



LUCAS ALVES DIAS OLIVEIRA

**DESENVOLVIMENTO DE CLASSIFICADORES *FUZZY*
DEDICADOS À MANUTENÇÃO DE LOCOMOTIVAS,
BASEADO NAS TÉCNICAS DE MANUTENÇÃO CENTRADA
NA CONFIABILIDADE**

**LAVRAS – MG
2020**

LUCAS ALVES DIAS OLIVEIRA

**DESENVOLVIMENTO DE CLASSIFICADORES *FUZZY* DEDICADOS À
MANUTENÇÃO DE LOCOMOTIVAS, BASEADO NAS TÉCNICAS DE
MANUTENÇÃO CENTRADA NA CONFIABILIDADE**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e automação, para a obtenção do título de Mestre.

Prof. Dra. Sílvia Costa Ferreira

Orientadora

Prof. Dr. Daniel Furtado Leite

Coorientador

**LAVRAS - MG
2020**

Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).

Oliveira, Lucas Alves Dias.

Desenvolvimento de classificadores *fuzzy* dedicados à
manutenção de locomotivas, baseado nas técnicas de Manutenção
Centrada na Confiabilidade / Lucas Alves Dias Oliveira. - 2020.
123 p. : il.

Orientador(a): Sílvia Costa Ferreira.

Coorientador(a): Daniel Furtado Leite.

Dissertação (mestrado acadêmico) - Universidade Federal de
Lavras, 2020.

Bibliografia.

1. Manutenção Centrada na Confiabilidade. 2. Classificadores
fuzzy C-means. 3. Classificação de falhas. I. Ferreira, Sílvia Costa.
II. Leite, Daniel Furtado. III. Título.

LUCAS ALVES DIAS OLIVEIRA

**DESENVOLVIMENTO DE CLASSIFICADORES *FUZZY* DEDICADOS À
MANUTENÇÃO DE LOCOMOTIVAS, BASEADO NAS TÉCNICAS DE
MANUTENÇÃO CENTRADA NA CONFIABILIDADE**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e automação, para a obtenção do título de Mestre.

APROVADO em: 20 DE FEVEREIRO DE 2020.

Dra. Sílvia Costa Ferreira	UFLA
Dr. Wilian Soares Lacerda	UFLA
Dra. Thais Martins Mendes	UFJF

**LAVRAS - MG
2020**

AGRADECIMENTOS

Durante os dois anos de mestrado contei com o auxílio técnico e apoio moral de várias pessoas que foram fundamentais para que este trabalho se concretizasse. Assim, deixo os meus mais sinceros agradecimentos àqueles que contribuíram mesmo que indiretamente para o desenvolvimento deste estudo.

Agradeço primeiramente minha orientadora Sílvia, pela enorme dedicação e paciência oferecida. Um exemplo de profissionalismo no âmbito acadêmico.

Ao meu coorientador Daniel, pelo auxílio técnico e direcionamento para fundamentação de ideias até então um pouco abstratas.

À minha noiva Carolina, por todas as palavras de incentivo e otimismo. Por sempre me fazer acreditar que certos objetivos são factíveis de serem atingidos.

Aos meus familiares e amigos pelo apoio moral e palavras de conforto nos momentos de cansaço e estresse.

E por fim, ao Programa de Pós-Graduação em Engenharia de Sistemas e Automação da UFLA, pela oportunidade concebida de desenvolver este trabalho acadêmico.

RESUMO

A manutenção, em sua nova era, está pautada na inclusão de novas estratégias, que visam avaliar com precisão os parâmetros vitais de certos equipamentos, possibilitando intervenções dedicadas de modo a otimizar seus índices de confiabilidade. Destacam-se as metodologias atribuídas ao auxílio de tomadas de decisões, visando a otimização de recursos em função da confiabilidade exigida a cada processo produtivo, como a manutenção centrada na confiabilidade (RCM), a análise de causa e efeito (FMEA) e a análise de causa raiz (RCA). Pretendeu-se por meio deste estudo, unificar em uma só estrutura os conceitos do RCA, FMEA e RCM, de modo a estabelecer critérios para o desenvolvimento de um algoritmo inteligente, dedicado à detecção de certos modos de falha instaurados em um grupo de equipamentos. Para tal, utilizou-se de duas etapas. A primeira, consistiu da seleção das perturbações mais representativas e de passível ocorrência em um grupo composto de 47 locomotivas diesel-elétricas, fundamentando-se nas metodologias de FMEA e RCA. Ao todo, foram identificados 32 modos de falha, e por meio de um processo de seleção, baseando-se no método RCM, foram designadas quatro para o desenvolvimento de um sistema inteligente dedicado à detecção destes. A segunda etapa, consistiu da elaboração de um classificador embasado nas técnicas de clusterização *fuzzy C-means*, destinado a detectar e classificar estas ocorrências. O desenvolvimento do algoritmo se baseou em seis estágios: aquisição de dados, pré-processamento de dados, extração de características, treinamento, validação, teste e classificação. A aquisição dos dados foi realizada por meio de equipamentos embarcados instalados ao grupo de análise, designados a coletar 26 diferentes parâmetros operacionais. O pré-processamento foi responsável em reduzir a dimensionalidade da base de dados via seleção de parâmetros úteis. A extração de características foi utilizada para se definir características relevantes à representatividade de cada modo de falha. A etapa de treinamento e validação, foi aplicada para criação de um modelo que melhor representou as informações de estudo. E a etapa de testes, consistiu em testar a eficiência dos agrupamentos após a classificação dos modos de falha por meio de rótulos e limiares outorgado aos mesmos. O algoritmo obteve êxito para classificação dos 4 modos de falha selecionados, apresentando um nível de acurácia de 97,9%. Conclui-se que utilização de tais metodologias, de modo a estabelecer critérios para o desenvolvimento do algoritmo, propiciou ao projeto certa fundamentação lógica, convertendo a grande quantidade de informações providas do meio produtivo, muitas das vezes imprecisas se analisadas isoladamente, em fundamentos determinantes para sua construção.

Palavras-chave: RCA. RCM. *Fuzzy C-means*. Locomotivas Diesel-elétricas. Manutenção.

ABSTRACT

Maintenance, in its new era, is based on the inclusion of new strategies, which aim to accurately assess the vital parameters of certain equipment, enabling dedicated interventions in order to optimize their reliability indexes. We highlight the methodologies attributed to the aid of decision making, aiming at the optimization of resources according to the reliability required for each production process, such as maintenance centered on reliability (RCM), cause and effect analysis (FMEA) and analysis root cause (RCA). The aim of this study was to unify the concepts of RCA, FMEA and RCM in a single structure, in order to establish criteria for the development of an intelligent algorithm, dedicated to the detection of certain failure modes installed in a group of equipment. For this, two stages were used. The first consisted of selecting the most representative and likely occurring disturbances in a group composed of 47 diesel-electric locomotives, based on FMEA and RCA methodologies. In all, 32 failure modes were identified, and through a selection process, based on the RCM method, four were designated for the development of an intelligent system dedicated to their detection. The second step, consisted of the elaboration of a classifier based on the fuzzy C-means clustering techniques, aimed at detecting and classifying these occurrences. The development of the algorithm was based on six stages: data acquisition, data pre-processing, feature extraction, training, validation, testing and classification. Data acquisition was performed using embedded equipment installed in the analysis group, designed to collect 26 different operational parameters. Pre-processing was responsible for reducing the dimensionality of the database via the selection of useful parameters. Characteristic extraction was used to define characteristics relevant to the representativeness of each failure mode. The training and validation stage was applied to create a model that best represents the study information. And the testing step, consisted of testing the efficiency of the clusters for a later classification of the failure modes by means of labels and thresholds granted to them. The algorithm was successful for classification in 3 of the 4 failure modes selected, presenting an accuracy level of 92%. The use of such methodologies, in order to establish criteria for the development of the algorithm, provided the project with a certain logical basis, converting the large amount of information provided by the productive environment, often inaccurate if analyzed in isolation, in determining fundamentals for its construction. It is concluded that maintenance methodologies have high functionality, when attributed to the development of algorithms dedicated to equipment reliability.

Keywords: RCA. RCM. *Fuzzy C-means*. Diesel-electric locomotives. Maintenance.

LISTA DE FIGURAS

Figura 1 - Diagrama de bloco sistema de transmissão diesel-elétrico	17
Figura 2 - Locomotiva diesel-elétrica arquitetura AC-DC	19
Figura 3 - Locomotiva diesel-elétrica em corte e seus principais componentes	20
Figura 4 - Expectativa da manutenção ao longo das décadas	23
Figura 5 - Evolução das técnicas de manutenção ao longo das décadas	24
Figura 6 - Curva da banheira tradicional	30
Figura 7 - Padrões de falha RCM	30
Figura 8 - Função de pertinência linear tipo triangular e trapezoidal	43
Figura 9 - Função de pertinência linear tipo Gaussiana	43
Figura 10 - Variável linguística “estatura” e suas funções de pertinência	44
Figura 11 - Fluxograma primeira etapa do trabalho	51
Figura 12 - Fluxograma pré-processamento dos dados extração das características	61
Figura 13 - Relação de atributos extraídos para entrada no classificador fuzzy	63
Figura 14 - Fluxograma etapas de treinamento e validação do algoritmo	64
Figura 15 - Representação estágio pré-processamento do MF1 e M2	67
Figura 16 - Representação do estágio pré-processamentodas do MF3	69
Figura 17 - Representação do estágio pré-processamento do MF4	71
Figura 18 - Índices Xie-Beni e PC relativos aos 24 modelos de agrupamentos gerados	72
Figura 19 - Modelo de agrupamento 16 clusters gerado para o MF1 e MF2	74
Figura 20 - Modelo de agrupamento 16 clusters gerado para o MF3	75
Figura 21 - Modelo de agrupamento 16 clusters gerado para o MF4	76
Figura 22 - Processo de rotulação e classificação do MF1 e MF2	77
Figura 23 - Processo de rotulação e classificação do MF3	78
Figura 24 - Processo de rotulação e classificação do MF4	79
Figura 25 - Matriz de confusão	80
Figura 26 - Motor a combustão modelo 645E3B	90
Figura 27 - Relação ângulo do eixo virabrequim versus ciclo de um motor quatro tempos ...	91
Figura 28 - Ciclo de um motor quatro tempos	92
Figura 29 - Relação ângulo do eixo virabrequim versus ciclo de um motor dois tempos	92
Figura 30 - Sequência de operação de um motor dois tempos	92
Figura 31 - Sistema de admissão de ar locomotiva diesel-elétrica	93
Figura 32 - Sistema de arrefecimento de uma locomotiva diesel-elétrica	94

Figura 33 - Sistema de combustível de uma locomotiva diesel-elétrica	95
Figura 34 - Sistema de lubrificação de uma locomotiva diesel-elétrica	96
Figura 35 - Sistema de controle motor diesel de uma locomotiva diesel-elétrica AC-DC	97
Figura 36 - Sistema de controle gerador de tração locomotiva diesel-elétrica AC-DC	97
Figura 37 - Esquema simplificado sistema de propulsão locomotivas AC-DC	99
Figura 38 - Circuito frenagem dinâmica locomotiva diesel-elétrica AC-DC	100
Figura 39 - Sistema freio pneumático de uma locomotiva	101
Figure 40 - Truque B	104
Figure 41 - Truque C	104
Figure 42 - Truque D rígido	104
Figure 43 - Truque articulado (B - B)	104

LISTA DE QUADROS E TABELAS

Quadro 1 - Análise das ocorrências das falhas e suas respectivas classificações	53
Quadro 2 - Classificações dos modos de falha por intermédio das técnicas de RCM	55
Quadro 3 - Variáveis monitoradas pelo sistema embarcado das locomotivas	57
Quadro 4 - Variáveis de monitoramento dos modos de falha selecionados	60
Tabela 1 - Distribuição dos dados base de treinamento, validação e teste	64

APÊNDICE B:

Quadro 5 - Classificações classe de falha para sintoma padronizado	105
Quadro 6 - Classificações classe de falha para sistema	105
Quadro 7 - Classificações classe de falha para conjunto	105
Quadro 8 - Classificações classe de falha para item	106

APÊNDICE C:

Quadro 9 - Classificação das causas técnicas das falhas baseado na metodologia RCA	107
--	-----

APÊNDICE D

Quadro 10 - Classificação dos modos de falha pelo método RCM	116
--	-----

LISTA DE ABREVIATURAS E SIGLAS

AAR - *Association of American Railroads*
ABNT - Associação Brasileira de Normas Técnicas
AC - *Alternating current*
AM - Aprendizado de máquinas
BKG – *Brake grid*
CC – Corrente contínua
CEF - Causa e efeito
DC - *Direct current*
DFMEA - *Design Failure Mode and Effects Analysis*
EMD - Electro-Motive diesel
EMF - Efeito do modo de falha
FAA - *Federal Aviation Administration*
FCM - *fuzzy C-Means*
FMEA - *Failure Modes and Effects Analysis*
FP - Fator de predição
FPRIO - Fator de priorização
GA - Gerador auxiliar
GG - *Gath-Geva*
GK - *Gustafson-Kessel*
GPRS - *General Packet Radio Services*
HP- *Horse-power*
IS - Índice de severidade
ID - Índice dunn
IJ - Índice jaccard
IM - Índices de informação mútua
IR - Índice rand
IRA - Índice rand ajustado
LS - Índice largura de silhueta
MC - Manutenção corretiva
MD - Motor diesel
MFA - Manipulador de freio automático
MP - Manutenção preventiva

MPC - Microprocessada

MSG - *Maintenance Steering Group*

MT - Motor de tração

NA- Não se aplica

NACO - Nada constatado

OC - Ocorrência

PFMEA - *Process Failure Modes and Effects Analysis*

RCA - *Root Cause Analysis*

RCM - *Reliability Centered Maintenance*

RP - Reservatório principal

RPM - Rotações por minutos

S - Severidade

TO - Taxa de ocorrência

TPM - *Total Productive Maintenance*

VM - Parâmetros passíveis de monitoramento

SUMÁRIO

1	INTRODUÇÃO	14
2	LOCOMOTIVAS E MANUTENÇÃO.....	16
2.1	Sistemas diesel-elétricos	16
2.2	Uma visão geral sobre locomotivas.....	17
2.3	Locomotivas de transmissão diesel-elétricas e seus principais sistemas.....	19
2.4	Fundamentos da manutenção	21
2.5	Evolução histórica da manutenção	22
2.6	Análise de Modo e Efeito de Falha (FMEA)	24
2.7	Análise de Causa Raiz (RCA)	26
2.7.1	Análise de falhas.....	27
2.8	Manutenção centrada na confiabilidade (RCM).....	28
2.9	Diagnóstico de Falhas.....	33
3	SISTEMAS INTELIGENTES	34
3.2	Clusterização	37
3.2.1	Medidas de similaridade.....	38
3.2.2	Métodos de clusterização	39
4	FUNDAMENTOS DA LÓGICA <i>FUZZY</i>	41
4.1	Conjuntos <i>fuzzy</i>	42
4.2	Clusterização <i>fuzzy</i>	44
4.3	Algoritmos de clusterização <i>fuzzy</i>	45
4.3.1	Clusterização <i>Fuzzy C-Means</i>	46
4.4	Índices de Validação	47
4.4.1	Índice de validação externo	48
4.4.2	Índice de validação relativo.....	48
4.4.3	Índice de validação interno.....	48
4.4.4	Critério de Xie-Beni	49
4.4.5	Coeficiente de Partição (PC)	50
5	MATERIAIS E MÉTODOS.....	51
5.1	Análise de uma base histórica de ocorrências de falha em um grupo de locomotivas ...	52
5.2	Priorização dos modos de falha utilizando a metodologia RCM.....	53
5.3	Aquisição de dados e definição das variáveis de monitoramento.....	56
5.4	Pré-processamento e extração de características	60
5.5.1	Separação da base de dados.....	64

5.5.2 Treinamento e validação do algoritmo	65
5.5.3 Teste e classificação	65
6 RESULTADOS E DISCUSSÕES	67
6.1 Resultados do pré-processamento e extração de características	67
6.2 Resultados do processo de treinamento e validação do classificador.....	72
6.3 Resultados do processo de classificação.....	76
7 CONSIDERAÇÕES FINAIS	82
REFERÊNCIAS	83
APÊNDICE A – Locomotivas diesel-elétricas e seus sistemas.....	89
APÊNDICE B – Classificações utilizadas para definição dos modos de falha	105
APÊNDICE C – Classificação das causas técnicas das falhas (RCA)	107
APÊNDICE D – Classificação dos modos de falha (RCM)	116
APÊNDICE E – Linguagem algoritmo classificador	119

1 INTRODUÇÃO

Grandes exigências por otimização de resultados vêm compelindo empresas das mais variadas especialidades a investirem em quesitos estratégicos, até pouco tempo negligenciados, como por exemplo, a engenharia da confiabilidade. Paradas na produção podem acarretar em prejuízos incalculáveis se não administradas de forma planejada. Encontrar o equilíbrio entre eficiência, custo, disponibilidade, confiabilidade e conservação de ativos tem sido o foco destas organizações. Em um setor de transporte e logística por exemplo, a carga do grau de complexidade da gestão dos bens de produção, certos fatores tornaram-se primordiais para que empresas se tornem rentáveis, como: eficiência energética, aderência ao tempo de transporte planejado, custos destinados à operação, manutenção e conservação dos meios de produção, disponibilidade, confiabilidade e segurança operacional. Dentre os fatores mencionados, pode-se dizer que a estratégia de manutenção impacta significativamente em todos eles. Excessos elevariam os custos e o tempo de indisponibilidade dos ativos, já a falta acarretaria em baixa confiabilidade comprometendo a aderência de transporte, eficiência energética e segurança operacional. Os modelos de manutenção aplicados devem ser explorados e otimizados em acordo com as necessidades específicas de cada processo.

Diante de tais expectativas, amplia-se a empregabilidade de metodologias dedicadas a otimização das estratégias de manutenção, ao mesmo tempo em que são atribuídos aos *softwares* de computadores encargos de cunhos decisivos. Os computadores passaram a desempenhar um papel de suma importância no auxílio às tomadas de decisão estratégicas, assim como as metodologias de manutenção, que passaram a ser empregadas de forma a instituir diretrizes para as engenharias de confiabilidade. A partir da identificação de certos padrões, tornou-se possível prever, por exemplo, se um equipamento da linha de produção está prestes a falhar, bastando para isto a execução de um algoritmo dedicado. Porém, apesar da existência de tantas tecnologias vigentes, ainda se nota um baixo aproveitamento no processamento das informações disponibilizadas pelas linhas de produção como base para tomadas de decisão. Na revisão literária, encontra-se muitos estudos referentes ao desenvolvimento de algoritmos dedicados à confiabilidade de ativos, porém, há escassas abordagens a respeito das diretrizes destinadas à aceção de critérios para sua elaboração.

Das metodologias de manutenção existentes, destaca-se o RCM (*Reliability Centered Maintenance*) ou “manutenção centrada na confiabilidade”, consistindo basicamente em uma política de manutenção estruturada para analisar e compreender as atividades necessárias de

modo a manter uma confiabilidade desejada a qualquer meio produtivo, idealizando a redução máxima do custo financeiro para todo o ciclo de vida do ativo.

Dos algoritmos inteligentes aplicados à manutenção de ativos, a lógica *fuzzy* alcançou grande empregabilidade, por se tratar de uma ferramenta capaz de coletar informações descritas em linguagem natural, geralmente vagas, e convertê-las em formato numérico de fácil manipulação por computadores.

Pretendeu-se por meio deste estudo, unificar em uma só estrutura os conceitos fundamentais da metodologia do RCM e os fundamentos da lógica *fuzzy*, de modo a estabelecer critérios para o desenvolvimento de um algoritmo inteligente dedicado à detecção de certos modos de falha instaurados em um grupo de locomotivas, que, por se tratar de equipamentos não estacionários e de elevada complexidade sistêmica, apresentam certos modos de falha ímprobos de bloqueio pelas convencionais técnicas.

1.1 Objetivos

O objetivo geral deste trabalho é definir uma metodologia para seleção de parâmetros úteis e de passível aquisição, para o desenvolvimento de classificadores *fuzzy* customizados e dedicados às tomadas de decisões estratégicas para manutenção em um seletivo grupo de ativos, fundamentada na adaptação das técnicas de RCM.

