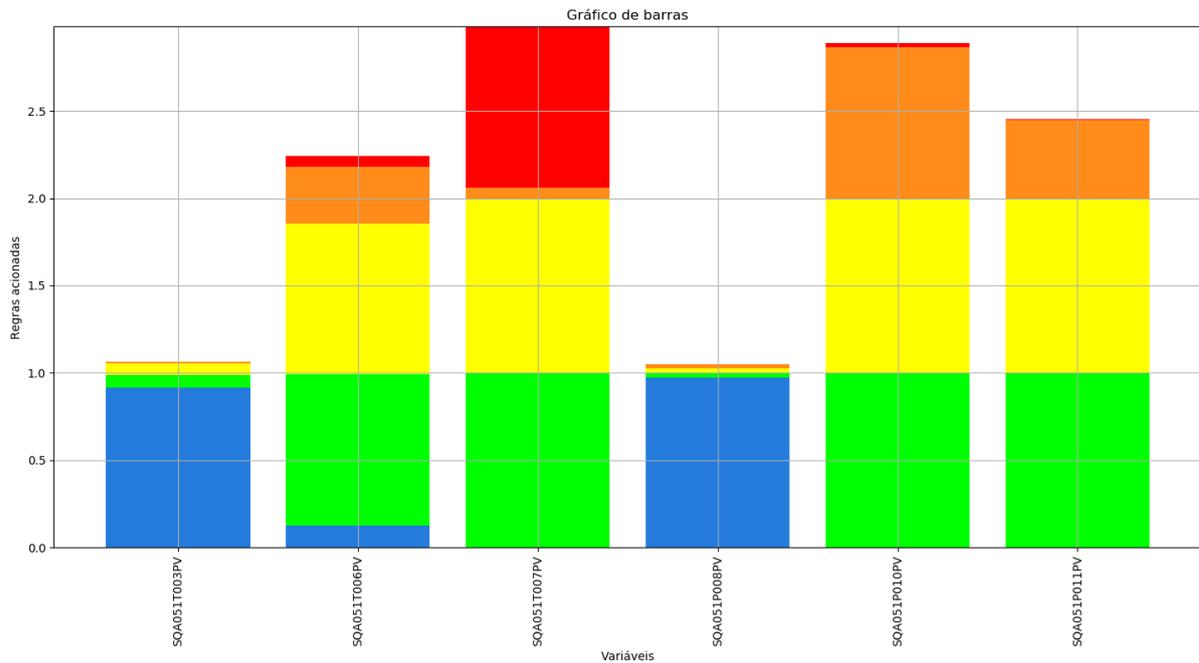


Figura 73 – Gráfico de barras do subsistema de Óleo Lubrificante, da sexta janela selecionada (Azul → R7, Verde → R8, Amarela → R6, Laranja → R5, Vermelha → R1).

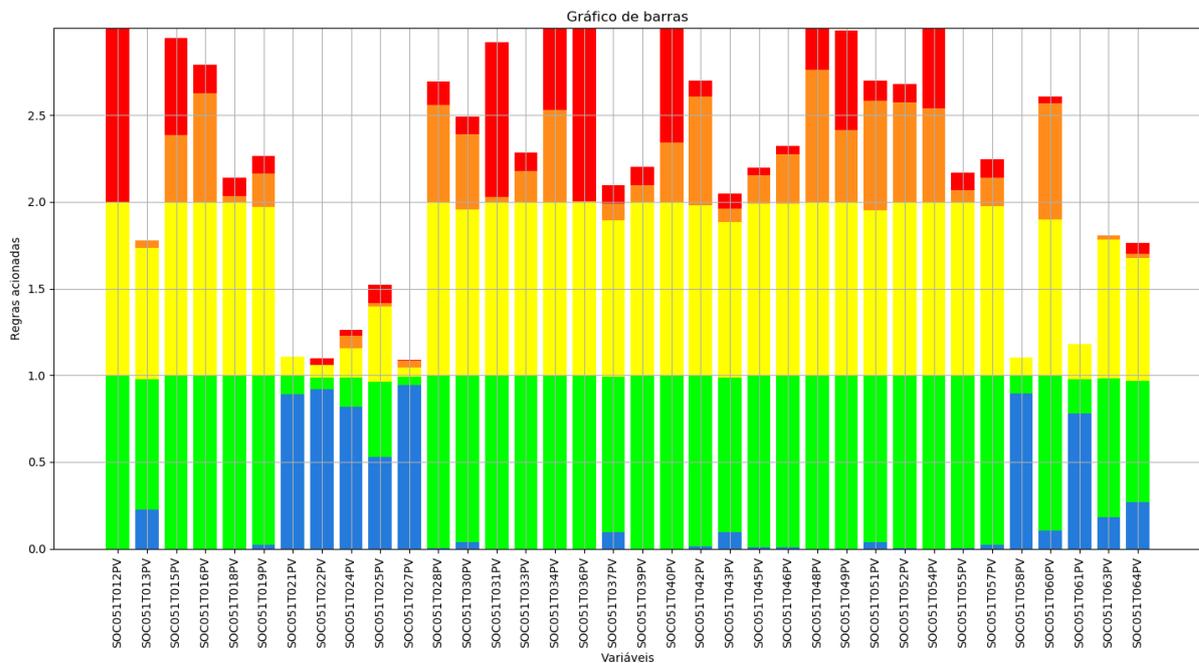


Figura 74 – Gráfico de barras do subsistema de Cilindros, da sexta janela selecionada (Azul → R7, Verde → R8, Amarela → R6, Laranja → R5, Vermelha → R1).

Em relação ao subsistema de óleo lubrificante (Figura 73), de acordo com a análise dos gráficos de barras empilhadas, fica evidente que nenhuma variável deste subsistema está operando na faixa normal (azul ou verde). Nenhuma variável supera este patamar, apresentando um sinal de atenção (amarelo). Além disso, nota-se que algumas variáveis deste subsistema entram na faixa de estresse (laranja). Por fim, três variáveis que compõem este subsistema, sendo uma delas a temperatura de saída do óleo lubrificante (cujo sensor é identificado pela tag SQA051T007PV) (vermelho 0.9) chegaram na Zona Vermelha, fora dos Limites de Controle, indicando que estão operando em situação de inadequação. Vale ressaltar que a situação de inadequação da temperatura de saída do óleo lubrificante (vermelho 0.9) (cujo sensor é identificado pela tag SQA051T007PV), mostrada no mês de Junho, pela Figura 73, está ainda maior do que a situação de inadequação (vermelho 0.5), mostrada no mês de Maio, pela Figura 70.

Em relação ao subsistema do cilindro (Figura 74), de acordo com a análise dos gráficos de barras empilhadas, fica claro que nenhuma variável está operando na faixa normal (azul ou verde). Fica claro também que, somente algumas variáveis superaram este patamar, apresentando um sinal de atenção (amarelo). Além disso, nota-se também que poucas variáveis entraram nas faixas de estresse (laranja). Por fim, a maioria das variáveis deste subsistema chegaram na Zona Vermelha (Inadequação), fora dos Limites de Controle. Destaque especial é dado a temperatura de revestimento dos cilindros B7 (vermelho 0.1), B4 (vermelho 0.601) e A6 (vermelho 0.2) (cujo sensores são identificados, respectivamente, pelas tags SOC051T057PV, SOC051T049PV e SOC051T028PV). Vale ressaltar que a situação de estresse (laranja) da temperatura de revestimento dos cilindros B7 (laranja 0.1) e A6 (laranja 0.7) (cujo sensores são identificados, respectivamente, pelas tags SOC051T057PV e SOC051T028PV) e a situação de inadequação (vermelha) da temperatura de revestimento do cilindro B4 (vermelho 0.6) (cujo sensor é identificado pela tag SOC051T049PV), mostradas na Figura 71, se tornaram situações de inadequação para os cilindros B7 (vermelho 0.1) e A6 (vermelho 0.2) e, no caso da situação de inadequação do cilindro B4, se tornaram situações de inadequação com valores um pouco maiores (vermelho 0.601) do que as situações de inadequação mostradas no mês de Maio (vermelho 0.6). Estas evidências são mostradas na Figura 74.

Vale destacar também que a partir dos resultados apresentados nos gráficos de barras empilhadas nesta janela, no subsistema de cilindros, percebe-se que o modelo estatístico aponta alterações estatísticas também em outros cilindros, como por exemplo, os cilindros A1 (sensor 1), A2 (ambos os sensores), A3 (ambos os sensores), B1 (ambos os sensores), B2 (ambos os sensores), entre outros.

#### 4.2.7 Análise 7: julho 2019

A sétima análise foi realizada na janela de tempo do mês de julho iniciada às 17:42:00 do dia 01-jul-2019 e finalizada às 00:08:04 do dia 08-jul-2019. Esta janela está indicada no diagrama da potência ativa do gerador do mês de julho, conforme mostra Figura 75.

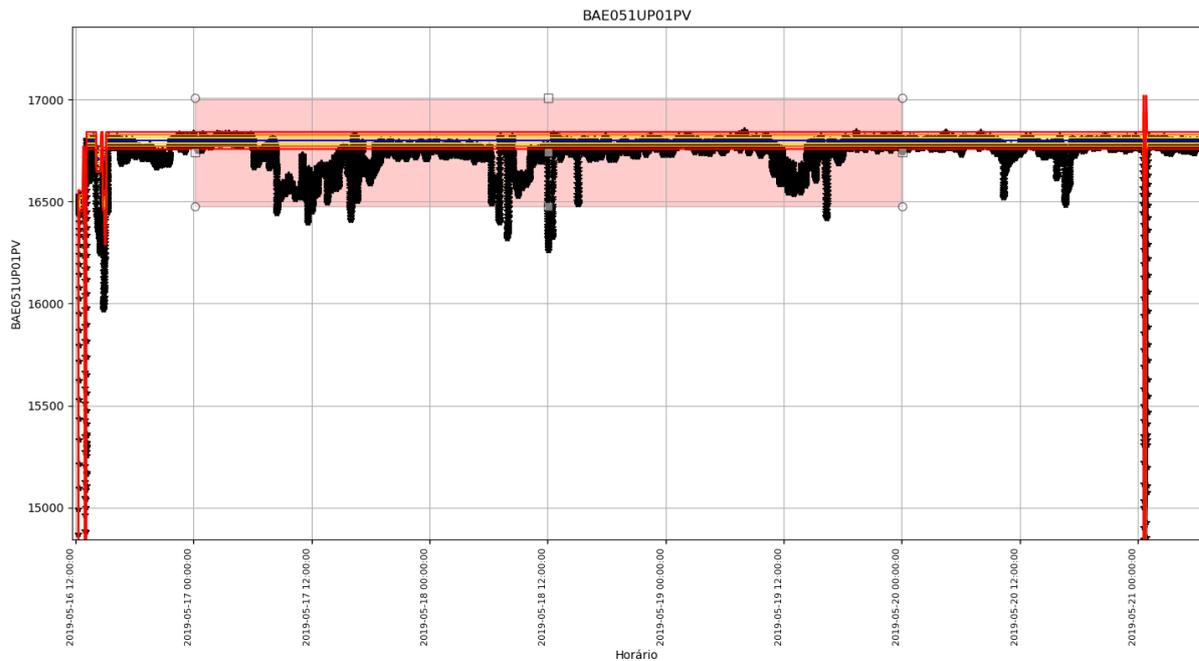


Figura 75 – Área selecionada do espectro da potência ativa do gerador do diagrama do mês de julho.

Na janela da Figura 75, foram gerados os gráficos de barras empilhadas para os subsistemas de óleo lubrificante e cilindros, conforme apresentados nas Figuras 76 e 77.

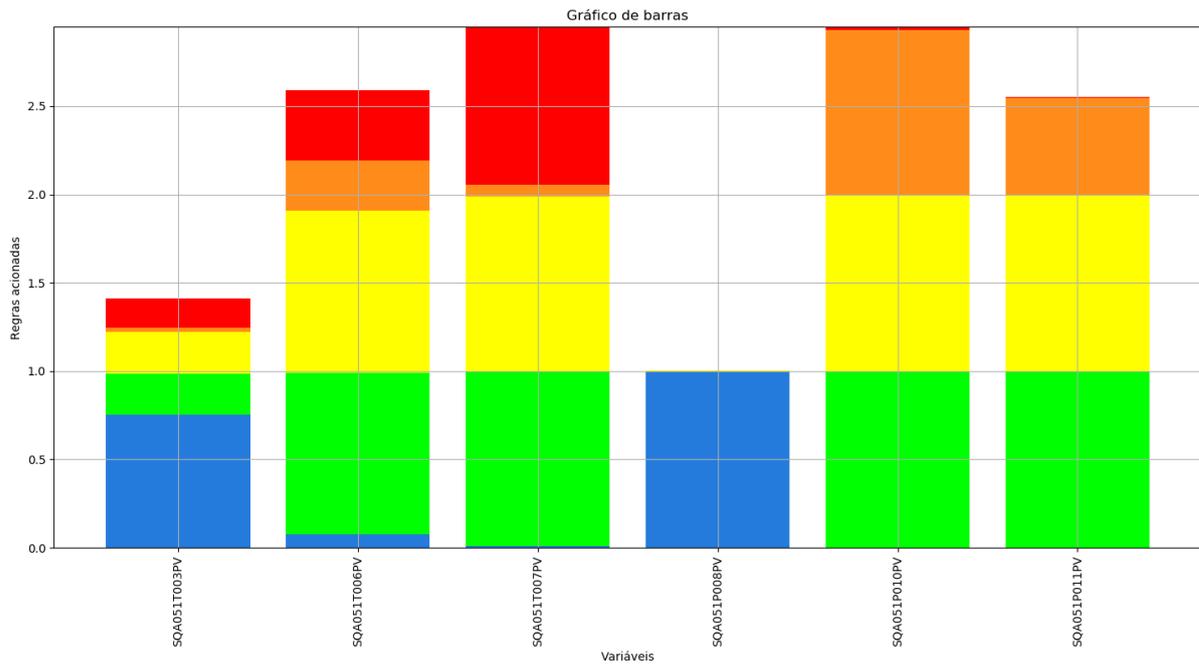


Figura 76 – Gráfico de barras do subsistema de Óleo Lubrificante, da sétima janela selecionada (Azul → R7, Verde → R8, Amarela → R6, Laranja → R5, Vermelha → R1).

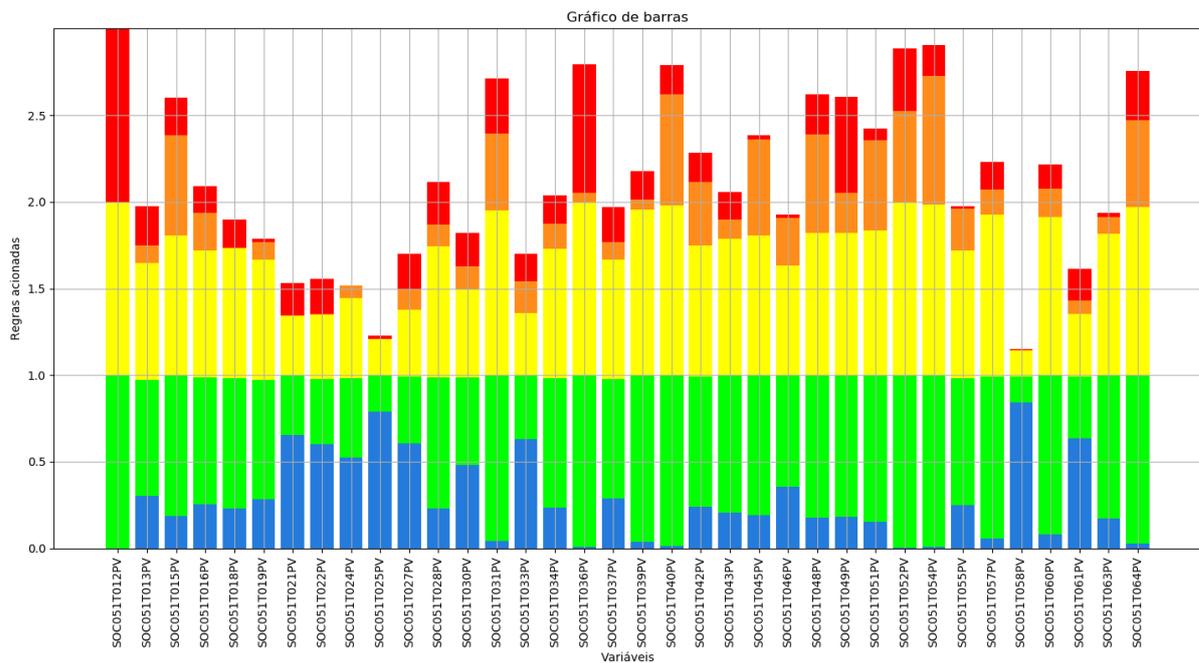


Figura 77 – Gráfico de barras do subsistema de Cilindros, da sétima janela selecionada (Azul → R7, Verde → R8, Amarela → R6, Laranja → R5, Vermelha → R1).

Em relação ao subsistema de óleo lubrificante (Figura 76), de acordo com a análise dos gráficos de barras empilhadas, fica evidente que apenas um variável deste subsistema está operando na faixa normal (azul ou verde), delimitando uma linha horizontal no

gráfico. Nenhuma variável supera este patamar, apresentando um sinal de atenção (amarelo). Além disso, nota-se que apenas uma variável deste subsistema entra na faixa de estresse (laranja). Por fim, a maioria das variáveis que compõem este subsistema, sendo uma delas a temperatura de saída do óleo lubrificante (cujo sensor é identificado pela tag SQA051T007PV) (vermelho 0.9) chegaram na Zona Vermelha, fora dos Limites de Controle, indicando que estão operando em situação de inadequação. Vale ressaltar que a situação de inadequação da temperatura de saída do óleo lubrificante (vermelho 0.9) (cujo sensor é identificado pela tag SQA051T007PV), mostrada no mês de Julho, pela Figura 76, se manteve ruim igual a inadequação (vermelho 0.9), mostrada no mês de Junho, pela Figura 73.

Em relação ao subsistema do cilindro (Figura 77), de acordo com a análise dos gráficos de barras empilhadas, fica claro que nenhuma variável está operando na faixa normal (azul ou verde). Fica claro também que, nenhuma variável superou este patamar, apresentando um sinal de atenção (amarelo). Além disso, nota-se também que poucas variáveis entraram nas faixas de estresse (laranja). Por fim, a maioria das variáveis deste subsistema chegaram na Zona Vermelha (Inadequação), fora dos Limites de Controle. Destaque especial é dado a temperatura de revestimento dos cilindros B7 (vermelho 0.2), B4 (vermelho 0.62) e A6 (vermelho 0.3) (cujo sensores são identificados, respectivamente, pelas tags SOC051T057PV, SOC051T049PV e SOC051T028PV). Vale ressaltar que as situações de inadequação (vermelha) da temperatura de revestimento dos cilindros B7 (vermelho 0.2), B4 (vermelho 0.62) e A6 (vermelho 0.3) (cujo sensores são identificados, respectivamente, pelas tags SOC051T057PV, SOC051T049PV e SOC051T028PV), mostradas no mês de Julho, pela Figura 77, se tornaram um pouco maiores do que as situações de inadequação dos cilindros B7 (vermelho 0.1), B4 (vermelho 0.601) e A6 (vermelho 0.2), mostradas no mês de Junho, pela Figura 74.

Vale destacar também que a partir dos resultados apresentados nos gráficos de barras empilhadas nesta janela, no subsistema de cilindros, percebe-se que o modelo estatístico aponta alterações estatísticas também em outros cilindros, como por exemplo, os cilindros A1 (ambos os sensores), A2 (ambos os sensores), A3 (ambos os sensores), B1 (ambos os sensores), B2 (ambos os sensores), entre outros.

#### 4.2.8 Análise 8: agosto 2019

A oitava análise foi realizada na janela de tempo do mês de agosto iniciada às 07:59:45 do dia 01-ago-2019 e finalizada às 13:11:33 do dia 01-ago-2019. Esta janela está indicada no diagrama da potência ativa do gerador do mês de agosto, conforme mostra Figura 78.

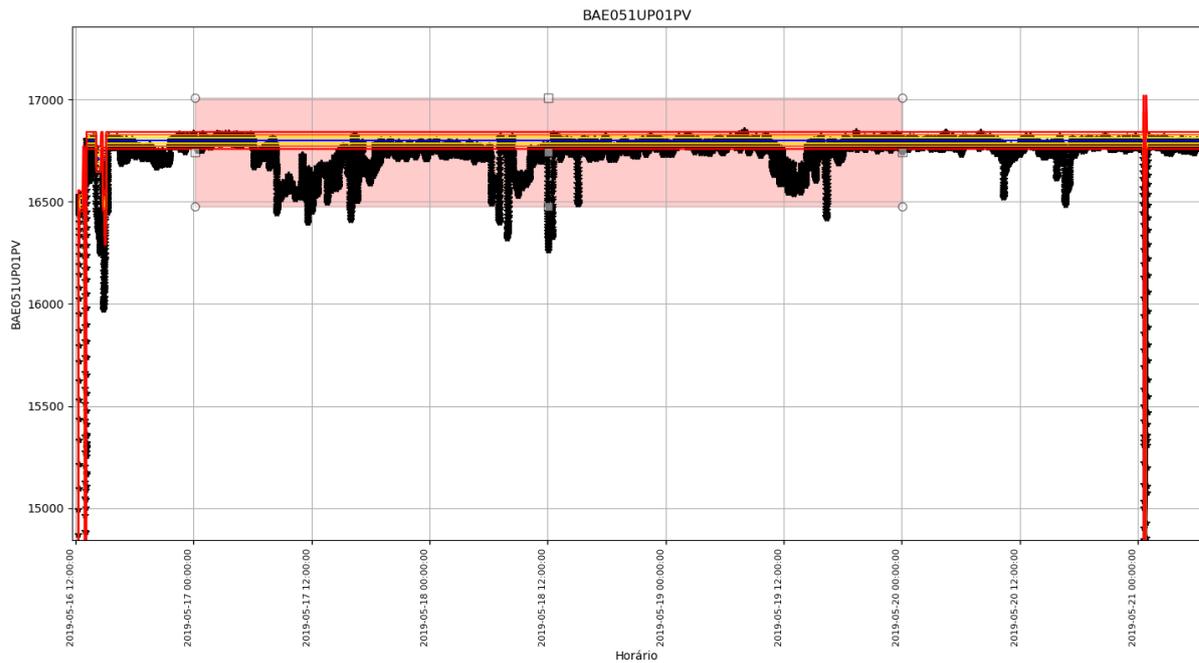


Figura 78 – Área selecionada do espectro da potência ativa do gerador do diagrama do mês de agosto.

Na janela da Figura 78, foram gerados os gráficos de barras empilhadas para os subsistemas de óleo lubrificante e cilindros, conforme apresentados nas Figuras 79 e 80.

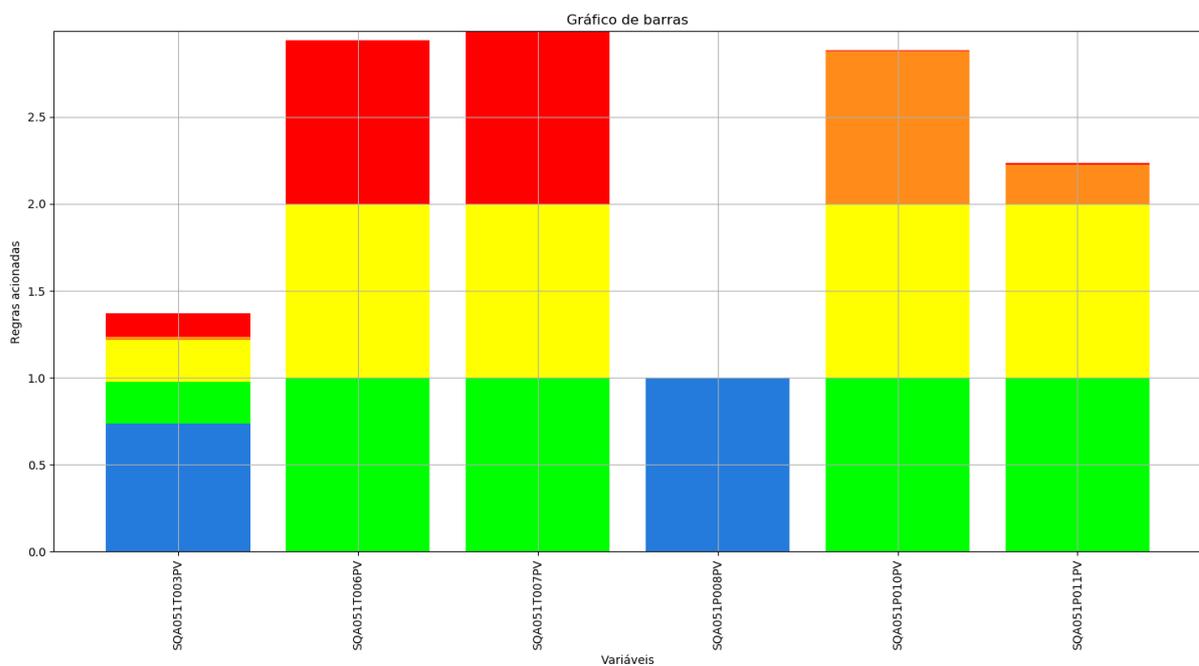


Figura 79 – Gráfico de barras do subsistema de Óleo Lubrificante, da oitava janela selecionada (Azul → R7, Verde → R8, Amarela → R6, Laranja → R5, Vermelha → R1).

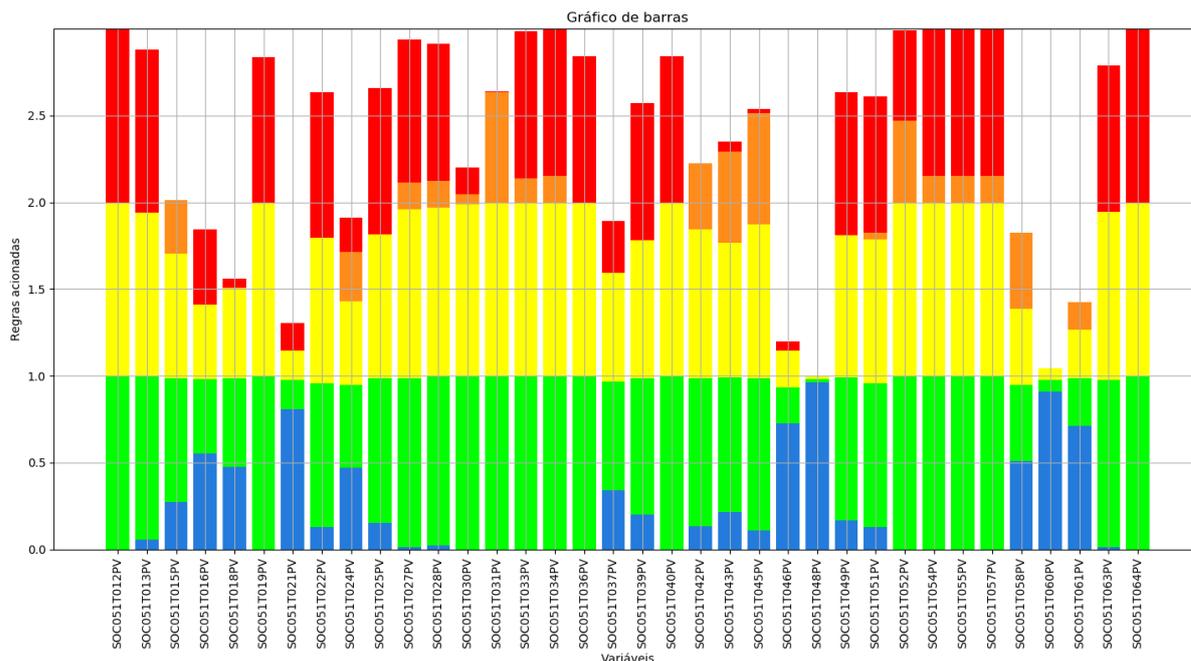


Figura 80 – Gráfico de barras do subsistema de Cilindros, da oitava janela selecionada. (Azul  $\rightarrow$  R7, Verde  $\rightarrow$  R8, Amarela  $\rightarrow$  R6, Laranja  $\rightarrow$  R5, Vermelha  $\rightarrow$  R1 )

Em relação ao subsistema de óleo lubrificante (Figura 79), de acordo com a análise dos gráficos de barras empilhadas, fica evidente que apenas uma variável deste subsistema está operando na faixa normal (azul ou verde), delimitando uma linha horizontal no gráfico. Nenhuma variável supera este patamar, apresentando um sinal de atenção (amarelo). Além disso, nota-se que apenas uma variável deste subsistema entra na faixa de estresse (laranja). Por fim, a maioria das variáveis que compõem este subsistema, sendo uma delas a temperatura de saída do óleo lubrificante (cujo sensor é identificado pela tag SQA051T007PV) (vermelho 1.0) chegaram na Zona Vermelha, fora dos Limites de Controle, indicando que estão operando em situação de inadequação. Vale ressaltar que a situação de inadequação da temperatura de saída do óleo lubrificante (vermelho 1.0), mostrada no mês de Agosto, pela Figura 79, está ainda maior do que a situação de inadequação (vermelho 0.9), mostrada no mês Julho, pela Figura 76. Em outras palavras, conforme esperado, o mês de Agosto apresenta a pior situação de inadequação da temperatura de saída do óleo lubrificante, com 100% de ativação da Zona Vermelha.