1.2 Justificativas

A revisão bibliográfica realizada ao longo desta pesquisa, e experiências adquiridas na participação em estruturas de engenharias de confiabilidades, possibilitaram a constatação de uma escassa abordagem referente às diretrizes destinadas à aceção de critérios para o desenvolvimento de algoritmos destinados a confiabilidade de ativos.

2 LOCOMOTIVAS E MANUTENÇÃO

Este capítulo está disposto por meio de dois principais tópicos: locomotivas diesel-elétricas e fundamentos da manutenção. No primeiro, disserta-se sobre os aspectos construtivos de uma locomotiva, dando ênfase ao sistema de transmissão diesel-elétrico e à descrição de sua arquitetura. O objetivo é fornecer informações relevantes para posterior apresentação da metodologia utilizada para o diagnóstico de falhas. No segundo tópico, apresenta-se uma revisão literária sobre os fundamentos e conceitos da manutenção, sua evolução ao longo das décadas e suas transformações ao decorrer das gerações. Foram abordadas as principais técnicas e metodologias empregadas para auxílio às tomadas de decisões estratégicas relativas ao controle, planejamento e otimização dos recursos destinados ao gerenciamento da manutenção.

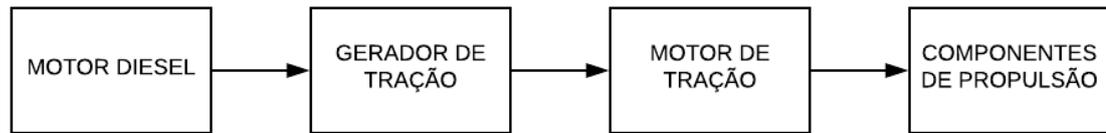
2.1 Sistemas diesel-elétricos

O sistema diesel-elétrico consiste em um sistema de transmissão de potência aplicado geralmente a grandes máquinas de transporte, predominantemente no transporte marítimo, ferroviário e mineração. Neste sistema, a transmissão de energia se inicia em um motor a combustão de grande escala, que a dissemina para geradores ou alternadores de potência, que, por sua vez, transmite a energia para motores elétricos acoplados aos sistemas de propulsão (GRITSH, 2007). A vantagem deste, comparado aos sistemas puramente mecânicos, é a possibilidade de transmitir grandes potências por maiores distâncias, com elevada eficiência e baixa perda energética (BORBA, 2014).

A Figura 1 apresenta um diagrama de blocos com a representação de um sistema classificado como diesel-elétrico. Esse sistema é composto por quatro subsistemas principais: o motor diesel, o gerador de tração, o motor de tração e os componentes de propulsão.

O motor diesel é um motor a combustão interna que utiliza alta compressão nos cilindros como fonte de inflamação do combustível. Sua função é acionar o gerador de tração e vários outros componentes auxiliares por intermédio de acoplamentos mecânicos (SANTOS, 2010). O gerador de tração, por sua vez, irá converter o torque produzido pela fonte primária (motor diesel) em grandezas elétricas. Máquinas projetadas até a década de 70 estão equipadas com geradores de corrente contínua. Com os avanços da eletrônica de potência este tipo de gerador entrou em desuso, predominando o uso de geradores de corrente alternada (PEREIRA, 2007).

Figura 1 - Diagrama de bloco sistema de transmissão diesel-elétrico



Fonte: Borba (2014)

O motor de tração converte novamente potência elétrica em potência mecânica, transmitindo-a por meio de acoplamentos mecânicos aos componentes de propulsão, podendo estes serem roldões, rodas, propulsores, turbinas, entre outros. Inicialmente, eram empregados motores elétricos de corrente contínua, pelo elevado torque e possibilidade de um melhor controle, porém, com o desenvolvimento dos inversores de frequência, tais motores vêm perdendo sua empregabilidade para os motores assíncronos (BORBA, 2014).

Por se tratar de subsistemas com elevado grau de instabilidade, é difícil operar tais máquinas sem um eficiente sistema de controle, que permita uma interação desde a fonte primária até os elementos de propulsão. Normalmente, o rendimento de um sistema de transmissão diesel-elétrico está entre 80% a 86%, dependendo dos diferentes tipos de aplicação e arquitetura (BORBA, 2014).

2.2 Uma visão geral sobre locomotivas

Borba (2014) definiu uma locomotiva como um veículo ferroviário que tem a finalidade de movimentar um comboio compostos por vagões, seja de carga ou passageiro, formando o que se denomina trem. As locomotivas são classificadas de acordo com seu sistema de tração, existindo quatro tipos principais: locomotivas a vapor; locomotivas diesel-elétricas; locomotivas elétricas e locomotivas automotrizes.

As primeiras locomotivas apareceram no século XIX, propulsionadas por motores a vapor, chamadas popularmente no Brasil de Maria Fumaça, em atributo à densa nuvem de fumaça e vapor produzida durante sua operação. Sua patente se deu por Richard Trevithick, exatamente no ano de 1804, tornando-se economicamente viável somente alguns anos após o primeiro percurso realizado. Registros históricos afirmam que este modelo de locomotiva chegou a um recorde de velocidade de 203 km/h (LNER – LONDON NORTH EASTERN RAILWAY, 2007).

Durante a década de cinquenta, as locomotivas diesel-elétricas substituíram as locomotivas a vapor, divergindo desta pela forma de transmissão da energia geradora até as

fontes consumidoras. Atualmente, este é o tipo de sistema mais utilizado no transporte de carga no Brasil. Este sistema permite que as locomotivas desenvolvam sua potência máxima mesmo em velocidades reduzidas, em função do alto torque produzido em seus motores de tração. Existem três diferentes arquiteturas para este sistema, que são: DC-DC (corrente contínua – corrente contínua), AC-DC (corrente alternada – corrente contínua) e AC-DC-AC (corrente alternada – corrente contínua – corrente alternada).

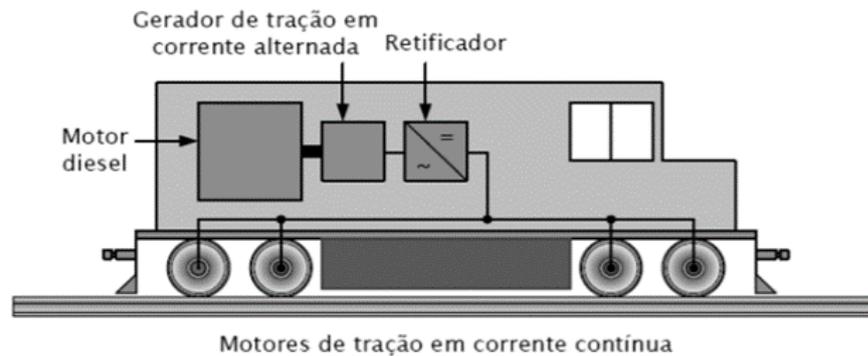
As primeiras locomotivas diesel-elétricas denominadas DC-DC, utilizam geradores de tração em corrente contínua, possuem sistemas de controle de propulsão e excitação bastante rudimentares (sem muita eletrônica embarcada), além de utilizarem motores de corrente contínua para propulsão (motores de tração). Posteriormente, com o avanço da eletrônica de potência, os geradores síncronos passaram a substituir os geradores DC, permitindo a redução no tamanho dos componentes, aumentando significativamente a capacidade de geração e potência efetiva entregue aos motores de tração, além de evoluir consideravelmente no quesito controle operacional (propulsão, excitação e aderência). Estas locomotivas, denominadas AC-DC, ainda possuem motores de tração DC, exigindo um sistema de retificação na transmissão entre o gerador síncrono e os mesmos (pontes retificadoras com diodos de potência). O emprego destes motores ainda se dava pela necessidade de um preciso controle de torque e velocidade nos rodéiros, características ainda não factíveis aos motores de corrente alternada.

Já em meados dos anos 90, adjunto à evolução dos inversores de frequência, surgem as primeiras locomotivas com a arquitetura denominada AC-DC-AC, empregando geradores síncronos de potência acoplados aos motores a combustão e motores de tração de corrente alternada (motores síncronos), controlados diretamente por inversores de frequência. Além de aumentar significativamente a eficiência energética através do aumento do esforço trator, alcançou-se também uma maior compacidade das unidades de tração, com menores níveis de ruídos e vibrações, além da significativa melhora no controle de aderência (BORBA, 2014). Observa-se na Figura 2 a arquitetura de uma locomotiva AC-DC, utilizada como base para este trabalho.

As locomotivas denominadas elétricas, necessitam de uma fonte externa de energia, seja por meio de cabos suspensos ou pela utilização do trilho como um condutor. Embora o custo para a construção de uma linha que opere com este sistema seja grande, sua operação é significativamente mais barata em relação aos sistemas diesel-elétricos. Além disto, possuem um melhor sistema de controle de aceleração e frenagem, tornando este sistema ideal para transporte de passageiros em densas zonas populacionais. Os trens de alta velocidade, em quase sua totalidade, utilizam este sistema de transmissão por demandar maior controle e eficiência

energética. Embora a maior parte das locomotivas elétricas operem com corrente contínua, existem muitos sistemas que utilizam corrente alternada (EVARISTO, 2017).

Figura 2- Locomotiva diesel-elétrica arquitetura AC-DC



Fonte: Borba (2014)

As locomotivas automotrices são veículos ferroviários construídos com um posto de condução em cada uma de suas extremidades, movida por um motor térmico, geralmente a diesel. A principal característica deste sistema é a sua construção integrada, estando a unidade tratora e a unidade motriz inseridas dentro de um só bloco. São trens relativamente pequenos (entre 8 a 20) metros, dedicados exclusivamente ao transporte de passageiros.

Por este estudo se tratar do desenvolvimento de um sistema dedicado a tomadas de decisões estratégicas para manutenção em um grupo de locomotivas diesel-elétricas de arquitetura AC-DC, as demais arquiteturas não serão abordadas.

2.3 Locomotivas de transmissão diesel-elétricas e seus principais sistemas

De acordo com Borba (2014), o desenvolvimento das locomotivas que utilizam o sistema de transmissão diesel-elétricas partiu-se dos seguintes pressupostos históricos:

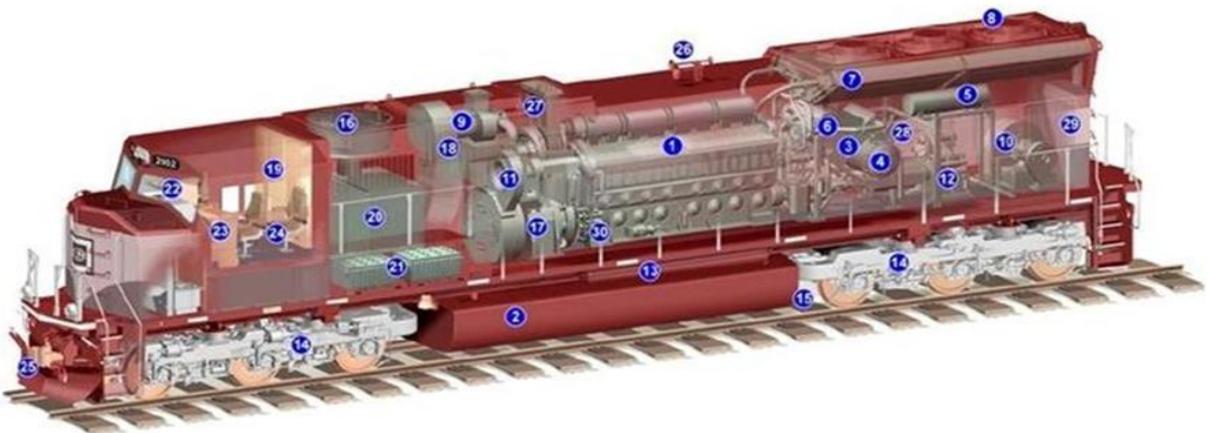
- a) 1866 – Wener Von Siemens inventou o gerador de corrente contínua auto excitado;
- b) 1892 – Rudolf Diesel patenteou o primeiro motor a combustão interna a óleo combustível;
- c) 1897 – Passaram a ser comercializados os primeiros modelos de motores diesel;
- d) 1925 – O motor diesel foi pela primeira vez empregado em uma locomotiva de manobra da “Central of New Jersey Railroad”;

- e) 1934 – O motor diesel foi novamente utilizado no novo trem de passageiros “Zephyr”;
- f) 1941 – O motor diesel passou a ser utilizado em escala para o transporte de carga na ferrovia Santa Fé, substituindo as locomotivas a vapor;
- g) 1970 – Com a evolução da eletrônica de potência os alternadores passaram a ser aplicados nas locomotivas em substituição aos geradores DC, permitindo a construção de locomotiva de maior potência e esforço trator;
- h) 1990 – Com o avanço dos inversores de frequência, foi possível aplicação de motores de tração em corrente alternada nas locomotivas, possibilitando ganhos no sistema de controle e aderência, e consecutivamente o aumento da relação potência / esforço trator.

Na constante busca pelo aprimoramento da eficiência, em conjunto com as evoluções tecnológicas das unidades de tração, foram desenvolvidos sistemas de transmissão mais sofisticados, alcançando além de um maior rendimento no tracionamento, uma maior compacidade, confiabilidade e manutenibilidade das unidades de tração (BORBA, 2014).

Na Figura 3 podem ser visualizados os principais componentes e unidades físicas de uma locomotiva diesel-elétrica. De uma forma macro, uma locomotiva arquitetura diesel-elétrica pode ser subdivida em 13 sistemas distintos: motor a combustão; admissão de ar; arrefecimento; combustível; lubrificação; excitação e controle de potência; propulsão; frenagem dinâmica; pneumática; estrutura; sistema de iluminação; sistema de partida e carga de bateria; sistema de transmissão mecânico. Esses sistemas estão detalhados no Anexo A, e o nível de profundidade apresentado em cada tópico variará em acordo com as necessidades do estudo. Cabe ressaltar que em razão deste estudo ser direcionado a uma frota específica de locomotivas AC-DC, será dado maior ênfase a este tipo de arquitetura.

Figura 3 - Locomotiva diesel-elétrica em corte e seus principais componentes



Legenda:

- | | |
|---|------------------------------------|
| 1- Motor diesel | 16- Resistências freio dinâmico |
| 2- Tanque de combustível | 17- Gerador de tração |
| 3- Resfriador de óleo lubrificante | 18- Filtro de inercia |
| 4- Filtro de óleo lubrificante | 19- Armário elétrico 1 |
| 5- Reservatório auxiliar de água | 20- Armário elétrico 2 |
| 6- Reservatório da água de resfriamento | 21- Baterias de partida |
| 7- Radiadores | 22- Console do maquinista |
| 8- Ventiladores do sistema resfriamento | 23- Console do auxiliar |
| 9- Soprador truque 1 | 24- Poltronas |
| 10- Soprador do truque 2 | 25- Engates |
| 11- Soprador do gerador | 26- Buzina |
| 12- Compressor de ar | 27- Escapamento do motor diesel |
| 13- Reservatório de ar | 28- Filtro primário de combustível |
| 14- Truque | 29- Reservatório de areia |
| 15- Motor de tração | 30- Motores de partida |

Fonte: Adaptado de Borba (2014)

2.4 Fundamentos da manutenção

Os conceitos de manutenção estão pautados na trajetória da evolução dos processos industriais desde o surgimento das primeiras máquinas térmicas alimentadas a vapor (LUCATELLI, 2002). Desta maneira, são vastas as etimologias e definições para o tema. Segundo a Associação Brasileira de Normas Técnicas - ABNT (1994), a manutenção é a associação de todas as ações técnicas e administrativas atribuídas a manter ou devolver a um equipamento o seu estado normal de operacionalidade.

Para Monks (1989), a manutenção é uma atividade concebida para manter os bens de produção nas mais perfeitas circunstâncias, de modo a sustentar às metas organizacionais. As decisões referentes à manutenção devem refletir na viabilidade do sistema a longo prazo. Por outro lado, Dunn (1997) definiu a manutenção como qualquer atividade remetida a um ativo que assegure sua função. Para o autor, as modificações não são manutenções, mesmo sendo executadas por mantenedores.

Uma definição bem mais completa comparada às demais é apresentada por Gits (1992). Segundo o autor, o processo primário da industrialização é a produção na qual uma entrada (material, energia e mão de obra) é transformada em um produto de saída, utilizando para isto artifícios técnicos dedicados (somatório de elementos físicos que exercem funções específicas nesta transformação). O estado do sistema técnico é completamente relevante ao processo, podendo ser alterado por diversas variáveis externas, conduzindo inevitavelmente a uma saída

secundária, que seria a demanda pela manutenção. Manutenção é o somatório das atividades requeridas para manter os sistemas ou restaurá-los ao estado necessário para execução de sua função na produção.

Independente da definição empregada, observa-se que todos os autores relacionam a manutenção à capacidade de manter, reestabelecer ou preservar a função requerida de um ativo. Todos estes conceitos já outorgam destaque ao papel que a manutenção pode exercer na otimização de um processo produtivo. Por esta razão, os processos de gerenciamento da manutenção sofreram consideráveis transformações ao decorrer de sua história, principalmente nas últimas três décadas, talvez mais do que qualquer outra atividade de gerenciamento (MOUBRAY, 1997).

Em tempos de elevada competitividade e sobrevivência entre mercados globalizados, a função manutenção passa a ter especial atenção dos mais diversos setores, em razão da fundamental necessidade do controle de despesas operacionais, dos quais os de manutenção representa um grande componente de custo controlável (FLEMING; FRANÇA, 1997).

2.5 Evolução histórica da manutenção

A primeira geração da manutenção iniciou-se por volta do século XVI com o desenvolvimento das primeiras máquinas têxteis, perpetuando até a segunda guerra mundial. Os equipamentos até então eram simples e de fácil conserto, característica de um período de baixa mecanização industrial (KARDEC; NASCIF, 1999). Nesta conjuntura, a manutenção não planejada (a mais elementar de todas as formas de manutenção) foi a técnica mais propícia de implementação, em razão do baixo volume de produção e simplicidade dos equipamentos. Também conhecida por manutenção corretiva (MC), esta técnica se caracteriza por uma atuação reativa, ou seja, somente executada após a quebra do equipamento em conjunto com a parada da produção (LUCATELLI, 2002).

O período pós-guerra trouxe consigo a necessidade de aumentar significativamente as linhas de produção em função da alta demanda de produtos, reduzindo a tolerância aos atrasos e elevando o grau de exigências em suas fabricações. Por consequência, houve um forte aumento das mecanizações nas indústrias, compostas agora por sistemas bem mais complexos, exigindo uma metodologia de manutenção mais apurada. Nasce daí a segunda geração da manutenção (LUCATELLI, 2002). A partir deste cenário, passou-se a idealizar a prevenção das falhas como sustentação para disponibilidade e confiabilidade dos meios produtivos, resultando

no conceito de manutenção preventiva (MP), caracterizada por intervenções sistemáticas com base em ciclos pré-estabelecidos (KARDEC; NASCIF, 1999).

A terceira geração da manutenção teve seu início na década de setenta, impulsionadas pelo aumento de custos que as paradas não programadas passaram a representar. Um dos fatores atribuídos a este aumento foi a tendência mundial da utilização de sistemas *just in time*, onde estoques reduzidos para uma produção em andamento intensificavam ainda mais os impactos de uma parada não planejada. Esta última geração foi oriunda das novas exigências e características de um novo mercado, agora globalizado, fazendo que a acirrada concorrência buscasse estratégias ainda não exploradas para redução dos custos, como os de manutenção. Outro fator que contribuiu para esta mudança de patamar foi a evolução dos sistemas de automação, advento da informática, tornando as plantas industriais extremamente complexas e sensíveis às variáveis externas, transformando a confiabilidade e a disponibilidade em fatores decisivos para o seu gerenciamento (KARDEC; NASCIF, 1999).

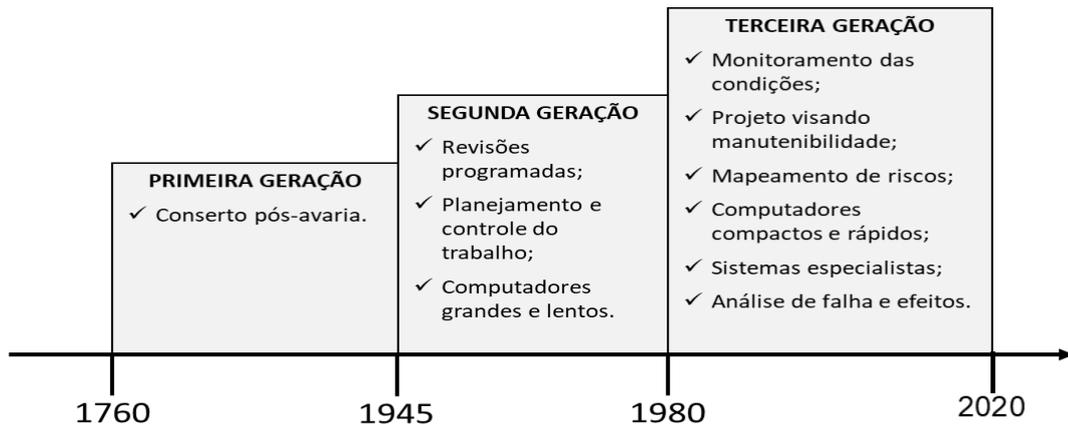
Nesta nova etapa, destaca-se a inclusão de novas estratégias como o monitoramento das condições operacionais dos ativos (manutenção preditiva), análise de risco e o emprego intensivo da tecnologia da informação (ALKAIM, 2003). Esta geração, é uma fonte das maiores contribuições concernente ao desenvolvimento de metodologias, técnicas e estratégias, abrangendo desde as manutenções preditivas, atribuídas ao início desta nova era, a utilização de ferramentas mais complexas para auxílio na tomada de decisão ou análise das falhas, como o FMEA (*Failure Modes and Effects Analysis*), TPM (*Total Productive Maintenance*), RCA (*Root Cause Analysis*) e RCM (*Reliability Centered Maintenance*) (MOUBRAY, 1997). Observa-se por meio das Figuras 4 e 5 uma síntese histórica da evolução da manutenção ao longo das décadas (expectativas *versus* técnicas empregadas).

Figura 4 - Expectativa da manutenção ao longo das décadas



Fonte: Adaptado Moubray (1997)

Figura 5 - Evolução das técnicas de manutenção ao longo das décadas



Fonte: Moubray (1997)

2.6 Análise de Modo e Efeito de Falha (FMEA)

A análise de modo e efeito de falha (FMEA – *Failure Mode and Effect Analysis*), segundo a Associação Brasileira de Normas Técnicas – ABNT 5464 (1994), é um método qualitativo dedicado a análise da confiabilidade através do estudo dos modos de falha propícios a ocorrerem a um item específico de um sistema, para uma posterior determinação de seus efeitos sobre os demais subsistemas ou na função principal do conjunto.

Podendo ser traduzido ao português como análise dos modos de falha e efeitos, este método foi desenvolvido como uma ferramenta de previsibilidade, aplicada para garantir (até a extensão permissível) que os potenciais modos de falha e suas consequências sejam identificados e eliminados antes de sua ocorrência (SAKURADA, 2001).

Apesar desta ferramenta ter sido desenvolvida com enfoque no desenvolvimento de novos processos e produtos, o FMEA passou a ter aplicabilidade em diversas outras conjunturas, em razão de sua grande versatilidade. Atualmente é empregada tanto para redução de falhas em processos e produtos já existentes, quanto em processos administrativos. Também tem sido aplicada em condições mais específicas, tais como análise de risco nas engenharias de segurança ou indústria de alimentos. Para todas as colocações citadas, as etapas e o método de execução são os mesmos, diferenciando somente em função do objetivo (TOLEDO; AMARAL, 2008), podendo ser classificado em dois tipos: DFMEA (*Design Failure Mode and Effects Analysis*) e PFMEA (*Process Failure Modes and Effects Analysis*).

O DFMEA, também conhecido como FMEA de produto ou projeto, visa identificar possíveis falhas em produtos, examinando seus efeitos em níveis micros de operação,

facilitando assim a identificação de possíveis desvios que possam ocorrer ao projeto. Tem por foco a melhoria do *design*, ao invés de focar no processo de fabricação como um todo. Este tipo de FMEA deve ser aplicado quando os critérios e requisitos de performance ainda estiverem sendo criados. O resultado desta análise poderá levar a uma lista de melhorias a serem conduzidas ao decorrer do projeto. Utiliza-se para este tipo de abordagem análises qualitativas ou quantitativas, variando com a necessidade da aplicação (SANDER, 2019).

Por outro lado, o PFMEA ou FMEA de processo, consiste em avaliar os processos de fabricação e montagem em um sistema, subsistema ou componente, focando principalmente nos possíveis modos de falha que possam ocorrer aos produtos em consequência de uma deficiência neste processo. Esta técnica é muito utilizada na indústria automotiva e áreas fortemente concentradas na fabricação ou montagem de itens, assim como áreas clínicas ou demais setores onde se tenha uma maior preocupação com a saúde e segurança. O objetivo desta abordagem é identificar e priorizar processos que são de alto risco e consequentemente conduzi-los ao FMEA, identificando assim os possíveis modos de falha que possam atrelá-los. Posteriormente uma análise mais detalhada é realizada para cada risco priorizado, de modo a determinar suas causas e readequar o processo focando em sua neutralização (SANDER, 2019).

Para utilização da metodologia FMEA, antes de tudo, é necessária certa familiarização com as definições de modo, causa e efeito de falha. Dorneles, Matschulat e Rodrigues (2010), definiram modo de falha como “a maneira na qual uma falha se manifesta” ou “maneira como o componente de estudo deixa de executar sua função”. Dentro da contextualização do FMEA, o modo de falha é uma propriedade inerente a cada item observado, visto que cada um possui sua particularidade dentro de uma suposta ocorrência como: função, fabricação, material, ambiente de trabalho, entre outros.

Quanto ao efeito de falha, atribui-se este termo às consequências que um modo de falha tem à operação, função ou produção o qual está incumbido, podendo ser classificados como efeito local ou efeito final (DEPARTMENT OF DEFENSE WASHINGTON DC, 1980). Dentro do âmbito FMEA, os efeitos de falha são resultantes produzidas por um modo de falha quando este vem a se manifestar. O modo de falha tem ocorrência interna ao processo, em níveis de sistema, conjunto ou item, gerando os efeitos externos (DORNELES, MATSCHULAT, RODRIGUES, 2010). Em resumo, um modo de falha é uma anomalia que ocorre em nível de componente, já seu efeito em nível sistêmico.

Por fim, a causa de falha pode ser atribuída aos processos físicos ou químicos, defeitos de projeto, defeitos de qualidade, aplicação incorreta de peças, entre outros fatores que

desencadearam de forma direta ou indireta a falha (DEPARTMENT OF DEFENSE WASHINGTON DC, 1980).

2.7 Análise de Causa Raiz (RCA)

A Análise de Causa Raiz (RCA – *Root Cause Analysis*) é uma metodologia que visa a neutralização de reincidências de falhas em equipamento ou processos, de modo a sair da conduta reativa (BAPTISTA, 2007). O objetivo deste método é analisar o comportamento das falhas ocorridas em um sistema, e explicar qual foi ocorrência, o seu motivo e como eliminar a sua recorrência. Diferente de apenas abordar causas que contribuíram para a existência de um certo problema, a RCA tem por propósito a descoberta da causa fundamental, ou seja, aquela o qual sem ela o modo de falha não existiria, eliminando-a por intermédio de ações de bloqueio (AGUIAR, 2014).

Gray e Ursprung (2013) afirmaram que embora a RCA possua uma roupagem retrospectiva de análise de erro, atuando no problema após sua ocorrência, seu objetivo é prevenir eventos futuros. Por outro lado, Ammerman (1998) retratou os seguintes propósitos para a metodologia RCA:

- a) Eliminação de causas plausíveis e aparentes, não sustentadas por dados coletados do problema;
- b) Determinação das causas raízes e secundárias para o problema e que precisam de intervenções corretivas;
- c) Eliminação de presumíveis causas relativas à problemas de performance, como por exemplo: procedimentos, equipamentos, pessoas e processos;
- d) Seleção de causas que requerem apuração.

A RCA é um processo que demanda homem-hora de especialistas que estejam envolvidos diretamente com as atividades relacionadas ao problema, envolvendo várias etapas em sua construção. Para alguns processos de investigação, é necessário o levantamento de hipóteses de causas raízes e sua validação por intermédio de ensaios destrutivos, podendo encarecer sua utilização (AGUIAR, 2014). A RCA está diretamente relacionada aos seguintes conceitos:

- a) **Fatores causais:** de acordo com Baptista (2007), são todos os fatores que podem afetar de uma forma lógica os resultados, incluindo aqueles que comprovadamente induzem ao fenômeno;
- b) **Causas:** de acordo com a ABNT 5462 (1994) são as circunstâncias relativas a fabricação, uso ou projeto que acarretam em uma falha;
- c) **Causa raiz:** causa a qual se bloqueada, levaria a extinção de novas ocorrências para o modo de falha analisado. Não aplicada apenas à ocorrência focal, mas também a um grupo genérico de possíveis ocorrências, principal ponto que reforça a necessidade de que esta deva ser identificada e corrigida. (BAPTISTA, 2007).

Para elaboração de uma análise de causa raiz (RCA) é necessária a sucessão das seguintes etapas, conforme proposta de Baptista (2007): Definição do problema; Análises pontual e sistêmica do problema; Levantamento de hipóteses de causas primárias e secundárias; Verificação das hipóteses traçadas através de ensaios e investigações em campo; Definição das causas primárias e secundárias; Definição de possíveis planos de tratativa; Estudo de viabilidade dos planos de tratativa propostos, priorização dos planos que representem maior viabilidade técnica e financeira; Implementação da solução (plano priorizado); Acompanhamento dos resultados.

Ainda que todas as etapas anteriormente citadas tenham sido realizadas, haverá casos em que a causa raiz ainda permanecerá oculta, pois, existem hipóteses difíceis de serem validadas. Quando isto ocorre, o correto é considerá-la dentro do espectro de tratativas, resguardando de novas recorrência do problema (AGUIAR, 2014).

2.7.1 Análise de falhas

A ABNT 5462 (1994) define análise de falha como um exame lógico e sistemático de um item que falhou, de modo a identificar e analisar o mecanismo, a causa e as consequências da falha. Por outro lado, Baptista (2007) a define como uma inspeção detalhada de componentes danificados com a finalidade de se determinar qual o modo de falha responsável pela ocorrência. Para o autor, existem cinco formas ou mecanismos que levam a falha em um componente, sendo eles:

- a) **Sobrecarga:** quando o valor de intensidade da carga (seja ela elétrica ou mecânica) ultrapassa os valores nominais admissíveis do componente, levando-o a sua

deformação, fratura ou um sobreaquecimento a ponto de danificar seus circuitos elétricos;

- b) **Fadiga:** fenômeno de ruptura evolutiva de uma matéria sujeita a ciclos repetitivos de deformação e tensão. Cargas flutuantes durante um período relativamente longo de tempo pode levar a instauração deste tipo de falha, deixando na maioria das vezes assinaturas para sua detecção;
- c) **Corrosão:** é um fenômeno de interface irreversível, que transforma as características estruturais de um metal por meio de sua interação química ou eletroquímica com o meio a que se encontra. Este fenômeno pode levar ao crimpamento de peças móveis ou fraturas estruturais nos componentes de um equipamento;
- d) **Falhas influenciadas por corrosão:** falhas influenciadas indiretamente pela ação da corrosão em componentes e peças, seja pela redução de sua resistência mecânica, ou qualquer outra característica prescindível a função que exerce;
- e) **Desgaste:** desgaste pode ser definido pela remoção de material de forma indesejável de superfícies de contato decorrente ação mecânica em um componente, classificadas como abrasivas ou fadiga de contato.

2.8 Manutenção centrada na confiabilidade (RCM)

A Manutenção Centrada na Confiabilidade (RCM- *Reliability Centered Maintenance*) teve início na década de sessenta no setor aeronáutico americano, em virtude de necessidades específicas não abrangidas pelas demais metodologias existentes. Neste período, a FAA (*Federal Aviation Administration*), órgão americano responsável pela regulamentação das linhas aéreas, convocou um grupo de estudo, liderado por Norlan e Heap, denominado MSG (*Maintenance Steering Group*) com intuito de avaliar os métodos de manutenção utilizados pelas companhias aéreas e propor alternativas para ampliação da taxa de confiabilidade de seus ativos (LUCATELLI, 2002).

Em 1967 ocorreu a publicação dos resultados desta pesquisa, através de um documento intitulado MSG1. A empresa Boeing foi a pioneira na sua utilização, como base para implementação de um novo programa de manutenção. Com certos aperfeiçoamentos práticos, o MSG1 foi republicado em 1970 com o título de MSG2, passando ser utilizados por demais agências, inclusive pelo departamento de defesa americano. Este documento foi difundido ao público externo em 1978, através da publicação do relatório *Reliability Centred Maintenance*

(RCM) e ainda hoje é considerado um dos mais importantes documentos para gestão de equipamentos (MATA FILHO; MIRANDA; LIMA, 1998).

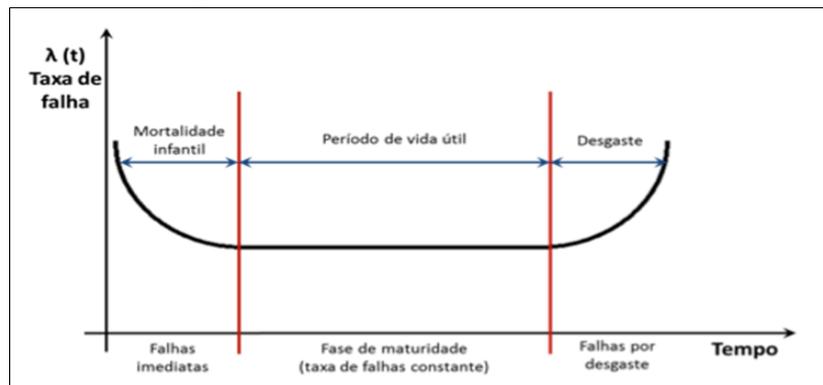
Por fim, em 1993 foi confeccionada a última versão do documento, publicado sob o nome de MSG3, trazendo uma abordagem mais ampla, incorporando a terotecnologia, que nada mais é que projetistas da área de manutenção atuando junto ao projeto na otimização de *layouts*, instalações, acessibilidade e manutenibilidade (SIQUEIRA, 2000).

Moubroy (1997) define a manutenção centrada na confiabilidade como um processo utilizado para a determinação do que deve ser feito, de modo a assegurar que qualquer ativo físico permaneça nas condições esperadas pelos usuários, no contexto operacional presente. Ou seja, diferente das demais estratégias de manutenção que foca no direcionamento de recursos para preservação do estado geral de um ativo, o RCM prioriza a conservação de sua funcionalidade. Podem ser extraídos desta definição, os quatro propósitos fundamentais do RCM, que são (MOUBRAY, 1997):

- a) Preservação da função do sistema;
- b) Identificação de falhas funcionais e execução do FMEA;
- c) Classificação e priorização das falhas funcionais em virtude de suas consequências;
- d) Elaboração das atividades fundamentais de manutenção por intermédio de um diagrama de decisão, associadas ao estudo de viabilidade técnica e custo/benefício.

Outra quebra de paradigma atribuída aos estudos de RCM, está em sua divergência com a convenção de que estatisticamente os equipamentos são mais propícios a apresentarem falha à medida que envelhecem. O único padrão de comportamento da confiabilidade estabelecido até o momento era a “curva da banheira”, onde as falhas imediatas e as falhas por desgaste eram bem caracterizados (FIGURA 6). O RCM demonstrou que a relação idade e confiabilidade tem certa assertividade para alguns modos de falha, nos quais a idade esteja diretamente relacionada à fadiga e à corrosão. Porém, com o avanço das tecnologias, os equipamentos passaram a conter certos itens e componentes que não se associam a tal determinação (LUCATELLI, 2002).

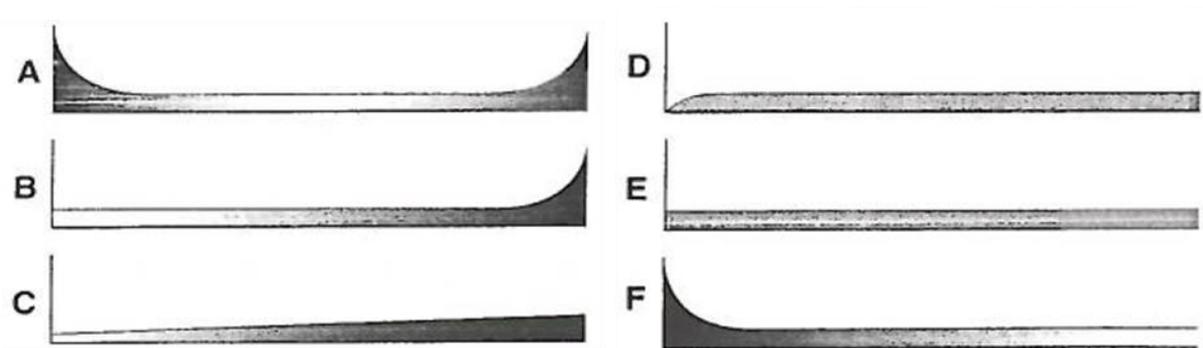
Figura 6- Curva da banheira tradicional



Fonte: Adaptado de Lafraia (2015)

De acordo com Moubray (1997) os equipamentos agora mantidos são bem mais complexos do que os existentes a 40 anos atrás, resultando em alterações significativas nos padrões das falhas, conforme demonstrado na Figura 7. Os gráficos estão relacionados com a probabilidade condicional de uma falha em relação a sua idade operacional. O padrão A é a conhecida curva da banheira, caracterizada por uma alta probabilidade de falhas nos primeiros dias de operação (conhecida como taxa de mortalidade infantil), seguida de uma probabilidade constante e gradualmente aumentada à medida que o equipamento envelhece. O padrão B representa uma probabilidade de falha progressiva à medida que o equipamento sofre desgaste. O padrão C está relacionado ao aumento lento da probabilidade da falha, porém sem uma idade de desgaste identificável. O padrão D mostra baixa probabilidade de falhas nos primeiros dias de aplicação e posteriormente uma evolução para uma probabilidade constante. O padrão E mostra uma probabilidade condicional de falha constante para toda a vida do ativo. Já o padrão F possui uma alta taxa de mortalidade infantil, estabilizando esta proporcionalidade à medida que o ativo envelhece.

Figura 7 - Padrões de falha RCM



Fonte: Moubray (1997)

Dunn (1997) classificou os padrões das curvas A, B e C como padrões atribuídos à componentes mais elementares, com modos de falhas predominantemente simples, como desgaste e fadiga de componentes mecânicos. Por outro lado, segundo o autor, os padrões das curvas D, E e F são atribuídos aos modos de falhas de itens complexos, como sistemas de controle hidráulico, sistemas eletrônicos e sistemas pneumáticos, os quais possuem probabilidade aleatória de falhas.

De acordo com Moubray (1997), para aplicação do processo de RCM, antes de tudo, é necessário especificar e analisar os quesitos de manutenção já existentes para os ativos, e então definir quais deles serão submetidos ao processo de revisão. Posteriormente, cada ativo priorizado deverá passar pelas seguintes avaliações:

- a) Definição das funções e padrões de desempenho esperado do ativo no seu contexto presente de operação, de acordo com a seguinte classificação:
 - Funções primárias, as quais sumarizam os objetivos principais que levaram a aquisição do equipamento. Nesta categoria devem ser mencionados os parâmetros primários esperados para execução de sua função, como por exemplo: velocidade nominal, capacidade de transporte, capacidade de armazenamento, potência, torque, entre outros;
 - Funções secundárias àquelas relacionadas às expectativas para o ativo além dos objetivos e parâmetros principais, como por exemplo: Segurança, conforto, integridade estrutural, economia energética, estética, entre outros.
- b) Levantamento dos modos de falha deverão por intermédio de bases históricas de ocorrências (se houver) e conhecimento técnico e empírico de especialistas entre outros fatores;
- c) Definição das consequências de cada modo de falha, a qual implica em listar os efeitos dos modos de falha definidos anteriormente. Para esta tarefa, pode ser usado um diagrama de causa e efeito, tendo como suporte a atribuição de pesos às seguintes questões: Apresentação da falha (oculta ao operador, visível ao operador);
 - Impactos a segurança e ao meio ambiente;
 - Impactos na produção;
 - Danos físicos causados ao equipamento;
 - Dispendiosidade para sua reparação.