Em relação ao subsistema do cilindro (Figura 80), de acordo com a análise dos gráficos de barras empilhadas, fica claro que apenas uma variável está operando na faixa normal (azul ou verde). Fica claro também que, poucas variáveis superam este patamar, apresentando um sinal de atenção (amarelo). Além disso, nota-se também que algumas variáveis entraram nas faixas de estresse (laranja). Por fim, a maioria das variáveis deste subsistema chegaram na Zona Vermelha (Inadequação), fora dos Limites de Controle. Destaque especial é dado a temperatura de revestimento dos cilindros B7 (vermelho 0.8),

B4 (vermelho 0.75) e A6 (vermelho 0.83) (cujo sensores são identificados, respectivamente, pelas tags SOC051T057PV, SOC051T049PV e SOC051T028PV). Vale ressaltar que as situações de inadequação (vermelha) da temperatura de revestimento dos cilindros B7 (vermelho 0.8), B4 (vermelho 0.75) e A6 (vermelho 0.83) (cujo sensores são identificados, respectivamente, pelas tags SOC051T057PV, SOC051T049PV e SOC051T028PV), mostradas no mês de Agosto, pela Figura 80, se tornaram muito piores do que as situações de inadequações dos cilindros B7 (vermelho 0.2), B4 (vermelho 0.62) e A6 (vermelho 0.3), mostradas no mês de Julho, pela Figura 77. Em outras palavras, conforme esperado, o mês de Agosto apresenta a pior situação de inadequação da temperatura de revestimento dos cilindros B7, B4 e A6.

Vale destacar também que a partir dos resultados apresentados nos gráficos de barras empilhadas nesta janela, no subsistema de cilindros, percebe-se que o modelo estatístico aponta alterações estatísticas também em outros cilindros, como por exemplo, os cilindros A1 (ambos os sensores), A2 (sensor 2), A3 (ambos os sensores), B1 (ambos os sensores), B2 (sensor 2), entre outros.

De posse destas 8 análises foi realizado uma correlação do grau de severidade da condição operacional da UG 5 com o sinistro ocorrido nesta mesma UG no dia 01-ago-2019, conforme apresentado na Tabela 16 e nas Figuras do Apêndice C.

Tabela 16 – Tabela que apresenta os acontecimentos do sinistro do dia 01-ago-2019.

Horário	Descrição
00:50	Substituição da rede de controle do cilindro B6
08:19	Gás Trip; alarme de vazamento de gás
09:15	Teste de vazamento de gás, identificado vazamento no cilindro A6
10:40	Substituição dos <i>orings</i> da rede dupla de gás cil. A5 para A6
10:40	Substituição dos <i>orings</i> da caneta de gás do cil. A6
10:50	Teste de vazamento de gás; UGD não apresentou vazamento
14:41	<i>Shutdown</i> , alarme do detector de névoa
14:45	Informado o desligamento da máquina 05
15:05	Inspeção nos filtros <i>backflusing</i> e verificado a presença de limalhas
15:15	Passeio de bielas e verificado que o cilindro B7 está travado

Nota-se a adequada aderência entre os desvios estatísticos apresentados nos gráficos de barras empilhadas desde a análise 4 até a análise 8 e o apontamento do sinistro do dia 01-ago-2019 que é o cilindro B7 ter travado, mostrado na Tabela 16 e nas Figuras do Apêndice C, ou seja, o modelo estatístico aqui proposto já estava alertando de forma precoce a ocorrência de *shutdown* do dia 01-ago-2019 desde a análise 4, no mês de Abril, quando o cilindro B7 passou a atuar de uma condição normal (azul 1.0 ou verde 0.0) dos 3 primeiros meses para uma condição de atenção (amarelo 0.1) e foi se degradando até chegar em Junho em uma faixa da Zona Vermelha (0.1), na qual foi piorando nos próximos meses, até que por fim, chega em Agosto (vermelho 0.8) com a maior porcentagem de ativação da Zona Vermelha, comprovando assim que este cilindro está em situação de ina-

dequação e possivelmente iria travar, validando assim este modelo estatístico. Observa-se também outra adequada aderência entre os desvios estatísticos apresentados nos gráficos de barras empilhadas e o apontamento do sinistro do dia 01-ago-2019, pois o cilindro A6, se encontrava normal (região azul 1.0 ou verde 0.0) nos 3 primeiros meses de análise, desde a análise 1 até análise 3, e no mês seguinte de Abril (Análise 4) passou a atuar na faixa de estresse (laranja 0.63). Após isto, no mês de Maio (Análise 5) este nível de estresse aumenta (laranja 0.7). No mês de Junho, este cilindro se degrada ainda mais passando a atuar na faixa Vermelha (Inadequação) (0.2). E no mês de Julho, este índice de inadequação vai crescendo (vermelho 0.3) até chegar em Agosto, com o maior grau de inadequação (vermelho 0.83), comprovando também, com mais de um evento, a validação deste modelo estatístico. Além destes apontamentos de aderência com os acontecimentos do sinistro do dia 01-ago-2019, nota-se também que outros cilindros vinham se degradando antes da parada do dia primeiro, destaque especial é dado neste trabalho para o cilindro B4. Este cilindro B4 vinha trabalhando em situação normal (azul 1.0 ou verde 0.0), nos 3 primeiros meses (Análise 1 até Análise 3), e no mês seguinte de Abril (Análise 4) passou a atuar na faixa de estresse (laranja 0.3). Após isto, nos meses de Maio (vermelho 0.6), Junho (vermelho 0.601) e Julho (vermelho 0.62) (Análise 5, 6 e 7) este cilindro se degrada ainda mais passando a atuar em situação de inadequação com níveis cada vez maiores até chegar em Agosto (vermelho 0.75), com o maior grau de inadequação. Por fim, embora não esteja registrado no apontamento do sinistro do dia 01-ago-2019, observa-se também que a temperatura de saída do óleo lubrificante se encontrava normal nos 3 primeiros meses (azul 1.0 e verde 0.0) (Análise 1 até Análise 3), e a partir do mês de Abril (Análise 4) passa a atuar na faixa de atenção (amarelo 0.1). Após isto, nos meses de Maio (vermelho 0.5), Junho (vermelho 0.9) e Julho (vermelho 0.9) (Análise 5, 6 e 7) esta temperatura se degrada ainda mais passando a atuar em situação de inadequação com níveis cada vez maiores até chegar em Agosto (vermelho 1.0), com a maior porcentagem de ativação do grau de inadequação, comprovando que a temperatura de saída do óleo lubrificante estava esquentando e, conseqüentemente, a propriedade mecânica do óleo lubrificante de lubrificar e resfriar as peças móveis do MCI foi perdida. Estas duas últimas análises realizadas neste trabalho, comprova também, que o modelo estatístico já estava alertando de forma preditiva, com 4 meses de antecedência, que não só outros cilindros já apresentavam problemas como também outras variáveis de outros subsistemas, como aqui mostrado, a temperatura de saída do óleo lubrificante do subsistema de óleo lubrificante.

### 4.3 Desempenho e validação do modelo estatístico após o retorno da UG 5

Para verificar o desempenho e a validação do modelo estatístico, após o retorno da manutenção corretiva da UG 5, devido ao sinistro do dia 01-ago-2019, da mesma forma

que a análise aplicada na subseção anterior, primeiramente, foi selecionado 1 janela de tempo para cada mês no gráfico da potência ativa do gerador da UG 5 para os meses de Novembro e Dezembro, pois foi quando a UG voltou a atuar. Após isto, foram gerados gráficos de barras empilhadas para cada uma delas para os subsistemas de óleo lubrificante e cilindros. E, por fim, os resultados estatísticos destas análises foram correlacionados com o grau de severidade da condição operacional da UG 5, verificando a validação do modelo, conforme detalhado nas subseções seguintes.

### 4.3.1 Análise 9: novembro 2019

A primeira análise, após o retorno da UG 5, foi realizada na janela de tempo do mês de novembro iniciada às 02:54:09 do dia 19-nov-2019 e finalizada às 16:47:55 do dia 19-nov-2019. Esta janela está indicada no diagrama da potência ativa do gerador do mês de novembro, conforme mostra Figura 81.

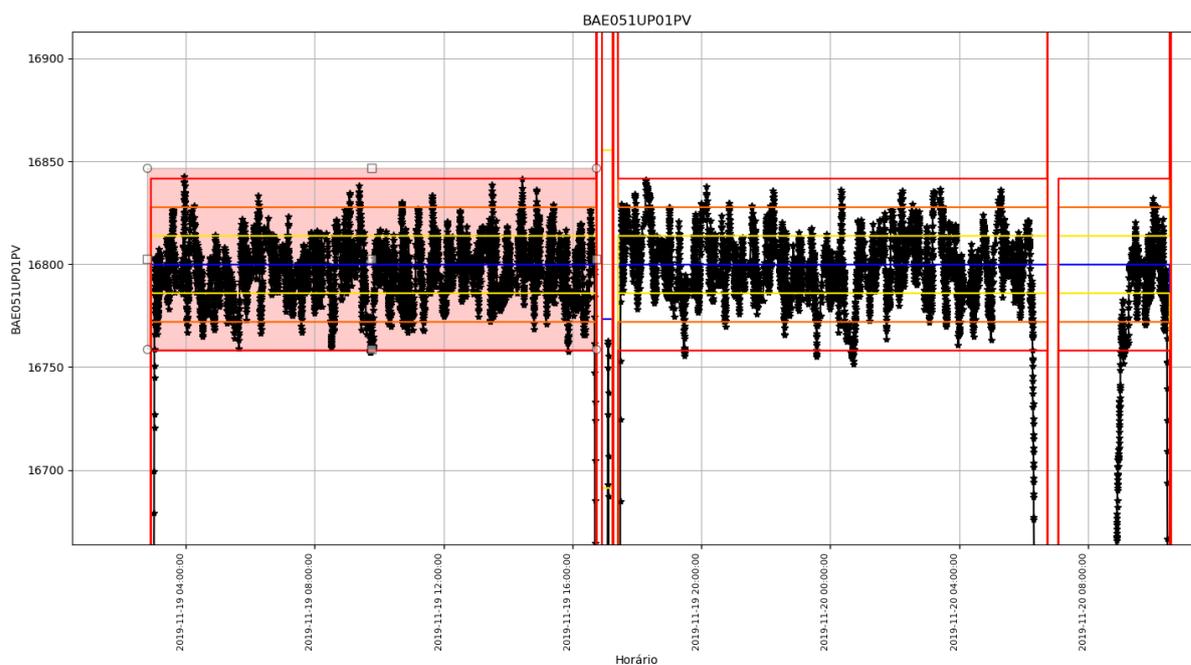


Figura 81 – Área selecionada do espectro da potência ativa do gerador do diagrama do mês de novembro.

Na janela da Figura 81, foram gerados os gráficos de barras empilhadas para os subsistemas de óleo lubrificante e cilindros, conforme apresentados nas Figuras 82 e 83.

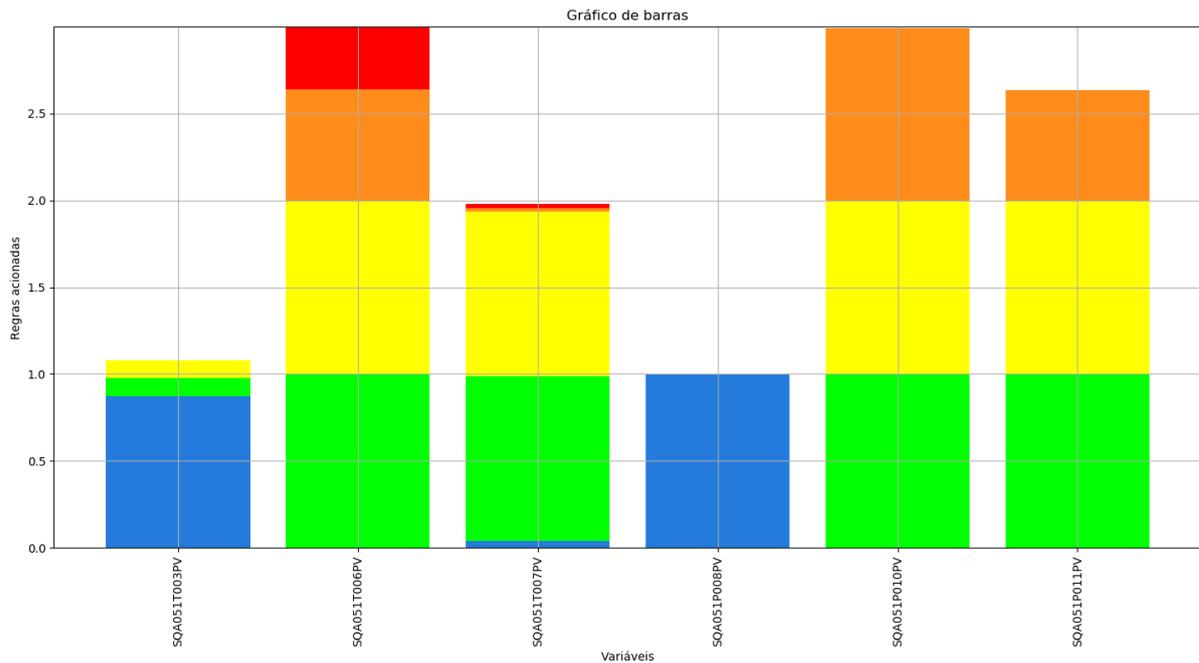


Figura 82 – Gráfico de barras do subsistema de Óleo Lubrificante, da nona janela selecionada (Azul → R7, Verde → R8, Amarela → R6, Laranja → R5, Vermelha → R1).

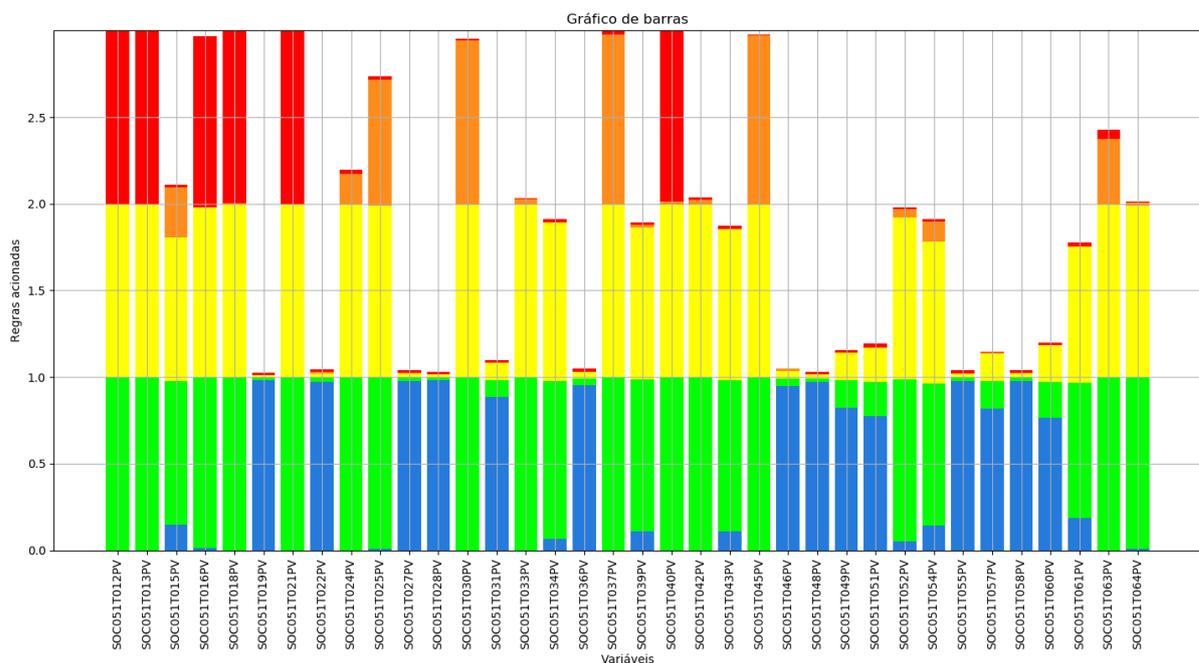


Figura 83 – Gráfico de barras do subsistema de Cilindros, da nona janela selecionada (Azul → R7, Verde → R8, Amarela → R6, Laranja → R5, Vermelha → R1).

Em relação ao subsistema de óleo lubrificante (Figura 82), de acordo com a análise dos gráficos de barras empilhadas, fica evidente que apenas uma variável deste subsistema está operando na faixa normal (azul ou verde), delimitando uma linha horizontal no

gráfico. Somente uma variável supera este patamar, apresentando um sinal de atenção (amarelo). Além disso, nota-se que apenas algumas variáveis deste subsistema entram na faixa de estresse (laranja). Por fim, duas variáveis que compõem este subsistema, sendo uma delas a temperatura de saída do óleo lubrificante (cujo sensor é identificado pela tag SQA051T007PV) (vermelho 0.01) chegaram na Zona Vermelha, fora dos Limites de Controle, indicando que estão operando em situação de inadequação. Vale ressaltar que esta situação de inadequação da temperatura de saída do óleo lubrificante (vermelho 0.01), mostrada no mês de Novembro, pela Figura 82, está bem melhor do que as situações de inadequações mostradas pelas Zonas vermelha nos meses de Maio (0.5), Junho (0.9), Julho (0.9) e Agosto (1.0), pelas Figuras 70, 73, 76 e 79. Em outras palavras, a temperatura de saída do óleo lubrificante da UG 5 retornou suas atividades de lubrificação e resfriamento bem melhores do que as apresentadas pelos meses que antecederam a parada do dia 01-ago-2019. Consequentemente, pode-se concluir que a UG 5 volta melhor do que antes do sinistro.

Em relação ao subsistema do cilindro (Figura 83), de acordo com a análise dos gráficos de barras empilhadas, fica claro que nenhuma variável está operando na faixa normal (azul ou verde). Fica claro também que, nenhuma variável supera este patamar, apresentando um sinal de atenção (amarelo). Além disso, nota-se também que poucas variáveis entraram nas faixas de estresse (laranja), como destaque a temperatura de revestimento do cilindro B7 (laranja 0.001) (cujo sensor é identificado pela tag SOC051T057PV) . Por fim, a maioria das variáveis deste subsistema chegaram na Zona Vermelha (Inadequação), fora dos Limites de Controle. Destaque especial é dado a temperatura de revestimento dos cilindros B4 (vermelho 0.01) e A6 (vermelho 0.01) (cujo sensores são identificados, respectivamente, pelas tags SOC051T049PV e SOC051T028PV). Vale ressaltar que as situações de inadequação (vermelha) da temperatura de revestimento dos cilindros B4 (vermelho 0.01) e A6 (vermelho 0.01) (cujo sensores são identificados, respectivamente, pelas tags SOC051T049PV e SOC051T028), mostradas no mês de Novembro, pela Figura 83, se tornaram muito melhores do que as situações de inadequação mostradas nos meses de Junho (B4 (vermelho 0.601) e A6 (vermelho 0.2)), Julho (B4 (vermelho 0.62) e A6 (vermelho 0.3)) e Agosto (B4 (vermelho 0.75) e A6 (vermelho 0.83)), pelas Figuras 74, 77 e 80. Em outras palavras, os níveis de inadequação (vermelha) da temperatura de revestimento dos cilindros B4 (vermelho 0.01) e A6 (vermelho 0.01), após o retorno da UG 5, se tornaram bem menores do que os níveis apresentados pelos meses que antecederam a parada do dia 01-ago-2019. Além disso, a temperatura de revestimento do cilindro B7 passou da situação de inadequação (vermelho 0.83) para faixa de estresse (laranja 0.001), melhorando sua condição em relação as condições apresentadas nos meses que antecederam a parada do dia 01-ago-2019, sendo Junho (vermelho 0.1), Julho (vermelho 0.2) e Agosto (vermelho 0.8), conforme mostram as Figuras 74, 77 e 80. Consequentemente, pode-se concluir que os cilindros B7, B4 e A6 se tornaram melhores do que antes da parada da UG.

### 4.3.2 Análise 10: dezembro 2019

A segunda análise, após o retorno da UG 5, foi realizada na janela de tempo do mês de dezembro iniciada às 00:00:00 do dia 17-dez-2019 e finalizada às 00:01:00 do dia 18-dez-2019. Esta janela está indicada no diagrama da potência ativa do gerador do mês de dezembro, conforme mostra Figura 84.

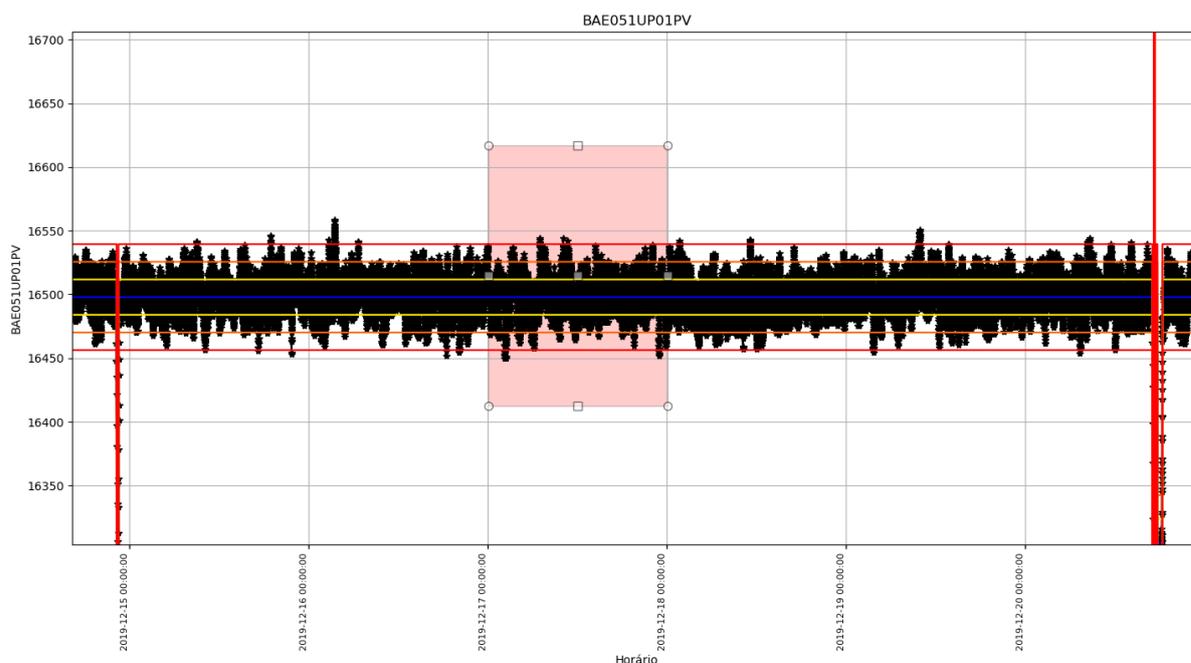


Figura 84 – Área selecionada do espectro da potência ativa do gerador do diagrama do mês de dezembro.

Na janela da Figura 84, foram gerados os gráficos de barras empilhadas para os subsistemas de óleo lubrificante e cilindros, conforme apresentados nas Figuras 85 e 86.

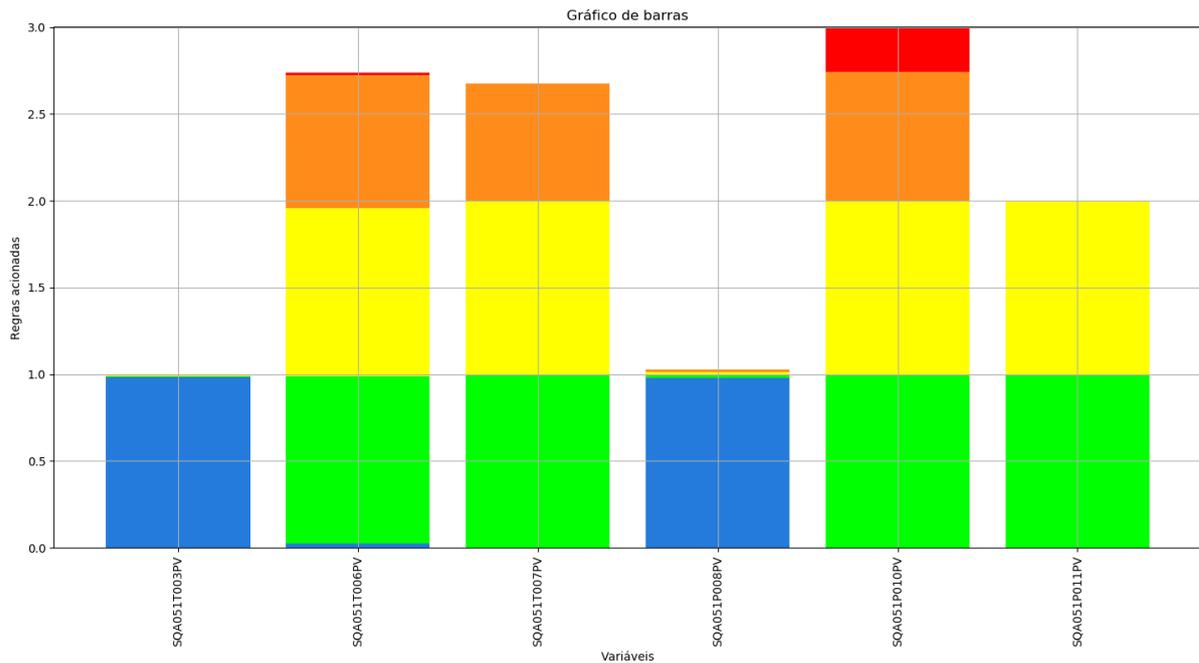


Figura 85 – Gráfico de barras do subsistema de Óleo Lubrificante, da décima janela selecionada (Azul → R7, Verde → R8, Amarela → R6, Laranja → R5, Vermelha → R1).