- d) Caracterização dos efeitos de cada modo de falha, uma vez que cada modo de falha afeta de alguma forma a organização, mas, em cada caso seus efeitos serão diferentes. Eles podem afetar desde a operação a qualidade dos produtos, serviços ou clientes. Uma das características da metodologia RCM é que ela reconhece muito mais as consequências da falha do que suas características técnicas em si. Este processo de avaliação também muda a ênfase para longe do conceito de que todas as falhas são malélicas e devam ser tratadas;
- e) Atribuição de um grau de importância para cada modo de falha, levando em consideração as classificações obtidas pelo intermédio dos quatro itens anteriores. Cada modo de falha deverá ser tratado em acordo com sua significância dentro do processo;
- f) Definição dos métodos de bloqueio para cada modo de falha. Nesta etapa é definida toda estratégia de intervenção nos ativos, baseada nas classificações anteriores. O tipo de intervenção pode ser classificado em:
- Tarefas proativas: são tarefas empreendidas antes da instauração por completo do modo de falha, detectadas através do acompanhando de parâmetros operacionais do equipamento. Conhecida por manutenção preditiva;
 - Ações padrão: tratam do estado da falha e são empregadas na impossibilidade da implementação da abordagem proativa.
- g) Definição das atitudes a serem tomadas em condições nas quais nenhuma tarefa proativa é apropriada. O RCM reconhece três ações padrão para este tipo de ocorrência:
- Busca da falha: implica na verificação periódica de funções ocultas de modo a prevenir a instauração de um modo de falha já eminente;
 - Reprojeto: implica em fazer melhorias na capacidade intrínseca do equipamento com a finalidade de excluir a possibilidade do modo de falha mapeado. Isto inclui modificações de *hardware* e *software*;
 - Nenhuma manutenção programada: implica a não utilização de estratégias para bloqueio do modo de falha. Entende-se que é menos dispendioso conviver com a possibilidade de certas ocorrências do que bloqueá-las.

2.9 Diagnóstico de Falhas

O diagnóstico de falhas é o processo de identificação e determinação da relação entre informações relevantes do processo ou sistema e os padrões de falha. O diagnóstico engloba a detecção, o isolamento e identificação da falha. A detecção de falha é o processo de identificar se esta ocorreu naquele sistema ou não. A isolação é a tarefa de encontrar o instante do componente de falha e isolá-lo, enquanto a identificação visa determinar o padrão e a severidade desta. O principal objetivo do diagnóstico de falhas é prover informações de suporte às políticas de decisões da manutenção, visando definir estratégias ótimas de manutenção (LEI, 2016).

Existem vários métodos de diagnóstico de falhas que podem ser agrupados de uma maneira genérica em: métodos baseados em modelo e métodos baseados em dados (YANG et al., 2011). Os métodos baseados em modelo utilizam um modelo matemático do sistema para estimar o seu estado e os seus parâmetros. Os dados estimados são comparados com as características normais do processo, e então é possível identificar falhas. Já os métodos baseados em dados, fazem uso dos dados de operação do processo, nas condições normais de operação e com falhas, visando extrair o conhecimento para realizar o diagnóstico (CARMO, 2018).

De acordo com Carmo (2018), o diagnóstico de falhas baseados em dados pode ser feito por métodos estatísticos ou por meio de classificadores. Os classificadores fazem um mapeamento dos dados o que gera uma função de associação visando classificar dados não rotulados de entrada dentro de classes pré-definidas. Ftoutou e Chouchane (2019) ressaltam a importância dos algoritmos inteligentes nos processos de detecção de falhas. Por ser o foco deste trabalho, esses algoritmos serão abordados separadamente no próximo Capítulo.

3 SISTEMAS INTELIGENTES

Este capítulo é composto por três principais objetos de discussão. Primeiro, é abordado o tema aprendizado de máquinas, suas principais definições, empregabilidade, tipos de tarefas existentes e suas classificações, enfatizando seu uso para clusterização de dados. No segundo, são abordados os fundamentos da lógica *fuzzy*, destacando-se o algoritmo de agrupamento *fuzzy C-means*, por se tratar de um importante elemento para o desenvolvimento do presente estudo. Por fim, são apresentados os conceitos de validação de dados e sua aplicabilidade em algoritmos de clusterização.

3.1 Aprendizado de máquina

Aprendizado de máquinas (AM) é uma área de pesquisa da inteligência artificial que se destina a desenvolver faculdades de aprendizado em *softwares* de computadores, baseadas em sua própria experiência. Utilizando um conjunto de dados de experiências passadas, estas pesquisas objetivam desenvolver algoritmos capazes de aprender por si só a executar certas tarefas (FACELI et al., 2011).

Para Cerri e Carvalho (2017), o aprendizado de máquinas é uma área de pesquisa multidisciplinar, englobando: inteligência artificial, teoria da complexidade computacional, probabilidade e estatística, teoria da informação, filosofia, psicologia, neurobiologia, entre outros. Os autores apresentaram como exemplo um algoritmo destinado a distinguir diferentes características botânicas em três variáveis distintas existentes em uma espécie de flor. Assim como os seres humanos aprendem a diferenciá-las pela observação, um algoritmo de AM também o fará.

Já Mitchel (1997) definiu o tema como uma ciência que estuda a construção de algoritmos que melhoram seu desempenho na execução de tarefas à medida que às executam. Grande parte dos métodos utilizados no AM adquirem experiências a partir dos dados do problema, ou seja, quanto melhor for a qualidade dos dados, melhor será seu desempenho.

Prati (2006) observou que o AM tem uma grande associação com a estatística, dado que ambas as conjunturas se baseiam na análise de dados. Porém, o AM utiliza representações heurísticas, enquanto a estatística foca em modelos teóricos bem definidos. A versatilidade dos métodos de AM os tornam adequados para conjunturas nas quais existam pouco conhecimento sobre o domínio, dificultando a escolha de modelos estatísticos complexos. O preço por esta flexibilidade é a ausência do poder analítico-teórico que os modelos estatísticos pré-definidos

possuem. As tarefas de aprendizado podem ser classificadas em dois principais focos, que são: as tarefas descritivas e as tarefas preditivas.

As tarefas descritivas buscam desenvolver algoritmos que proponham analisar dados passados e obter uma compreensão em tempo real dos acontecimentos, buscando tomadas de decisão de cunho imediato. Este tipo de tarefa trabalha com análise de bases históricas e o cruzamento de singularidades existentes entre os dados, visando a geração de um panorama claro e preciso do momento. A clusterização de dados está entre as principais tarefas deste tipo de classificação (FORGY, 1965). De uma forma geral, este modelo busca rotular as distâncias dos dados em relação aos grupos existentes, de forma que, as distâncias entre os dados de um mesmo grupo sejam menores que as distâncias dos dados de grupos distintos. Pode-se citar como exemplo os agrupamentos de texto, onde um algoritmo busca agrupar textos que abordem um mesmo assunto, separando-os dos demais. Não se restringindo apenas aos textos, este tipo de tarefa tem grande aplicabilidade na engenharia, biologia, medicina, *marketing*, entre outras áreas (CERRI; CARVALHO, 2017).

Por outro lado, as tarefas preditivas são indicadas para predição de resultados futuros, baseando-se da análise e experiências de dados passados. Para isto, é feita uma varredura nos dados ao longo de um determinado período, visando a determinação de padrões, com o objetivo de prever comportamentos pósteros (BARROS, 2016). Estas tarefas podem ser subdivididas em: tarefas de classificação e tarefas de regressão.

As tarefas de classificação, buscam classificar categorias pré-definidas aos dados. Pode-se citar como exemplo os sistemas dedicados à classificação de clientes de um banco em duas diferentes categorias, “sim” e “não”. O objetivo é avaliar o histórico destes clientes para aprender a distinguir se o banco deverá conceder linhas de crédito no futuro (CERRI; CARVALHO, 2007).

As tarefas de regressão, por sua vez, objetivam a predição de valores das variáveis numéricas de saída, baseando-se nos valores de entrada. Neste tipo de tarefa, os algoritmos tendem a modelar a dependência do rótulo em seus recursos à medida que estes forem variados. A entrada de um algoritmo de regressão é um conjunto com rótulos de valores conhecidos, e a saída será uma função utilizada como meio de predição do valor do próximo rótulo para qualquer novo conjunto (MICROSOFT, 2019). Pode ser tomado como exemplo: previsão de preços de residências baseados em seus atributos (localização, tamanho, depreciação, entre outros fatores), previsão dos valores de ações, previsão de vendas de produtos baseados na publicidade, entre outros.

De outro ponto de vista, os sistemas de aprendizado de máquina podem ser categorizados como supervisionado, não-supervisionado e semi-supervisionado. No aprendizado supervisionado, existe o recebimento prévio de um conjunto de instâncias, e cada instância é formada por um grupo de atributos de entrada e saída (rótulos) (SOUTO et al., 2003). A implementação deste tipo de técnica se baseia na concepção de um conjunto de dados denominado conjunto de treinamento, onde amostras são retiradas do sistema e classificadas previamente pelo supervisor. Desta maneira, a máquina poderá verificar durante seu processo de aprendizado se suas respostas estão ou não coerentes com o esperado, ajustando-as de maneira que, os erros de tal conjunto sejam minimizados. Tal abordagem, tem bastante aplicabilidade em problemas de classificação e regressão, onde sabe-se de antemão os resultados esperados para um dado número de pontos (SILVA, 2008). Como exemplos dos algoritmos de aprendizado supervisionado podem ser citados as redes neurais artificiais do tipo *multilayer perceptron*, máquinas de vetores de suporte e árvores de decisão (BITTENCOURT, 2005).

No aprendizado não-supervisionado, existe para cada instância apenas os atributos de entrada. Utiliza-se desta técnica quando o objetivo é encontrar padrões ou tendências em um conjunto de dados (agrupamentos ou *clusters*) que sustentem o seu entendimento (COSTA, 1999). As técnicas de agrupamento são bastante similares às de classificação de padrões, pois, em ambas, se deseja que o algoritmo seja capaz de determinar a classe apresentada por um novo padrão com base em observações passadas. A diferença consiste no fato de que no aprendizado supervisionado, um conjunto de dados já classificado é fornecido ao sistema, enquanto no não-supervisionado tais classificações não existem, e o sistema deverá por si só decidir através de agrupamento de semelhantes quais são as classes pertinentes. São exemplo deste tipo de técnica: detecção de novidades, redução de dimensionalidades e clusterização de dados, sendo esta última de interesse do presente estudo (SILVA, 2008).

As técnicas de aprendizado semi-supervisionado utilizam de ambas as técnicas para encontrar uma hipótese capaz de classificar novas observações entre as classes existentes. Ou seja, aplica-se inicialmente das técnicas de aprendizado não-supervisionado para a extração do padrão de normalidade, em seguida, das técnicas supervisionadas para definição de um limiar para classificação destas anomalias.

3.2 Clusterização

Segundo Linden (2009) a clusterização, ou *clustering*, é o nome atribuído a um grupo de técnicas computacionais de aprendizado não-supervisionado das quais o propósito consiste na separação de objetos em grupos, baseando-se em suas singularidades. A ideia fundamental é colocar em um mesmo grupo objetos que sejam similares, obedecendo a critérios pré-estabelecidos. Estes grupos, devem apresentar alta homogeneidade interna e elevada segregação em relação aos demais objetos. Os objetos, também denominados exemplos, tuplas e/ou registros, representa uma entrada de dados, podendo ser constituídos por um vetor de atributos numéricos ou categóricos. O agrupamento é uma importante ferramenta utilizada para redução das dimensões de um conjunto e extração de suas características ocultas.

Cassiano (2014) definiu a análise de agrupamento como uma técnica não-supervisionada de mineração de dados multivariados que, partindo exclusivamente das informações das variáveis de cada caso, objetiva agrupá-las automaticamente em K grupos, geralmente distintos, denominados *clusters*. Na literatura, a clusterização também é chamada de análise de agrupamento, *clustering*, *typology*, *classification analysis* ou *numerical taxonomy*. Qualquer método de clusterização é estabelecido por um algoritmo específico, que designará como será feita a divisão dos *clusters*, embasados no conceito de distância ou similaridade entre as observações.

A clusterização pode ser aplicada com objetivo de reduzir o número de objetos para um número de subgrupos específico, quando o observador deseja formular hipóteses sobre a natureza dos dados baseadas em suas peculiaridades. Entretanto, o uso mais habitual da clusterização tem sido para propósitos exploratórios, baseados na classificação empírica de objetos (CASSIANO, 2014). De uma forma geral, a clusterização é empregada para cumprimento de pelo menos um dos seguintes objetivos:

- a) Identificação de estruturas implícitas: detecção de anormalidades, identificação de características específicas e geração de hipóteses para dados analisados;
- b) Classificação natural: identificação de grau de semelhança entre formas ou organismos;
- c) Compressão: métodos de organização de dados.

O problema em se trabalhar com um método não-supervisionado consiste da ausência de rótulos ou qualquer tipo de informação para a manipulação das instâncias (ZHU; GOLDBERG, 2009). Ankerst et al. (1999) abordaram três características distintas que amparam

certas limitações para este tipo de técnica. A primeira está relacionada à dificuldade de se determinar os parâmetros de entrada, especialmente para conjuntos de dados contendo objetos com muitos tributos. A segunda está na sensibilidade do algoritmo a estes parâmetros, levando a frequentes produções de diferentes partições do conjunto mesmo para ajustes de parâmetros significativamente diferentes. A terceira está na ampla distribuição dos conjuntos de dados reais de elevada dimensão, não podendo ser revelada por um algoritmo de clusterização usando somente um ajuste de parâmetro global (ANKERST et al, 1999 apud DUAN et al, 2006).

3.2.1 Medidas de similaridade

Conforme mencionado, o interesse da clusterização fundamenta-se na formação de grupos de objetos no qual seus elementos sejam mais similares entre si do que aos pertencentes a outros grupos. Para que isto seja factível, é necessário quantificar suas similaridades, utilizando-se de uma estrutura de dados capaz de correlacioná-las. Define-se por medidas de dissimilaridades números positivos que expressam a “distância” existente entre dois objetos, de modo a mensurar seu grau de singularidade. Quanto menor o valor da similaridade mais semelhantes serão os objetos analisados, e obedecendo aos critérios de agrupamento, tenderão a compartilhar os mesmos *clusters*. Da mesma forma, quanto maior for este valor, menos similares serão os objetos e em consequência, farão parte de *clusters* distintos (CASSIANO, 2014).

Para a clusterização, deve-se inicialmente estabelecer uma forma de mensurar o seu grau de proximidade, ou o quão bem seus valores se comparam. A distância entre eles viabiliza a quantificação de suas peculiaridades para um posterior agrupamento. Não existe necessariamente uma regra de similaridade que atenda a todos os tipos de variáveis contidas em uma base de dados. Normalmente utilizam-se das seguintes medidas de distância: Euclidiana, Manhattan, Minkowski e Mahalanobis (CASSIANO, 2014).

A distância Euclidiana, que é a mais utilizada nos algoritmos de clusterização, é definida por uma linha reta condicionada entre dois pontos que representam os objetos (CASSIANO, 2014). Considerando objetos com p atributos, a distância Euclidiana é dada por:

$$d(i, j) = \sqrt{|x_{i1} - x_{j1}|^2 + |x_{i2} - x_{j2}|^2 + \dots + |x_{ip} - x_{jp}|^2} \quad (3.1)$$

Onde $d(i, j)$ é a distância Euclidiana entre os dados localizados na posição x_i e x_j .

3.2.2 Métodos de clusterização

Cassiano (2014) apresentou uma série de quesitos que devem ser atendidos por um método ideal de clusterização, sendo eles:

- a) Descobrir *clusters* com formas arbitrárias (esférica, cilíndrica, linear, alongada, elíptica, espiralada, entre outros);
- b) Identificar variados tamanhos de *clusters*;
- c) Admitir diversos tipos de variáveis, ou seja, devem ser capazes de lidar com variáveis dos tipos: binárias, nominais, ordinais, escaladas em proporção, escaladas em intervalos, ou mesmo a combinação destas;
- d) Ser irreduzível à ordem de apresentação dos objetos, de forma que, um mesmo conjunto de objetos devem fornecer os mesmos resultados, independente da ordem de entrada;
- e) Processar corretamente objetos com qualquer número de atributos (devem ter a capacidade de manejar com eficiência objetos de grandes dimensões e fornecer resultados precisos);
- f) Ser escalável de modo a lidar com qualquer quantidade de objeto (devem ser rápidos e escalonáveis com o número de dimensões e com a quantidade de objetos a serem clusterizados, mesmo com bases de dados de grande porte);
- g) Prover resultados interpretáveis e utilizáveis (as descrições dos *clusters* devem ser facilmente assimiláveis, compreensíveis e de simples representações);
- h) Ser imunes a ruídos (dados do mundo real podem possuir ruídos ou dados perdidos. Suas existências não devem afetar a qualidade da clusterização a ser obtida);
- i) Aceitar certas restrições (aplicações do mundo real podem necessitar do agrupamento de objetos em acordo com tipos de restrições. Os métodos devem encontrar grupos de dados com comportamentos que satisfaça as restrições estabelecidas);
- j) Encontrar por si só o número adequado de *clusters* (encontrar o número ideal de clusters de uma forma natural é uma tarefa dispendiosa. Muitos métodos necessitam da definição de um valor de referência).

Entretanto, dificilmente alguma técnica de clusterização atenderá todos estes quesitos, embora exista consideráveis estudos que visam atender cada ponto mencionado de uma forma

individual. Em consequência disto, existem muitos métodos apropriados para atender grandes quantidades de objetos, outros para pequenas. Métodos que necessitam do fornecimento da quantidade de *clusters* pelo usuário, outros que não possui esta exigência. Métodos mais adequados à utilização de *clusters* de forma cilíndrica, outros que sua forma seja irrelevante, e assim por diante (AGRAWAL et al. 1998).

Em geral, os métodos de clusterização podem ser classificadas em dez diferentes categorias, sendo elas: métodos hierárquicos; métodos particionais; métodos baseados em densidade; métodos baseados em grade; métodos baseados em modelos; métodos baseados em redes neurais; métodos baseados em lógica *fuzzy*; métodos baseados em kernel; métodos baseados em grafos; métodos baseados em computação evolucionária.

Para o desenvolvimento deste estudo, foram utilizadas técnicas baseadas na lógica *fuzzy*. Nesta abordagem, cada elemento pode pertencer a várias classes com diferentes valores de pertinência, diferente da abordagem clássica, onde o elemento pertence unicamente a uma determinada classe. Estão entre os principais algoritmos *fuzzy* de clusterização o *fuzzy* C-Means (FCM), *Gustafson-Kessel* (GK) e *Gath-Geva* (GG). Os fundamentos da lógica *fuzzy* serão apresentados no tópico a seguir.

4 FUNDAMENTOS DA LÓGICA FUZZY

Os princípios da lógica *fuzzy* foram primeiramente abordados por Jan Lukasiewicz em 1920. Ele introduziu o conceito de pertinência parcial com o objetivo de fornecer um aparato matemático para tratamento de informações de caráter vago ou impreciso (TANSCHKEIT, 2012). Porém, em 1960, este tema rendeu uma extensão importante, atribuída a Lofti Asker Zadeh, embasado nos estudos de Lukasiwicz. O autor observou que muitas das regras apresentadas no cotidiano não podem ser expressas pela lógica clássica, nem pela lógica de três valores de Lukasiewicz, como por exemplo definir empiricamente a idade de uma pessoa apenas se baseando em sua aparência física. Tais indagações levaram Zadeh a desenvolver o que hoje se conhece por lógica *fuzzy* (RIGNEL; CHENCI; LUCAS, 2011).

Diferente da lógica booleana, que apenas admite os valores “verdadeiro” ou “falso”, na lógica *fuzzy* os valores podem variar além do espectro binário, desta forma uma pertinência de 0,5 e 0,1 pode representar meia verdade e quase falso, respectivamente (SILVA, 2012).

Na teoria clássica de conjuntos, o conceito de pertinência de um elemento a um conjunto é bem definido, ou seja, dado um conjunto A em um universo X , os elementos deste universo simplesmente pertencem ou não àquele conjunto (TANSCHKEIT, 2012). Esta ideia pode ser expressa pela seguinte função característica:

$$u_A(x) = \begin{cases} 1 & \text{se } x \in A \\ 0 & \text{se } x \notin A \end{cases} \quad (3.2)$$

em que, $u_A(x)$ é função de pertinência, X é universo de discurso, e x é um elemento.

Zadeh abordou uma caracterização mais abrangente, generalizando a função característica, de forma que ela pudesse assumir infinitos valores no intervalo $[0, 1]$. Deste modo um conjunto *fuzzy* A em um universo X é definido por uma função de pertinência $u(x): X \rightarrow [0,1]$ representado pelo seguinte conjunto de pares ordenados (TANSCHKEIT, 2012):

$$A = \{x, u_A(x)\} \mid x \in X \quad (3.3)$$

Wagner (2003) definiu a lógica *fuzzy* como uma ferramenta capaz de coletar informações descritas em linguagem natural, geralmente vagas, e convertê-las em um formato numérico de fácil manipulação por computadores. Ao longo de nossas vidas utilizamos conceitos de linguagem natural como: o trabalho está “quase” terminado, a água está “quente”,

o ar está “frio”. Dentro das teorias clássicas de conjuntos seria impossível tais classificações, diferente da teoria de conjuntos *fuzzy* (KLIR, 1997).

Gomide, Gudwin e Tanscheit (1995) abordaram de forma comparativa a teoria de controle clássica em relação as técnicas de modelagem *fuzzy*. Para que seja possível a implementação do controle de um processo através de abordagens lineares convencionais de controle é necessária inicialmente derivar o modelo matemático que o descreve, postulando-se de um conhecimento detalhado sobre ele. Este fato nem sempre é factível tendo-se em vista que tal abordagem somente seria aplicável à sistemas onde o processo é bem definido. Já a modelagem *fuzzy*, possibilita o manuseio das informações qualitativas e dados imprecisos, a ponto de reduzir a dispendiosidade de um projeto anteriormente intratável.

4.1 Conjuntos *fuzzy*

A definição de conjuntos *fuzzy* é geralmente aplicada para descrever a teoria de conjuntos que engloba exclusivamente conceitos de lógica *fuzzy*. Vista como uma ampliação da teoria dos conjuntos clássicos, esta teoria está diretamente associada aos conceitos básicos de funções de pertinência, operações com conjuntos, números, relações, regras, entre outras características, dentro de tal universo incerto (ALVES, 2007).

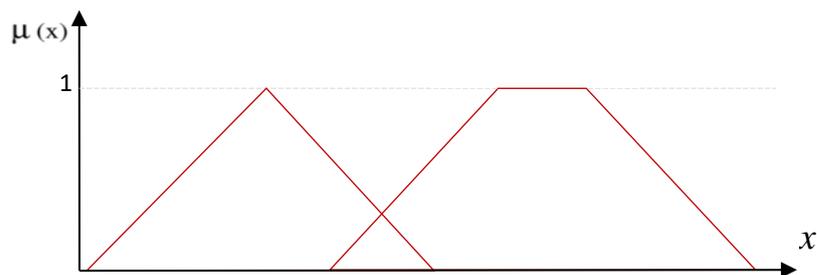
Rentería (2006) definiu um conjunto *fuzzy* como uma associação entre o conceito impreciso e sua modelagem numérica, atribuindo a cada indivíduo no universo um valor entre 0 e 1. Um conjunto *fuzzy* é definido por uma função denominada função de pertinência, que indicará o grau de significância de cada elemento em relação a cada conjunto. Os conjuntos *fuzzy* possuem a importante propriedade de expressar transições graduais de pertinência para não pertinência, permitindo a captura de expressões vagas em linguagem natural.

Ortega (2001) classificou estes conjuntos como um complexo de fronteiras não definidas introduzidas em substituição aos conjuntos clássicos, quando estes apresentam certas limitações para lidar com transições suaves entre classes. Sua definição, propriedades e operações são obtidas da generalização da teoria clássica. Conjuntos *fuzzy* podem ser definidos em universos discretos e contínuos.

Conjuntos discretos normalmente são representados por um vetor, contendo os graus de pertinência no conjunto A dos elementos correspondentes. Já os conjuntos contínuos são representados por funções de pertinência contínuas, sendo os modelos mais utilizados: lineares por partes (triangular ou trapezoidal), Gaussianos, ou alguma outra função algébrica especial.

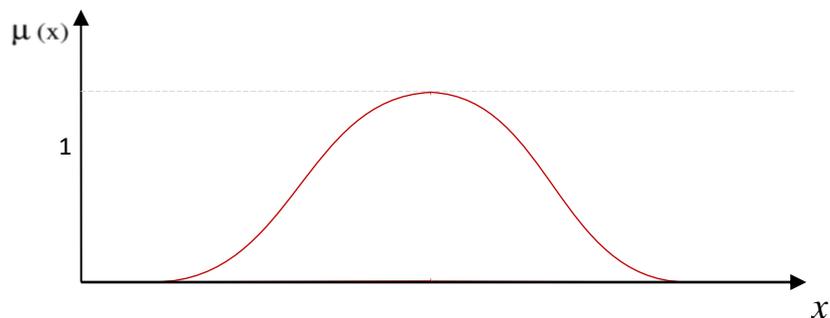
As funções lineares, devido a simplicidade, se tornaram mais populares em relação as demais. Este atributo também se dá pelo fato de que nem sempre o custo adicional exigido para a aplicação de funções mais complexas acarretará em uma melhora significativa na qualidade dos resultados (YEN; LANGARI, 1999). Consta na Figura 8 exemplos de funções de pertinência lineares, seguido de um exemplo de função Gaussiana, Figura 9.

Figura 8 - Função de pertinência linear tipo triangular e trapezoidal



Fonte: Do autor (2020)

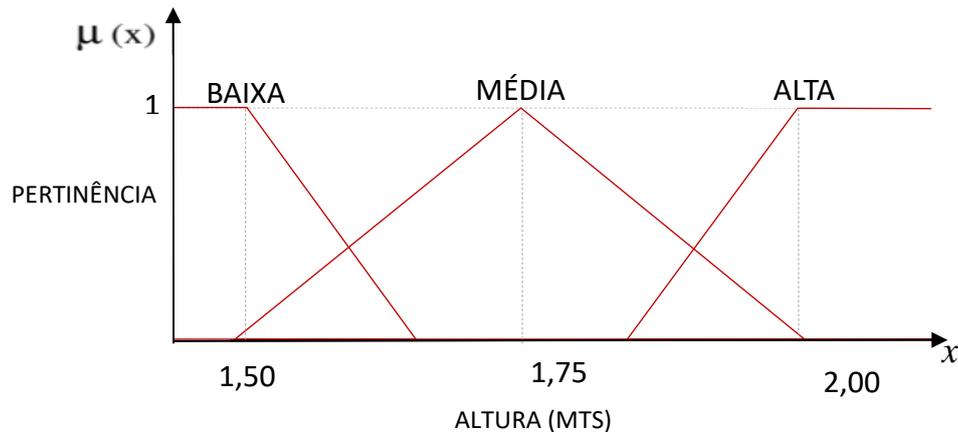
Figura 9 - Função de pertinência linear tipo Gaussiana



Fonte: Do autor (2020)

As funções de pertinência dependem diretamente do conjunto a que se deseja representar, podendo assumir diferentes formas. Para explicar a relevância deste contexto na determinação de uma função de pertinência e sua distribuição ao longo de um dado universo, foi considerada em caráter de exemplo uma variável linguística denominada “estatura”. Esta variável foi associada aos valores linguísticos: “baixa”, “média” e “alta” e seus conjuntos denotados “A”, “B” e “C”, definidos pelas funções de pertinência apontadas na Figura 3.3 (TANSCHKEIT, 2012).

Figura 10- Variável linguística “estatura” e suas funções de pertinência



Fonte: Do autor (2020)

Observa-se que estaturas abaixo de 1,50 metros apresentam grau de pertinência igual a 1 no conjunto A, decrescendo à medida que a estatura aumenta. Estaturas iguais a 1,75 metros é totalmente compatível com o conjunto B, assim como as estaturas acima de 1,75 metros apresentam grau de pertinência diferente de zero em C. Pessoas com altura superior a 2 metros, são “definitivamente” altas. As funções de pertinência devem ser definidas com base na experiência do usuário sobre o domínio do problema. Na prática, as formas escolhidas podem ser ajustadas em função dos resultados observados (TRANSCHEIT, 2012).

4.2 Clusterização *fuzzy*

Conforme já mencionado, a clusterização é uma técnica de análise de dados aplicada à solução de problemas que carecem de categorização. De acordo com Mota (2018), a modelagem fundamentada em agrupamentos *fuzzy* se baseia no conceito de pertinência para a determinação do grau em que uma amostra concerne à um grupo. Estudos relativos a utilização deste método se destinam a otimizar resultados de questões complexas de classificação. Este tipo de agrupamento, se distingue das técnicas clássicas em razão da possibilidade de suporte para associações parciais.

Nos conjuntos *fuzzy*, cada amostra de dados pode pertencer à várias classes simultaneamente, apresentando características importantes para descrever grânulos de informação (CHATTOPADHYAY; PRATI HAR; SARKAR, 2011). Estão entre os principais algoritmos *fuzzy* de clusterização: *fuzzy* C-Means (FCM), *Gustafson-Kessel* (GK) e *Gath-Geva* (GG).

4.3 Algoritmos de clusterização *fuzzy*

A escolha de um algoritmo de clusterização, dentre os diversos tipos existentes na literatura, deve estar relacionada à aplicação desejada e aos dados disponíveis. Se a análise dos clusters for útil para o propósito de exploração de dados, poderão ser comparados resultados em meio a execução de mais de um algoritmo, a fim de se descobrir padrões de comportamento (CAVALCANTI JUNIOR, 2006).

O algoritmo de clusterização *fuzzy* mais comum é o *Fuzzy C-Means* (FCM), sendo este, um dos primeiros algoritmos propostos para análise de agrupamentos. Ele consiste da versão *fuzzy* de um dos algoritmos de agrupamento mais populares e estudados da atualidade, denominado *K-means* (WU et al., 2008). Trata-se de um algoritmo iterativo que introduz valores arbitrários em “*c*” clusters, e com base nestes, relaciona cada elemento ao cluster mais próximo, formando “*c*” grupos. Utiliza-se a distância Euclideana. Posteriormente, o algoritmo calcula o centro de cada grupo formado, associando dados aos centros mais próximos. Desta maneira, os cálculos prosseguem iterativamente, até que as diferenças entre os centros do passo atual, em relação ao passo anterior, sejam mínimas. No FCM, cada objeto pertence a todos os grupos, porém com graus de pertinência distintos, sendo um elemento alocado em um grupo de acordo com o maior grau de pertinência (ZORZATE et al., 2006). O resultado final deste algoritmo consiste de uma matriz de partição $U = [u_{ij}]_{K \times N}$, contendo o grau de pertinência do objeto x_j ao grupo C_i .

O algoritmo *Gustafson-Kessel* (GK), apresentado por Donald E. Gustafson e Willian C. Kessel, em 1979, representa uma modificação do tradicional FCM, sendo a distância Euclidiana substituída pela distância de Mahalanobis. Esta inclui uma matriz de covariância entre os atributos disponíveis na base de dados. Esta matriz possui a incumbência de calcular a relação entre atributos, com a finalidade de possibilitar maior flexibilidade geométrica na representação dos grupos encontrados (BEZDEK et al., 2005). A matriz de covariância possibilita ao algoritmo determinar clusters na forma elipsoidal não necessariamente alinhada aos eixos ortogonais (GUSTAFSON; KESSEL, 1979).

Já o algoritmo *Gath-Geva* (GG), utiliza uma distância não-linear com respeito às matrizes de covariância, não se limitando em seu volume, apesar de também utilizar grupos hiperelípticos. Ao contrário do algoritmo de agrupamento GK, não existe neste algoritmo uma constante de volume para cada grupo, se tornando uma eficiente ferramenta para a detecção de grupos hiperelípticos com diferentes tamanhos e densidades. Em contrapartida, a distância empregada abrange um termo exponencial e, desta maneira, decresce mais rapidamente que a

norma induzida por produto interno. Isto faz com que o algoritmo encontre divisões quase-rígidas, e conseqüentemente, seja mais sensível a condições iniciais.

Por se tratar este estudo do desenvolvimento de um classificador baseado nos fundamentos de FCM, esta técnica será melhor explorada no tópico a seguir.

4.3.1 Clusterização *Fuzzy C-Means*

O algoritmo FCM é uma técnica não-hierárquica de agrupamento de dados originalmente desenvolvida por Jim Bezdek, em 1981, cujo propósito se destina a encontrar relações *fuzzy* para um conjunto de dados. Esta técnica se inicia com uma suposição incorreta referente aos centros de cada agrupamento, assinalando um grau de pertinência aos dados. Iterativamente, o *software* atualiza os centros de cada agrupamento, assim como os graus de pertinência anteriormente supostos. Esta iteração se destina em minimizar uma função objetivo, que representa a distância de cada padrão em relação ao centro de cada agrupamento. Estas pertinências podem assumir qualquer valor real no intervalo $[0, 1]$ (VALE, 2005). Apesar do grau de pertinência ser distinto em relação aos grupos, restringe-se geralmente sua função, de forma que a soma destas seja igual a 1, conforme demonstrado abaixo, onde i representa uma amostra, k o número de grupos, e u_{ik} o valor de pertinência da amostra i no grupo k :

$$\sum_{k=1}^k u_{ik} = 1 \quad (3.5)$$

Vários critérios de clusterização foram propostos para identificar partições *fuzzy* em uma determinada base de dados X . Destes, o mais comum está associado ao erro dos mínimos quadrados generalizados. Dado $X = \{x_1, x_2, \dots, x_N\} \subset R^n$, sendo este um conjunto com N amostras a serem alocadas em c clusters, onde x_k representa uma amostra (MOTA, 2018). O algoritmo é uma função iterativa que minimiza uma função objetivo, definida como:

$$J_m(U, v) = \sum_{k=1}^N \sum_{i=1}^c (u_{ik})^m \|x_k - v_i\|_A^2 \quad (3.6)$$

Em que U é a partição *fuzzy* de X ; c é o número de *clusters* em X ($2 \leq c < n$); $v = (v_1, v_2, \dots, v_c)$ é o vetor de centros; m é a constante de fuzzição ($1 \leq m \leq \infty$); A é a matriz de covariâncias ($n \times n$); $\|\cdot\|_A$ é a norma matricial induzida.

A matriz de partição A é a matriz identidade no FCM, o que induz clusters esféricos. A distância ao quadrado entre x_k e v_i em é dada pelo produto interno da diferença como:

$$d_{ik}^2 = \|x_k - v_i\|_A^2 = (x_k - v_i)^T A (x_k - v_i) \quad (3.7)$$

Os centros dos *clusters* e a matriz U são atualizados conforme:

$$v_i = \frac{\sum_{k=1}^N (u_{ki})^m x_k}{\sum_{k=1}^N (u_{ki})^m} \quad (3.8)$$

$$u_{ki} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ki}}{d_{kj}} \right)^{\frac{1}{m-1}}} \quad (3.9)$$

Para implementação, a matriz U é inicializada de forma aleatória. Então, U e v são atualizados de forma iterativa pela equação (3.8) e (3.9). Os centros dos *cluster* convergem para um determinado ponto no espaço dos dados quando não há mais variação significativa da matriz de partição observada, ou seja $\|\Delta U\| < \varepsilon$, em que ε é um limiar (MOTA, 2018).

4.4 Índices de Validação

De acordo com Horta (2013), os algoritmos de clusterização sempre apresentam alguma resposta, mesmo para o caso em que a base de dados não contém subestruturas. Nestes casos, as amostras são provenientes de distribuição uniforme. Um mesmo algoritmo pode ser aplicado várias vezes à mesma base, gerando soluções diferentes que tentam minimizar uma função objetivo.

Define-se por índice de validação (ou métodos de validação de modelos classificadores) as técnicas utilizadas para obtenção de uma quantificação do resultado de clusterização (CAVALCANTI JUNIOR, 2006). O índice é usado para determinação da quantidade ideal de *clusters* (RIBEIRO, 2017).

Yatskiv e Gusarova (2006) citam que o processo de análise de cluster finda examinar as seguintes propriedades de agrupamento: densidade; tamanhos e formas de aglomerado;

separabilidade de aglomerados, e robustez de certificação. Os índices ou critérios de validação podem ser internos, externos ou relativos, estando estes definidos a seguir.

4.4.1 Índice de validação externo

Os índices de validação externos medem o nível de concordância entre duas soluções (JAIN; DUBES, 1998). Neste tipo de validação, uma das partições comparadas consistirá de uma solução obtida pelo algoritmo, denotada por: $C^{ob} = \{C_1^{ob}, \dots, C_k^{ob}\}$, enquanto que a partição restante representará uma solução de referência para o conjunto analisado, denotado por $C^{ref} = \{C_1^{ref}, \dots, C_q^{ref}\}$. Para comparação de partições, vários critérios de similaridade se baseiam na contagem em pares de grupos. Estão entre os principais índices de validação externa: o índice rand (IR); índice jaccard (IJ); índice rand ajustado (IRA); e índice de informação mútua (IM) (PADILHA; CARVALHO, 2017).

4.4.2 Índice de validação relativo

Os índices relativos correlacionam as disposições dos agrupamentos entre si, a fim de determinar quais agrupamentos são mais estáveis ou mais apropriados aos dados (ARAÚJO NETO; NEGREIROS, 2017). Define-se desta forma, qual dentre um conjunto de soluções de agrupamento melhor representará os dados (JAIN; DUBES, 1998). Porém, foi observado que assim como qualquer algoritmo de agrupamento, diferentes índices deste tipo possuirão distintas suposições e subjetividade, cabendo aos envolvidos no processo de mineração dos dados optar pela solução que mais se adequa (PADILHA; CARVALHO, 2017). Estão entre os principais índices de validação relativa: o índice Dunn (ID), e o índice largura de silhueta (LS).

4.4.3 Índice de validação interno

Os índices de validação interna tomam por base uma matriz de similaridades e o grau em que uma solução é justificada, que pode ser visto como o grau de concordância encontrado pelo algoritmo entre o agrupamento e próprio conjunto de dados. Muitas das vezes, este índice é utilizado como função objetivo, a ser otimizado pelo algoritmo de agrupamento (PADILHA; CARVALHO, 2017).

Este tipo de validação é considerado o mais popular entre os demais índices citados. Ele é dividido em quatro categorias em função do tipo de estrutura da classe analisada: as ausências

completas de classe; presença de classe única; presença de poucas classes; presença de classificação hierárquica (YATSKIV e GUSAROVA, 2006).

4.4.4 Critério de Xie-Beni

A medida Xie-Beni (XIE; BENI, 1991) é um critério de validade baseado em uma função que identifica partições C difusas compactas e separadas, sem suposições quanto ao número de subestruturas inerentes aos dados. Essa função estará diretamente relacionada ao conjunto de dados, à distância geométrica, à distância entre os centroides do *cluster* e à partição difusa gerada por qualquer algoritmo difuso utilizado. Assim, esse critério é representado pelo quociente entre o erro quadrático médio de todos os pontos em relação a um centro e pela distância média entre os centroides dos *clusters*. A medida classificada como excelente, pelo critério Xie-Beni, é aquela ao qual o erro é pequeno, porém a distância entre os centros é grande, indicando que os pontos que têm maior pertinência ao grupo estão próximos entre si e distantes de pontos com menor pertinência. Os valores ótimos são os mais próximos de zero.