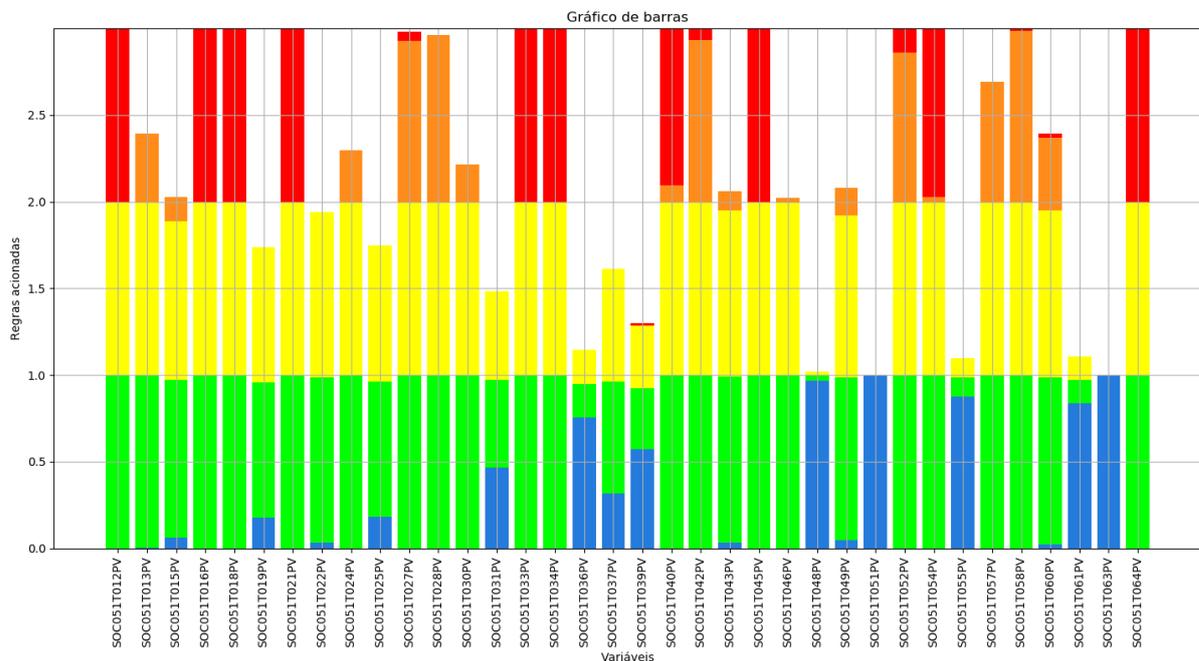


Figura 86 – Gráfico de barras do subsistema de Cilindros, da nona janela selecionada (Azul → R7, Verde → R8, Amarela → R6, Laranja → R5, Vermelha → R1).

Em relação ao subsistema de óleo lubrificante (Figura 85), de acordo com a análise dos gráficos de barras empilhadas, fica evidente que apenas uma variável deste subsistema está operando na faixa normal (azul ou verde), delimitando uma linha horizontal

no gráfico. Somente uma variável supera este patamar, apresentando um sinal de atenção (amarelo). Além disso, nota-se que apenas algumas variáveis deste subsistema entram na faixa de estresse (laranja), sendo uma delas a temperatura de saída do óleo lubrificante (cujo sensor é identificado pela tag SQA051T007PV) (laranja 0.7). Por fim, duas variáveis que compõem este subsistema chegaram na Zona Vermelha, fora dos Limites de Controle, indicando que estão operando em situação de inadequação. Vale ressaltar que a temperatura de saída do óleo lubrificante, mostrada pela Zona Vermelha (0.01) da Figura 82, saiu da situação de inadequação no mês de Novembro e passou a atuar na situação de estresse (laranja 0.7) no mês de Dezembro, conforme mostrado na Figura 85. Vale ressaltar ainda que a situação de estresse (laranja 0.7) mostrada no mês de Dezembro, pela Figura 85 está ainda melhor do que as situações de inadequações mostradas pelas Zonas vermelha nos meses de Maio (0.5), Junho (0.9), Julho (0.9) e Agosto (1.0), pelas Figuras 70, 73, 76 e 79. Em outras palavras, a temperatura de saída do óleo lubrificante da UG 5 no mês de Dezembro apresentou suas atividades de lubrificação e resfriamento ainda melhores do que as apresentadas tanto pelos meses que antecederam a parada do dia 01-ago-2019 quanto para o primeiro mês após esta parada.

Em relação ao subsistema do cilindro (Figura 86), de acordo com a análise dos gráficos de barras empilhadas, fica claro que poucas variáveis estão operando na faixa normal (azul ou verde). Fica claro também que, algumas variáveis superaram este patamar, apresentando um sinal de atenção (amarelo). Além disso, nota-se também que algumas variáveis entraram nas faixas de estresse (laranja), destacando a temperatura de revestimento dos cilindros B7 (laranja 0.7), B4 (laranja 0.2) e A6 (laranja 0.9) (cujo sensores são identificados, respectivamente, pelas tags SOC051T057PV, SOC051T049PV e SOC051T028PV). Por fim, a maioria das variáveis deste subsistema chegaram na Zona Vermelha (Inadequação), fora dos Limites de Controle. Vale ressaltar que as situações de inadequação (vermelha) da temperatura de revestimento dos cilindros B4 (vermelho 0.01) e A6 (vermelho 0.01) (cujo sensores são identificados, respectivamente, pelas tags SOC051T049PV e SOC051T028PV), mostradas no mês de Novembro, pela Figura 83, se tornaram situações de estresse B4 (laranja 0.2) e A6 (laranja 0.9) no mês de Dezembro, conforme mostradas na Figura 86. Consequentemente, estas situações se encontram muito melhores do que as situações de inadequação mostradas nos meses de Junho (B4 (vermelho 0.601) e A6 (vermelho 0.2)), Julho (B4 (vermelho 0.62) e A6 (vermelho 0.3)) e Agosto (B4 (vermelho 0.75) e A6 (vermelho 0.83)), pelas Figuras 74, 77 e 80. Em outras palavras, os níveis de inadequação (vermelha) da temperatura de revestimento dos cilindros B4 e A6 apresentados pelos meses que antecederam a parada do dia 01-ago-2019, se tornaram níveis de estresse, após o segundo mês de retorno da UG 5. Além disso, vale ressaltar também que, a situação de estresse (laranja 0.7) da temperatura de revestimento do cilindro B7 (cujo sensor é identificado pela tag SOC051T057PV), mostradas na Figura 86, se tornaram muito melhores do que as situações de inadequação mostradas no mês de

de Junho (vermelho 0.1), Julho (vermelho 0.2) e Agosto (vermelho 0.8), pelas Figuras 74, 77 e 80. Consequentemente, pode-se concluir que os cilindros B7, B4 e A6 se tornaram melhores do que antes da parada da UG.

A partir das análises realizadas nestas duas últimas seções, nota-se que o modelo estatístico aqui proposto é capaz de monitorar a condição operacional de um MCI estatisticamente, via regras de Nelson, e indicar de forma precoce aos operadores das máquinas qual grau de severidade encontra-se os motores que compõem a UTE em questão, ou seja, se os motores em análise estão bons ou ruins e, como está a condição deles quando retornam as atividades. Consequentemente, com estes apontamentos foi possível validar o modelo proposto neste trabalho e ainda ajudar os operadores das máquinas tanto no processo de tomada de decisão sobre a manutenção dos MCI quanto verificar se a condição de retorno desses motores estão boas ou ruins. Vale ressaltar que, é muito importante notar que essas previsões devem ser entendidas mais como uma probabilidade estatística de uma falha do que um problema físico real.

## 5 Conclusão

O presente trabalho analisou a capacidade de um modelo estatístico em prever estatisticamente uma falha precoce em um motor de combustão interna (Wärtsilä 18V46) em operação em uma usina termelétrica no Brasil. Embora existam na literatura vários trabalhos que realizam a análise precoce de falhas no motor de combustão interna, nenhum trabalho realizou esta análise baseado nas regras de Nelson. Portanto, o método de análise aqui apresentado é inédito e foi validado a partir de dois estudos de caso, sendo o primeiro estudo de caso uma comparação entre o grau de severidade da condição operacional da unidade geradora 5 encontrado no tratamento de dados e o evento de parada desta mesma unidade geradora no dia 01-ago-2019 e o segundo os apontamentos estatísticos do grau de severidade da unidade geradora 5 quando ela retorna da manutenção de sua parada. O mecanismo de análise, conforme já foi mencionado, é baseado nos princípios do controle estatístico de processos e nas regras de Nelson.

Foi apresentado um sistema de visualização gráfica, concentrando as regras de Nelson para todas variáveis medidas por sensores, em forma de gráfico de barras empilhadas, utilizando-se uma escala de cores diferentes, que indicam progressivamente o desvio de cada variável de seu valor referência. As regras foram ordenadas conforme seu grau de severidade, criando-se uma progressão de cores que vai desde uma situação normal até uma situação fora do intervalo de 3 desvios padrão, que caracteriza a situação fora dos limites de controle na carta de controle. A escala de cores inicia-se em azul (situação normal), e avança para verde (satisfatório), amarela (atenção), laranja (insatisfatório) e termina em vermelho (inadequado). Vale ressaltar que existe ainda a cor roxa, na qual indica uma situação de mudança rápida no valor médio da variável. Essa mudança, para cima, ou para baixo, indica uma situação atípica iminente. Assim, este gráfico fornece ao pessoal de supervisão uma visualização mais instintiva e rápida das possíveis tendências de falha na planta.

Os gráficos de barras empilhadas obtidos das regras de Nelson foram correlacionados com o grau de severidade da condição operacional da UG 5 e com o sinistro da mesma no dia 01/ago/2019, apresentando uma boa correspondência nas previsões, como a falha no Cilindro A6 e a falha no cilindro B7 (cilindro indicado no sinistro do dia 01/ago/2019). Pode-se concluir que o cilindro B7 vinha em estado de normalidade nos 3 primeiros meses de análise, sendo janeiro (azul 1.0 e verde 0.0), fevereiro (azul 1.0 e verde 0.0) e março (azul 1.0 e verde 0.0), até que no próximo mês, em abril, o cilindro B7 passou a atuar em uma condição de estresse (laranja 0.03) e foi se degradando até passar a atuar na faixa de inadequação (vermelho 0.1), ou seja, na faixa fora dos limites de controle, no mês de junho. Após isto, nos próximos meses, essa condição de inadequação continuou pio-

rando, até que por fim, em agosto, atinge o maior nível de inadequação (vermelho 0.8), ou seja, a maior porcentagem de ativação da Zona Vermelha, comprovando, portanto, que o modelo estatístico vinha alertando de forma precoce a aproximadamente 4 meses que possivelmente o cilindro B7 iria travar, validando assim o modelo estatístico proposto neste trabalho. Ressalta-se também que, a partir desta análise, comprova-se a capacidade do modelo estatístico em prever estatisticamente ocorrências de falhas de maneira preditiva.

Ressalta-se também outra adequada aderência entre os desvios estatísticos apresentados nos gráficos de barras empilhadas e o apontamento do sinistro do dia 01/ago/2019, pois o cilindro A6, se encontrava em condição normal nos 3 primeiros meses de análise, desde de janeiro (azul 1.0 e verde 0.0) até março (azul 0.99 e verde 0.01), e no mês seguinte de abril passou a atuar em condição de estresse (laranja 0.63). Após isto, no mês de maio este nível de estresse aumenta (laranja 0.7). No mês de junho, este cilindro se degrada ainda mais passando a atuar na faixa de inadequação (vermelho 0.2), região fora dos limites de controle. E no mês de julho (vermelho 0.3), este índice de inadequação vai crescendo até chegar em agosto (vermelho 0.83), com o maior grau de inadequação, comprovando também, com mais de um evento, a validação deste modelo estatístico.

Além das aderências com os cilindros específicos dos acontecimentos do sinistro do dia 01/ago/2019, percebe-se também que outros cilindros vinham se degradando antes da parada do dia primeiro, destaque especial é dado neste trabalho para o cilindro B4. Este cilindro B4 vinha trabalhando em condição de normalidade nos 3 primeiros meses (azul 1.0 e verde 0.0), e no mês seguinte, em abril, passou a atuar na faixa de atenção (laranja 0.3). Após isto, nos meses de maio (vermelho 0.6), junho (vermelho 0.601) e julho (vermelho 0.62) este cilindro se degrada ainda mais de forma progressiva passando a ter níveis maiores de inadequação até chegar em agosto (vermelho 0.75), com um maior grau de inadequação.

Embora não esteja registrado no apontamento do sinistro do dia 01/ago/2019, observa-se também que à partir dos resultados apresentados pelos gráficos de barras empilhadas obtidos das regras de Nelson, que a temperatura de saída do óleo lubrificante da UG 5 (cujo sensor é identificado pela tag SQA051T007PV) está operando na faixa normal nos primeiros meses de análise, sendo eles janeiro (azul 1.0 e verde 0.0), fevereiro (azul 0.99 e verde 0.01) e março (azul 1.0 e verde 0.0). Foi também possível concluir que, no mês seguinte, em abril, esta temperatura passou de uma condição normal para uma condição de atenção (amarelo 0.1). Verificou-se também que, nos meses seguintes, sendo maio (vermelho 0.5), junho (vermelho 0.9) e julho (vermelho 0.9) esta temperatura se degrada ainda mais passando de uma situação de atenção para situação de inadequação. Estas situações de inadequação foram se degradando de forma progressiva até atingir níveis maiores de inadequação até chegar no mês de agosto (vermelho 1.0) com 100% da ativação do grau de inadequação, comprovando assim que, esta temperatura de saída do

óleo lubrificante da UG 5 estava aquecendo e, conseqüentemente, a propriedade mecânica do óleo lubrificante de lubrificar e resfriar as peças móveis do MCI foi perdida. A partir desta conclusão, pode-se concluir também que o cilindro B7 pode ter travado devido a essa perda da propriedade do óleo lubrificante, deixando de lubrificar as partes móveis, e conseqüentemente, gerando o aquecimento (por falta de resfriamento) e raspagem nas peças móveis, como é o caso do casquilho indicado no acontecimento do sinistro do dia 01/ago/2019.

Além dos apontamentos de aderência com os acontecimentos do sinistro do dia 01/ago/2019, foi apresentado também os apontamentos estatísticos do grau de severidade da UG 5 quando ela retorna de manutenção corretiva. A partir disso, pode-se concluir que os níveis de inadequação da temperatura de revestimento dos cilindros B4 (vermelho 0.01) e A6 (vermelho 0.01), no primeiro mês após o retorno da UG 5, se tornaram bem melhores do que os níveis apresentados pelos meses que antecederam a parada do dia 01/ago/2019, sendo junho (B4 (vermelho 0.601) e A6 (vermelho 0.2)), julho (B4 (vermelho 0.62) e A6 (vermelho 0.3)) e agosto (B4 (vermelho 0.75) e A6 (vermelho 0.83)). Pode-se concluir também que, a temperatura de revestimento do cilindro B7, após o retorno da UG 5, passou da faixa de inadequação (vermelho 0.83) para a faixa de estresse (laranja 0.001), melhorando a sua condição operacional em relação as condições apresentadas nos meses anteriores ao sinistro, como junho (vermelho 0.1), julho (vermelho 0.2) e agosto (vermelho 0.8).

Com a análise do segundo mês após o retorno da UG 5, ou seja, dezembro de 2019, pode-se concluir que os níveis de inadequação da temperatura de revestimento dos cilindros B4 (vermelho 0.01) e A6 (vermelho 0.01), no mês de novembro, tornaram-se situações de estresse B4 (laranja 0.2) e A6 (laranja 0.9). Conseqüentemente, estas situações se encontram muito melhores tanto em relação a situação de inadequação do primeiro mês após retorno da UG, quanto as situações de inadequação mostradas nos meses que antecederam a parada do dia 01/ago/2019, sendo junho (B4 (vermelho 0.601) e A6 (vermelho 0.2)), julho (B4 (vermelho 0.62) e A6 (vermelho 0.3)) e agosto (B4 (vermelho 0.75) e A6 (vermelho 0.83)). Além disso, concluiu-se também que, a situação de estresse (laranja 0.7) da temperatura de revestimento do cilindro B7, se tornou muito melhor tanto em relação ao primeiro mês após o retorno da UG 5 (laranja 0.001), quanto as situações de inadequação mostradas no mês de de junho (vermelho 0.1), julho (vermelho 0.2) e agosto (vermelho 0.8). Conseqüentemente, pode-se concluir que os cilindros B7, B4 e A6 se tornaram melhores do que antes da parada da UG.

Com relação à temperatura de saída do óleo lubrificante, após o retorno da UG 5, no mês de novembro, pode-se concluir que a situação de inadequação (vermelho 0.01) está bem melhor do que as situações de inadequações mostradas pelas zonas vermelhas nos meses que antecederam a parada, sendo maio (0.5), junho (0.9), julho (0.9) e agosto

(1.0). Em outras palavras, a temperatura de saída do óleo lubrificante da UG 5 retornou suas atividades de lubrificação e resfriamento bem melhores do que as apresentadas nos meses anteriores ao sinistro. No segundo mês após o retorno da UG 5, pode-se concluir que a temperatura de saída do óleo lubrificante saiu da situação de inadequação no mês de novembro (vermelho 0.01) e passou a atuar na situação de estresse (laranja 0.7) no mês de dezembro. Além disso, pode-se concluir que a situação de estresse (laranja 0.7) mostrada no mês de dezembro está ainda melhor do que as situações de inadequações mostradas pelas zonas vermelhas nos meses de maio (0.5), junho (0.9), julho (0.9) e agosto (1.0). Em outros termos, concluiu-se que a temperatura de saída do óleo lubrificante da UG 5, no mês de dezembro, apresentou suas atividades de lubrificação e resfriamento ainda melhores do que as apresentadas tanto pelos meses que antecederam a parada do dia 01/ago/2019 quanto para o primeiro mês após o retorno da UG 5.

A partir das análises realizadas neste trabalho pelos gráficos de barras empilhadas, pode-se concluir que o modelo estatístico aqui proposto é capaz de monitorar a condição operacional de um MCI estatisticamente, via regras de Nelson, e indicar de forma precoce aos operadores das máquinas qual grau de severidade encontra-se os motores que compõem a UTE em pauta, ou seja, se os motores em análise estão bons ou ruins e, como está a condição deles quando retornam as atividades após uma manutenção corretiva. Conseqüentemente, com estes apontamentos foi possível validar o modelo proposto neste trabalho e ainda ajudar os gestores desta UTE e operadores das máquinas tanto no processo de tomada de decisão sobre a manutenção dos MCI quanto verificar se a condição de retorno desses motores estão boas ou ruins. Vale ressaltar que, é muito importante notar que essas previsões devem ser entendidas mais como uma probabilidade estatística de uma falha do que um problema físico real.

O mecanismo de análise aplica as regras de Nelson com base nos dados de vários sensores conectados ao sistema de supervisão da planta. Na fase atual deste trabalho, a análise é realizada em uma janela de tempo selecionada pelo operador. Dentro dessa janela de tempo selecionada, o mecanismo de análise aplica as regras de Nelson e exibe um gráfico de barras empilhadas que concentra as informações de todos os sensores (ou sensores selecionados, se desejado) a partir de uma escala de cores. Esses gráficos serão importantes pois irão direcionar o departamento de manutenção das UTEs e os operadores das máquinas para a manutenção preditiva e, conseqüentemente, irá ajudar a usina na redução de custos operacionais na geração de energia elétrica.

Como oportunidades de pesquisas futuras relacionadas ao tema desse trabalho, citam-se: i) a aplicação e análise do modelo estatístico em tempo real nas UTEs; ii) a aplicação do modelo estatístico em um cenário no qual as unidades geradoras utilizem gás natural como combustível base; iii) implementação de uma janela de tempo deslizante autônoma para que permita a geração de alarmes no caso de uma tendência de falha de-

tectada; iv) Calcular o estresse da unidade geradora e gerar um acumulador denominado indicador de desgaste; v) Calcular o desvio associado a probabilidade de ocorrência de um evento apontado pela ativação das regras de Nelson.; vi) Realizar o monitoramento da condição operacional do subsistema de mancal a partir do modelo estatístico via regras de Nelson.

## Referências

- 1 CORPORATION, W. *Aerial shot of Power Plant*. [S.l.]. Disponível em: <<https://dam.wartsila.com/dam/app/#/s/kEvD6326ty>>. Citado 2 vezes nas páginas 9 e 25.
- 2 CORPORATION, W. *Machine room external view*. [S.l.]. Disponível em: <<https://dam.wartsila.com/dam/?w=wzl9RK6Jml>>. Citado 2 vezes nas páginas 9 e 26.
- 3 CORPORATION, W. *Air intakes*. [S.l.]. Disponível em: <<https://dam.wartsila.com/dam/?w=wzl9RK6Jml>>. Citado 2 vezes nas páginas 9 e 26.
- 4 CORPORATION, W. *Exhaust pipe*. [S.l.]. Disponível em: <[https://dam.wartsila.com/dam/?w=zFI\\_iwENVf](https://dam.wartsila.com/dam/?w=zFI_iwENVf)>. Citado 2 vezes nas páginas 9 e 27.
- 5 CORPORATION, W. *Engines inside engine hall at Power Plant*. [S.l.]. Disponível em: <<https://dam.wartsila.com/dam/?w=dVgTtJDnqV>>. Citado 2 vezes nas páginas 9 e 27.
- 6 CORPORATION, W. *Radiators*. [S.l.]. Disponível em: <<https://dam.wartsila.com/dam/?w=yGbJxplSRX>>. Citado 2 vezes nas páginas 9 e 28.
- 7 CORPORATION, W. *Tank*. [S.l.]. Disponível em: <<https://dam.wartsila.com/dam/?w=J9lmCgY2ut>>. Citado 2 vezes nas páginas 9 e 29.
- 8 CORPORATION, W. *Tower escape*. [S.l.]. Disponível em: <<https://dam.wartsila.com/dam/app/#/s/lYtKM2QxxX>>. Citado 2 vezes nas páginas 9 e 29.
- 9 CORPORATION, W. *Oil control room*. [S.l.]. Disponível em: <<https://dam.wartsila.com/dam/app/#/s/kEvD6326ty>>. Citado 2 vezes nas páginas 9 e 30.
- 10 CORPORATION, W. *Control room*. [S.l.]. Disponível em: <<https://dam.wartsila.com/dam/?w=sQ6WrFVQj8>>. Citado 2 vezes nas páginas 9 e 31.
- 11 CORPORATION, W. *Motor generator example*. [S.l.]. Disponível em: <<https://www.wartsila.com/media/news/24-01-2018-wartsila-gas-engines-to-provide-reliable-electricity-supply-to-subaru-car-factory-and-saitama-heating-and-cooling-centre-2106005>>. Citado 2 vezes nas páginas 9 e 31.
- 12 MATRIZ Elétrica Brasileira. [S.l.]. Disponível em: <<https://app.powerbi.com/viewr=eyJrIjojNjc4OGYyYjQtYWM2ZC00YjllLWJlYmEtYzdkNTQ1MTc1NjM2IiwidCI6IjQwZDZmOWI4LWVjYTctNDZhMi05MmQ0LWVhNGU5YzAxNzBlMSIsImMiOjR9/>>>. Citado na página 24.
- 13 ESMIN, A. A.; LAMBERT-TORRES, G. Application of particle swarm optimization to optimal power systems. *International Journal of Innovative Computing, Information and Control*, v. 8, n. 3A, p. 1705–1716, 2012. Citado na página 24.
- 14 MENDONÇA, P. et al. Detection and modelling of incipient failures in internal combustion engine driven generators using electrical signature analysis. *Electric Power Systems Research*, Elsevier, v. 149, p. 30–45, 2017. Citado na página 24.

- 15 PANG, L. et al. Thermal stress and cyclic stress analysis of a vertical water-cooled wall at a utility boiler under flexible operation. *Energies*, Multidisciplinary Digital Publishing Institute, v. 12, n. 6, p. 1170, 2019. Citado na página 24.
- 16 JAREMKIEWICZ, M.; TALER, J. Online determining heat transfer coefficient for monitoring transient thermal stresses. *Energies*, Multidisciplinary Digital Publishing Institute, v. 13, n. 3, p. 704, 2020. Citado na página 24.
- 17 BRÜTSCH, R. et al. Insulation failure mechanisms of power generators. *IEEE electrical insulation magazine*, IEEE, v. 24, n. 4, p. 17–25, 2008. Citado na página 24.
- 18 LEW, D. et al. Impacts of wind and solar on emissions and wear and tear of fossil-fueled generators. In: IEEE. *2012 IEEE Power and Energy Society General Meeting*. [S.l.], 2012. p. 1–8. Citado na página 24.
- 19 TOLMASQUIM, M. T. et al. Energia termelétrica: gás natural, biomassa, carvão, nuclear. *Rio de Janeiro: EPE*, p. 25, 2016. Citado 3 vezes nas páginas 25, 31 e 32.
- 20 SCHRAMM, J. Estudo da dispersão de poluentes em uma usina termelétrica localizada em linhares utilizando o modelo calpuff. 2016. Citado na página 25.
- 21 ANSDALE, R. F.; LOCKLEY, D. J. *The Wankel RC Engine*. [S.l.]: Iliffe London, 1968. Citado na página 32.
- 22 BONALDI, E. L. et al. Sistema híbrido para previsão de falhas no sistema de arrefecimento de usina termelétrica baseado em técnicas avançadas de processamento estatístico de sinais. Citado 2 vezes nas páginas 32 e 35.
- 23 PELLICEL, A. et al. Desenvolvimento de uma metodologia inteligente para manutenção preditiva de turbogeradores. In: . [S.l.: s.n.], 2011. Citado 4 vezes nas páginas 32, 33, 35 e 66.
- 24 PELLICEL, A. et al. Sistema de monitoramento para manutenção preditiva de grandes usinas termelétricas. Citado na página 33.
- 25 FAST, M.; PALME, T. Application of artificial neural networks to the condition monitoring and diagnosis of a combined heat and power plant. *Energy*, Elsevier, v. 35, n. 2, p. 1114–1120, 2010. Citado 3 vezes nas páginas 33, 35 e 66.
- 26 MARCOS, I. P. M. Metodologia para monitoramento inteligente de condição de máquina: Uma abordagem usando funções de pertinência fuzzy. 2012. Citado 3 vezes nas páginas 33, 35 e 66.
- 27 AUDAS, J. Requirement analysis of a signal database for power plant automation signals. 2014. Citado na página 33.
- 28 RIBEIRO, P. F. da S. et al. Monitoring system of the parameters of operation of internal combustion engines in thermoelectric plants for fault detection. *International Journal of Advanced Engineering Research and Science*, AI Publications, v. 5, n. 8. Citado na página 33.
- 29 SAMTANI, S. et al. Identifying scada vulnerabilities using passive and active vulnerability assessment techniques. In: IEEE. *2016 IEEE Conference on Intelligence and Security Informatics (ISI)*. [S.l.], 2016. p. 25–30. Citado na página 33.

- 30 MAYADEVI, N.; VINODCHANDRA, S.; USHAKUMARI, S. Failure forecast engine for power plant expert system shell. In: IEEE. *2012 IEEE International Conference on Advanced Communication Control and Computing Technologies (ICACCCT)*. [S.l.], 2012. p. 380–384. Citado na página 34.
- 31 NEVALA, T. Upgrading the wois used in the gas engine test run (in finnish). Thesis - UNIVERSITY OF 303 VAASA, 2018. Citado na página 34.
- 32 CORPORATION, W. *Wärtsilä Operator's Interface System - WOIS user's manual*. [S.l.], 2008. Citado 8 vezes nas páginas 34, 66, 67, 70, 74, 75, 78 e 79.
- 33 BONALDI, E. L. et al. Sistema para diagnóstico termomecânico de falhas em motores de combustão interna. In: *IX Congresso Brasileiro de Planejamento Energético, IX CBPE, Florianópolis*. [S.l.: s.n.], 2014. Citado na página 34.
- 34 RIBEIRO, L. et al. Equipment for predictive maintenance in hydrogenerators. *AASRI Procedia*, Elsevier, v. 7, p. 75–80, 2014. Citado na página 34.
- 35 SANT'ANA, W. C. et al. Influence of rotor position on the repeatability of frequency response analysis measurements on rotating machines and a statistical approach for more meaningful diagnostics. *Electric Power Systems Research*, Elsevier, v. 133, p. 71–78, 2016. Citado na página 34.
- 36 SALOMON, C. P. et al. A study of fault diagnosis based on electrical signature analysis for synchronous generators predictive maintenance in bulk electric systems. *Energies*, Multidisciplinary Digital Publishing Institute, v. 12, n. 8, p. 1506, 2019. Citado na página 34.
- 37 DORANTES, P. N. M.; GONZALEZ, J. P. N.; MENDEZ, G. M. Fault detection systems via a novel hybrid methodology for fuzzy logic systems based on individual base inference and statistical process control. *IEEE latin america transactions*, IEEE, v. 12, n. 4, p. 706–712, 2014. Citado na página 34.
- 38 RIOS, E. d. M. et al. Estatística descritiva, probabilidade e estimação: noções para o ensino básico. Universidade Federal de Goiás, 2014. Citado 2 vezes nas páginas 37 e 38.
- 39 TAVARES, M. Estatística aplicada à administração. *Sistema Universidade Aberta do Brasil*, 2007. Citado 4 vezes nas páginas 37, 38, 39 e 147.
- 40 ACTION, P. *MEDIDAS DE POSIÇÃO*. [S.l.]. Disponível em: <<http://www.portaction.com.br/estatistica-basica/21-medidas-de-posicao>>. Citado na página 38.
- 41 CURTIS, A. E. et al. The mystery of the z-score. *AORTA Journal*, Thieme Medical Publishers, v. 4, n. 4, p. 124, 2016. Citado 2 vezes nas páginas 39 e 40.
- 42 WALPOLE, R. E. *Probabilidade & Estatística para engenharia e ciências*. [S.l.]: Pearson Prentice Hall, 2009. Citado na página 40.
- 43 WERKEMA, M. C. C. Ferramentas estatísticas básicas para o gerenciamento de processos. In: *Ferramentas estatísticas básicas para o gerenciamento de processos*. [S.l.: s.n.], 1995. p. 384–384. Citado 2 vezes nas páginas 40 e 96.

- 44 NELSON, L. S. The shewhart control chart-tests for special causes. *Journal of quality technology*, Taylor & Francis, v. 16, n. 4, p. 237–239, 1984. Citado 10 vezes nas páginas 40, 41, 54, 56, 57, 58, 60, 61, 62 e 97.
- 45 GRIFFITHS, D. et al. The probability of an out of control signal from nelson's supplementary zig-zag test. *Journal of Statistical Theory and Practice*, Springer, v. 4, n. 4, p. 609–615, 2010. Citado 12 vezes nas páginas 41, 42, 43, 44, 55, 56, 57, 58, 59, 60, 62 e 63.
- 46 MONTGOMERY, D. C. *Introduction to statistical quality control, 3rd edition*. [S.l.]: Wiley, 1996. Citado 7 vezes nas páginas 42, 43, 44, 63, 98, 99 e 100.
- 47 OLIVEIRA, C. C. d. et al. Manual para elaboração de cartas de controle para monitoramento de processos de medição quantitativos em laboratórios de ensaio. *Instituto Adolfo Lutz. São Paulo*, p. 18, 2013. Citado 5 vezes nas páginas 45, 54, 55, 63 e 100.
- 48 CAMPOS, R.; ROCHA, R. O controle estatístico de processos (cep) para o monitoramento da qualidade do farelo lex no processo do óleo de soja na empresa cac. *IV Encontro de Produção Científica e Tecnológica*, v. 4, n. 2009, p. 13, 2009. Citado na página 45.
- 49 ÖZTUNA, D.; ELHAN, A. H.; TüCCAR, E. Investigation of four different normality tests in terms of type 1 error rate and power under different distributions. *Turkish Journal of Medical Sciences*, The Scientific and Technological Research Council of Turkey, v. 36, n. 3, p. 171–176, 2006. Citado 5 vezes nas páginas 46, 47, 48, 49 e 81.
- 50 NORMALIDADE de variáveis: métodos de verificação e comparação de alguns testes não-paramétricos por simulação, author=Leotti, Vanessa Bielefeldt and Coster, Rodrigo and Riboldi, João, journal=Revista HCPA. Porto Alegre. Vol. 32, no. 2 (2012), p. 227-234, year=2012. Citado 3 vezes nas páginas 46, 47 e 49.
- 51 CEP, D. *Gestão Integrada da Qualidade e do Marketing Organizacional*. [S.l.]. Disponível em: <<http://www.datalyzer.com.br/site/suporte/administrador/info/arquivos/info44/44.html>>. Citado na página 47.
- 52 WIKIPÉDIA. *Histograma*. [S.l.]. Disponível em: <<https://pt.wikipedia.org/wiki/Histograma>>. Citado na página 47.
- 53 WIKIPÉDIA. *Gestão Integrada da Qualidade e do Marketing Organizacional*. [S.l.]. Disponível em: <[https://pt.wikipedia.org/wiki/Gr%C3%A1fico\\_Q-Q](https://pt.wikipedia.org/wiki/Gr%C3%A1fico_Q-Q)>. Citado na página 47.
- 54 GRÁFICOS para verificar normalidade. [S.l.]. Disponível em: <<https://docs.ufpr.br/~lucambio/CE224/1S2015/QQplot.pdf>>. Citado na página 48.
- 55 PÔLHA, D. A. M. *Validação na Produção de Substâncias Ativas para a Indústria Farmacêutica*. Tese (Doutorado), 2016. Citado 3 vezes nas páginas 49, 50 e 51.
- 56 MCNEESE, D. B. *Anderson-Darling Test for Normality*. [S.l.]. Citado na página 50.
- 57 ANNIS, C. *Goodness-of-Fit tests for Statistical Distributions*. [S.l.]. Citado na página 50.

- 58 MÉTODOS e fórmulas para Teste de Normalidade. [S.l.]. Disponível em: <<https://support.minitab.com/pt-br/minitab/19/help-and-how-to/statistics/basic-statistics/how-to/normality-test/methods-and-formulas/methods-and-formulas/>>. Citado na página 50.
- 59 TESTE de Shapiro-Wilk. [S.l.]. Disponível em: <<http://www.uel.br/projetos/experimental/pages/arquivos/Shapiro.html>>. Citado 2 vezes nas páginas 51 e 52.
- 60 HANUSZ, Z.; TARASINSKA, J.; ZIELINSKI, W. Shapiro-wilk test with known mean. *REVSTAT-Statistical Journal*, Instituto Nacional de Estatística, v. 14, n. 1, p. 89–100, 2016. Citado 3 vezes nas páginas 51, 52 e 53.
- 61 PERCENTAGE points of the W test for  $n = 3(1)50$ . [S.l.]. Disponível em: <[http://www.uel.br/projetos/experimental/pages/arquivos/Probabilidades\\_Shapiro.pdf](http://www.uel.br/projetos/experimental/pages/arquivos/Probabilidades_Shapiro.pdf)>. Citado na página 52.
- 62 AN analysis of variance test for normality. [S.l.]. Disponível em: <[http://www.uel.br/projetos/experimental/pages/arquivos/Shapiro\\_Tabelas.pdf](http://www.uel.br/projetos/experimental/pages/arquivos/Shapiro_Tabelas.pdf)>. Citado na página 52.
- 63 TESTE de Kolmogorov-Smirnov. [S.l.]. Disponível em: <[http://www.uel.br/projetos/experimental/pages/arquivos/Kolmogorov-Smirnov.html#:~:text=%C3%A9%20usada%20para%20testar%20a,%E2%88%92S\(x\)%E2%88%A3](http://www.uel.br/projetos/experimental/pages/arquivos/Kolmogorov-Smirnov.html#:~:text=%C3%A9%20usada%20para%20testar%20a,%E2%88%92S(x)%E2%88%A3)>. Citado 3 vezes nas páginas 52, 53 e 89.
- 64 ENTRINGER, R. C. A combinatorial interpretation of the euler and bernoulli numbers. *Nieuw. Arch. Wisk*, v. 14, n. 1, p. 966, 1966. Citado na página 58.
- 65 OEIS. *Number of alternating permutations of order n*. [S.l.]. Disponível em: <<https://oeis.org/A001250/list>>. Citado na página 58.
- 66 JOHN. *Alternating permutation*. [S.l.]. Disponível em: <[https://en.m.wikipedia.org/wiki/Alternating\\_permutation](https://en.m.wikipedia.org/wiki/Alternating_permutation)>. Citado na página 58.
- 67 TASKESEN, E. *Parametric - distfit documentation*. [S.l.]. Disponível em: <<https://erdogant.github.io/distfit/pages/html/Parametric.html>>. Citado 3 vezes nas páginas 63, 64 e 92.
- 68 MONTGOMERY, D. C.; RUNGER, G. C. *Applied statistics and probability for engineers*. [S.l.]: John Wiley & Sons, 2010. Citado 3 vezes nas páginas 64, 92 e 93.
- 69 FURLANI, C. E. A.; SILVA, R. P. D. *Apostila Didática N°2 Motores de Combustão Interna*. [S.l.], 2006. Disponível em: <<http://lamma.com.br/private/docs/c0d4b9692a8c31cab7cda401c9382350.pdf>>. Citado 3 vezes nas páginas 67, 70 e 76.
- 70 CORPORATION, W. *Engine Drawing*. [S.l.]. DAAE014769. Citado 8 vezes nas páginas 68, 69, 71, 72, 73, 77, 78 e 80.
- 71 GARCIA, R. F. *Benefícios e importância do turbocompressor e intercooler em motores diesel*. [S.l.], 2020. Disponível em: <<https://www.grupocultivar.com.br/noticias/beneficios-e-importancia-do-turbocompressor-e-intercooler-em-motores-diesel>>. Citado na página 68.

- 72 LUFETEC. *Tudo que você precisa saber sobre grupo motor gerador*. [S.l.]. Disponível em: <[http://estudio01.proj.ufsm.br/cadernos/ifsul/tecnico\\_biocombustivel/motores\\_combustao\\_interna\\_e\\_seus\\_sistemas.pdf](https://lufetec.com.br/grupomotorgerador/#:~:text=O%20alternador%20gerador%2C%20muitas%20vezes,capacidade)%2C%20em%20energia%20el%C3%A9trica.> Citado 2 vezes nas páginas 71 e 77.</p><p>73 TILLMANN, C. A. da C. <i>Motores de Combustão Interna e seus Sistemas</i>. [S.l.], 2013. Disponível em: <<a href=)>. Citado na página 72.
- 74 CORPORATION, W. *Internal Scheme Cooling Water System*. [S.l.]. DAAE014773. Citado na página 75.
- 75 CORPORATION, W. *Internal Scheme Exhaust Gas and Combustion Air System*. [S.l.]. DAAE014774. Citado 2 vezes nas páginas 76 e 77.
- 76 MURARO, W. et al. Avaliação do funcionamento de motor ice com gás de baixo poder calorífico proveniente da gaseificação de casca de arroz. [sn], 2006. Citado na página 78.
- 77 KODAMA, L. S. Estudo da rentabilidade de fundos imobiliários com utilização da média móvel. Universidade Estadual Paulista (Unesp), 2021. Citado na página 92.
- 78 CHEADLE, C. et al. Analysis of microarray data using z score transformation. *The Journal of molecular diagnostics*, Elsevier, v. 5, n. 2, p. 73–81, 2003. Citado na página 95.
- 79 ALVES, J. *Teorema central do limite compreendendo e aplicando*. Tese (Doutorado) — Dissertação de Mestrado. Cruz das Almas, Universidade Federal do Recôncavo, 2016. Citado 4 vezes nas páginas 147, 148, 149 e 154.

# Apêndices

# APÊNDICE A – Desenvolvimento analítico do Teorema Central do Limite

Este Apêndice apresenta os detalhes do desenvolvimento analítico do Teorema Central do Limite (TCL) utilizando termos matemáticos.

## A.1 Teorema Central do Limite

O teorema central do limite (TCL) é um dos teoremas mais conhecidos na estatística e garante que independente da distribuição original das variáveis, as médias das medidas destas variáveis agrupadas de uma mesma população seguem uma distribuição normal (39).

Em termos matemáticos, usando os mesmos métodos que Laplace, a definição do TCL é dada por:

Seja  $(X_1, X_2, \dots, X_N)$  os valores de uma amostra aleatória independentes e identicamente distribuídos (i.i.d)<sup>1</sup>, de média  $\mu$  e variância  $\sigma^2$  finitas, o cálculo das somas das variáveis aleatórias, designada  $S_N$ , é definida por (79)

$$S_N = X_1 + X_2 + \dots + X_N = \sum_{i=1}^N X_n \quad (\text{A.1})$$

Então, neste caso, uma variável aleatória  $Z_N$ , dada por (79)

$$Z_N = \frac{S_N - N\mu}{\sigma\sqrt{N}}, \quad (\text{A.2})$$

converge em distribuição quando o  $N \rightarrow \infty$  para uma variável aleatória gaussiana padrão (ou seja,  $\mathcal{N}(0, 1)$ ). Algebricamente, isso é dado por (79)

$$Z_N = \frac{S_N - N\mu}{\sigma\sqrt{N}} \xrightarrow{\infty} \mathcal{N}(0, 1) \quad (\text{A.3})$$

Teoricamente, dizer que uma variável aleatória converge em uma distribuição para outra é a mesma coisa que dizer que uma função de distribuição cumulativa (FDC) converge para outra FDC. Especificamente para este caso, a matemática que sustenta essa informação é dada por (39)

<sup>1</sup> (i.i.d) representa que além das variáveis serem independentes, todas as variáveis  $X_1, X_2$  até  $X_n$  possuem as mesmas distribuições

$$\lim_{N \rightarrow \infty} P_r[Z_N \leq Z] = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-\frac{x^2}{2}} dx = \Phi(Z) \quad (\text{A.4})$$

em que  $\Phi(Z)$  é a FDC da distribuição normal ( $\mathcal{N}(0, 1)$ ).

A partir da teoria de probabilidade esta convergência é considerada fraca uma vez que todas as outras formas pela qual uma variável aleatória pode convergir para outra implicam em convergência para distribuição (79).

O TCL será demonstrado, matematicamente, a partir de 3 partes, sendo

- (i): Média de  $Z_N$  é igual a zero. Algebricamente  $E[Z_N] = 0$
- (ii): Mostrar que de fato  $Z_N$  tem variância unitária. Algebricamente  $var[Z_N] = 1$
- (iii): Por fim, será demonstrado a convergência em distribuição usando o método de função característica de Laplace  $Z_N \xrightarrow{\infty} \mathcal{N}(0, 1)$ .

Para melhor entendimento da definição de cada parte, elas serão detalhadas em subseções separadas.

### A.1.1 Demonstração que $E[Z_N] = 0$

Para demonstrar que  $E[Z_N] = 0$ , expande-se o valor esperado de  $Z_N$  ( $E[Z_N]$ ) usando a sua definição matemática dada por (79)

$$E[Z_N] = E\left[\frac{S_N - N\mu}{\sigma\sqrt{N}}\right] \quad (\text{A.5})$$

Como todos os elementos desta fração são determinísticos, menos o  $S_N$ , o valor esperado dos elementos determinístico é o próprio valor determinístico. Aplicando esse conceito na equação (A.5), resulta-se em

$$E[Z_N] = E\left[\frac{S_N - N\mu}{\sigma\sqrt{N}}\right] = \frac{E[S_N] - N\mu}{\sigma\sqrt{N}} \quad (\text{A.6})$$

Expandindo  $S_N$  em função de  $X_n$ , ou seja, substituindo (A.1) em (A.6), obtêm-se

$$E[Z_N] = E\left[\frac{S_N - N\mu}{\sigma\sqrt{N}}\right] = \frac{E\left[\sum_{i=1}^N X_n\right] - N\mu}{\sigma\sqrt{N}} \quad (\text{A.7})$$

Sabendo que o valor esperado é uma função linear, troca-se o valor do somatório pelo valor esperado, resultando em

$$E[Z_N] = E\left[\frac{S_N - N\mu}{\sigma\sqrt{N}}\right] = \frac{\sum_{i=1}^N E[X_n] - N\mu}{\sigma\sqrt{N}} \quad (\text{A.8})$$

Pela definição do teorema o valor esperado de cada  $X_n$  é  $\mu$  (79). Algebricamente,  $E[X_n] = \mu$ , então

$$E[Z_N] = E\left[\frac{S_N - N\mu}{\sigma\sqrt{N}}\right] = \frac{\sum_{i=1}^N \mu - N\mu}{\sigma\sqrt{N}} \quad (\text{A.9})$$

Calculando o valor do somatório  $\sum_{i=1}^N \mu$ , obtêm-se

$$\sum_{i=1}^N \mu = N\mu \quad (\text{A.10})$$

Substituindo (A.10) em (A.9), obtêm-se

$$E[Z_N] = E\left[\frac{S_N - N\mu}{\sigma\sqrt{N}}\right] = \frac{N\mu - N\mu}{\sigma\sqrt{N}} \quad (\text{A.11})$$

Calculando a diferença entre os elementos do numerador, resulta em  $E[Z_N]$  igual a zero. Matematicamente, isso é dado por

$$E[Z_N] = E\left[\frac{S_N - N\mu}{\sigma\sqrt{N}}\right] = \frac{N\mu - N\mu}{\sigma\sqrt{N}} = 0 \quad (\text{A.12})$$

### A.1.2 Demonstração que $var[Z_N] = 1$

Para demonstrar que  $var[Z_N] = 1$ , usa-se a definição matemática teórica de variância ( $var[Z_N]$ ), dada por (79)

$$var[Z_N] = E[(Z_N - E[Z_N])^2]. \quad (\text{A.13})$$

Como o valor da média de  $Z_N$  já foi calculada, conforme (A.12), sabe-se que  $E[Z_N]$  é igual a zero. Substituindo este valor em (A.13), obtêm-se

$$\text{var}[Z_N] = E[(Z_N - \overbrace{E[Z_N]}^0)^2] = E[Z_N^2] \quad (\text{A.14})$$

Utilizando a definição de  $Z_N$ , dada pela equação (A.2), em (A.14), obtêm-se

$$\text{var}[Z_N] = E[Z_N^2] = E\left[\left(\frac{S_N - N\mu}{\sigma\sqrt{N}}\right)^2\right] \quad (\text{A.15})$$

Novamente, como  $\sigma$  e  $N$  são determinísticos, o valor esperado dos elementos determinísticos é o próprio valor determinístico, então pode-se retirar esse valor do valor esperado. Aplicando esse conceito na equação (A.15), Obtêm-se

$$\text{var}[Z_N] = E[Z_N^2] = E\left[\left(\frac{S_N - N\mu}{\sigma\sqrt{N}}\right)^2\right] = \frac{1}{N\sigma^2}E[(S_N - N\mu)^2] \quad (\text{A.16})$$

Para expandir  $S_N$  precisa-se definir uma nova variável aleatória, na qual é dada por  $X_n - \mu$ . Nota-se que  $S_N - N\mu$  é igual ao  $\sum(X_n - \mu)$ . Portanto, substituindo estas informações em (A.16), obtêm-se

$$\begin{aligned} \text{var}[Z_N] &= E[Z_N^2] = E\left[\left(\frac{S_N - N\mu}{\sigma\sqrt{N}}\right)^2\right] = \frac{1}{N\sigma^2}E[(S_N - N\mu)^2] = \\ &= \frac{1}{N\sigma^2}E\left[\left[\sum(X_n - \mu)\right]^2\right] \end{aligned} \quad (\text{A.17})$$

Expandindo o quadrado da função  $[\sum(X_n - \mu)]$ , obtêm-se

$$\begin{aligned} \text{var}[Z_N] &= \frac{1}{N\sigma^2}E\left[\left[\sum(X_n - \mu)\right]^2\right] \\ &= \frac{1}{N\sigma^2}E[(x_1 - \mu)^2 + 2(x_1 - \mu)(x_2 - \mu) + (x_2 - \mu)^2 + \dots \\ &\quad + 2(x_1 - \mu)(x_3 - \mu) + 2(x_2 - \mu)(x_3 - \mu) + (x_3 - \mu)^2 + \dots] \end{aligned} \quad (\text{A.18})$$

Novamente, como o valor esperado é um operador linear, então aplica-se o valor esperado em cada termo de soma. Aplicando esse conceito na equação (A.18), obtêm-se

$$\begin{aligned} \text{var}[Z_N] &= \frac{1}{N\sigma^2}E\left[\left[\sum(X_n - \mu)\right]^2\right] \\ &= \frac{1}{N\sigma^2}[E[(x_1 - \mu)^2] + E[2(x_1 - \mu)(x_2 - \mu)] + E[(x_2 - \mu)^2] + \dots \\ &\quad + E[2(x_1 - \mu)(x_3 - \mu)] + E[2(x_2 - \mu)(x_3 - \mu)] + E[(x_3 - \mu)^2] + \dots] \end{aligned} \quad (\text{A.19})$$

Nota-se que todos estes termos tem formas bem familiares, o primeiro termo dado por  $(x_1 - \mu)^2$  é a variância de  $X$  que é igual a  $\sigma^2$ . O segundo termo dado por  $2(x_1 - \mu)(x_2 - \mu)$  é a covariância de  $X_1$  e  $X_2$ , como eles são independentes, o seu valor é igual a zero. Seguindo este raciocínio para os demais termos da equação (A.19), obtêm-se que os termos elevados ao quadrado que representam a variância são iguais  $\sigma^2$  e os termos que são multiplicados por 2 que representam as covariâncias são iguais a zero, pois são independentes. Portanto, obtêm-se

$$\text{var}[Z_N] = \frac{1}{N\sigma^2} E\left[\left[\sum (X_n - \mu)\right]^2\right] = \frac{1}{N\sigma^2} * (N\sigma^2) = 1 \quad (\text{A.20})$$

### A.1.3 Demonstração que $Z_N \xrightarrow{\infty} \mathcal{N}(0, 1)$

Para demonstrar a convergência em distribuição de  $Z_N$  para a gaussiana padrão, será mostrado que a função característica de  $Z_N$  tende para a função característica da normal padrão. A função característica de  $Z_N$  é dada por

$$\mu_{Z_N}(w) = E[e^{jwZ_N}]. \quad (\text{A.21})$$

Expandindo a função característica de  $Z_N$ , obtêm-se

$$\begin{aligned} \mu_{Z_N}(w) &= E[e^{jwZ_N}] = E\left[\exp\left(jw\frac{S_N - N\mu}{\sigma\sqrt{N}}\right)\right] \\ &= E\left[\exp\left(\frac{jw}{\sigma\sqrt{N}}\sum_{i=1}^N(X_n - \mu)\right)\right]. \end{aligned} \quad (\text{A.22})$$

Como o somatório de um exponencial é o produto de exponenciais. Aplicando este conceito em (A.22), obtêm-se

$$\begin{aligned} \mu_{Z_N}(w) &= E[e^{jwZ_N}] = E\left[\exp\left(jw\frac{S_N - N\mu}{\sigma\sqrt{N}}\right)\right] \\ &= E\left[\exp\left(\frac{jw}{\sigma\sqrt{N}}\sum_{i=1}^N(X_n - \mu)\right)\right] \\ &= E\left[\prod_{i=1}^N \exp\left(\frac{jw}{\sigma\sqrt{N}}(X_n - \mu)\right)\right]. \end{aligned} \quad (\text{A.23})$$

Dado que  $X_n$  são independentes, então o valor esperado do produto é igual ao produto dos valores esperados. Então,

$$\begin{aligned}
 \mu_{Z_N}(w) &= E[e^{jwZ_N}] = E\left[\exp\left(jw\frac{S_N - N\mu}{\sigma\sqrt{N}}\right)\right] \\
 &= E\left[\exp\left(\frac{jw}{\sigma\sqrt{N}}\sum_{i=1}^N(X_i - \mu)\right)\right] \\
 &= E\left[\prod_{i=1}^N \exp\left(\frac{jw}{\sigma\sqrt{N}}(X_i - \mu)\right)\right] \\
 &= \prod_{i=1}^N E\left[e^{\frac{jw}{\sigma\sqrt{N}}(X_i - \mu)}\right].
 \end{aligned} \tag{A.24}$$

E como todos os  $X_n$ s são independentemente distribuídos, obtêm-se

$$\begin{aligned}
 \mu_{Z_N}(w) &= E[e^{jwZ_N}] = E\left[\exp\left(jw\frac{S_N - N\mu}{\sigma\sqrt{N}}\right)\right] \\
 &= E\left[\exp\left(\frac{jw}{\sigma\sqrt{N}}\sum_{i=1}^N(X_i - \mu)\right)\right] \\
 &= E\left[\prod_{i=1}^N \exp\left(\frac{jw}{\sigma\sqrt{N}}(X_i - \mu)\right)\right] \\
 &= \prod_{i=1}^N E\left[e^{\frac{jw}{\sigma\sqrt{N}}(X_i - \mu)}\right] \\
 &= \left[E\left[e^{\frac{jw}{\sigma\sqrt{N}}(X_i - \mu)}\right]\right]^N.
 \end{aligned} \tag{A.25}$$

Para continuar a demonstração desta 3ª parte, duas importantes propriedades da exponencial são destacadas. A primeira propriedade diz respeito a maneira na qual a exponencial pode ser definida. Algebricamente esta definição é dada por

$$e^x = \lim_{N \rightarrow \infty} \left(1 + \frac{x}{N}\right)^N \tag{A.26}$$

A segunda propriedade é sobre a série de Taylor da exponencial em torno de zero que é dada por

$$\begin{aligned}
 e^x &= \lim_{N \rightarrow \infty} \left(1 + \frac{x}{N}\right)^N \\
 &= \sum \frac{x^n}{n!}
 \end{aligned} \tag{A.27}$$

De posse destas 2 propriedades, expande-se a equação (A.25) em série de Taylor e obtêm-se

$$E\left[e^{\frac{jw}{\sigma\sqrt{N}}(X_n-\mu)}\right] = E\left[1 + \frac{jw}{\sigma\sqrt{N}}(X - \mu) + \frac{1}{2}\left(\frac{jw}{\sigma\sqrt{N}}\right)^2 (X - \mu)^2 + 0\left[\left(\frac{jw}{\sigma\sqrt{N}}\right)^3\right]\right]. \quad (\text{A.28})$$

Nota-se que foi utilizado a série de Taylor em torno de zero visto que  $Z_N$  tem média nula. O valor 0 da equação pode ser pensado como qualquer coisa de ordem cúbica. Separando os valores esperados, pois a esperança da soma é a soma das esperanças, e usando as hipóteses do teorema, obtêm-se

$$\begin{aligned} E\left[e^{\frac{jw}{\sigma\sqrt{N}}(X_n-\mu)}\right] &= E\left[1 + \frac{jw}{\sigma\sqrt{N}}(X - \mu) + \frac{1}{2}\left(\frac{jw}{\sigma\sqrt{N}}\right)^2 (X - \mu)^2 + 0\left[\left(\frac{jw}{\sigma\sqrt{N}}\right)^3\right]\right] \\ &= 1 + \frac{jw}{\sigma\sqrt{N}}E[X - \mu] - \frac{w^2}{2\sigma^2N}E[(X - \mu)^2] + E\left[0\left[\frac{-jw^3}{\sigma^3N^{\frac{3}{2}}}\right]\right] \end{aligned} \quad (\text{A.29})$$

Como já citado anteriormente o segundo termo é zero porque corresponde a covariância e o terceiro termo é igual a  $\sigma^2$  pois corresponde a variância. Aplicando estes conceitos em (A.29), obtêm-se

$$\begin{aligned} E\left[e^{\frac{jw}{\sigma\sqrt{N}}(X_n-\mu)}\right] &= E\left[1 + \frac{jw}{\sigma\sqrt{N}}(X - \mu) + \frac{1}{2}\left(\frac{jw}{\sigma\sqrt{N}}\right)^2 (X - \mu)^2 + 0\left[\left(\frac{jw}{\sigma\sqrt{N}}\right)^3\right]\right] \\ &= 1 + \frac{jw}{\sigma\sqrt{N}}E[X - \mu] - \frac{w^2}{2\sigma^2N}E[(X - \mu)^2] + E\left[0\left[\frac{-jw^3}{\sigma^3N^{\frac{3}{2}}}\right]\right] \\ &= 1 - \frac{w^2}{2N} + E\left[0\left[\frac{-jw^3}{\sigma^3N^{\frac{3}{2}}}\right]\right] \end{aligned} \quad (\text{A.30})$$

Por fim, nota-se que o terceiro termo da (A.30) decresce com  $N^{\frac{3}{2}}$ , enquanto que o segundo termo decresce com  $N$ . Sendo assim, quando  $N \rightarrow \infty$  o último termo pode ser desprezado com relação ao segundo, uma vez que ele tende pra zero muito mais rápido. Consequentemente, pode-se escrever o limite da característica de  $Z_N$  como

$$\begin{aligned} \lim_{N \rightarrow \infty} \mu_{Z_N}(w) &= \lim_{N \rightarrow \infty} \left[ E\left[ e^{\frac{jw}{\sigma\sqrt{N}}(X_n-\mu)} \right] \right]^N \\ &= \lim_{N \rightarrow \infty} \left[ 1 - \frac{w^2}{2N} \right]^N \end{aligned} \quad (\text{A.31})$$

Comparando a equação (A.31) com a equação (A.27) que caracteriza a série de Taylor da exponencial centrada em zero, percebe-se que o expoente  $x$  é a igual ao fator

$\frac{-w^2}{2}$  que multiplica  $\frac{1}{N}$ , ou seja, o resultado da equação (A.31) é igual a  $e^{\frac{-w^2}{2}}$ , que é a função característica da gaussiana normalizada.