A equação que representa a medida Xie-Beni, com a substituição da distância Euclidiana pelo seno ao quadrado (KLEN, 2015), é a seguinte:

$$XB = \frac{\sum_j^K \sum_{i=1}^N u_{ij}^m [1 - (x_i \cdot v_j)^2]}{N (\min_{j \neq k} [1 - (v_j \cdot v_k)^2])} \quad (3.10)$$

Onde:

x_i ; v_j e v_k são vetores unitários com p - dimensões

$\forall j = 1 \dots K$

$\forall i = 1 \dots N$

N : número de amostras;

K : número de *clusters*;

u_{ij}^m : grau de pertinência;

V_j e V_k : centro de *clusters*;

$\min_{j \neq k} [1 - (V_j \cdot V_k)^2]$ = menor distância entre os agrupamentos.

A desvantagem da utilização da medida Xie-Beni é que ela tem uma tendência de um comportamento decrescente, enquanto o número de agrupamentos se aproxima do número total

de dados. Esse problema ocorre em maior frequência em um grande número de medidas, quando se utiliza o valor da função objetivo como critério para se eleger o número adequado de conjuntos. Assim, à medida que aumenta, o valor da função objetivo tende a diminuir, pois, com o acréscimo do número de agrupamentos, a soma das distâncias de cada amostra aos centros acaba reduzindo. Este problema pode ser contornado escolhendo-se adequadamente o número máximo de agrupamentos, quando se agrupam as descontinuidades em famílias. A escolha pode ser feita através da inspeção visual do diagrama de frequência de polos (KLEN, 2015).

4.4.5 Coeficiente de Partição (PC)

A medida de validação PC indica o número ótimo de categorias de um espaço amostral quando seu valor máximo é atingido. O valor deve se encontrar no intervalo de $[1/c, 1]$, indicando inexistência de grupos bem definidos quando este valor estiver próximo de $1/c$. O número ideal de *cluster* está no valor máximo. Assim, PC mensura a quantidade de sobreposição entre os centros de *cluster* e pode ser definida pela equação (BALASKO, ABONYI, FEIL, 2014; BEZDEK et al, 2005):

$$PC_{(c)} = \frac{1}{N} \sum_{i=1}^c \sum_{j=1}^N (\mu_{ij})^2 \quad (3.11)$$

onde:

c = número de *clusters*;

μ_{ij} é a associação dos pontos de dados j no *cluster* i ;

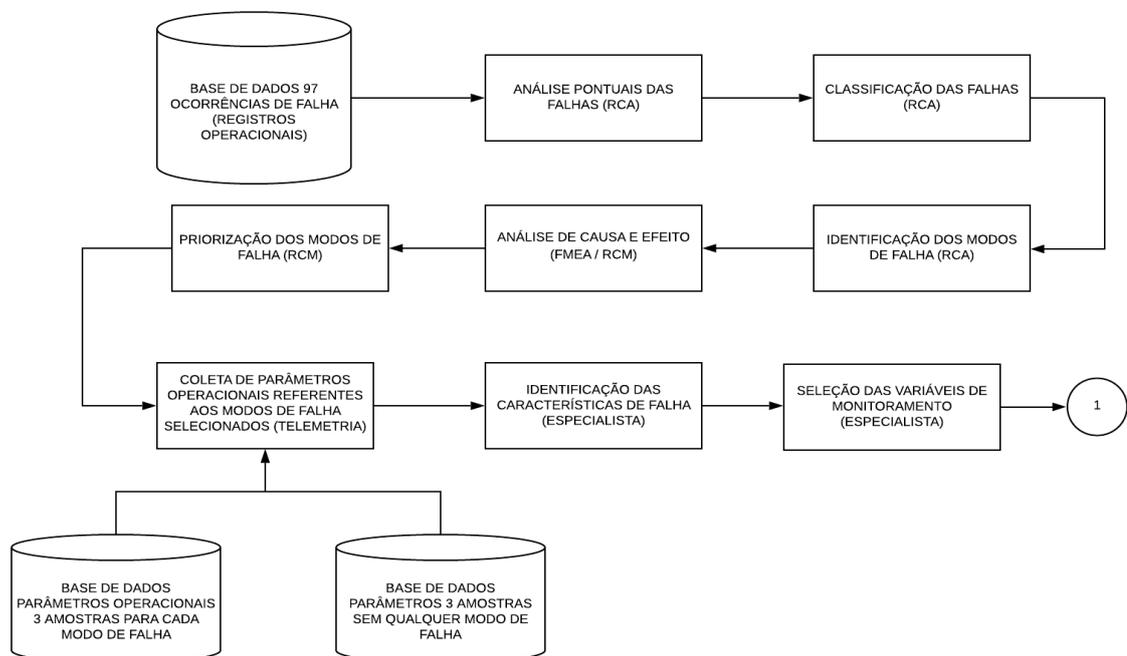
N = espaço amostral.

A desvantagem da utilização da medida de validação PC é a falta de conexão direta com alguma propriedade dos próprios dados (BALASKO, ABONYI, FEIL, 2014). Além disso, PC exhibe uma dependência de c com tendência a diminuir à medida que c aumenta (LI, 2011).

5 MATERIAIS E MÉTODOS

A metodologia deste trabalho foi dividida em duas principais etapas. A primeira, consistiu da seleção das perturbações mais representativas e de passível ocorrência em um grupo de 47 locomotivas diesel-elétrica. Para tal, conforme demonstrado no fluxograma da Figura 11, utilizou-se uma base de dados composta de 97 avarias, ocorridas em um intervalo contínuo de 10 meses. Aplicou-se nesta base as técnicas de análise compreendidas na metodologia RCA, obtendo a classificação de cada falha. Desta classificação, estimou-se os modos de falha de passível ocorrência ao grupo de locomotivas analisado. Posteriormente, através da aplicação das metodologias FMEA e RCM, priorizou-se os modos de falha mais representativos no contexto operacional. Foram extraídos por meio de instrumentação embarcada os parâmetros funcionais de cada locomotiva, e através de conhecimento especialista, identificadas as características fundamentais de cada modo de falha selecionado. Desta identificação, foram definidas as variáveis de entrada para o algoritmo.

Figura 11- Fluxograma primeira etapa do trabalho



Fonte: Do autor (2020)

A segunda etapa, se embasou no desenvolvimento de um classificador fundamentado na técnica de clusterização *fuzzy C-Means*, dedicado à detecção e classificação dos modos de falha anteriormente selecionados. O desenvolvimento deste algoritmo foi concretizado através de seis

estágios, sendo eles: aquisição de dados, pré-processamento de dados, extração de características, treinamento, validação, teste e classificação. Cada estágio, em conjunto com as etapas mencionadas do projeto estão elucidados nos subtópicos a seguir.

5.1 Análise de uma base histórica de ocorrências de falha em um grupo de locomotivas

Para esta primeira etapa do trabalho, foi coletada uma base histórica referente ao registro de falhas ocorridas em um grupo específico de 47 locomotivas diesel-elétricas do tipo AC-DC modelo EMD SD40 MPC (microprocessada), que opera nos estados do Paraná, Santa Catarina e Porto Alegre. Utilizou-se de um período de acompanhamento de janeiro a outubro de 2018, totalizando uma base com 97 ocorrências.

Cada uma das ocorrências e suas respectivas causas técnicas foram analisadas pontualmente e classificadas em quatro diferentes níveis: sistema, conjunto, item e problema, obedecendo as seguintes definições:

- a) **Sistema:** sistema da locomotiva que levou ao fator causal;
- b) **Conjunto:** conjunto que levou ao mau desempenho do sistema;
- c) **Item:** item que levou à falha do conjunto;
- d) **Problema:** característica de falha apresenta pelo item.

Assim, a causa técnica relativa a cada ocorrência foi definida pelo somatório destes quatro níveis, conforme demonstrado na equação 5.1:

$$CT = SIS + CO + IT + PR \quad (5.1)$$

Onde:

CT é a causa técnica; SIS é o sistema; CO é o conjunto; IT é o item; PR é o problema.

O modo de falha por sua vez, foi caracterizado pelos seguintes graus classificatórios: sintoma padronizado, conjunto e item. Para o sintoma padronizado, foi considerado o fator causal que levou à parada não planejada do ativo. A equação para o modo de falha está representada a seguir:

$$MF = SP + (CO + IT) \quad (5.2)$$

Onde:

MF é modo de falha; SP é o sintoma padronizado; CO é o conjunto; IT é o item.

Para o sintoma padronizado, foram utilizadas 22 classificações, conforme apresentado no Quadro 1 do Apêndice B. Para o sistema foram definidas 13 classificações, segundo Quadro 2 do Apêndice B. Para o conjunto 60 classificações, estando estas apresentadas no Quadro 3 do Apêndice B. E, por fim para o item, 50 classificações de acordo com o Quadro 4 do Apêndice B. O Quadro 1 apresenta três exemplos de como foi feita a classificação das 97 ocorrências do período avaliado. As demais classificações, se encontram Apêndice C.

Quadro 1- Análise das ocorrências das falhas e suas respectivas classificações

DATA	EQUIP.	FROTA	MODO DE FALHA	CLASSE DE FALHA			
			SINTOMA PADRONIZADO	SISTEMA	CONJUNTO	ITEM	PROBLEMA
06/01/2018	9504	SD40	Baixa isolamento circuito de potência	Propulsão	Motor de tração	Escovas	Baixa isolamento
15/01/2018	9479	SD40	Travamento de rodeiro	Propulsão	Motor de tração	MT - Rolamento lado pinhão	Travado
16/01/2018	9520	SD40	Acusando MD quente	Arrefecimento	Ventilador elétrico	Motor do ventilador radiador	Curto

Fonte: Do autor (2020)

Para o equipamento 9504, por exemplo, pode-se avaliar a classe de falha e o modo de falha da seguinte maneira:

- a) **Classe de falha:** problema técnico de baixa isolamento nas escovas do motor de tração do sistema de propulsão da locomotiva;
- b) **Modo de falha:** parada do ativo em função da baixa isolamento do circuito de potência, que teve como causa o aterramento do porta escovas de um dos motores de tração.

5.2 Priorização dos modos de falha utilizando a metodologia RCM

Com as falhas pontualmente classificadas, esta etapa consiste em determinar quais dos modos de falha serão priorizados. Para esta função, foi utilizada uma adaptação das ferramentas de RCM abordadas no Tópico 2, obedecendo a seguinte equação de avaliação para cada modo de falha mapeado:

$$\text{FPRIO} = (\text{TO}) \times (\text{EMF}) \times (\text{IS}) \times (\text{VM}) \times (\text{FP}) \quad (5.3)$$

Onde:

- a) FPRIO é fator de priorização;
- b) TO é a taxa de ocorrência, dada por:

$$\text{TO} = \frac{\text{Número de eventos ocorridos}}{\text{Total de eventos analisados}} \quad (5.4)$$

- c) EMF é o efeito do modo de falha, baseado nos seguintes pesos:
 - **Peso 1:** perda parcial da função primária da máquina, possibilidade de seguir operando até próximo posto de manutenção;
 - **Peso 2:** perda total da função primária da máquina, porém com possibilidades de corretiva não planejada no local da falha para recuperação da operacionalidade do ativo;
 - **Peso 3:** perda total da função primária da máquina, com possibilidade de corretiva não planejada no local da falha, porém com necessidade de liberação do ativo com alguma restrição operacional;
 - **Peso 4:** perda total da operacionalidade da máquina, sem qualquer possibilidade de recuperação no local da avaria, necessitando o reboque da locomotiva para oficina.
- d) IS é índice de severidade, baseado no agrupamento de duas variáveis classificatórias, atreladas aos pesos OE= 1, OO= 2, EE= 3, EO= 4, ES= 5, OS= 6, sendo:
 - **Letra 1** é relativa à visibilidade do modo de falha:
 - E: evidente ao operador;
 - O: oculta ao operador.
 - **Letra 2** é relativa à consequência do modo de falha:
 - S: riscos de danos à segurança pessoal, pessoal ou meio ambiente;
 - O: impactos operacionais;

- E: impactos econômicos, sem impactar significativamente na operação.
- e) VM é o número de parâmetros passíveis de monitoramento para predição do modo de falha:
- Fator variante em acordo com os números de variáveis, podendo variar de 1 a 6.
- f) FP é o fator de predição, que define o grau de precisão para detectar uma iminência de falha por meio do monitoramento de parâmetros operacionais da máquina:
- **Fator 1:** sem possibilidade de detecção;
 - **Fator 2:** baixa precisão, ou detecção algumas horas antes da falha ser instaurada;
 - **Fator 3:** média precisão, ou detecção alguns dias antes da falha ser instaurada;
 - **Fator 4:** alta precisão, ou detecção algumas semanas antes da falha ser instaurada;
 - **Fator 5:** alta precisão, ou detecção alguns meses antes da instauração da falha.

A partir dos dados obtidos, determinou-se que as falhas priorizadas seriam aquelas com fator de priorização maior que 1,5.

Ao todo, foram identificados 32 modos de falhas distintos, e por meio da etapa de priorização quatro atenderam o critério $FPRIO > 1,5$ e foram selecionados para o estágio de classificação por meio do algoritmo. O Quadro 2 apresenta os modos de falha selecionados e suas respectivas classificações pelo emprego da metodologia de RCM. As demais classificações se encontram no Apêndice D.

Quadro 2- Classificações dos modos de falha por intermédio das técnicas de RCM

MODO DE FALHA	CONSEQUÊNCIA	EMF	OC	TO	S	IS	FP	VM	FPRIO
Baixa aderência (Controle de aderência / Transdutor de corrente)	Perda parcial operacionalidade da máquina, com possibilidade de seguir até próximo posto de manutenção.	1	9	9%	OO	2	5	6	5,57
Baixa aderência (MT / Campo aberto)	Perda parcial operacionalidade da máquina, possibilidade de seguir até próximo posto de manutenção.	1	5	5%	OO	2	5	6	3,09
Baixa potência (Filtro primário combustível / Elemento do filtro)	Perda parcial operacionalidade da máquina, possibilidade de seguir até próximo posto de manutenção.	2	5	5%	OO	2	3	4	2,47
Acusando MD quente (radiador / radiador conjunto)	Perda total da operacionalidade da máquina, com possibilidade de corretiva no local, porém necessita de liberação com alguma restrição.	4	5	5%	EO	4	2	1	1,65

Legenda: (EMF) efeito modo de falha, (OC) ocorrência, (TO) taxa de ocorrência, (S) severidade, (IS) índice de severidade, (FP) fator de predição, (VM) variáveis monitoráveis, (FPRIO) fator de priorização.

Fonte: Do autor (2019)

Para o modo de falha “baixa aderência (controle de aderência / transdutor de corrente)” por exemplo, pode-se avaliar o FPRIO da seguinte maneira: o efeito do modo de falha será a perda parcial da operacionalidade da máquina, com possibilidade de ela seguir até o próximo posto de manutenção. A taxa de ocorrência deste modo de falha é de 9% das 97 falhas classificadas, sendo esta, uma falha oculta ao operador, com alto fator de predição e possibilidade de ser monitorada por 6 variáveis distintas. Esta classificação obteve um fator de priorização 5,57.

Assim, foram selecionados os seguintes modos de falha, que por caráter de simplificação, serão referidos por MF1 (modo de falha 1), MF2 (modo de falha 2), MF3 (modo de falha 3), MF4 (modo de falha 4) e SF (sem falha).

- a) **MF1:** Baixa aderência; Controle de aderência; Transdutor de corrente;
- b) **MF2:** Baixa aderência; Motor de tração; campo aberto;
- c) **MF3:** Baixa potência; Filtro primário de combustível; Elemento de filtro;
- d) **MF4:** Acusando motor Diesel quente; Radiador; Radiador conjunto.
- e) **SF:** Sem falha (sem modos de falha instaurado).

A próxima etapa deste trabalho se baseiou na coleta de uma base de dados referente aos parâmetros funcionais do grupo de locomotivas em análise, com a finalidade de relacionar os modos de falha priorizados com possíveis padrões e paridades existentes.

5.3 Aquisição de dados e definição das variáveis de monitoramento

Os parâmetros funcionais das locomotivas foram coletados por meio de um sistema embarcado permanente denominado SAL (*System Automation Locomotive*), presente em cada uma das 47 locomotivas (parte integrante do sistema de microprocessamento). Este sistema é composto por uma CPU (*Central Processing Unit*), uma interface de controle, sensores para leitura dos parâmetros funcionais da máquina, um módulo registrador e uma interface GPRS (*General Packet Radio Services*) dedicada à transmissão dos dados por meio de telemetria. Este

sistema é capaz de monitorar e registrar ao todo 26 variáveis, a uma taxa de amostragem de 1 Hertz, conforme descritas no Quadro 3.

Quadro 3- Variáveis monitoradas pelo sistema embarcado das locomotivas

SISTEMA	PARÂMETROS MONITORÁVEIS	TIPO DE SENSORIAMENTO	FAIXA TRABALHO
Arrefecimento	Temperatura da água de arrefecimento	PT100	70 - 85 °C
	Pressão de água sistema arrefecimento	Transdutor pressão (4-20 mA)	55 - 65 °C
Partida e carga de bateria	Tensão da bateria	Voltímetro	62 - 74 Volts
Combustível	Pressão do óleo combustível	Transdutor pressão (4-20 mA)	26 - 34 PSI
Pneumático	Pressão cilindro de freio	Transdutor pressão (4-20 mA)	0 - 74 PSI
	Pressão do encanamento geral	Transdutor pressão (4-20 mA)	0 - 90 PSI
	Pressão do reservatório principal	Transdutor pressão (4-20 mA)	120 - 140 PSI
Partida e carga de bateria: Gerador auxiliar	Corrente de campo do gerador auxiliar	Transdutor corrente hall	1 - 5 Amperes
	Tensão de campo no gerador auxiliar	Voltímetro	5 - 10 Volts
	Tensão de saída do gerador auxiliar	Voltímetro	73 - 78 Volts
Propulsão: Gerador companheiro	Tensão no gerador companheiro	Voltímetro	50 - 250 Volts
Propulsão Gerador de tração	Corrente de campo do gerador tração	Transdutor corrente hall	20 - 70 Amperes
	Corrente de saída do gerador de tração	Transdutor corrente hall	0 - 2800 Amperes
	Potência de saída do gerador de tração	Relação Tensão x corrente (algoritmo)	0 - 3100 HP
	Tensão de saída do gerador de tração	Voltímetro	0 - 1000 Volts
Lubrificação	Pressão do lubrificante	Transdutor pressão (4-20 mA)	45 - 50 PSI
	Temperatura do óleo lubrificante antes do resfriador	PT100	70 - 90 °C
	Temperatura do óleo lubrificante depois do resfriador	PT100	70 - 78 °C
Motor a combustão	Regulador de carga do motor diesel	Sinal analógico reostato	0 - 100 %
Propulsão: Motores de tração	Corrente motor de tração 1	Transdutor corrente hall	0 - 1000 Amperes
	Corrente motor de tração 2	Transdutor corrente hall	0 - 1000 Amperes
	Corrente motor de tração 3	Transdutor corrente hall	0 - 1000 Amperes
	Corrente motor de tração 4	Transdutor corrente hall	0 - 1000 Amperes
Propulsão: Motores de tração	Corrente motor de tração 5	Transdutor corrente hall	0 - 1000 Amperes
	Corrente motor de tração 6	Transdutor corrente hall	0 - 1000 Amperes
Operação	Pontos de aceleração	Entrada discreta (digital)	0 - 8º ponto
	Velocidade da locomotiva	GPS	0 - 60 KM/H

Fonte: Do autor (2020)

A base coletada (concernente as 26 variáveis citadas) possuía inicialmente 879.454 amostras, representando um total de 22.865.804 dados (879.454 x 26), distribuídos em acordo com seguintes características de operação:

- a) 4.084.898 dados coletados de 3 locomotivas que não apresentaram quaisquer modos de falha, operando ao longo de 3 dias.

- b) 6.961.936 dados coletados de 4 locomotivas que apresentaram o MF1, operando em um intervalo de 3 dias.
- c) 6.475.888 dados coletados de 4 locomotivas que apresentaram o MF2, operando ao longo de 3 dias.
- d) 2.677.850 dados coletados de 4 locomotivas que apresentaram o MF3, em um intervalo de 3 dias em operação.
- e) 2.665.232 dados coletados de 3 locomotivas que apresentaram o MF4, operando em um intervalo de 3 dias.