Portanto, conclui-se que (79)

$$\lim_{N \rightarrow \infty} \mu_{Z_N}(w) = \mu_{\mathcal{N}(0,1)}(w) \quad (\text{A.32})$$

Vale ressaltar que as variáveis aleatórias utilizadas nas demonstrações deste capítulo não foram assumidas como contínuas ou discretas, e de fato não precisava pois o TCL vale para qualquer tipo de variável aleatória.

# APÊNDICE B – Distribuições Estatísticas

Este Apêndice apresenta os diferentes tipos de distribuições existentes na estatística e a aproximação da distribuição binomial pela distribuição normal.

## B.1 Tipos de Distribuições

Existem na estatística vários tipos de distribuições estatísticas com diferentes características e aplicações. Aqui estão alguns destes principais tipos de distribuições:

- 1: Distribuição Normal (ou Gaussiana): A distribuição normal é uma das distribuições mais comuns e amplamente estudadas. Ela é simétrica e assume uma forma de sino. É caracterizada por sua média e desvio padrão, que determinam sua localização e dispersão, respectivamente. Muitos fenômenos naturais e amostras aleatórias tendem a seguir essa distribuição. O modelo da função normal pode ser expresso matematicamente da seguinte forma:

Seja  $X$  uma variável contínua com média  $\mu$  em que  $-\infty < x < \infty$ , e  $\sigma > 0$  sua função de densidade de probabilidade (PDF), segue a seguinte fórmula:

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} \quad (\text{B.1})$$

Nessa fórmula:

- $x$  é a variável aleatória contínua.
- $\mu$  é a média da distribuição, que representa o valor esperado e o centro da curva.
- $\sigma$  é o desvio padrão da distribuição, que indica o grau de dispersão dos valores em relação à média.
- $\pi$  é o valor de pi, aproximadamente igual a 3.14159.

Dessa forma  $X$  apresenta uma média e um desvio padrão, que determinam sua localização e dispersão, respectivamente, e seguem as seguintes fórmulas:

- Média da distribuição dada por:  $E(X) = \mu$
- Variância da distribuição dada por:  $V(X) = \sigma^2$

- 2: Distribuição Uniforme: A distribuição uniforme é caracterizada por uma probabilidade constante para todos os valores dentro de um intervalo específico. Ela é frequentemente usada quando todos os valores possíveis são igualmente prováveis;
- 3: Distribuição Exponencial: A distribuição exponencial é usada para modelar eventos que ocorrem em uma taxa constante ao longo do tempo. É frequentemente utilizada em análises de tempo de vida e falha de sistemas;
- 4: Distribuição de Poisson: A distribuição de Poisson é usada para modelar a ocorrência de eventos discretos e independentes em um intervalo fixo de tempo ou espaço. É comumente aplicada em situações que envolvem contagem de eventos, como o número de chamadas recebidas em um call center em um determinado período;
- 5: Distribuição Binomial: A distribuição binomial é usada para modelar experimentos com dois resultados possíveis, geralmente rotulados como sucesso e fracasso. Ela fornece a probabilidade de obter um certo número de sucessos (parâmetro  $p$ ) em um número fixo de tentativas independentes (parâmetro  $n$ ). A função massa de probabilidade (PMF) de uma variável aleatória binomial  $Y$  é dada pela seguinte fórmula:

$$P(Y) = \binom{n}{k} p^k (1-p)^{n-k}, \quad Y \in \{0, \dots, n\} \quad (\text{B.2})$$

onde,

$$\binom{n}{k} = \frac{n!}{k!(n-k)!} \quad (\text{B.3})$$

Nessa fórmula:

- $P(Y)$  é a probabilidade de obter exatamente  $k$  sucessos em  $n$  ensaios.
- $\binom{n}{k}$  é o coeficiente binomial, que representa o número de combinações de  $n$  itens tomados  $k$  a  $k$ , dado por  $n!/(k!(n-k)!)$ , onde  $!$  indica o fatorial.
- $p^k$  é a probabilidade de ocorrer  $k$  sucessos.
- $(1-p)^{n-k}$  é a probabilidade de ocorrer  $n-k$  fracassos.

Dessa forma  $Y$  apresenta:

- Média da distribuição dada por:  $\mu = E(Y) = n * p$
- Variância da distribuição dada por:  $\sigma^2 = V(Y) = n * p * (1-p)$

- 6: Distribuição de Bernoulli: A distribuição de Bernoulli é um caso especial da distribuição binomial, onde há apenas uma tentativa. Ela modela experimentos com dois resultados possíveis, como “sucesso” ou “fracasso”;
- 7: Distribuição de Weibull: A distribuição de Weibull é frequentemente utilizada para modelar a taxa de falha de sistemas, especialmente em engenharia. Ela é flexível e pode descrever distribuições que são monotonamente crescentes, decrescentes ou em forma de "U";

Essas são apenas algumas das muitas distribuições estatísticas existentes. Cada distribuição tem suas próprias propriedades e é adequada para modelar diferentes tipos de fenômenos. A escolha da distribuição apropriada depende do contexto, dos dados e das suposições feitas sobre o processo em pauta.

## B.2 Aproximação da Distribuição Binomial pela Distribuição Normal

A aproximação da distribuição binomial pela distribuição normal é um conceito importante na teoria das probabilidades e estatística. Ela é baseada no teorema central do limite, que estabelece que, sob certas condições, a distribuição de uma média amostral se aproxima de uma distribuição normal, independentemente da forma da distribuição populacional subjacente.

A distribuição binomial descreve o número de sucessos em uma sequência de tentativas independentes e idênticas, cada uma com dois “sucesso” e “fracasso”), com uma probabilidade fixa de sucesso em cada tentativa. É caracterizada por dois parâmetros: o número de tentativas ( $n$ ) e a probabilidade de sucesso em cada tentativa ( $p$ ).

Quando o número de tentativas é grande e a probabilidade de sucesso não é muito próxima de 0 ou 1, podemos usar a distribuição normal como uma aproximação para a distribuição binomial. A aproximação é válida quando o número de tentativas ( $n$ ) é grande o suficiente e os parâmetros da distribuição binomial são tais que  $np$  e  $n(1-p)$  são ambos maiores que 5.

A aproximação da distribuição binomial pela distribuição normal é feita através da aplicação de uma transformação na variável aleatória binomial. Para uma variável aleatória binomial  $X$  com parâmetros  $n$  e  $p$ , a média é dada por  $\mu = np$  e o desvio padrão por  $\sigma = \sqrt{np(1-p)}$ . Aproximando a distribuição binomial pela distribuição normal, consideramos uma variável aleatória  $Y$  normalmente distribuída com média  $\mu$  e desvio padrão  $\sigma$ .

Para aproximar uma probabilidade específica de sucesso em uma distribuição binomial usando a distribuição normal, você pode calcular a área sob a curva normal correspondente aos limites do intervalo desejado. Aproximadamente, a probabilidade de sucesso em uma distribuição binomial estará contida dentro de dois desvios padrão da média, usando a distribuição normal.

# APÊNDICE C – Sinistro do dia 01 de agosto de 2019

Este Apêndice apresenta os detalhes do sinistro ocorrido na unidade geradora do dia primeiro de Agosto de 2019.

## C.1 Descrição do Evento

No dia 01/ago/2019, a unidade de geração de energia UG 5 desligou automaticamente às 14:41 horas devido atuação do alarme de proteção no detector de névoa. Conforme procedimento, a equipe de operação realizou a inspeção nos filtros *backflushing*, onde foi constatada a presença de partículas metálicas. Foi realizada a abertura do cárter para inspeção (passeio de biela), onde foi detectado que o mancal móvel do cilindro B7 encontrava-se travado no eixo. Após detectada a falha, o motor ficou indisponível para a operação no sistema.

## C.2 Cronologia do Evento no WOIS

- **Cronologia do Evento:**

- **Dia 31/jul/2019**

- 23:46h - Redução da carga para retirada do modo GD, devido rede de controle do cilindro B6 estar rompida;

- **Dia 01/ago/2019**

- 00:05h - Realizado a substituição da rede de controle (grande) do cilindro B6;

- 00:47h – Setado (-1) na duration do Cil B7;

- 00:48h – Setado (-0,5) na duration do Cil A6;

- 00:48h – Setado (-1) na duration do Cil A6;

- 00:49h – Setado (-0,5) na duration do Cil A7;

- 00:50h – Setado (-1) na duration do Cil A;

- 00:50h – Setado (-1,5) na duration do Cil A7;

- 00:50h – Elevação de carga para 16000Kw;

- 00:50h – Setado (0,5) na duration do Cil B9;

- 00:51h – Setado (-1,75) na duration do Cil A7;
- 00:56h – Elevada a carga para 16500kW em modo GD;
- 02:14h - Redução da carga para 14000kW para retirada do modo GD, para efetuar lavagem da turbina;
- 02:16h – Operando em HFO;
- 02:21h - Redução da carga para 10000kW para retirada do modo GD, para efetuar lavagem da turbina;
- 02:23h - Redução da carga para 5000kW para retirada do modo GD, para efetuar lavagem da turbina;
- 02:34h - Redução da carga para 3000kW para retirada do modo GD, para efetuar lavagem da turbina;
- 02:38h - Redução da carga para 2500kW para retirada do modo GD, para efetuar lavagem da turbina;
- 03:06h - Finalizado a lavagem das turbinas e elevada a carga para 10000kW;
- 03:08h – Alarme de Desvio de temperatura Cil A1 – Temperatura acima da média, durante elevação de carga;
- 03:09h – Alarme de Desvio de temperatura Cil A1 – Temperatura acima da média, durante elevação de carga;
- 03:10h – Alarme de Desvio de temperatura Cil A3 – Temperatura acima da média, durante elevação de carga;
- 03:12h – Alarme de Desvio de temperatura Cil A3 – Temperatura acima da média, durante elevação de carga;
- 03:16h – Elevação de carga para 14000kW para entrada em modo GD;
- 03:24h – Selecionado Modo GD; 03:30h – Setado (-0,5) na duration do Cil A6;
- 03:30h – Setado (-1) na duration do Cil A2;
- 03:30h – Setado (0,5) na duration do Cil B2;
- 03:31h – Setado (0,5) na duration do Cil B3;
- 03:31h – Setado (-1) na duration do Cil A6;
- 03:31h – Setado (0,75) na duration do Cil A3;
- 03:31h – Setado (0,5) na duration do Cil A4;
- 03:32h – Setado (-1) na duration do Cil A7;
- 03:32h – Setado (-1,5) na duration do Cil A7;
- 03:32h – Setado (0,5) na duration do Cil A5;

- 03:32h – Setado (-2) na duration do Cil A7;
- 03:33h – Elevação de carga para 16000kW em modo GD;
- 03:34h – Elevação de carga para 16500kW em modo GD;
- 03:38h – Elevação de carga para 16550kW em modo GD;
- 03:40h – Elevação de carga para 16600kW em modo GD; 08:18h - Gás trip; alarme de vazamento de gás;
- 08:18h – Operando em HFO;
- 08:20h - Redução da carga para 14000kW para mudança para modo GD;
- 08:20h – Elevação de carga para 16500kW;
- 09:15h - Realizado teste de vazamento de gás, identificado vazamento no cilindro A6, motor em HFO;
- 10:40h - Foram substituídos os orings da rede dupla de gás cilindro A5 para A6 e orings da caneta de gás do cilindro A6;
- 10:56h - Selecionado Modo GD;
- 10:56h - Redução da carga para 14000kW para mudança para modo GD e teste de vazamento de gás, onde não apresentou mais vazamentos. Por estratégia de geração, a unidade ficará em HFO até 12:00h;
- 11:00h - Elevação de carga para 16600kW em HFO;
- 11:12h – Alarme de alta temperatura de gases de exaustão antes do turbo “A” (TE511);
- 11:14h – Alarme de alta temperatura de gases de exaustão antes do turbo “A” (TE511);
- 11:16h - Redução da carga para 16000kW devido alta temperatura no turbo antes do lado A (TE511);
- 11:20h – Alarme de alta temperatura de gases de exaustão antes do turbo “A” (TE511);
- 11:25h – Alarme de alta temperatura de gases de exaustão antes do turbo “A” (TE511);
- 11:41h – Alarme de alta temperatura de gases de exaustão antes do turbo “A” (TE511);
- 12:01h – Alarme de alta temperatura de gases de exaustão antes do turbo “A” (TE511);
- 13:04h - Redução da carga para 14000kW para mudança para modo GD;
- 13:05h - Selecionado Modo GD;

- 13:12h - Setado (-1) na duration do Cil B7;
- 13:12h - Setado (-5) na duration do Cil B2;
- 13:12h - Setado (0,5) na duration do Cil B2;
- 13:12h - Setado (1) na duration do Cil B2;
- 13:12h – Gás Trip devido desvio de temperatura no Cil B2;
- 13:21h - Selecionado Modo GD;
- 13:25h - Setado (-0,5) na duration do Cil A7;
- 13:40h - Elevação de carga para 16000kW em GD;
- 13:43h - Elevação de carga para 16500kW em GD;
- 13:44h - Elevação de carga para 16600kW em GD;
- 13:45h - Elevação de carga para 16700kW em GD;
- 13:45h - Elevação de carga para 16800kW em GD;
- 13:47h - Elevação de carga para 16900kW em GD;
- 13:48h - Elevação de carga para 17000kW em GD;
- 14:12h - Redução da carga para 16900kW devido restrição de carga devido temperatura de ar de carga (derating);
- 14:40:33h – Alarme no PCN;
- 14:41:33h – Alarme e shutdown devido atuação do detector de névoa (QS700).

### C.3 Evidências Pós Evento

1. Temperaturas dos gases de exaustão Cil A7 / B7 estavam com valores maior que a média;
2. Cilindros A7 e B7: Cabeçotes ( -20 bar ) – Conectora foi até 740 Bar e Mancais móveis com ( - 20 bar ) em relação ao padrão normal em todos os componentes;
3. Foi realizado Mar Prime e IMES anterior a quebra que não apresentaram anormalidades;
4. Verificadas as análises de óleo lubrificante antes do evento e não apresentaram anormalidades;
5. Foram solicitados do fornecedor, os espectros de vibração da unidade UG 5 para análise, uma vez que não apresentaram anormalidades no relatório do mês de Julho de 2019;

6. Realizada a desmontagem do conjunto de força A8/B8, A6/B6, A2/B2 e não foram encontradas anormalidades;
7. Realizada inspeção e não houve engripamento no pistão, no entanto foi encontrada avaria na bucha superior da biela do Cil B7;
8. Identificado limalha no anel lubrificador da coroa do pistão;
9. Em inspeção do filtro automático, foram encontradas limalhas;
10. Aguardando informação de teste da válvula injetora do Cil B7 (pressão de abertura), no entanto, foi verificado inicialmente que a injeção estava uniforme na cabeça do pistão;
11. Verificado que a trava do casquinho Cil B7 estava danificada.

#### C.4 Inspeção de Campo Pós Evento

Foi identificado que o casquilho do cilindro B7 encontrava-se danificado, conforme mostra a Figura 87.

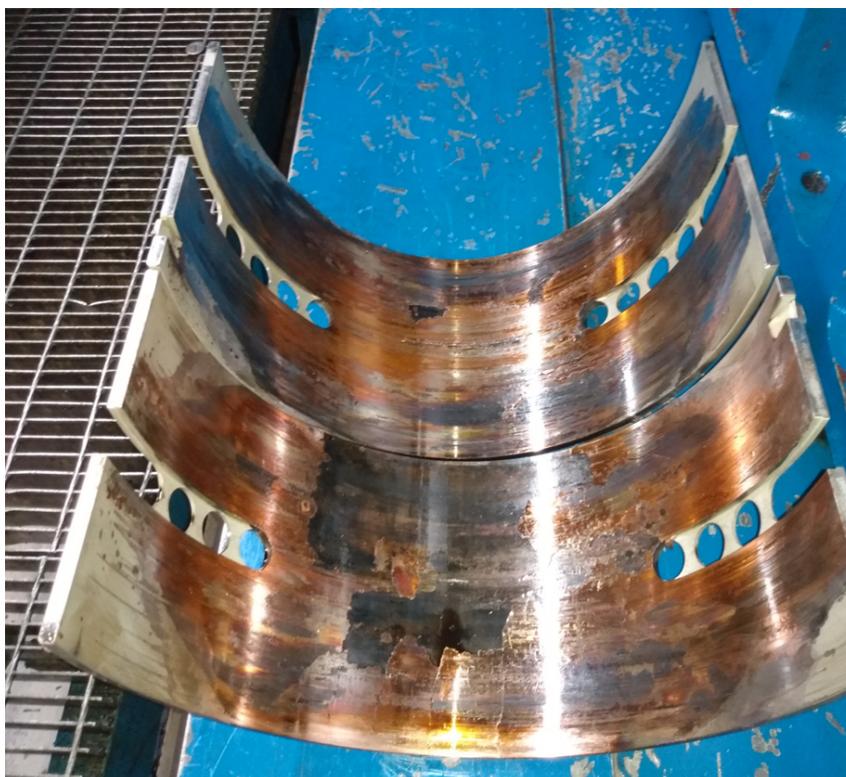


Figura 87 – Casquilho do Cilindro B7 danificado.

Na Figura 87 percebe-se a mudança na coloração e perda da primeira camada do material (*flash layer*), possivelmente causada por elevação de temperatura.

Foi identificado também que na parte posterior do casquilho do cilindro B7 ocorreu mudança de coloração possivelmente causada por elevação de temperatura, conforme mostram as imagens da Figura 88.

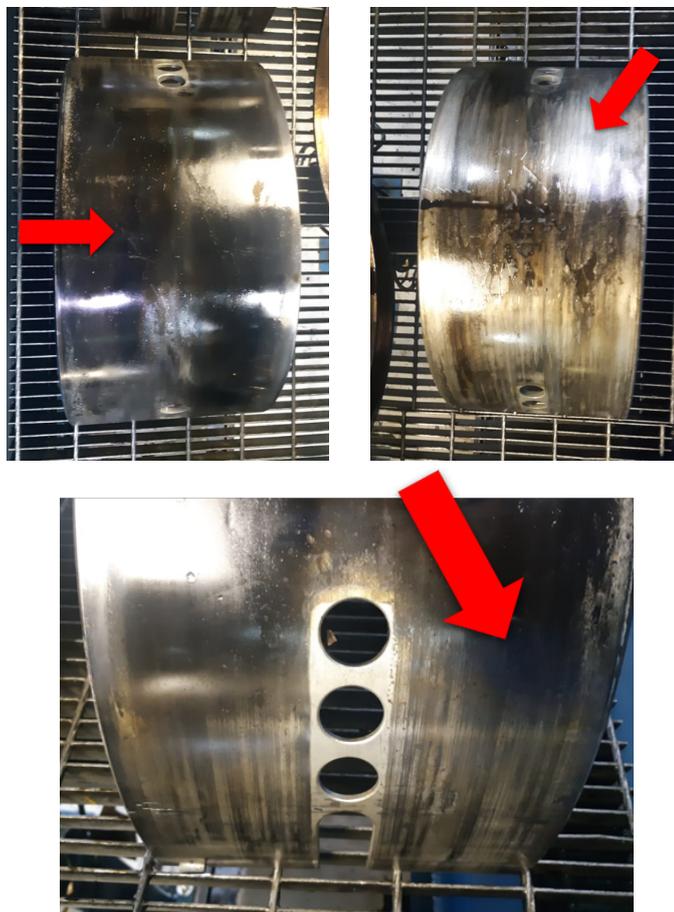


Figura 88 – Sinais de deslocamento do casquilho na capa.

Além disso foi identificado que o casquilho do cilindro B7 encontrava-se deslocado, conforme mostra a Figura 89.



Figura 89 – Deslocamento do cilindro B7.

Foi identificado também que o casquilho do cilindro B7 encontrava-se danificado nas extremidades, conforme mostra a Figura 90.



Figura 90 – Dano na lateral do casquilho do cilindro B7.

Ainda foi identificado que a trava do casquilho do cilindro B7 encontrava-se danificada, conforme mostram as imagens da Figura 91.

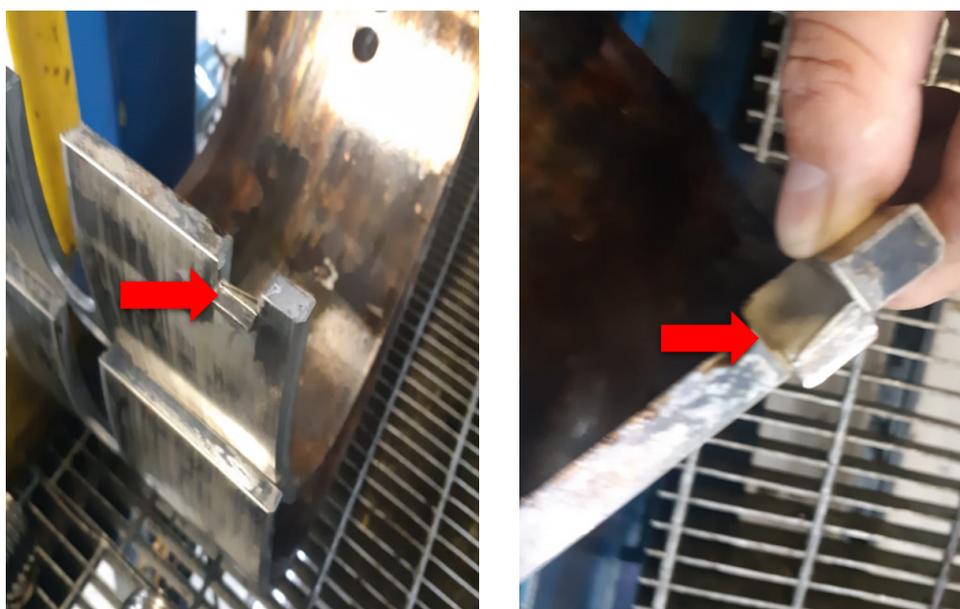


Figura 91 – Trava do casquilho do cilindro B7 danificada.

Foi identificado também que a bucha da biela sofreu avaria em decorrência da limalha, conforme mostram as imagens da Figura 92.



Figura 92 – Bucha da biela com defeito devido a decorrência da limalha.

Por fim, foi identificado a presença de limalha no alojamento do filtro automático de óleo lubrificante, conforme mostram as imagens da Figura 93.



Figura 93 – Presença de limalha no alojamento do filtro automático de óleo lubrificante.

# Anexos

## Article

# Condition Monitoring of Internal Combustion Engines in Thermal Power Plants Based on Control Charts and Adapted Nelson Rules

Fernanda Mitchelly Vilas Boas <sup>1,2</sup>, Luiz Eduardo Borges-da-Silva <sup>1</sup>, Helcio Francisco Villa-Nova <sup>1</sup>, Erik Leandro Bonaldi <sup>2</sup>, Levy Ely Lacerda Oliveira <sup>2</sup>, Germano Lambert-Torres <sup>2</sup> , Frederico de Oliveira Assuncao <sup>2</sup>, Claudio Inacio de Almeida Costa <sup>2</sup>, Mateus Mendes Campos <sup>2</sup>, Wilson Cesar Sant'Ana <sup>2\*</sup> , Josue Lacerda <sup>2,3</sup>, Jose Luiz Marques da Silva Junior <sup>3</sup> and Edenio Gomes da Silva <sup>3</sup>

- <sup>1</sup> Itajuba Federal University, Pro-Reitoria de Pesquisa e Pos-Graduacao (PRPPG), Itajuba 37500-903, MG, Brazil; fernandamitchellyvb@hotmail.com (F.M.V.B.); leborges@unifei.edu.br (L.E.B.-d.-S.); helcio.villanova@unifei.edu.br (H.F.V.-N.)
- <sup>2</sup> Gnarus Institute, Itajuba 37500-052, MG, Brazil; erik@institutognarus.com.br (E.L.B.); levy@institutognarus.com.br (L.E.L.O.); germanoltorres@gmail.com (G.L.-T.); fredeoa@gmail.com (F.d.O.A.); claudiocosta@yahoo.com (C.I.d.A.C.); m.campos.mateus@gmail.com (M.M.C.); josue.lacerda@raesa.com.br (J.L.)
- <sup>3</sup> Rio Amazonas Energia S.A. (RAESA), Manaus 69099-899, AM, Brazil; jose.marques@raesa.com.br (J.L.M.d.S.J.); edenio.silva@raesa.com.br (E.G.d.S.)
- \* Correspondence: wilson\_santana@ieee.org



**Citation:** Vilas Boas, F.M.; Borges-da-Silva, L.E.; Villa-Nova, H.F.; Bonaldi, E.L.; Oliveira, L.E.L.; Lambert-Torres, G.; Assuncao, F.d.O.; Costa, C.I.d.A.; Campos, M.M.; Sant'Ana, W.C.; et al. Condition Monitoring of Internal Combustion Engines in Thermal Power Plants Based on Control Charts and Adapted Nelson Rules. *Energies* **2021**, *14*, 4924. <https://doi.org/10.3390/en14164924>

Academic Editor: Filipe Magno de Gouveia Quintal

Received: 9 July 2021

Accepted: 6 August 2021

Published: 11 August 2021

**Publisher's Note:** MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



**Copyright:** © 2021 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

**Abstract:** In thermal power plants, the internal combustion engines are constantly subjected to stresses, requiring a continuous monitoring system in order to check their operating conditions. However, most of the time, these monitoring systems only indicate if the monitored parameters are in nonconformity close to the occurrence of a catastrophic failure—they do not allow a predictive analysis of the operating conditions of the machine. In this paper, a statistical model, based on the statistical control process and Nelson Rules, is proposed to analyze the operational conditions of the machine based on the supervisory system data. The statistical model is validated through comparisons with entries of the plant logbook. It is demonstrated that the results obtained with the proposed statistical model match perfectly with the entries of the logbook, showing our model to be a promising tool for making decisions concerning maintenance in the plant.

**Keywords:** condition-based maintenance; failure analysis; internal combustion engines; Nelson Rules; statistical process control

## 1. Introduction

The current stage of evolution of thermal power plants (TPPs), in conjunction with the low reservoir levels of their hydro counterparts (due to longer periods of high temperatures or droughts [1]), has resulted in the dispatch of TPPs in order to fulfill occasional demand [2]. Furthermore, due to the ever-increasing penetration of intermittent renewable sources, in combination with the fact that large thermal generation systems may have limited power ramping capability [3], TPPs using internal combustion engines (ICEs) can be dispatched in less time. However, a great number of ICEs in the TPPs are constantly exposed to stresses [4], increasing the chances of catastrophic failures. Inherent factors to thermal power generators (such as the number of start-ups, average load, variation in load and ambient temperature) can increase the levels of stress on the assets [5,6]. This increase on the stress levels may put the asset on the path towards failure. An accumulation of stresses may lead to wear and an increase in the vibration of the unit, decreasing the energy efficiency, decreasing the insulation resistance, increasing the consumption of replacement items, among other situations [7,8], and decreasing the generation reliability in consequence.

When the failures are identified at an incipient stage, appropriate actions can be performed to avoid breakdowns and the resulting losses [9,10]. The concept of condition-based maintenance (CBM) is based on the continuous monitoring of certain parameters and the evaluation of whether some of these parameters indicate signs of decreasing performance [11].

The in-depth knowledge of the plant environment, with regard to the condition of its main assets, is an important factor to gain information on the stress levels and wear and tear of the assets, as well as to perform maintenance control more effectively, which can reduce costs and postpone investments. Several approaches to the implementation of supervisory systems based on the resources of the environment in which they are inserted have been proposed in the literature, such as the methods presented in [12–15]. In the work of Audas [12], a database scheme was proposed in order to solve issues related with manual workload (spreadsheet-based) of TPP signal data. In Ribeiro et al. [13], a real-time monitoring system was presented in order to identify early failures in the energy generation of the TPPs. In Samtani et al. [14], an approach was presented to rate and identify the vulnerability of an Internet-enabled data acquisition and supervision system (SCADA). In Mayadevi et al. [15], a new technique was proposed that is capable of predicting failures in plants that use SCADA as a supervisory system. In the present context, special emphasis is given to the Wärtsilä Operator's Interface System (WOIS), which is discussed in depth in [16,17].

In WOIS, the operators can control and monitor the generators and related systems through an interface consisting of windows. These windows are classified into three categories: main, process and object. In the main window, the operator has an overview of the set of generators and their states, in addition to access to lists of alarms, graphs and reports. In the process window, operators have access to measurements and graphic symbols that describe more detailed information about the process itself. Finally, in the object window, the operator has access to detailed information about analog measurements [16]. As a result, operators are able to access all important plant data via the WOIS graphical interface.

Another interesting proposition in this context is the Marprime system [18]. With this system, operators can perform both the monitoring and measurement of internal pressure with or without ultrasound data of the internal combustion engines in a portable way. This system also provides the operator with analysis and diagnostic software [19]. Still related to the scope of this article, there are different approaches to maintenance: corrective, preventive and predictive maintenance. A review of these approaches is presented in [20]. However, special emphasis is given to predictive maintenance. This kind of maintenance allows the monitoring of the operational behavior of the generating units and has the ability to foresee a possible failure before the shutdown of the unity [20].

The concept of statistical process control (SPC) can be brought into this context [21] and here is considered as an option to monitor the operative condition of the internal combustion engines of the TPP and indicate a trend of failures in the medium and long term based on the stresses to which the monitored assets were subjected. This concept is based on control charts that enable the tracking of each monitored parameter within certain limits [22]. Lampreia et al. [23] propose the use of the EWMA (Exponentially Weighted Moving Average) on the control charts of the pressure and temperature of a maritime ICE in order to decide when to activate a spare refrigeration system for the engine. However, the EWMA has insufficient rules to consider the behavior of data points that are not very close to the average.

This current paper presents a statistical model (SM) based on SPC and adapted Nelson Rules (which enable the indication of statistically abnormal behavior of variables [24]). The adapted Nelson rules are a set of eight rules that provide for better decisions concerning the behavior of the data points on the entire control chart. Hence, the maintenance personnel of the TPP can benefit from the use of statistical monitoring in order to develop strategies for the maintenance of all its assets, without the need for a complex infrastructure.

The asset sensing method integrates the ability to monitor and locate regions of abnormal operation, allowing for intelligent asset management. When the SM finds such regions, it can issue an alert of the probability of future failure if the asset continues operating under these conditions. However, in order to do so, data need to be available (which originate from the plant's supervisory system itself, field measurements, online monitoring systems and even reports from the maintenance personnel) to allow the interpretation of these data (in order to extract valuable information) and decision making in relation to the events.

In order to improve the performance of the original supervisory system [16], this article analyzes the ability of the proposed SM to present indications of failure probabilities. In order to provide the analysis with practical appeal, the operating data used refer to the history of an internal combustion engine of model 18V46, from the manufacturer Wärtsilä. The rest of the paper is organized as follows: Section 2 presents the fundamental concepts about the development of the SM. Section 3 presents the validation of the proposed SM based on the data of an internal combustion engine operating in a TPP in Brazil. Finally, Section 4 presents the main conclusions of the work and some opportunities for future research.

## 2. Materials and Methods

This section presents the analytical development of the SM based on thermal power generators (each of them driven by a Wärtsilä 18V46 internal combustion engine) of a TPP in Brazil. Section 2.1 presents a general description of this engine.

The proposed statistical model is based on the assumption that there is no prior knowledge of the operating conditions of the engines nor ideal operating ranges of the monitored variables (a variable is a term used to describe the information from each sensor—a further discussion on the variables is presented in Section 2.2). From this assumption, the goal of the technique presented in this article is to characterize the generating units from a model based on variable control charts, in which the control limits are updated according to the arrival of new data from the sensors.

In order to simplify the analysis, each generating unit is divided into 11 subsystems. Each subsystem has distinct characteristics and modes of operation. A set of 112 variables is distributed among the 11 subsystems, as presented in Section 2.2.

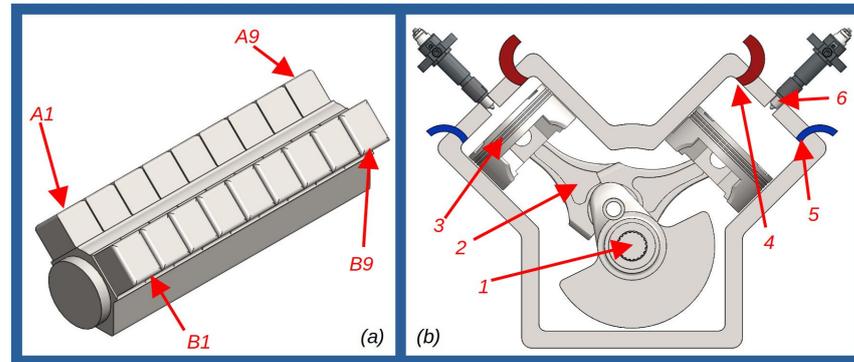
The data from the 112 variables are processed at a fixed time basis of a few units of seconds. At each update, statistical calculations are performed for each variable (mean and standard deviation). The operational probability regions are updated on the control chart, and the adapted Nelson Rules are applied to the new point of monitored quantities, resulting in a percentage of activation of those rules. Section 2.3 discusses the development of the statistical model, including the control charts and the adapted Nelson Rules.

### 2.1. General Description of the 18V46 Engine

Figure 1 presents the basic drawings of the 18V46 engine. The 18V46 engine is configured in a V format with 18 cylinders, arranged as 9 cylinders on side A and 9 on side B, as presented in Figure 1a. Figure 1b presents the most important parts of a pair of cylinders (1—crankshaft, 2—connecting rod, 3—piston, 4—exhaust gas valve, 5—inlet valve and 6—fuel injection valve).

The 18V46 has a hybrid fuel mode between Gas–Diesel (GD) or Heavy Fuel Oil (HFO). The cycle starts with the piston (one of the pair) in downward motion and the opening of the inlet valve to fill the cylinder with air. As the pistons are in alternate motion (due to the movement of the crankshaft), as soon as the piston reaches the bottom of the cylinder, it returns in an upward motion. During the upward motion, the injection valve releases HFO in the cylinder in order to ignite the mixture of air and fuel in the cylinder. If the engine is in GD mode, the gas is released in the cylinder through the fuel injection valve. If the engine is in HFO mode, the fuel injection valve also releases the amount of HFO related to the working force of the pistons (apart from the ignition parcel). As the piston moves upwards, the compression of the HFO (both in GD and HFO modes) produces the

combustion of the fuel, which in turn produces the downward movement of the piston. At the same time, the exhaust gas valve opens in order to liberate the hot gases produced in the fuel combustion. As the piston is in downward motion, the cycle repeats. The up and down movement of the pistons is transmitted to the crankshaft through the connecting rod. The rotational movement of the crankshaft acts as a prime mover for a synchronous generator connected at the same shaft, thus generating electricity.

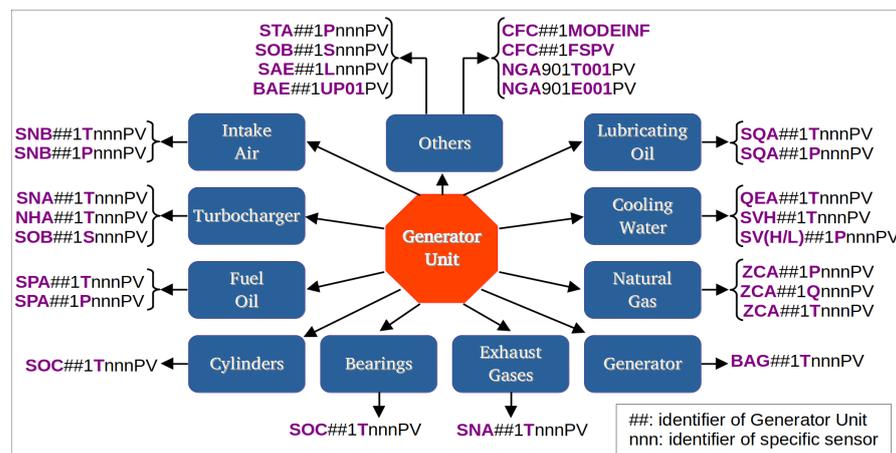


**Figure 1.** Didactic illustration of the 18V46 engine—(a) positioning of the cylinders—(b) parts of the cylinders.

### 2.2. Subsystems and Variables

In an ICE, monitoring is established for thermal and hydraulic variables (basically, temperature and pressure, in previously defined locations) accompanied by the angle of the eccentric axis. Failures and consequent damages in unmonitored positions present, in most cases, a delay from their occurrence until their detection by monitoring. In most cases, this delay is of different time scales for thermal changes in relation to hydraulic changes, leading to a great difficulty in assessing the temporal onset and fault location. The use of statistical control over the monitoring process makes it possible to establish a coalition between the thermal and hydraulic data of the control variables throughout the operating journey of the ICE, defining stops and maintenance criteria.

The diagram of Figure 2 presents the division of the a generation unit into its sub-systems, named as intake air, turbocharger, fuel oil, cylinders, bearings, lubricating oil, cooling water, generator, natural gas, exhaust gases and others. Each subsystem is further divided into several variables (that contain data from a multitude of sensors installed in the system). In total, each generator unit has 112 variables. The sensors are the same as those already installed in the Wärtsilä supervisory system. The variables also follow the same naming convention (tags) of the Wärtsilä system [17,25]. Table 1 presents a description of the variables.



**Figure 2.** Diagram of a generator unity, divided into 11 subsystems (further divided into variables).

**Table 1.** Distribution of variables from the subsystems of generator unity number ##.

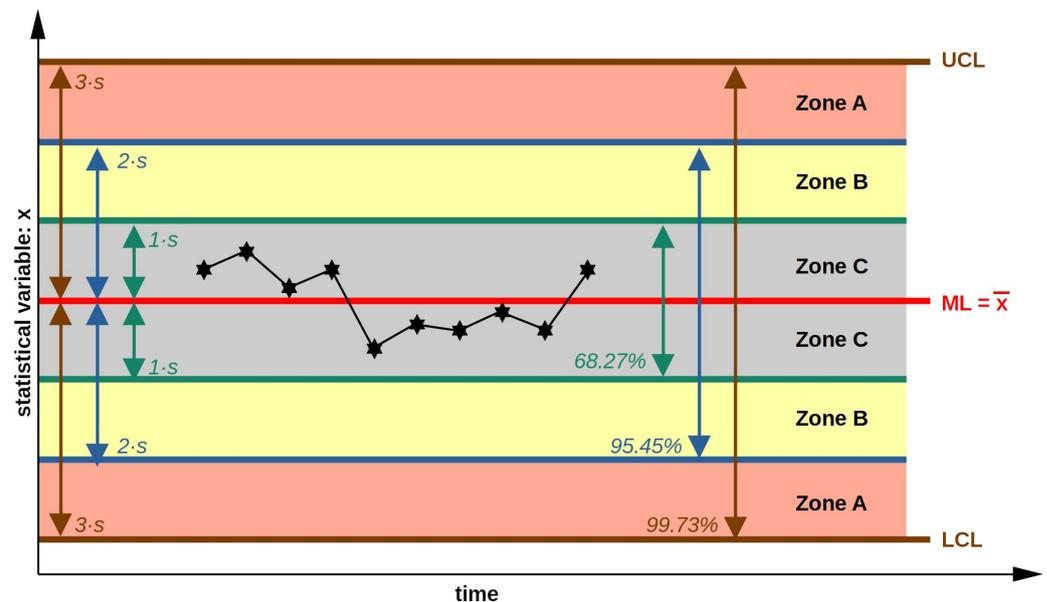
Subsystem	Variable	Description
Intake Air	SNB##1T001PV	Turbo air inlet temperature
	SNB##1T002PV	Charge air temperature in receiver
	SNB##1P002PV	Charge air pressure in receiver
Turbocharger	SNA##1T055PV	Exhaust gas temperature before turbo A
	NHA##1T001PV	Exhaust gas temperature after turbo A
	SNA##1T056PV	Exhaust gas temperature before turbo B
	NHA##1T002PV	Exhaust gas temperature after turbo B
	SOB##1S002PV	Turbo A speed
	SOB##1S003PV	Turbo B speed
Fuel Oil	SPA##1T002PV	Fuel oil inlet temperature
	SPA##1P004PV	Fuel oil inlet pressure
Cylinders	SOC##1TnnnPV	Cylinder (identified by nnn) liner temperature
Bearings	SOC##1TnnnPV	Main/Thrust bearing (identified by nnn) temperature
Exhaust Gases	SNA##1TnnnPV	Exh.gas. of cylinder (identified by nnn) temperature
Natural Gas	ZCA##1P101PV	Valve skid gas pressure inlet
	ZCA##1P102PV	Valve skid gas pressure outlet
	ZCA##1Q101PV	Main gas flow
	ZCA##1T001PV	Valve skid gas temperature outlet
Generator	BAG##1TnnnPV	Generator winding or bearings (identified by nnn) temperature
Cooling water	QEA##1TnnnPV	Cooling water temperatures (at positions identified by nnn)
	SVH##1TnnnPV	HT water temperatures (at outlets identified by nnn)
	SV(H/L)##1P003PV	(H/L)T water inlet pressure
Lubricating Oil	SQA##1TnnnPV	Lube oil temperature (at positions identified by nnn)
	SQA##1PnnnPV	Lube oil pressure (at positions identified by nnn)
Others	STA##1PnnnPV	Air pressure (at positions identified by nnn)
	SOB##1S001PV	Engine speed
	SAE##1L001PV	Torsional vibration
	BAE##1UP01PV	Generator active power
	CFC##1MODEINF	Fuel sharing (GD/HFO) mode
	CFC##1FSPV	Fuel sharing (GD/HFO) percentage
	NGA901T001PV	Outdoor temperature
	NGA901E001PV	Absolute humidity

### 2.3. Statistical Model

Based on the variables of each subsystem, the control criteria to be used as indicative of abnormalities in monitoring the variables are defined with the objective of indicating the occurrence of abnormal wear. The statistical analysis of each monitored variable is performed through control charts, as illustrated in Figure 3.

Figure 3 presents an example of the expected behavior of a random variable, plotted as the black curve (called  $x$ ). The red line (called ML) characterizes the middle line; in other words, it characterizes the average ( $\bar{x}$ ) of the measures of each variable  $x$ . The brown lines represent the statistical limits in which the variable is expected to swing in extreme cases, although still under normality. The limits are called the UCL (Upper Control Limit) and LCL (Lower Control Limit) and are determined based on the average  $\bar{x}$  and standard deviation  $s$ . Three zones (A, B and C) are defined in the figure. Zone C is the region in which the variable deviates from the average in less than one standard deviation (above or below). Zone B is the region in which the variable is between one and two deviations from the average (above or below). Zone A is the region in which the variable is between two and three deviations from the average (above or below). Considering a normal distribution, it is known from probability theory [22] (pp. 119–120) that any random variable has a 68.27% chance to be measured in a region limited between two standard deviations ( $\pm 1 \cdot s$ ),

a 95.45% chance to be measured in a region between four standard deviations ( $\pm 2 \cdot s$ ) and a 99.73% chance to be measured in a region between six standard deviations ( $\pm 3 \cdot s$ ). Hence, if any measurement is obtained outside of six standard deviations, it is considered that this measurement is “outside the control limits”, as this would have only a 0.27% of chance of occurrence.



**Figure 3.** Example of control chart of a statistical variable  $x$ , with average  $\bar{x}$  and standard deviation  $s$ .

It is important to note that the application of the control chart as defined in Figure 3 is able to monitor the behavior of the variables. However, in practice, it is necessary to determine rules that point to the tendency of failures of the measured variables of the generator units and to indicate in some way an abnormality for the machine operator.

Commonly, the performance evaluation of the generating units of TPPs is performed through electronic and automatic monitoring and control systems. However, the reliance of these systems on the obtained parameters and measurements of the process generates increased difficulty in monitoring. Furthermore, the evaluation of all parameters by an operator, given the infinity of available parameters and the complexity of the processes involved, increases the difficulty. In this article, a statistical model is used to analyze the operating states of the generator units and to support the operators of these machines. According to this statistical model, the fault detection of the generator units is given by the activation of the adapted Nelson Rules, described briefly below:

- Rule #0: First point above (or below) the upper (or lower) control limit.
- Rule #1: Second point in the same Zone A, in three consecutive measurements.
- Rule #2: Fourth point in Zone B or A (on the same side), in five consecutive measurements.
- Rule #3: Ninth consecutive point on the same side of the average.
- Rule #4: Sixth consecutive point always below (or above) the previous ones.
- Rule #5: Eighth point outside C zones.
- Rule #6: Fifteenth consecutive point within C zones.
- Rule #7: Fourteenth alternating point up and down in any zone.

One of the possible problems that may arise in the application of the adapted Nelson rules is the requirement of a normal distribution for the data [26]. According to the Central Limit Theorem [22], it can be considered that, for a large number of samples, the probability

distribution of its average will be close to a normal distribution. Hence, the data from the sensors are normalized in terms of a z-score as (1).

$$z[n] = \frac{x[n] - \bar{x}}{s}, \quad (1)$$

where  $x[n]$  is the set of non-normalized data of each variable.  $\bar{x}$  is the average value of this set, calculated as (2).  $s$  is the sample standard deviation of the set and is calculated as (3).

$$\bar{x} = \frac{1}{N-1} \cdot \left( \sum_{n=1}^N x[n] \right), \quad (2)$$

where  $N$  is the number of samples in the set.

$$s = \sqrt{\frac{\sum_{n=1}^N (x[n] - \bar{x})^2}{N-1}}. \quad (3)$$

For each of the variables, the control charts of each variable are obtained in accordance with [27]. The zones A, B and C, as well as the control limits, are obtained based on the values of the average ( $\bar{x}$ , calculated in (2), which corresponds to the middle line, ML, of Figure 3) and the standard deviation ( $s$ , calculated in (3)). The upper and lower control limits (UCL and LCL, respectively) of the chart are based on a spread of three standard deviations from the average, as implied in (4) and (5).

$$UCL = \bar{x} + 3 \cdot s, \quad (4)$$

$$LCL = \bar{x} - 3 \cdot s. \quad (5)$$

In order to apply the Nelson Rules, the total region between the two limits (which comprises six standard deviations) is divided into the zones A, B and C, in accordance with Equations (6) to (11), as shown in Figure 3.

$$ZoneC_{upper} = \bar{x} + 1 \cdot s, \quad (6)$$

$$ZoneC_{lower} = \bar{x} - 1 \cdot s, \quad (7)$$

$$ZoneB_{upper} = \bar{x} + 2 \cdot s, \quad (8)$$

$$ZoneB_{lower} = \bar{x} - 2 \cdot s, \quad (9)$$

$$ZoneA_{upper} = \bar{x} + 3 \cdot s = UCL, \quad (10)$$

$$ZoneA_{lower} = \bar{x} - 3 \cdot s = LCL. \quad (11)$$

The previous equations are evaluated with a dynamic process: as each new piece of is data acquired from the sensors, all statistics (i.e., the average, the standard deviation, the control limits and the zones) are recalculated. To prevent the mean and standard deviation from having extrapolated values, some points are not considered for the calculation, as they are considered outliers by the system. In the development of this work, outliers are considered values greater than a maximum factor or smaller than a minimum factor. If the current value exceeds one of these limits, it is not considered in the calculation of the new mean and standard deviation of the variable. The maximum and minimum values are established in two ways for the variables: the first way is to use the system input data established by the machine manufacturer and presented in the equipment manual, and the second is to use values of  $x_{max} = \bar{x} + 10 \cdot s$  and  $x_{min} = \bar{x} - 10 \cdot s$ . The second option is used whenever there is no information established in the machine's operating manual or if the value established by the manufacturer has a very high operating range.

Regarding the statistical analysis, it is very important to put the fact into perspective that the machine monitoring process started with the ideal operating condition of the

engine, where all the sensors were in good operating condition and the machine was operating as expected by the manufacturer. With all initial operating conditions considered ideal, the mean and standard deviation of the variables become reliable bases in the calculation process.

As the system proposed in the work depends on the operating status of the sensors connected to the ICE, it is necessary to observe the condition of the sensor in operation. Considering the ideal initial operating conditions, if any measurement of a sensor starts to fail after a few months of system operation, the weight of an abnormal value sensor measurement will not abruptly affect the mean and standard deviation value of the analyzed variable. If the damaged sensor continues to provide erroneous measurements, the Nelson Rules judgments would indicate statistical abnormalities that could be associated with sensor malfunctions. As the entire system is based on the statistical analysis of a machine's operating history, the proposed system will indicate events, through the analysis of Nelson Rules, that are outside the historical statistical pattern of the system.

In CBM approaches, as well as the approach proposed in this paper, there must be strategies to deal with the events of failures on the sensors, and the system's users must be notified about these failures. Among these strategies, two forms are observed: measurement redundancy and comparison by measurement similarity. In the present work, the analyses performed according to the Nelson Rules can indicate problems in sensors, since any changes in the sensing of the variable will be shown by the Nelson Rules.

As discussed in Section 2.2, the developed system consists of 112 variables distributed in 11 subsystems that were chosen according to the characteristics and importance of the subsystem. Many of the monitored variables present redundancy in the measurement; i.e., more than one sensor measures the same variable (for example, the cylinder system that has two sensors to measure the cylinder temperature). This redundancy helps to determine possible sensor errors, as it is expected to obtain close values for the same measurement of a monitored quantity. In the case of a defective sensor, the Nelson Rules concerning that particular sensor will indicate changes that do not happen in the redundancy sensor. Whenever these changes persist in a variable and its redundant variable does not show equivalent changes, this is an indication of a possible sensor failure.

Each subsystem has characteristics that are linked to the variables chosen to be monitored. Many subsystems have parts that function similarly, such as cylinder system cylinders, exhaust gas system variables and others. With the proposed technique, it is possible to compare the Nelson Rules patterns between similar parts of the subsystems and identify if there are discrepant values between the triggered rules. These outliers can also be an indication of a possible sensor failure.

### 3. Results

In order to validate the statistical model (SM), an event that happened on 1 August 2019 at 14:41 in generation unit 05 of a Brazilian thermal power plant (TPP) has been considered. At that time, the proposed monitoring system was not in operation, and the event is used here only in order to validate the model (considering the historical data imported from the plant supervisory database). In that event, there was a shutdown and, after inspection, it was verified that cylinder B7 was locked.

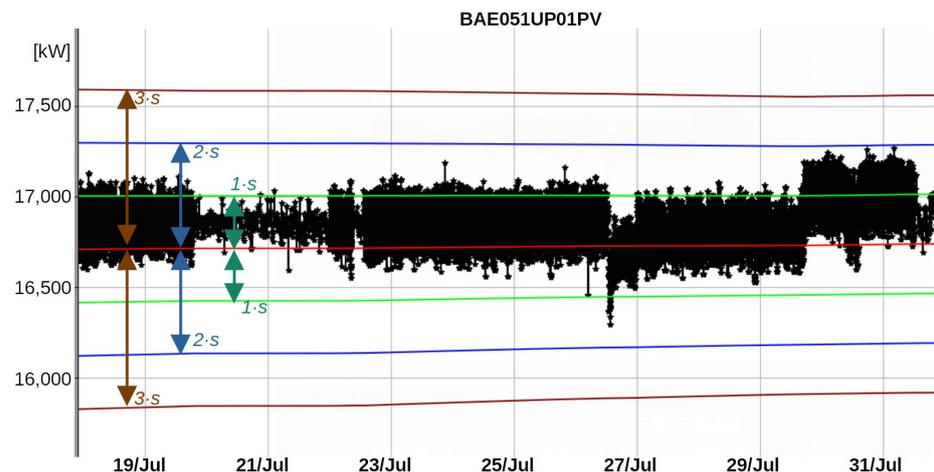
Within selected time windows, the SM generates bar graphs of the triggered Nelson Rules on the control charts as an objective and visual way to display the state of the machine to the operators. Comparisons are made between the events shown in the logbook and the Nelson Rules bar graphs in order to verify whether the SM is capable of displaying the problem described in the logbook. After an analysis of the logbook, it could be found that not only cylinder B7 had issues on 1 August 2019, but also other cylinders were not in an optimal condition (such as the A6 cylinder). Section 3.1 presents the analysis performed with the generation unit under "apparent" normal conditions (with data collected since 14 days before the day of the shutdown). Then, Section 3.2 presents the analysis of this same generation unit on the day of the shutdown event. Finally, Section 3.3 presents an

investigation performed on the disassembled engine and the analysis of the variable related to the root cause of the shutdown during the days of “apparent” normal conditions, which shows that the proposed system could have issued an alert (if in operation by that time) that could have prevented the shutdown and the associated material damage.

### 3.1. Operation within Normality

In order to obtain the control charts, first, the historical data of the active power provided by the TPP were gathered. Then, the statistical parameters (of all other sensors) were calculated as the average, standard deviation, LCL, UCL and the zones of each monitored variable. The use of the active power was based on the fact that it provides good indications of the load level of the internal combustion engine, and this information can be useful in order to avoid false positives.

Figure 4 presents the control diagram of the active power (variable BAE051UP01PV). The curve in black represents the variation of the active power in the time window from 17 July 2019 until 31 July 2019, which are the 14 days before the day of the shutdown event (as discussed in Section 3.2). The green lines represent the separation between zones C and B and the blue lines represent the separation between zones B and A. The brown lines represent the LCL and UCL.