Por meio de uma análise dos dados, e de conhecimento prévio da funcionalidade desta frota de locomotivas, foi possível determinar certas singularidades apresentadas a cada um dos modos de falha e correlacioná-las com padrões manifestados pelas variáveis monitoradas.

Inicialmente, foi necessário definir uma condição operacional comum para análise dos parâmetros, visto que em razão do elevado alcance dinâmico apresentado nos valores das variáveis, um mesmo modo de falha apresentou singularidades distintas para diferentes formas de condução da locomotiva. Como por exemplo o MF4, que manifestou nos valores da variável temperatura da água do sistema de arrefecimento um grande deslocamento em relação a média, justamente quando a locomotiva operava em sua máxima potência (oitavo ponto de aceleração do motor diesel), retornando à normalidade quando o motor diesel era menos exigido.

Importante ressaltar que condução de uma locomotiva diesel-elétrica está em função das seguintes características de operação: do ponto de aceleração do motor diesel, da potência demanda do gerador de tração em razão do esforço trator exigido pelo peso do trem, da velocidade de condução e do coeficiente de atrito entre roda e trilho. O motor diesel de uma locomotiva diesel-elétrica pode ser operado em oito rotações distintas, denominado pontos de aceleração. Para cada rotação, será liberado para o gerador de tração uma potência específica através do controle da corrente de campo deste gerador por meio de uma malha de controle. Locomotivas operando em oitavo ponto terão seus geradores de tração produzindo em máxima potência (para a frota SD40-MP observada 3000 HP). A potência de uma locomotiva por sua vez, será demandada pelo esforço trator exigido da locomotiva para o quadro de tração o qual o trem está submetido (peso total dos vagões mais variáveis da via como quantidade de rampas, curvas, entre outros).

Foi observado que durante operações em oitavo ponto em aceleração, as locomotivas apresentaram valores mais estáveis em seus parâmetros funcionais, muitos destes já conhecidos

através de manuais técnicos da máquina (parâmetros nominais). Também se observou que as singularidades existentes aos modos de falha eram bem mais acentuadas quando a locomotiva opera em potências mais elevadas. Desta forma, todas as características relativas aos modos de falha foram analisadas após o condicionamento dos parâmetros em oitavo ponto de aceleração.

Para o MF1, foram identificadas variações significativas no valor da corrente de um dos motores em relação aos demais. Esta disparidade ocorreu pelo aumento abrupto da rotação do eixo deste motor durante o deslize das rodas, que, ao ser detectada pelo sistema de controle e aderência, é imediatamente mitigada através da redução da corrente do campo do gerador de tração (correção da aderência). Oscilações nos valores das correntes entre motores de tração também podem estar associadas a outros fatores, como por exemplo a uma leitura incorreta apresentada por algum transdutor dedicado, levando a uma falsa detecção de deslize de rodas pelo sistema, comprometendo a operacionalidade da locomotiva em virtude da constante redução indevida no campo do gerador de tração.

Para o MF2, foram observadas variações ainda mais acentuada nos valores das correntes desses motores, ocorrendo na grande maioria das vezes de forma intermitente. Estas severas oscilações estão vinculadas com a alteração no valor da resistência da bobina de campo de um dos motores, caracterizando um provável rompimento desta bobina.

Para o MF3, observou-se que a variável potência do gerador de tração assumiu valores bem inferiores durante a ocorrência do modo de falha comparado aos intervalos de não ocorrência, principalmente em condições operacionais o qual era exigido uma maior capacidade de potência. Ao mesmo tempo que foi detectado um aumento bastante significativo na pressão do óleo combustível. Esta inversa proporção nos valores destas duas variáveis está diretamente relacionada ao baixo fluxo de diesel nos cilindros do motor diesel da locomotiva, ocasionada pela obstrução da linha de combustível pela impregnação dos filtros existentes neste sistema (razão pelo aumento da pressão na linha).

Para o MF4, foi observado uma elevação nos valores da variável temperatura do líquido de arrefecimento. Esta característica está diretamente relacionada a baixa eficiência na troca de calor efetuada pelo radiador (mais evidente durante operações que exigem maior potência da locomotiva pela elevação de seu esforço trator).

As singularidades detectas em cada modo de falha estão representadas no Quadro 4.

Quadro 4 – Variáveis de monitoramento dos modos de falha selecionados

MODO DE FALHA	VARIÁVEIS RELACIONADAS	SINGULARIDADES ENCONTRADAS
Baixa aderência / Controle de aderência / Transdutor de corrente	Corrente MT1 Corrente MT2 Corrente MT3 Corrente MT4 Corrente MT5 Corrente MT6	No momento que as locomotivas apresentaram este modo de falha, ocorreram desequilíbrios nos valores da corrente de um de seus motores de tração em relação aos demais.
Baixa aderência (MT / Campo aberto)	Corrente MT1 Corrente MT2 Corrente MT3 Corrente MT4 Corrente MT5 Corrente MT6	No momento que as locomotivas apresentaram este modo de falha, ocorreram desequilíbrios (de grandeza bem mais elevada que a apresentada ao MF1) nos valores da corrente de um de seus motores de tração em relação aos demais.
Baixa potência / Filtro primário combustível / Elemento do filtro	Pressão Diesel Potência do Gerador de tração	Foi identificado que as locomotivas que operavam com este modo de falha instaurado, apresentaram uma proporção inversa entre o valor da pressão do combustível e a potência do gerador principal. Ou seja, a medida que a pressão de combustível se elevava em valores acima do valor médio, a potência do gerador principal era reduzida.
Acusando MD quente / radiador / radiador conjunto	Temperatura do líquido de arrefecimento do motor diesel	Foi identificado que as locomotivas que apresentaram este modo de falha, operavam com a temperatura da água de arrefecimento acima da média em relação as locomotivas que não apresentaram o modo de falha.

Fonte: Do autor (2020)

Das 26 variáveis de monitoramento coletas, 9 foram suficientes para reconhecimento dos modos de falha (corrente MT1, corrente MT2, corrente MT3, corrente MT4, corrente MT5, corrente MT6, pressão diesel, potência gerador de tração e temperatura do líquido de arrefecimento do motor diesel), juntamente com a variável condicionante ponto de aceleração do motor diesel. Desta maneira, da base inicial contendo os 22.865.804 dados, foram selecionados 8.994.550 (10 vetores com 879.455 dados cada) para o desenvolvimento do algoritmo.

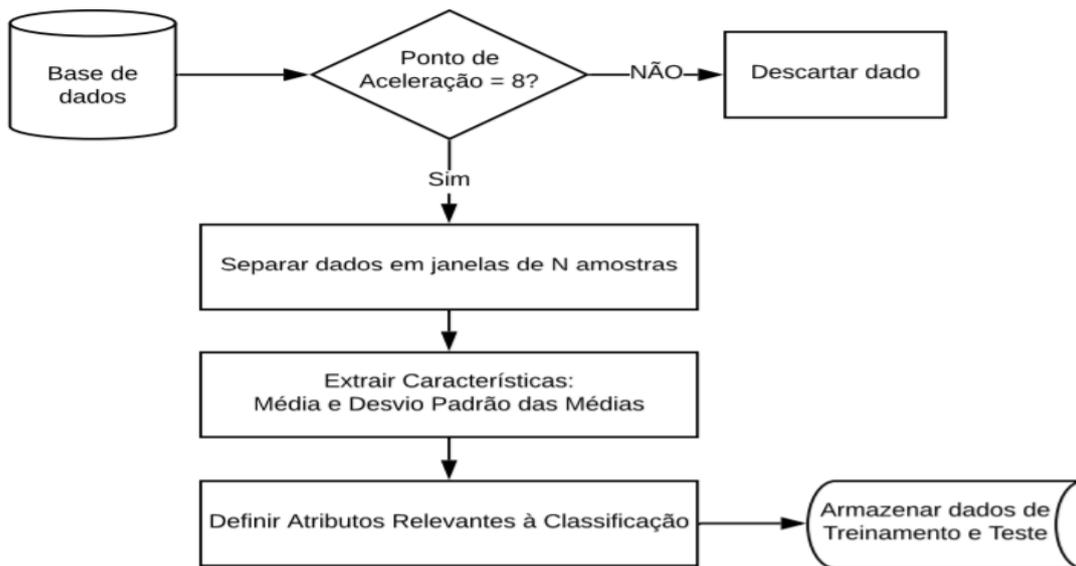
Uma vez definidas as variáveis a serem utilizadas no método proposto, a etapa seguinte se baseou no desenvolvimento do algoritmo para detecção e classificação dos modos de falha.

5.4 Pré-processamento e extração de características

O algoritmo classificador de falhas foi desenvolvido no *software* Matlab 2008, utilizando-se dos seguintes recursos de *hardware*: processador Intel Core i7-8550U Quad Core 1.8 GHz, memória RAM de 8 GB DDR4 2400 MHz e disco rígido de 1 TB 5400 RPM. A primeira etapa para sua elaboração transcorreu pelo pré-processamento dos dados de coleta,

visando a preparação, a organização e a estruturação da base. A segunda etapa baseou-se no processo de extração de características, tendo por objetivo a construção de combinações de valores para as variáveis selecionadas, de modo a descrever de maneira mais precisa as singularidades identificadas para cada modo de falha. Os atributos extraídos neste processo foram direcionados para entrada no classificador *fuzzy*. As etapas de pré-processamento e extração de característica estão representadas através do fluxograma da figura 12.

Figura 12- Fluxograma pré-processamento dos dados extração das características



Fonte: Do autor (2020)

Conforme mencionado no subtópico 5.3, locomotivas Diesel-elétricas são máquinas que apresentam uma extensa faixa dinâmica em seus parâmetros operacionais, resultando em uma elevada variabilidade nos valores apresentados pelos pontos monitoramento. Estas variações estão correlacionadas com as diferentes formas de condução da locomotiva durante o tráfego dos trens. Seria inviável a classificação de cada um dos modos de falha sem condicionantes operacionais pré-definidas. Por esta razão, foram reproduzidas no algoritmo as mesmas condicionantes utilizadas para o reconhecimento dos modos de falha baseado na análise humana.

Uma locomotiva operando próximo a sua potência nominal (quando operada em oitavo ponto), disporá de parâmetros mais lineares e conhecidos, facilitando a identificação das singularidades observadas aos modos de falha, acarretando em uma modelagem mais precisa para a concepção do classificador. Desta forma, a primeira fase da etapa de pré-processamento

se deu pela filtragem dos dados de entrada pelo condicionante oitavo ponto em aceleração, levando ao descarte dos demais dados que não atendiam este quesito. Esta etapa resultou na seleção dos dados de maior representatividade para o classificador e uma significativa redução da dimensionalidade da base, proporcionando uma maior precisão para categorização dos modos de falha. Das 879.455 amostras referente as 10 variáveis que deram entrada neste primeiro processo (9 variáveis de monitoramento mais uma variável condicionante), 41.284 foram selecionadas para a próxima etapa da construção do algoritmo, levando ao descarte das demais.

O pré-processamento de dados em sua segunda instancia, se baseou em uma nova redução da dimensionalidade da base de dados pela extração da média aritmética de cada variável para uma janela de 30 dados ($N=30$). Isso porque, a taxa de amostragem de 1 Hz do sistema de aquisição gerou uma grande quantidade de dados sem variações representativas, muitas vezes redundantes. Esta etapa do processo foi responsável pela redução da base 97% da base de dados, reduzindo-a de 41.284 para 1.423 amostras.

Posteriormente, os valores assumidos em cada uma das variáveis passaram por um processo de normalização, pois, a variação em suas ordens de grandezas poderiam comprometer a interpretação dos resultados. Para tal, foi utilizada a técnica de normalização tipo range (ou reescala), convertendo cada variável em valores entre 0 e 1.

Da base de dados já pré-processada, foram extraídos seis diferentes atributos (relativos às nove variáveis de monitoramento), de modo a representar as singularidades encontradas em cada um dos modos de falha, para posterior entrada no classificador *fuzzy*.

Para o MF1 e MF2, calculou-se a média aritmética e posteriormente o desvio padrão dos valores apresentados pelas correntes dos seis MTs, em razão das variações significativas apresentadas nos valores da corrente de um dos motores em relação aos demais durante a ocorrência destes modos de falha. Portanto, das seis variáveis referentes aos valores de corrente dos MTs, foram extraídos dois atributos para a entrada no classificador, sendo elas: a “média aritmética dos valores das correntes” e o “desvio padrão” calculado para as mesmas.

Para o MF3, calculou-se o desvio padrão referente aos valores apresentados pelas variáveis pressão do combustível e a potência do gerador de tração, pois durante a ocorrência deste modo de falha estas duas variáveis passaram a assumir uma proporcionalidade inversa, ou seja, a pressão de combustível se elevou a valores bem acima da média enquanto a potência do gerador de tração decaia a valores abaixo da nominal. Das variáveis pressão de combustível e potência do gerador de tração foram extraídos dois atributos para a entrada no classificador

fuzzy, que são: “o desvio padrão entre a pressão de combustível e a potência do gerador de tração” e a “pressão de combustível”.

Por fim, para o MF4, observou-se que durante a instauração do modo de falha, os valores apresentados pela variável temperatura do líquido de arrefecimento do motor diesel se elevaram a temperaturas bem acima da média se comparadas as locomotivas que operava sem o modo de falha, principalmente quando era exigido maior potência e esforço trator da locomotiva. Desta maneira, foi estabelecido como atributo para o MF4 a “temperatura do líquido de arrefecimento do motor diesel”.

Como resultado do processo de extração de características, foram obtidos os seis diferentes atributos representados na Figura 13 para entrada no classificador *fuzzy*.

Figura 13- Relação de atributos extraídos para entrada no classificador *fuzzy*

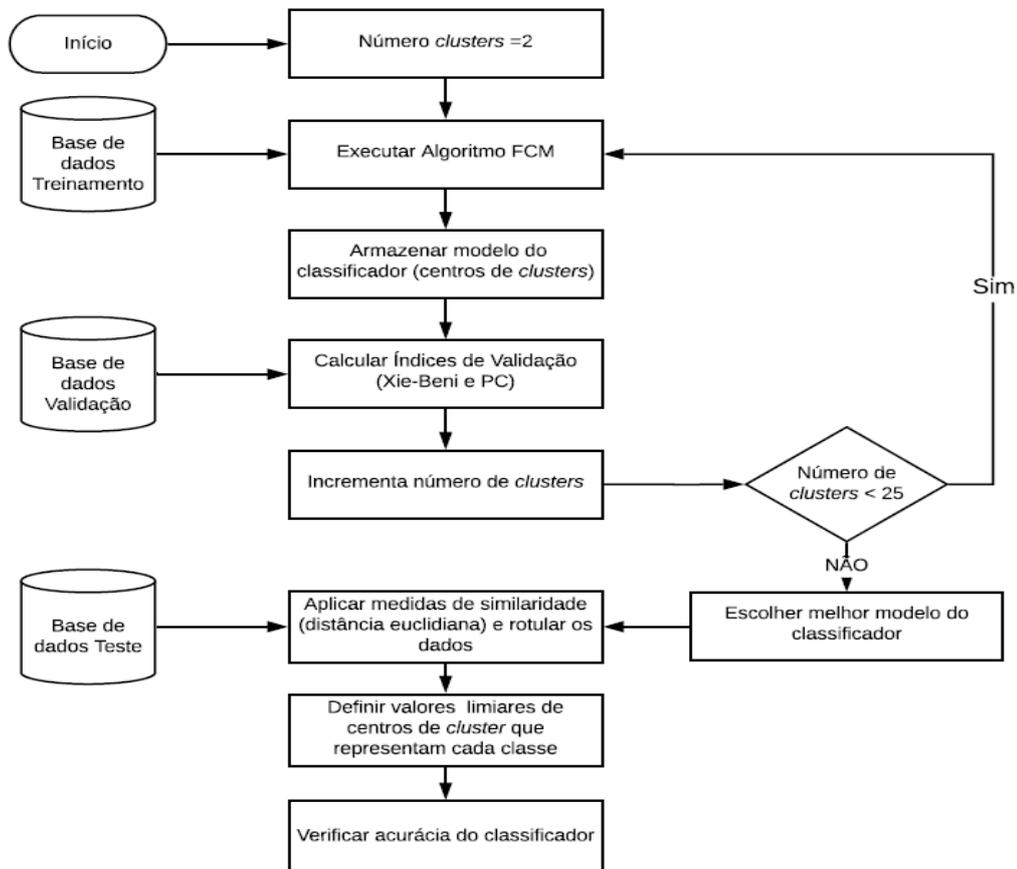


Fonte: Do autor (2020)

5.5 Clusterização *fuzzy C-Means*

Nesta etapa do estudo, foram gerados modelos por meio da técnica *fuzzy C-Means* para o reconhecimento e classificações das características dos modos de falha anteriormente extraídas. A implementação deste algoritmo foi realizada conforme fluxograma apresentado na Figura 15. Como pode ser visto, ele foi subdividido em 5 estágios: separação da base de dados, treinamento, validação, teste e classificação. Cada estágio deste fluxograma será melhor abordado nos subtópicos a seguir.

Figura 14- Fluxograma etapas de treinamento e validação do algoritmo



Fonte: Do autor (2020)

5.5.1 Separação da base de dados

A base de dados pré-processada, composta pelos seis atributos de entrada para o classificador (contendo as 1.423 amostras) foi fracionada, formando três grupos distintos denominados: base de treinamento (60% da base), base de validação (20% da base) e base de teste (20% da base), distribuídas em acordo com os números apresentados na Tabela 1.

Tabela 1- Distribuição dos dados nas base de treinamento, validação e teste

MODOS DE FALHA	DISTRIBUIÇÃO DAS AMOSTRAS		
	TREINAMENTO	VALIDAÇÃO	TESTE
MF1	144	54	42
MF2	45	50	51
MF3	61	15	15
MF4	100	33	35
SF	503	133	142
Total	853	285	285

Fonte: Do autor (2020)

A base de treinamento foi utilizada no processo de clusterização dos dados pela aplicação do algoritmo *fuzzy C-means*, com o objetivo de modelar o problema. Posteriormente, foi experimentado cada um dos grupos de *clusters* na segunda base, e através do cálculo dos índices de validação definido qual possuía maior representatividade. Com o número de *cluster* agora estabelecido, foi aplicado este agrupamento à terceira base para rotulação, classificação e o cálculo da acurácia do classificador. Cada uma destas etapas será detalhadamente descrita nos subtópicos a seguir.

5.5.2 Treinamento e validação do algoritmo

Na etapa de treinamento, o algoritmo *fuzzy C-Means* (FCM) foi executado visando a criação de um modelo que melhor representasse os dados. Entende-se como modelo os números de clusters e sua arquitetura entre centros definidos pelo FCM. Assim, FCM foi executado para um dado número de *clusters* e os modelos gerados foram armazenados. Em seguida, os dados de validação foram utilizados para obtenção do coeficiente de partição (PC) e do índice Xie-Beni. Foi definido um limite superior para o número de *clusters* $c_{max} = 25$, e o algoritmo foi executado para cada $c \in \{2, 3, \dots, c_{max}\}$. O modelo que minimizou o índice Xie-Beni ou maximizou o PC foi escolhido como o melhor modelo e utilizado na etapa de classificação.

5.5.3 Teste e classificação

Definido o modelo de agrupamento mais representativo através dos critérios de validação PC e Xie-Beni, esta última etapa do trabalho fundamentou-se em rotular e classificar os dados contidos em uma base distinta (base de teste) em função deste modelo, e então mensurar o nível de acurácia do classificador.

Para cada dado existente na base, foi definido o nível de similaridade deste em relação aos centros de *clusters* utilizando-se dos cálculos de suas distâncias euclidianas. Cada dado foi atribuído ao *cluster* que apresentou menor variação desta distância, obtendo desta forma a rotulação da base de dados.

Posteriormente, cada centro de cluster foi classificado em função de seu posicionamento no modelo extraído utilizando-se de limiares pré-estabelecidos, baseando-se nas características e singularidades observadas para cada modo de falha (subtópico 5.3).