**Figure 4.** Control chart of active power of the generation unit 05 between 17 July 2019 and 31 July 2019.

Similar graphs were also obtained for all other monitored variables. Conventionally, the maintenance personnel would have to analyze several control charts (for each monitored variable) in order to find a possible trend of failure. Figure 5, for example, presents the trend of the z-score of the variable SOC051T027PV (one of the two temperature sensors in cylinder A6 at the Cylinders subsystem) within the same time window as Figure 4.

As the complete analysis of a machine with 112 sensors is not practical, this paper proposes a visual indication in the form of bar graphs, displaying at once the activation percentage of each of the Nelson Rules for all variables. Figure 6 presents the bar graph of the cylinder subsystem. The horizontal axis of the figure presents the tags used in the Wärtsilä system for this subsystem (2 temperature sensors for each of the 18 cylinders) and the vertical axis presents the rules being triggered:

- Rule #6 is well activated for the majority of variables in this subsystem. This is an indication that their data points are inside the  $\pm 1 \cdot s$  region (as seen for variable SOC051T027PV from the control chart of Figure 5, where the majority of data points are between the green lines).
- Rules #5 and #2 have some percentage of activation. This is an indication that these variables have points that are outside the  $\pm 1 \cdot s$  region, although they are still statistically in normality.

- Rule #1 indicates some very small percentage of data points (for variables SOC051T019PV, SOC051T021PV, SOC051T022PV, SOC051T034PV and SOC051T058PV) in the regions either between  $+3 \cdot s$  and  $+2 \cdot s$  or between  $-2 \cdot s$  and  $-3 \cdot s$ , which are still statistically in normality as long as these percentages are below 4.28%.
- Rule #0 indicates that none of the variables have points outside the control limits of  $3 \cdot s$ .

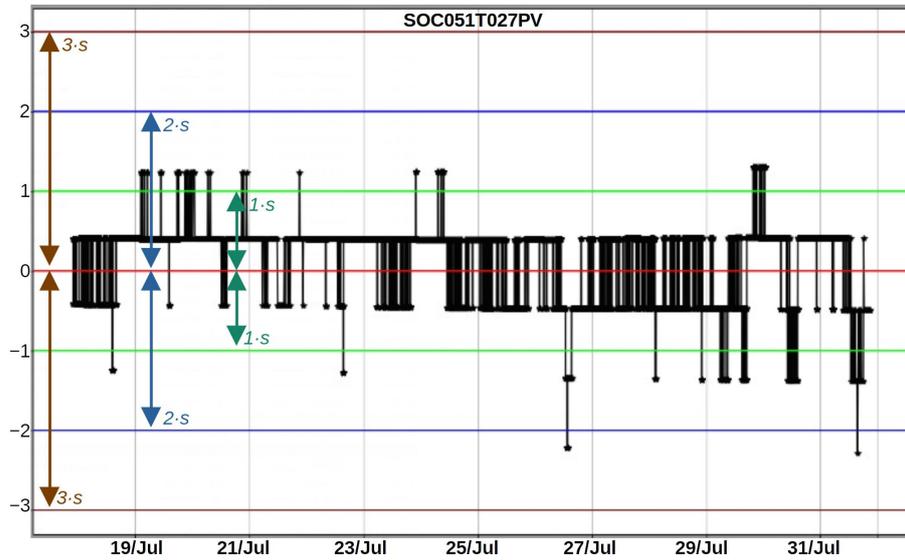


Figure 5. Trend of the variable SOC051T027PV (one of the two temperature sensors of cylinder A6 in the cylinders subsystem) between 17 July 2019 and 31 July 2019.

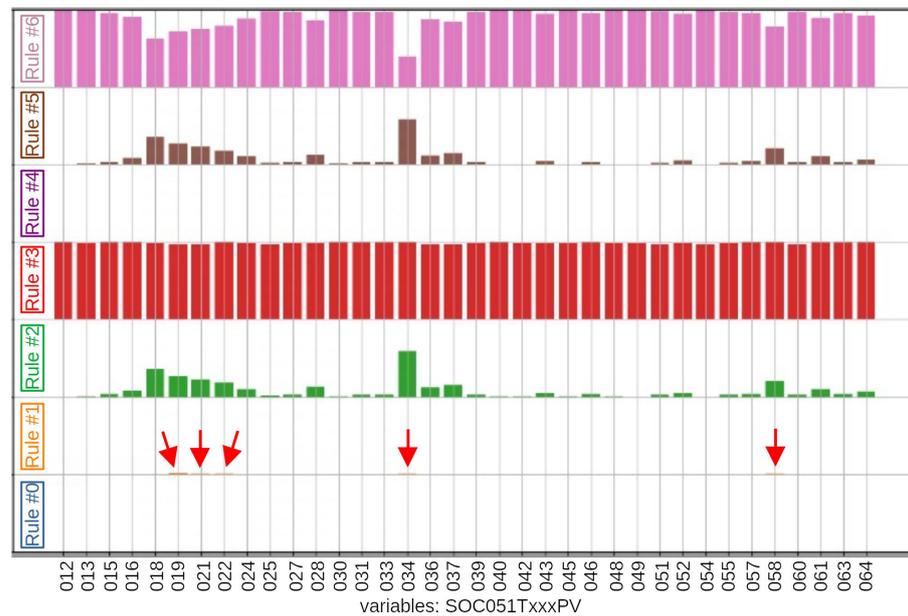


Figure 6. Bar graph of the cylinders subsystem between 17 July 2019 and 31 July 2019.

### 3.2. Operation on the Day of the Shutdown Event

The same generation unit that presented a statistical behavior under normality in Section 3.1 suffered a series of events, including a shutdown, hours after that period. Figure 7 presents the control diagram of the active power (variable BAE051UP01PV). The curve in black represents the variation of the active power in the time window from midnight of 1 August 2019 until 16:00 (4:00 p.m.) of the same day. In order to carry out the validation analysis of the SM, the dates, times and descriptions of the events that occurred in the unit were collected from the logbook (which has manual entries written by the TPP

personnel—the most relevant are shown in the figure). The figure also indicates two time windows in which the analyses were performed.

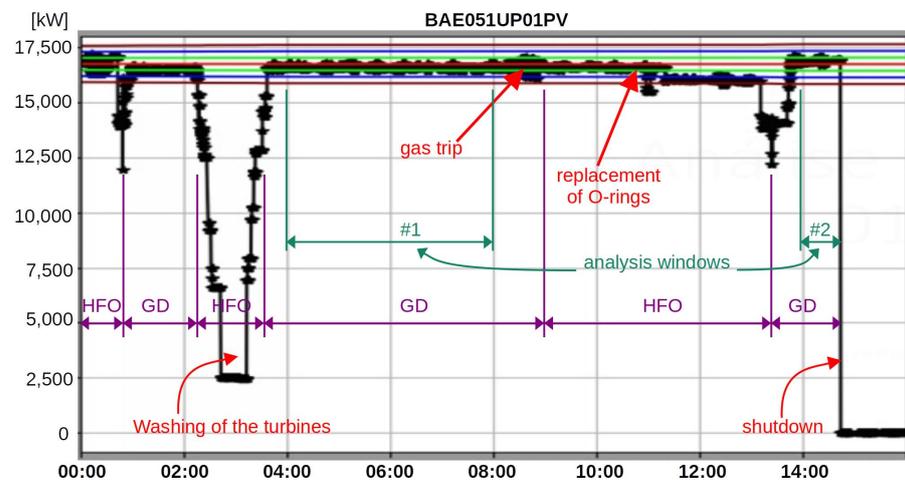


Figure 7. Control chart of active power of generation unit 05—on the day of the shutdown event.

The first analysis window (from 03:57 until 07:58) started after the washing of the turbines (it is important to note that the washing of the turbines is a usual procedure and had no relation to the events on that day) and ended before a gas trip event. Within this time window, the SM generated the bar graphs of the triggered Nelson Rules. Figure 8 presents the bar graph of the cylinder subsystem (the same subsystem presented earlier in Figure 6). This subsystem had two temperature sensors for each of the 18 cylinders (A1 to A9 and B1 to B9). The horizontal axis of the figure presents the tags used in the Wärtsilä system for this subsystem, and the vertical axis presents the rules being triggered. As indicated in the figure, the sensor SOC051T027PV (one of the two temperature sensors in cylinder A6) showed that rule #0 (blue) was activated for about 90% of the time in that time window, and about rule #1 (orange) was applicable for about 10% of the time. The statistical interpretation is that this variable was outside three standard deviations from its average value for 90% of the time window and in the zone between two and three deviations for 10% of the time. This characterizes a statistical anomaly, which might be associated with a failure on that cylinder.

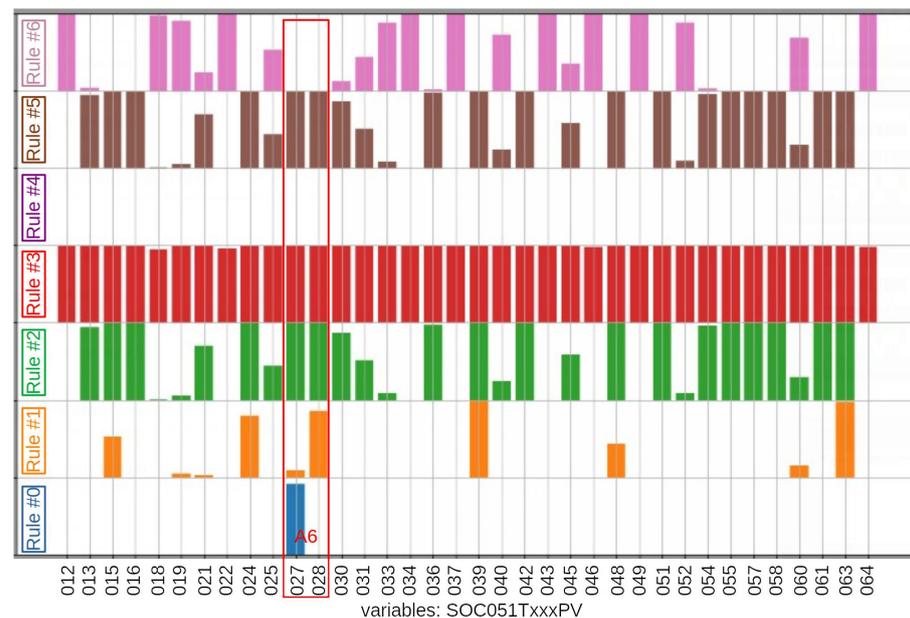
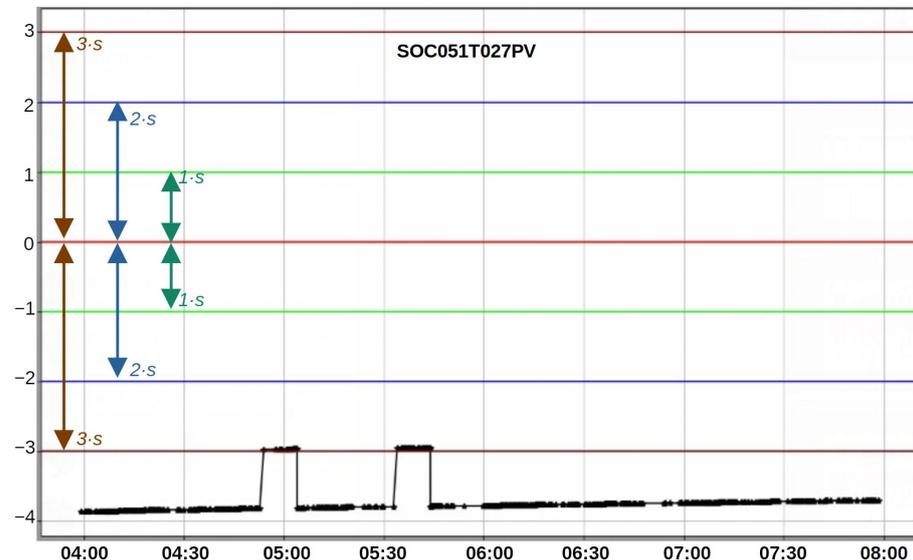


Figure 8. Bar graph of the cylinders subsystem during time window #1 (between 03:57 and 07:58).

Figure 9 presents the trend of the z-score of the variable SOC051T027PV (the same variable presented earlier in Figure 5) within the time window between 03:57 and 07:58. As expected from Figure 7, within this time window, that variable was outside of the three standard deviations limit for 90% of the time.



**Figure 9.** Trend of the variable SOC051T027PV (one of the two temperature sensors of cylinder A6 in the Cylinders subsystem) during the time window #1 (between 03:57 and 07:58).

Within the same time window between 03:57 and 07:58, Figure 10 presents the bar graph of the exhaust gases subsystem. This subsystem had one temperature sensor for each of the 18 cylinders (A1 to A9 and B1 to B9). The bar graph indicates that rule #0 was not activated for any of the variables, indicating that all variables worked within the range of three standard deviations from the average. However, in relation to the cylinder A6 (the same cylinder that had rule #0 activated in Figure 8), under the tag SNA051T029PV for the exhaust gases subsystem, it is possible to see that it worked in the region between two and three deviations, since rule #1 (orange) was activated for almost the entire time. It is interesting to note that the logbook had no entries related to this cylinder prior to the gas trip event that happened at 08:19 (after this time analysis window), while the SM already indicated some level of statistical anomaly regarding the behavior of this variable.

At 08:19, the logbook indicates a gas trip event. At 09:15, the logbook indicates that the maintenance personnel identified a leakage in the same A6 cylinder that the SM was indicating with a statistical anomaly.

At 10:40, the O-rings of cylinder A6 were replaced. At 10:50, another test was performed by the maintenance personnel, and the logbook indicates no leakage. Since the gas trip event (at 08:19), the combustion engine (which has a hybrid fuel mode: Heavy Fuel Oil (HFO) and Gas–Diesel (GD)) was switched to HFO mode and stayed in this mode during the O-ring replacement and leakage tests. The operation returned to GD mode at 13:24 (1:24 p.m.). It is important to note that it is preferable to analyze the system under similar conditions. Hence, aiming for a more coherent analysis, the next time window started after the return to GD mode and ended just before the shutdown event (at 14:41).

Figure 11 presents the bar graph of the cylinders subsystem after the return to GD mode, until the shutdown (time window from 13:51 to 14:39). It can be observed in the figure that cylinder A6 (variable SOC051T027PV) do not have rule #0 (blue) activated (in comparison with Figure 8), and rule #6 (pink—a rule that indicates normality) was activated. This is an indication that the statistical behavior of this cylinder returned to normality after the maintenance. However, in this figure, it can also be noted that some other variables (SOC051T025PV (one of the two temperature sensors of cylinder A5), SOC051T051PV (one of the two temperature sensors of cylinder B5) and SOC051T063PV and SOC051T064PV

(the two temperature sensors of cylinder B9)) showed rule #1 (orange) to be activated and rule #6 not to be activated, which is an indication that, although these variables were still inside the three deviations limits, some tendency towards failure might have appeared.

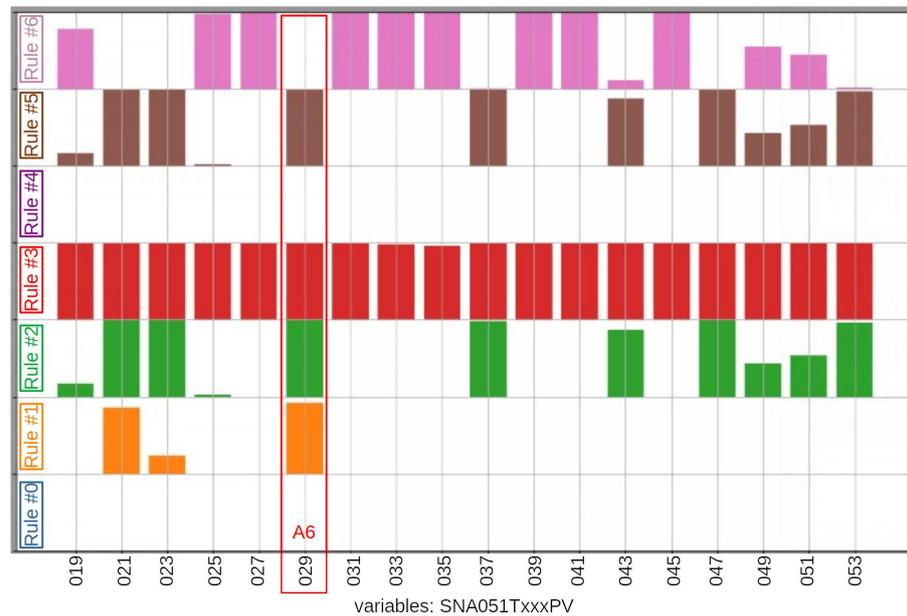


Figure 10. Bar graph of the exhaust gases subsystem during time window #1 (between 03:57 and 07:58).

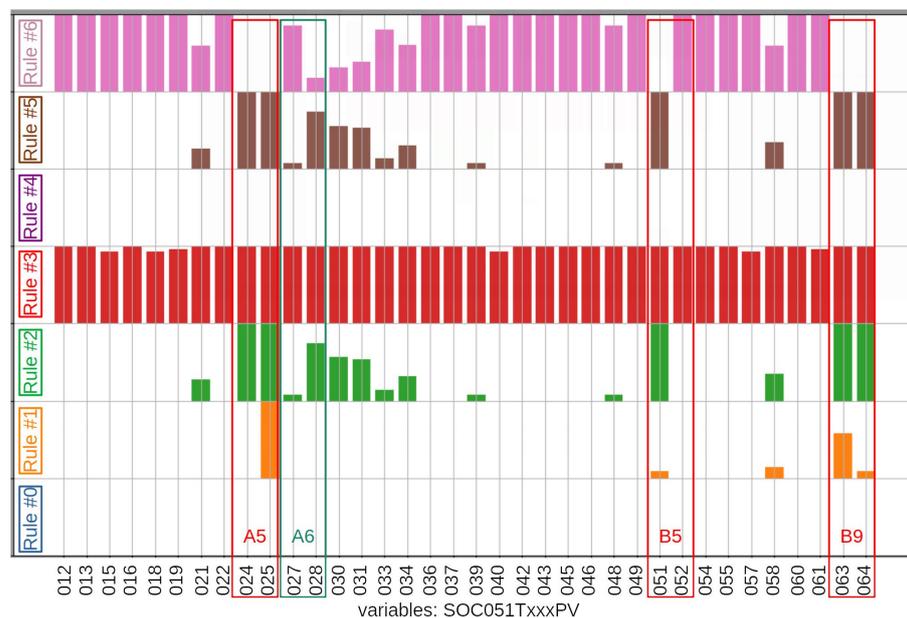
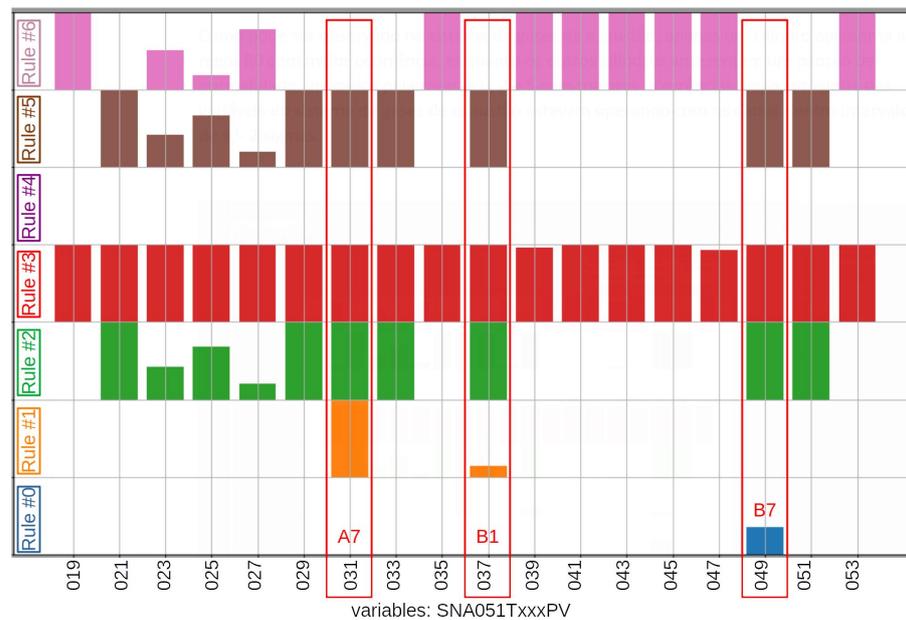


Figure 11. Bar graph of the cylinders subsystem during time window #2 (between 13:51 and 14:39).

Within the same time window between 13:51 and 14:39, Figure 12 presents the bar graph of the exhaust gases subsystem. The bar graph indicates that rule #0 (blue) was activated for variable SNA051T049PV (temperature sensor for cylinder B7), indicating operation outside three deviation limits. It can also be observed that, concerning variables SNA051T031PV (temperature sensor for cylinder A7) and SNA051T037PV (temperature sensor for cylinder B1), rule #1 (orange) was activated while rule #6 (pink) was not activated, indicating that these cylinders (especially A7) might have shown a trend towards failure.



**Figure 12.** Bar graph of the exhaust gases subsystem during time window #2 (between 13:51 and 14:39).

At 14:41, the logbook indicates a shutdown. At 15:05, the maintenance personnel started an inspection, and at 15:15, it was verified that cylinder B7 was locked.

### 3.3. Investigation on the Shutdown Event

After the shutdown of the engine, it was disassembled, and it was noticed that the bearing shells of several cylinders (not only B7) presented severe abrasion marks, as shown in Figure 13. Under regular conditions, the movement of the connecting rods in relation to the pistons and the crankshafts occurs under a viscous lubricating oil that prevents this kind of abrasion of a metallic part in friction with another metallic part. After an investigation, it was realized that inadequate lubrication had been an issue for some months before the failure.



**Figure 13.** Photography of one of the disassembled bearing shells.

Concerning the validation of the SM, it is interesting to note that the bar graphs presented in Section 3.2 show the engine operating outside normality for several variables that were under normal conditions in Section 3.1 only some hours before. However, analyzing the subsystem of bearings during that same interval of “apparent” normal

conditions (between 17 July 2019 and 31 July 2019), the bar graphs clearly indicate abnormal conditions with that system. Figure 14 presents the bar graphs for the temperature variables of the bearings subsystem. It can be noted that three of the main bearings already exhibited a behavior outside statistical normality 14 days before the failure. It is important to note that the proposed system was not in operation at the time of the events described here. If it were, the proposed visualization tool, which concentrates information of several variables, could have given more information to the maintenance team, and the shutdown event could have been prevented.

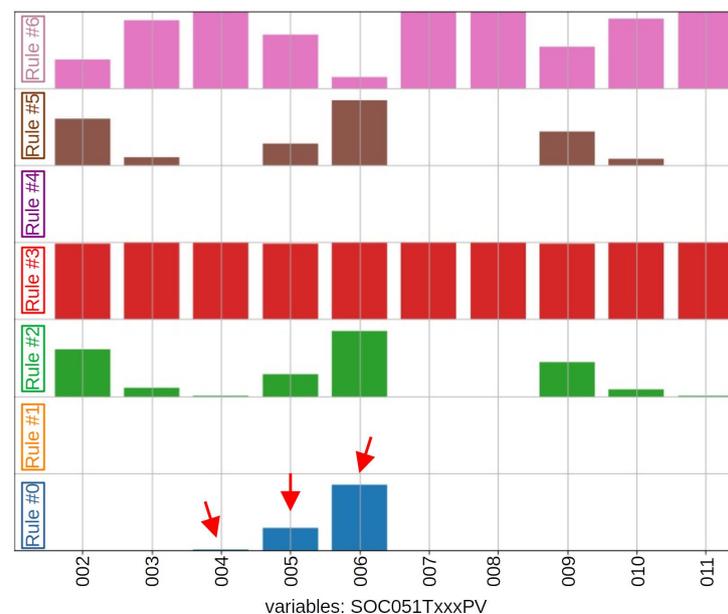


Figure 14. Bar graph of the bearings subsystem—between 17 July 2019 and 31 July 2019.

#### 4. Conclusions and Future Work

This paper presented a statistical model to analyze the operational condition of an internal combustion engine (Wärtsilä 18V46) in operation on a thermal power plant in Brazil. The statistical model has been validated according to entries in the plant's logbook. The model is based on the principles of statistical control processes and adapted Nelson Rules.

Conventional measurement techniques (of temperature, pressure, vibrations, viscosity and others) usually only assign a level of warning and alarm for each of the quantities. However, even if the asset does not reach the alarm levels, its operating cycle goes through moments of greater or lesser stresses, causing a degree of wear that accumulates over time and ends up leading to failures. The originality of this work is the proposition of a methodology that continuously monitors the stress levels suffered by the machine during its operation, even if the alarm limits are not reached. The stress levels can be inferred through the activation degree of the Nelson Rules on the control charts.

A graphical visualization system that takes the Nelson Rules into account for all sensors has been presented in the form of a bar graph. This graph provides a more objective visualization of possible failure trends of a plant to the supervision personnel. The obtained bar graphs of the Nelson Rules have been compared with several events pointed out in the logbook, presenting a good match in the comparisons. However, it is very important to note that the performed analyses must be understood more as a statistical likelihood of failure than an actual physical problem. Hence, the proposed bar graphs are a tool that can be used in order to make decisions concerning maintenance in the plant.

The events presented in this paper took place at a time before the development of the proposed system. The results show that, if in operation by the time prior to the events,

the proposed system could have issued an alert that could have prevented the shutdown and the associated material damage.

The statistical model applies the Nelson Rules based on the data of several sensors connected to the plant's supervisory system. In the current preliminary stage of this project, the analysis has been performed on a time window selected by the operator. Within this selected time window, the model applied the Nelson Rules and displayed a bar graph concentrating the information of all sensors (or selected sensors, if desired). As a future development, an autonomous sliding time window will be implemented allowing for the generation of alarms in the case of a detected trend of failure. Additionally, an inference engine is expected to be implemented in order to concentrate the activation degrees of individual Nelson Rules into a single "early damage index".

**Author Contributions:** Conceptualization, F.M.V.B., H.F.V.-N., L.E.B.-d.-S., E.L.B. and C.I.d.A.C.; Data curation, C.I.d.A.C., L.E.B.-d.-S., E.L.B., G.L.-T., J.L., J.L.M.d.S.J. and E.G.d.S.; Formal analysis and Investigation, F.M.V.B., L.E.B.-d.-S., E.L.B., L.E.L.O., F.d.O.A., C.I.d.A.C., M.M.C., W.C.S., J.L., J.L.M.d.S.J. and E.G.d.S.; Methodology and Software, F.M.V.B., L.E.B.-d.-S., E.L.B., L.E.L.O., G.L.-T., F.d.O.A. and M.M.C.; Writing, F.M.V.B. and W.C.S. All authors have read and agreed to the published version of the manuscript.

**Funding:** This research received no external funding.

**Acknowledgments:** The authors would like to thank RAESA and the Brazilian Research Agencies CNPq, CAPES and ANEEL R&D for their support of this project. The authors would also like to thank the mechanical engineer Ronny Francis Ribeiro Junior for the 3D drawings of Figure 1 and for the discussions related to thermal power plants.

**Conflicts of Interest:** The authors declare no conflict of interest.

## Abbreviations

The following abbreviations are used in this manuscript:

CBM	Condition-based maintenance
CC	Control charts
EWMA	Exponentially Weighted Moving Average
GD	Gas–Diesel
HFO	Heavy Fuel Oil
ICE	Internal combustion engine
LCL	Lower control limit
ML	Middle line (average)
SCADA	Supervisory Control and Data Acquisition System
SPC	Statistical process control
SM	Statistical model
TPP	Thermal power plant
UCL	Upper control limit
WISE	Wärtsilä Information System Environment
WOIS	Wärtsilä Operator's Interface System

## References

1. Lacerda, L.D.; Santos, J.A.; Marins, R.V.; Silva, F.A.D. Limnology of the largest multi-use artificial reservoir in NE Brazil: The Castanhão Reservoir, Ceará State. *An. Da Acad. Bras. De Ciências* **2018**, *90*, 2073–2096. [[CrossRef](#)] [[PubMed](#)]
2. Esmin, A.A.; Lambert-Torres, G. Application of particle swarm optimization to optimal power systems. *Int. J. Innov. Comput. Inf. Control* **2012**, *8*, 1705–1716.
3. Pearre, N.; Swan, L. Reimagining renewable electricity grid management with dispatchable generation to stabilize energy storage. *Energy* **2020**, *203*, 117917. [[CrossRef](#)]
4. Mendonca, P.; Bonaldi, E.; de Oliveira, L.; Lambert-Torres, G.; da Silva, J.B.; da Silva, L.B.; Salomon, C.; Santana, W.; Shinohara, A. Detection and modelling of incipient failures in internal combustion engine driven generators using Electrical Signature Analysis. *Electr. Power Syst. Res.* **2017**, *149*, 30–45. [[CrossRef](#)]
5. Pang, L.; Yi, S.; Duan, L.; Li, W.; Yang, Y. Thermal stress and cyclic stress analysis of a vertical water-cooled wall at a utility boiler under flexible operation. *Energies* **2019**, *12*, 1170. [[CrossRef](#)]

6. Jaremkiewicz, M.; Taler, J. Online Determining Heat Transfer Coefficient for Monitoring Transient Thermal Stresses. *Energies* **2020**, *13*, 704. [[CrossRef](#)]
7. Brutsch, R.; Tari, M.; Frohlich, K.; Weiers, T.; Vogelsang, R. Insulation Failure Mechanisms of Power Generators. *IEEE Electr. Insul. Mag.* **2008**, *24*, 17–25. [[CrossRef](#)]
8. Lew, D.; Brinkman, G.; Kumar, N.; Besuner, P.; Agan, D.; Lefton, S. Impacts of wind and solar on emissions and wear and tear of fossil-fueled generators. In Proceedings of the 2012 IEEE Power and Energy Society General Meeting, San Diego, CA, USA, 22–26 July 2012; pp. 1–8. [[CrossRef](#)]
9. Ribeiro, L.; Bonaldi, E.; de Oliveira, L.; da Silva, L.B.; Salomon, C.; Santana, W.; da Silva, J.B.; Lambert-Torres, G. Equipment for Predictive Maintenance in Hydrogenerators. *AASRI Procedia* **2014**, *7*, 75–80. doi:10.1016/j.aasri.2014.05.032. [[CrossRef](#)]
10. Sant’Ana, W.C.; Lambert-Torres, G.; da Silva, L.E.B.; Bonaldi, E.L.; de Oliveira, L.E.D.L.; Salomon, C.P.; da Silva, J.G.B. Influence of rotor position on the repeatability of frequency response analysis measurements on rotating machines and a statistical approach for more meaningful diagnostics. *Electr. Power Syst. Res.* **2016**, *133*, 71–78. [[CrossRef](#)]
11. Salomon, C.P.; Ferreira, C.; Sant’Ana, W.C.; Lambert-Torres, G.; Borges da Silva, L.E.; Bonaldi, E.L.; de Oliveira, L.E.d.L.; Torres, B.S. A study of fault diagnosis based on electrical signature analysis for synchronous generators predictive maintenance in bulk electric systems. *Energies* **2019**, *12*, 1506. [[CrossRef](#)]
12. Audas, J. Requirement Analysis of a Signal Database for Power Plant Automation Signals. Master’s Thesis, University of Vaasa, Vaasa, Finland, 2014.
13. da Silva Ribeiro, P.F.; Nascimento, M.H.R.; Junior, J.d.A.B.; Leite, J.C.; de Freitas, C.A.O. Monitoring System of the Parameters of Operation of internal Combustion Engines in Thermoelectric Plants for Fault Detection. *Int. J. Adv. Eng. Res. Sci.* **2018**, *5*. [[CrossRef](#)]
14. Samtani, S.; Yu, S.; Zhu, H.; Patton, M.; Chen, H. Identifying SCADA vulnerabilities using passive and active vulnerability assessment techniques. In Proceedings of the 2016 IEEE Conference on Intelligence and Security Informatics (ISI), Tucson, AZ, USA, 28–30 September 2016; pp. 25–30. [[CrossRef](#)]
15. Mayadevi, N.; Vinodchandra, S.; Ushakumari, S. Failure forecast engine for power plant expert system shell. In Proceedings of the 2012 IEEE International Conference on Advanced Communication Control and Computing Technologies (ICACCCT), Ramanathapuram, India, 23–25 August 2012; pp. 380–384. [[CrossRef](#)]
16. Nevala, T. Upgrading the WOIS Used in the Gas Engine Test Run. Bachelor’s Thesis, University of Vaasa, Vaasa, Finland, 2018. (In Finnish)
17. Wärtsilä Corporation. *Wärtsilä Operator’s Interface System—WOIS User’s Manual*; Wärtsilä Corporation: Helsinki, Finland, 2008.
18. Maridis GmbH. *MarPrime Technical Data*; Maridis GmbH: Rostock, Germany, 2015.
19. Bonaldi, E.; Souza, S.; Lima, D.; Lacerda, J.; Silva, L.; Oliveira, L.; Assunção, F.; Santos, C.; Teixeira, C.; Campos, M.; et al. Monitoring System of Power Operation Condition of Internal Combustion Engines. In Proceedings of the 13th Latin-American Congress on Electricity Generation and Transmission—CLAGTEE 2019, Santiago de Chile, Chile, 20–23 October 2019. (In Portuguese)
20. Bonaldi, E.; Oliveira, L.; Lambert-Torres, G.; Borges da Silva, J.; Silva, L.; Ribeiro, M.; Venceslau, A. Sistema para Diagnóstico Termomecânico de Falhas em Motores de Combustão Interna. In Proceedings of the IX Congresso Brasileiro de Planejamento Energético, IX CBPE, Florianópolis, Brazil, 25–27 August 2014. (In Portuguese)
21. Noradino Montes Dorantes, P.; Pablo Nieto Gonzalez, J.; Maximiliano Mendez, G. Fault Detection Systems via a Novel hybrid Methodology for Fuzzy Logic Systems based on Individual base inference and Statistical Process Control. *IEEE Lat. Am. Trans.* **2014**, *12*, 706–712. (In Spanish) [[CrossRef](#)]
22. Montgomery, D.C.; Runger, G.C. *Applied Statistics and Probability for Engineers*, 5th ed.; John Wiley & Sons, Inc.: Hoboken, NJ, USA, 2011.
23. Lampreia, S.; Requeijo, J.; Lobo, V. Diesel engine vibration monitoring based on a statistical model. *MATEC Web Conf. EDP Sci.* **2018**, *211*, 03007. [[CrossRef](#)]
24. Griffiths, D.; Bunder, M.; Gulati, C.; Onizawa, T. The probability of an out of control signal from Nelson’s supplementary Zig-Zag test. *J. Stat. Theory Pract.* **2010**, *4*, 609–615. [[CrossRef](#)]
25. Wärtsilä Corporation. *Coding of processes in Power Plants*; Wärtsilä Corporation: Helsinki, Finland, 2003.
26. Oliveira, C.C.d.; Granato, D.; Caruso, M.S.F.; Sakuma, A.M. *Manual para elaboracao de cartas de controle para monitoramento de processos de medicao quantitativos em laboratorios de ensaio*; Instituto Adolfo Lutz: São Paulo, Brazil, 2013; p. 18. (In Portuguese)
27. Montgomery, D.C. *Introduction to Statistical Quality Control*, 3rd ed.; Wiley: Hoboken, NJ, USA, 1996.

## **Model proposal for failure detection and classification of internal combustion engine operating condition**

**Fernanda Mitchelly Vilas Boas, Frederico Oliveira Assunção, Luiz Eduardo Borges da Silva, Erik Leandro Bonaldi, Levy de Lacerda de Oliveira, Germano Lambert-Torres, Claudio Inacio de Almeida Costa, Helcio Francisco Villanova, Sandro Fernandes de Souza, Danilo de Souza Lima, Josué da Costa Lacerda, and Bruno Renó Gama**

**Abstract** Internal combustion engines are intermittently operating in Thermolectric Power Plants (TPP) and consequently suffer a lot of detriktion. Due to this, these engines are subject to ostentatious controls of temperatures, pressures and physical properties of the working fluids at critical points on the machine to monitor the behavior and abnormal events of this machine. However, often these controls only indicate abnormalities after a failure, not providing an early study of the operational state of the engine. A trend analysis of failures in auxiliary systems of the internal combustion engine, based on the matrix structure, is proposed in this article in order to verify the operational conditions of the auxiliary engine lubrication system and the influence that this system is producing on electrical generation based on operating data from the lubrication system of an internal combustion engine model similar to a Wärtsilä 18V46-C2. The proposed math model is validated through comparison with the standard behavior of the internal combustion engine lubrication system. It is demonstrated that the results obtained with the proposed methodology correspond to the high compatibility of the simulated results with the real data of failure of the lubrication system of the analyzed engine model, which makes this math model a favorable mechanism to direct predictive maintenance and, consequently, reduce operating costs of electricity generation.

### **1 Introduction**

The current stage of thermal machines, combined with the high demand of running for long periods of time and the need to guarantee an immediate supply of electricity, culminated in the development of techniques for the control and predictive detection of failures in the internal combustion engine.

Several failure detection approaches that efficiently use the resources of the internal combustion engine have already been proposed in the scientific literature. For example, in [1] it is proposed a system capable of monitoring the operating conditions of the engine and detecting, in advance, engine failures through convolutional

---

F. M. V. Boas (✉), F. O. Assunção, L. E. B. Silva, E. L. Bonaldi, L. L. Oliveira, G. L. Torres, C. I. d. A. Costa, H. F. V-Nova, S. F. Souza, D. S. Lima, J. C. Lacerda, B. R. Gama  
1303 BPS Ave, Itajubá, MG 37500903, Brazil  
e-mail: fernandamitchellyvb@hotmail.com

neural networks of one dimension (CNNs). In [2] a methodology is presented for the development of equipment capable of identifying and detecting early failures in an internal combustion engine, by means of current and voltage signals collected by measures external to the motor-generator group. In [3], the authors propose the development of a predictor system capable of performing the thermomechanical detection of failures in an internal combustion engine applying the electrical signature analysis of the generator's electrical signals. Already in [4] is presented the theoretical foundations for the development of a system capable of monitoring and diagnosing impending failures in marine engines in an on-line manner. In [5] the authors propose that inspection and fault detection in diesel engines be based on their operational conditions. In this proposal, the diagnostics rules are organized through the technique of failure modes and effects analysis (Failure Modes and Effects Analysis - FMEA) and of the distribution of failures. The operational parameters are established using a standard recognition technique, that is, compared a measured vector with a predefined fault vector and a standard diagnosis is arrived at. Already the fault matrix is formed by the junction of the measured vector with the predefined fault vector. In [6] a comparative bibliographic review of the diagnostics system that is based on the operational condition of diesel engines is presented. In it, the direction is given in the presentation of bibliographic sources of systems that detect flaws through knowledge and monitoring of the vibration signals. Already in [7] a system capable of organizing the fault diagnosis rules in the diesel engines through the fault tree analysis technique (Fault Tree Analysis - FTA) is proposed. As previously described, there are many references on failure detection using various techniques and models applied to both internal combustion engine and other types of engines. However, the method proposed in this work, in addition to presenting an innovative character, since, in the literature, no investigation uses auxiliary systems to detect failures in internal combustion engines, it also presents several advantages in its use. These advantages are based, especially, on the possibility of a complete analysis of the machine, involving all its subsystems, and what impact these subsystems are having on the efficiency of the engine as a whole. In addition, the variables used to carry out this analysis are, in their majority, variables already measured in a standard way in industrial machines, reducing invasive operations and programmed stops in the device under analysis for the insertion of measurement sensors. Therefore, the main objective of this work is to analyze the database of an internal combustion engine lubrication system similar to a Wärtsilä 18V46-C2 of a thermoelectric plant and, to determine if this lubrication system is more prone to failures, when compared to a standard behavior of the lubrication system of the analyzed engine model.

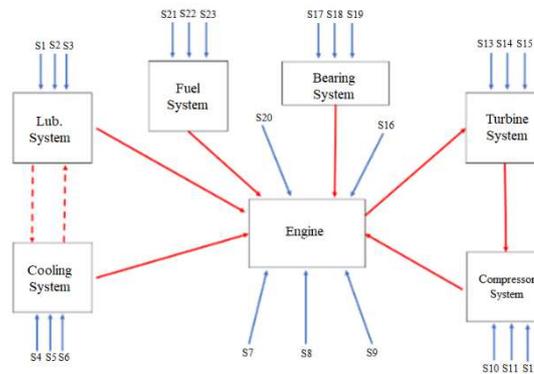
To fulfill the purposes of this work, the rest of it is organized as follows: Section 2 presents the development of the proposed system model, together with a more indepth analysis about the lubrication model. Section 3 presents the numerical results of the failures trend of the lubrication system when compared to the standard behavior of the lubrication system of the analyzed engine model. Finally, section 4 presents the main conclusions of the work and some opportunities for future research.

## 2 System Model

This section will present the stages of a system model development that uses the lubrication system data provided by an internal combustion engine, similar to a Wärtsilä 18V46-C2, already existing in the thermal power plant.

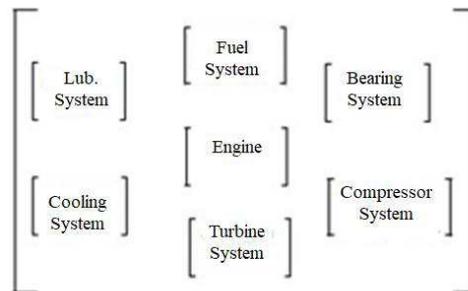
In order to carry out the development of this system, it is initially assumed that the internal combustion engine analyzed be divided into six auxiliary systems, such as, lubrication, cooling, fuel, turbine, compressor and bearing, as shown in Fig. 1. It is worth mentioning that S1, S2, ..., SN are just representations of the auxiliary system input variables.

**Fig. 1.** Engine division into six auxiliary systems.



Then, a matrix structure is established for this engine division, that is, a submatrix is created for the analyzed engine, a submatrix for each auxiliary system of the same and a matrix that encompasses this entire division, according to Fig. 2.

**Fig. 2.** Matrix structure for the system model.



Finally, for each auxiliary system of the analyzed engine, the submatrix containing the fundamental variables to characterize them is elaborated and, for the central system, the submatrix is formed by the powers and efficiencies involved in electrical generation.

4

According to the proposal of this work, special attention is given to the auxiliary lubrication system of the analyzed engine. Therefore, the following subsection will cover in more detail the modeling of this auxiliary system.

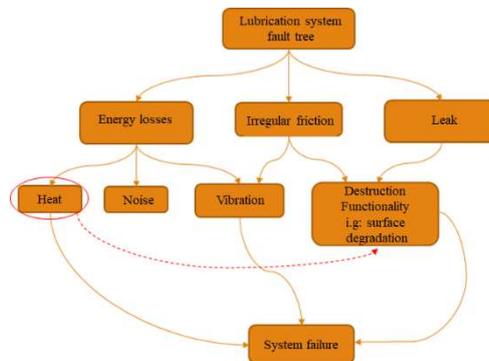
### 2.1 Lubrication system model

The lubrication system is one of the auxiliary systems of the internal combustion engine analyzed and the main focus of this work. Fundamentally, as its name suggests, this system is lubricating the moving parts of the internal combustion engine so that metallic friction does not occur and, consequently, wear of the parts and the increase in engine temperature [8].

The lubrication system consists of crankcase, oil pump and main oil gallery. In this system, the lubricating oil is reserved in the crankcase and, only starts to circulate through the engine, when the fisherman, who is inside the crankcase, sucks and pumps this oil into the main oil gallery of the internal combustion engine. After that, this oil is sent to the filters in the engine and, then directed towards the crankshafts, the bearings, the cylinders, the rings, the heads, the tappets and the rockers [8]. Finally, when the lubricant reaches the moving parts of the engine, it returns to the crankcase through gravity, restarting the cycle. These described processes are repeated as long as the engine is running and generating energy.

The performance of the lubrication system can be affected due to several factors, such as, energy losses, irregular friction, leakage, among other factors, as shown in the fault tree of the lubrication system in Fig. 3.

**Fig. 3.** Lubrication system fault tree.



One way to soften the effect of these factors is to use the lubrication system model proposed in this work and which will be described below.

In the model of the proposed lubrication system, the variables that characterize it are the magnitudes of the lubricating oil inlet and outlet temperature ( $T_{oi}$ ,  $T_{oo}$ ), the variation between the oil inlet and outlet pressures ( $\Delta P$ ), the inlet viscosities and

5

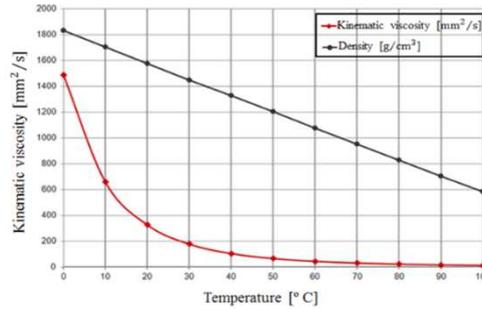
outlet ( $\mu_{oi}$ ,  $\mu_{oo}$ ) and the respective variation of lubricating oil flow rates ( $\Phi$ ), as shown in Fig. 4. It is worth noting that the positions of the matrix that assume zero values can be replaced by some other variable that is fundamental for this system.

**Fig. 4.** Lubrication system submatrix.

$$\begin{bmatrix} T_{oi} & \mu_{oo} & \Phi \\ \mu_{oi} & T_{oo} & 0 \\ 0 & 0 & \Delta P \end{bmatrix}$$

In Fig. 5, it is presented the characteristic viscosity curve, the red curve is used to calculate the oil viscosity. For the lubricating oil flow, it is adopted the value of 1.

**Fig. 5.** Characteristic curve of viscosity as a function of temperature.



Note that it is through the resulting math model that it is possible to determine whether the auxiliary lubrication system is having a greater influence on electrical generation. Using the math model, it is also possible to identify failure tendency through comparison with standard behaviours of lubrication system. In addition, the accumulated time of the malfunction of the respective auxiliary system can also be surveyed, even if the internal combustion engine operation is intermittent and still provides a direction for predictive maintenance and, consequently, a reduction in the electric generation operating costs.

### 3 Experimental Results

The numerical results presented in this section were made by means of computer simulation. In these numerical results, the percentage of right matrices, the percentage of wrong matrices and the total percentage of matrices analyzed are identified, respectively by, right matrices, wrong matrices and total matrices.

The bar graphs were obtained by the simulation of various measures of the lubrication system of the analyzed engine, each related to the generation of a matrix

containing the variables, which characterize this system, imported from the databases provided by the thermoelectric power plant. After importing the data, referring to the variables that make up the matrices of this system, it is calculated, based on the characteristic curve of Fig. 5 and, added to these matrices an input and output viscosity vector. Then, the times when all these variables act together are checked. A with load / without load classification is defined by the system condition to simulate the values of the variables that correspond to the motor's active power greater than zero (with load) and the values of the variables that correspond to the motor's active power equal to zero (without load).

At this moment of the simulation, the first condition of the lubrication system is generated, the outlet temperatures with or without load must be higher than the temperatures of inlets with or without load. Consequently, for true condition the measurement matrices with or without load are then generated. From the measurement matrices with or without load, the standard average matrix structure of the data with or without load is created.

After generating the standard matrix with load or without load, a second condition is imposed on the system model, that is, the input power of the without load lubricating oil and the output power of the without load lubricating oil must be greater than zero. If this condition is true, a variation of two standard deviations is adopted, that corresponds to approximately 95% of the analysis of the data provided and the new standard matrix of the lubrication system of the internal combustion engine analyzed with load is created. Otherwise, the system will not operate without a load. It is worth mentioning that, from this point on, only the cases with load will be considered in the development of the system model.

With the measurement matrix with load and of the new standard matrix with load, the comparison of each measures matrix with the standard matrix is performed. The system model should decide by right matrices whenever the variables that make up the matrix of measures with load are within the ranges of the variables that make up the new standard matrix and should decide on the wrong matrices otherwise. The total number of matrices is calculated by adding the number of right matrices with load and the number of wrong matrices without load. Finally, the months are varied for May (a), June (b), July (c) and August (d), repeating the process to generate the bar graphs of the quantities of the right, wrong and total matrices with charge.

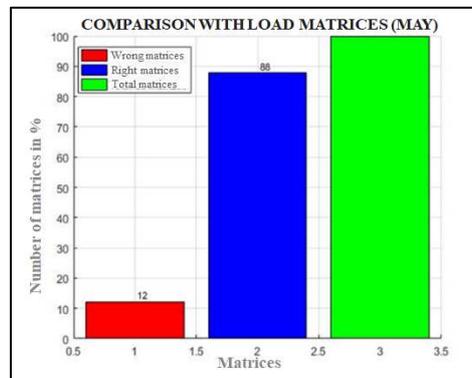
In terms of parameters used in the simulations, the data provided by the plant were considered for the variables monitored and measured at the plant. Already for non-measured variables, such as lubricating oil outlet pressure and variation of lubricating oil flow rates the value of 0 Pa and 1, respectively, is adopted. The lubricating oil inlet and outlet viscosity is calculated from the lubricating oil inlet and outlet temperatures using the characteristic red curve of Fig. 5. For the simulations of the bar graphs of the comparison of matrices with load the months were adopted May (a), June (b), July (c) and August (d).

7

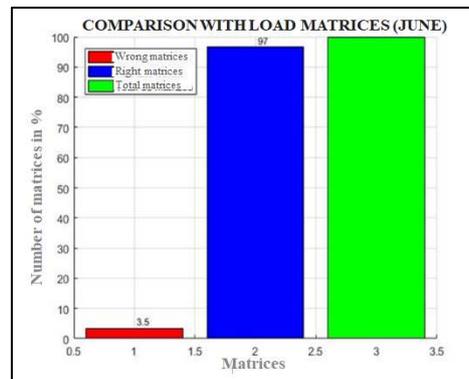
In Fig. 6 are presented some bar graphs that show the quantities of right, wrong and total matrices in %, for the months of May (a), June (b), July (c) and August (d).

It can be seen in Fig. 6, that the lubrication system of the analyzed engine did not suffer stress in the months of May (a), June (b) and July (c). And as these three months pass, the performance of this engine tends to improve even more. It is also noted that the month of June (b) is the one with the best performance, since it has the highest percentage of right matrices. In addition, it is also noted that the number of right matrices from June (b) to July (c) falls, but in a very small percentage. Finally, it is also noted that, in August (d), the performance of the engine analyzed is reversed, which means that the lubrication system underwent a maximum stress level, leading to the machine stopping.

**Fig. 6.** Charts of quantities of matrices with load (%) for the month of May (a), June (b).



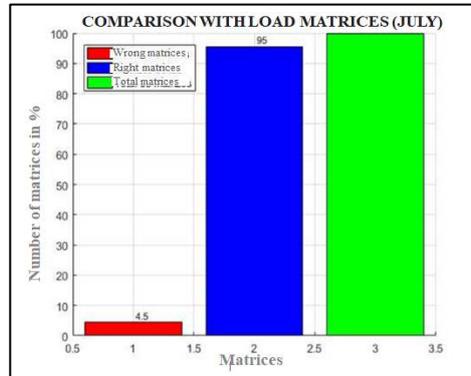
(a)



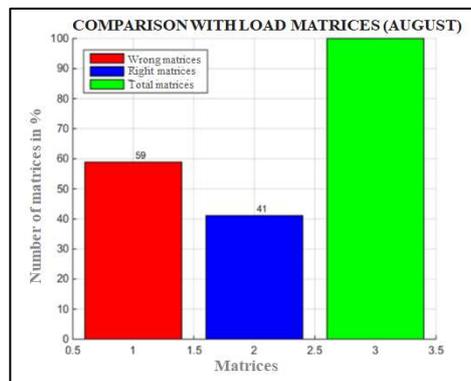
(b)

8

**Fig. 6.** Charts of quantities of matrices with load (%) for the month of July (c) and August (d).



(c)



(d)

## 4 Conclusion

This article presented the stages of a system model development and analyzed the failure trend of the internal combustion engine lubrication system similar to a Wärtsilä 18V46-C2, based on the data of this system, supplied by the thermal power plant. The proposed model proved to be innovative, since, although there are several works in the literature that perform the detection of failures in internal combustion engines, no work performed this detection based on the auxiliary systems of these engines. Thus, as mentioned before, the math model proposed here is innovator and validated by comparing the behavior of the measurement matrices of the lubrication system found in the simulations with the standard behavior of the lubrication system of the internal combustion engine. In addition to being innovative, this model is flexible, allowing to include in the matrix of the lubrication system any other fundamental variable to such system, and comprehensive, being able to be applied to

any thermoelectric with internal combustion engines. Already the analysis carried out revealed that the analyzed machine did not suffer stress in the months of May, June and July, which are shown with a higher percentage of right matrices. It was also possible to conclude that the month of June is the one that achieves the best performance, since it has the highest percentage of right matrices. Finally, there was a tendency to failure of the lubrication system of the analyzed engine, according to the inversion of the derivative of quantities from correct matrices to wrong matrices in month August, concluding, therefore, that this month there really was machine stop. These bar graph analyzes are of paramount importance as they will help both the TPP maintenance department and the engine operators to carry out predictive maintenance and, consequently, reduce operating costs of electrical generation.

As future research opportunities related to the theme of this article, mention: i) the failure trend analysis of the other internal combustion engine subsystems. ii) the adoption of a comparative scenario in which one engine had no accident and the other had.

## Acknowledgments

The authors would like to thank Usina Termelétrica Rio Amazonas Energia S.A. - RAESA and the National Agency for Research and Development (ANEEL P&D) for supporting this project.

## References

- [1] Ince T, Kiranyaz S, Eren L, Askar M, Gabbouj M (2016) Real-time motor fault detection by 1-D convolutional neural networks. *IEEE Transactions on Industrial Electronics* 63(11):7067-7075.
- [2] Bonaldi EL, Oliveira, LL, Lambert-Torres G, Silva JGB, Silva LEB, Ribeiro M, Venceslau A (2014) Sistema para Diagnóstico Termomecânico de Falhas em Motores de Combustão Interna 10.13140/RG.2.1.4713.0642.
- [3] Mendonça P, Bonaldi EL, Oliveira LL, Lambert-Torres G, Silva JGB, Silva LEB, Salomon CP, Sant'Ana WC (2015) Desenvolvimento de Sistema Preditivo para Diagnóstico Termomecânico de Falhas em Motores de Combustão Interna 10.13140/RG.2.1.1043.0487.
- [4] Maffei ACL (2007). *Monitoração e Diagnóstico de Motores de Propulsão Marítima* (Doctoral dissertation, Dissertação).
- [5] Fagerland H, Rothaug K, Tokle, P (1978) Monitoring and diagnosing process deviations in marine diesel engines. *Ship Research Institute of Norway* 90:321-340

10

- [6] Elliott C, BanisoleimanvK (1990) Advanced Health Monitoring Systems for Marine Medium Speed Diesel Engines - A Naval and Merchant View. ICMS 90 – Maritime Systems Integrity paper 1, 3-17
- [7] Perakis, AN, Inozu B (1990) Reliability analysis of great lakes marine diesels: state of the art and current modeling. Marine Technology and SNAME News 27(04):237-249.
- [8] Tillmann, CADC (2013) Motores de combustão interna e seus sistemas. Instituto Federal de Educação, Ciência e Tecnologia, 9-25.