Para o MF1, representado pelos atributos “média da corrente dos seis motores de tração” e “desvio padrão entre as correntes dos seis motores de tração”, foram classificados os centros

de *clusters* alocados entre os valores normalizados 0,05 e 0,19 do eixo “desvio padrão entre as correntes dos seis motores de tração”.

Para o MF2, também representado pelos atributos “média da corrente dos seis motores de tração” e “desvio padrão entre as correntes dos seis motores de tração”, foram classificados os centros de *clusters* que se encontravam alocados acima de 0,2 (valor normalizado) do eixo referente ao atributo “desvio padrão entre as correntes dos seis motores de tração”.

Para o MF3, retratado pelos atributos “desvio padrão entre pressão do combustível e potência do gerador de tração” e “potência do gerador de tração” foram classificados os centros de *clusters* alocados acima de 0,5 (valor normalizado) do eixo atinente ao atributo “desvio padrão entre pressão do combustível e potência do gerador de tração”.

Por fim, para o MF4, representado pelos atributos “temperatura do líquido de arrefecimento do motor diesel” e “potência do gerador de tração”, foram classificados os centros de *clusters* alocados acima de 0,6 (para valores normalizados) do eixo referente ao atributo “temperatura do líquido de arrefecimento do motor diesel”.

Desta forma obteve-se a classificação de cada centro de cluster, e os dados atribuídos a estes foram rotulados como indicativo das falhas. Os demais *clusters*, localizados fora do domínio dos limiares citados, foram classificados como sem falha.

Com a etapa de classificação concluída, a última fase deste trabalho consistiu em mensurar o nível de assertividade do classificador. Para isto, foi imputado na base de teste uma classificação baseada em conhecimento especialista, objetivando a identificação de seguimentos onde os valores apresentados pelos atributos reproduzam comportamentos semelhantes aos observados aos modos de falha. Como produto desta classificação foi gerado um vetor referência, possibilitando a verificação da acurácia do classificador por meios de comparação entre este vetor e os dados classificados pelo classificador. Através da aplicação destes dados em uma matriz de confusão, foi possível avaliar a quantidade de acertos, de falsos positivos e falsos negativos.

6 RESULTADOS E DISCUSSÕES

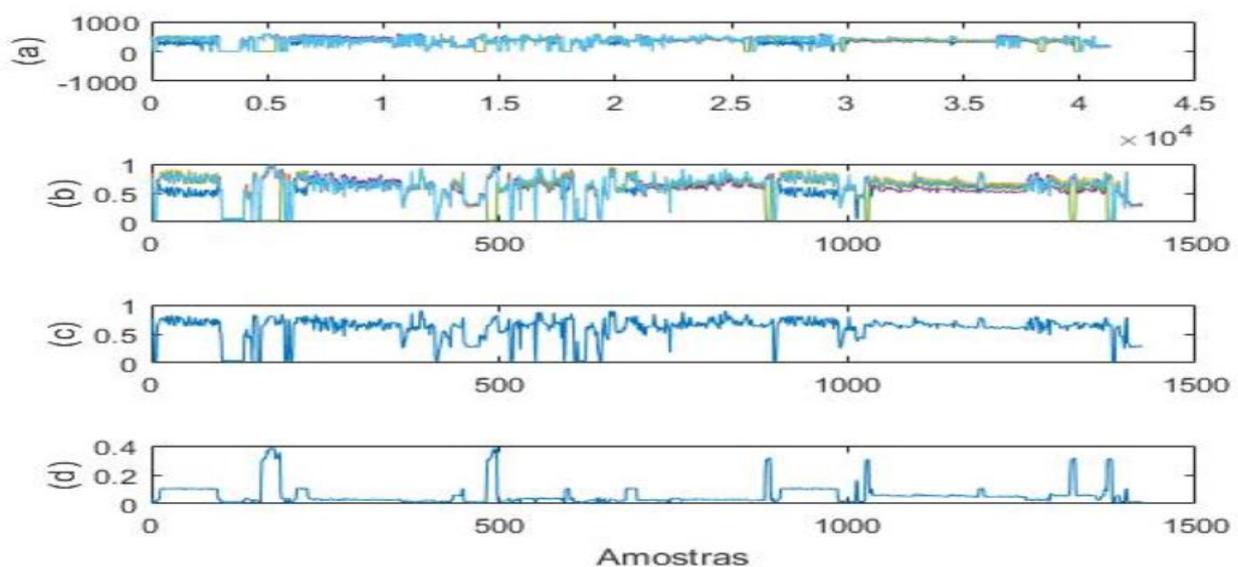
Nesta sessão do trabalho, buscou-se analisar os resultados obtidos em cada uma das etapas empregadas para a concepção do classificador, desde os processos utilizados para preparação das bases de dados, à escolha do modelo de agrupamento que melhor representou os modos de falha. Também consta nesta sessão uma análise relativa a funcionalidade do algoritmo no decorrer de sua aplicação na base de teste, baseando-se na interpretação dos resultados de entrada e saída do classificador.

6.1 Resultados do pré-processamento e extração de características

A etapa de pré-processamento teve seu início pelas 10 variáveis de entrada anteriormente selecionadas (9 variáveis relativas aos parâmetros da máquina e 1 variável condicionante). Estas variáveis foram organizadas em acordo com suas relações com cada modo de falha, tendo em vista facultar uma linha racional para análise referente a cada estágio executado pelo algoritmo.

Estão apresentadas nos gráficos contidos na Figura 15, a preparação da base para o MF1 e MF2, ambos representados pelas seis variáveis de entrada: corrente do MT1, corrente do MT2, corrente do MT3, corrente do MT4, corrente do MT5 e corrente do MT6.

Figura 15- Representação estágio pré-processamento e extração das características MF1 e M2



Legenda:

- (a)- Corrente dos 6 MTs filtrados pela condicionante 8º ponto aceleração.
- (b)- Corrente dos 6 MTs filtrados pela condicionante 8º ponto aceleração, pelo janelamento (N=30) e normalizado pela técnica tipo range (de 0 a 1).
- (c)- Atributo extraído “média dos valores referentes as correntes dos 6 MTs”.
- (d)- Atributo extraído “desvio padrão dos valores das correntes referentes aos 6 MTs”.

Fonte: Do autor (2020)

Verifica-se em (a) que a base já condicionada ao oitavo ponto de aceleração (composta pelas 41.284 amostras) apresentou algumas variações nos valores da corrente de um motor em relação aos demais, fatos que evidenciam possíveis ocorrências destes dois modos de falha. Dentro de um contexto analítico, em virtude da grande quantidade de dados sequenciais sem variações representativas (resultante da taxa de amostragem de 1 hertz utilizada no aquisitor de dados), seria necessária uma varredura visando à expansão de trechos específicos do gráfico para uma classificação visual destes pontos de ocorrência, elevando assim o tempo de análise. Na concepção do algoritmo, esta grande quantidade de dados sem variações significaria uma baixa otimização no tempo de execução em virtude da grande quantidade de informações redundantes a serem processadas.

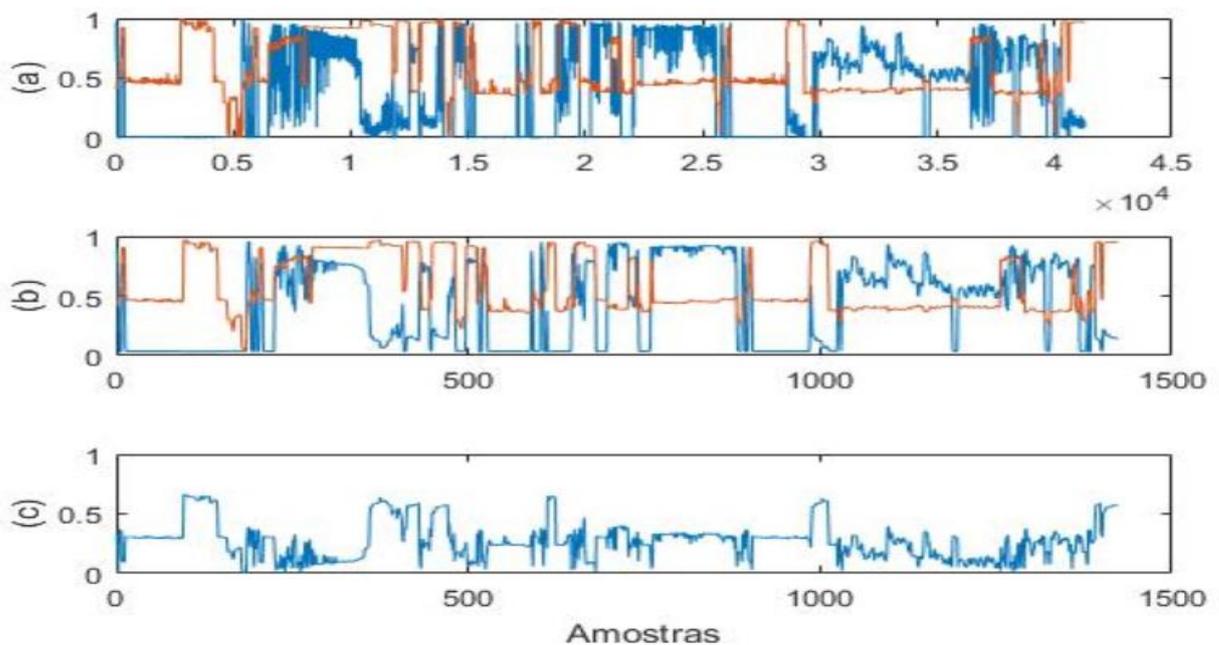
Em (b), consta a representação destes dados filtrados através do processo de janelamento (N=30) e também normalizados pela técnica tipo range de 0 a 1. Verifica-se que a base de dados composta inicialmente por 41.284 amostras passou a ser representada por 1.423, retratando uma redução de 97%. As peculiaridades dos modos de falha estão evidenciadas de maneira análoga em ambos os gráficos (a) e (b), concluindo que a redução da base não levou a perdas significativas para representatividade dos mesmos. Concernente ao algoritmo, esta redução no volume da base representou uma otimização no processamento dos dados, pois, foi possível obter as mesmas informações necessárias à classificação do MF1 e MF2 com apenas 3% dos dados relativos à base inicial. Quanto ao processo de normalização dos dados, uma vez que os valores apresentados pelas correntes dos seis MTs possuíam a mesma faixa de extensão (entre valores máximo e mínimo), pode-se dizer que os resultados relativos aos futuros agrupamentos seriam semelhantes aos dos dados não normalizados.

Em (c) e (d) estão as características extraídas para os dados apresentados no gráfico (b). No primeiro, consta os valores médios das correntes dos seis MTs, e no segundo os valores dos desvios padrões destas correntes. Dado que, a técnica de agrupamento de dados FCM utilizado para a concepção do classificador esteve em função de duas variáveis (eixo X e eixo Y), estes foram os atributos empregados para a sua construção (desvio padrão das correntes assumindo

os valores de X e a média das correntes os valores de Y). Relacionando as informações apresentadas entre os gráficos (b), que expressa a base de dados janelada em $N=30$ e normalizada, e (d), que apresenta o desvio padrão entre os valores das seis correntes dos MTs, foi possível detectar que nos pontos de possíveis ocorrências relativas ao MF1 e MF2, existem variações significativa nos valores atribuídos aos desvios padrões, com MF2 se diferenciando do MF1 pela amplitude desta variação (o MF2 apresenta maiores variações no desvio padrão em relação ao MF1).

Na Figura 16, está apresentada a etapa de pré-processamento e as características extraídas para o MF3, vinculadas às variáveis: potência do gerador de tração e pressão do combustível.

Figura 16- Representação do estágio pré-processamento e extração das características MF3



Legenda:

- (a)- Pressão do combustível (laranja) e potência do gerador de tração (azul), filtrada pelo 8º ponto de aceleração e normalizado (tipo range 0 a 1).
- (b)- Pressão do combustível (laranja e potência do gerador de tração (azul), filtrada pelo 8º ponto de aceleração, filtrada pelo janelamento $N=30$ e normalizado (tipo range 0 a 1).
- (c)- Atributo extraído “desvio padrão em relação a média entre pressão de combustível e potência do gerador de tração.

Fonte: Do autor (2020)

Em (a) verifica-se os valores assumidos pelas variáveis pressão de combustível (laranja) e a potência do gerador de tração (azul) ao longo da funcionalidade da locomotiva, filtrado pelo condicionamento oitavo ponto de aceleração. Diferente dos dados exibidos para MF1 e MF2 esta base foi apresentada com os seus dados normalizados ainda no primeiro estágio do pré-processamento visando simplificar sua interpretação, pois as duas variáveis apontadas possuíam faixas de trabalho bastante distintas, na razão de 1:91 (potência nominal do gerador de tração na faixa de 3100 HP e pressão nominal da linha de combustível em torno de 34 PSI).

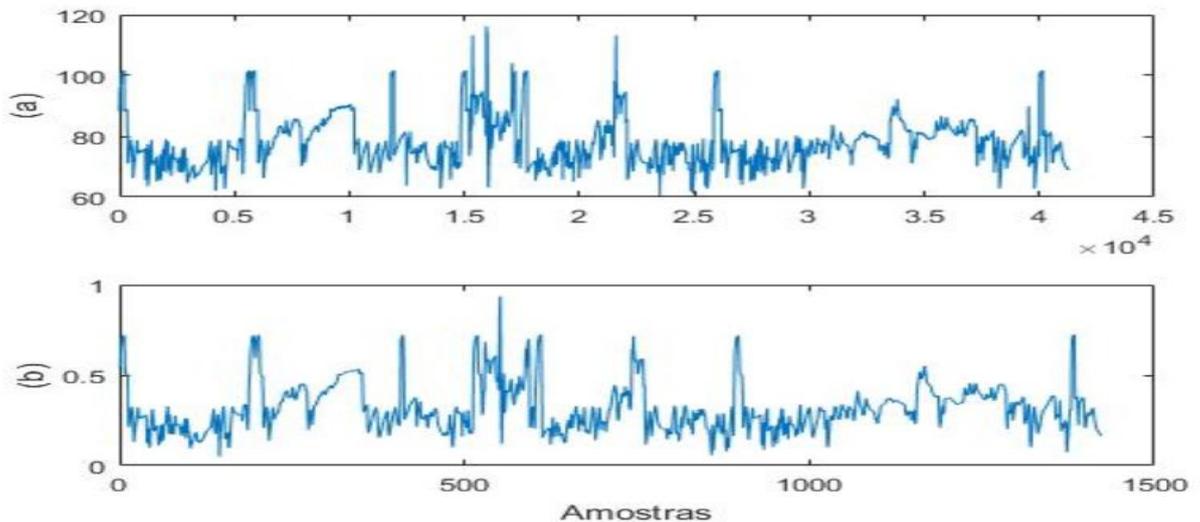
Pode ser detectado neste gráfico alguns pontos específicos onde os valores exibidos da pressão de combustível são significativamente superiores a potência do gerador de tração, pontos exequíveis de constatação em virtude do processo de normalização. Estes pontos evidenciam uma possível ocorrência do MF3. Assim como no caso anterior (para o MF1 e MF2), foi observada uma grande quantidade de informações redundantes em virtude da taxa de amostragem de 1 hertz utilizada pelo aquisitor de dados, o que levaria a uma baixa otimização no processamento dos dados pelo algoritmo caso a base não passasse por nenhum outro tipo de filtragem.

Em (b) consta a representação da base agora filtrada pelo processo de janelamento $N=30$, o que também levou à uma redução de 97% da base inicial. Verifica-se que o processo de janelamento facilitou a detecção das singularidades observadas para o MF3, tornando-a representação gráfica mais clara para uma análise visual, sendo detectados nove pontos de possíveis ocorrências. Para o algoritmo, esta redução no volume da base representou uma otimização no processamento dos dados, pois foi possível obter as mesmas informações necessárias à classificação do MF3 com apenas 3% dos dados relativos à base inicial.

No gráfico (c) está representada a característica “desvio padrão entre a pressão de combustível e potência do gerador de tração” extraída do gráfico (b). É possível detectar visualmente que os pontos de ocorrências observadas para o MF3 no gráfico (b) estão retratados de maneira bastante assertiva pela elevação nos valores apresentados no desvio padrão. Dado que o agrupamento de dados pela técnica FCM utilizada na concepção do algoritmo esteve em função de duas variáveis (eixo X e eixo Y), foram empregadas as seguintes características para classificação do MF3: “potência do gerador de tração” (assumindo o eixo X) e “desvio padrão entre a pressão de combustível e potência do gerador de tração” (assumindo os valores de Y).

Por fim, na Figura 17 está apresentada as etapas de pré-processamento e extração das características para o MF4, vinculadas à variável: temperatura do líquido de arrefecimento.

Figura 17- Representação do estágio pré-processamento e extração das características MF4



Legenda:

- (a)- Temperatura do líquido de arrefecimento do MD, filtrada pelo 8º ponto de aceleração.
- (b)- Temperatura do líquido de arrefecimento do MD, filtrada pelo 8º ponto de aceleração, após processo de janelamento ($N=30$) e normalização dos valores pela técnica tipo range (0 a 1).

Fonte: Do autor (2020)

Em (a) verifica-se os valores assumidos pela variável temperatura do líquido de arrefecimento do MD ao longo do funcionamento da locomotiva, filtrado pelo oitavo ponto em aceleração. Verifica-se por meio de uma análise visual nove pontos de possível ocorrência deste modo de falha, onde os valores apresentados assumem picos muito acima da média se comparado aos demais. Para este modo de falha específico, foi possível obter sua classificação apenas com uma variável, pois qualquer anomalia referente aos demais conjuntos do sistema de arrefecimento da locomotiva que pudesse refletir em um mal funcionamento deste, resultaria em algum tipo de distúrbio na variável em questão.

Em (b) está representada esta mesma variável, porém filtrada pelo processo de janelamento $N=30$ e com seus valores normalizados. Assim como nos casos anteriores, verifica-se que a base de dados agora composta por apenas 1.423 dados (redução de 97% da base inicial) não teve perda da representatividade do MF3 em função da redução de seu volume, pois é possível detectar os mesmos possíveis pontos de ocorrência em ambos os gráficos (a) e (b).

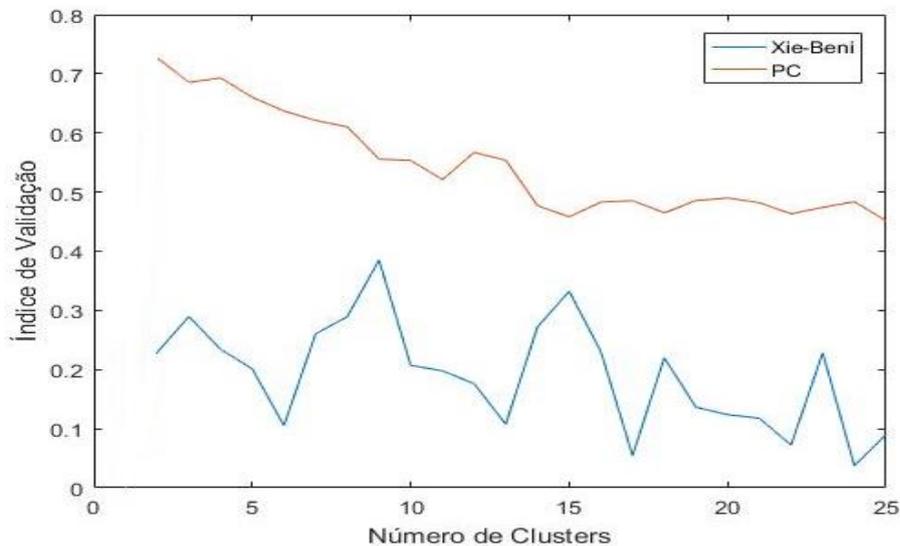
Para este modo de falha, foi utilizado por atributo os valores assumidos para a variável “temperatura do líquido de arrefecimento do MD”. Dado que o agrupamento de dados pela técnica FCM está em função de duas variáveis (eixo X e eixo Y), foi necessária a utilização de

uma variável auxiliar assumindo os valores referentes ao eixo Y. Desta forma, foram utilizadas para a concepção do classificador as seguintes características: “temperatura do líquido de arrefecimento do MD” (assumindo o eixo X) e “pressão do combustível” (assumindo os valores de Y) para a classificação do MF4.

6.2 Resultados do processo de treinamento e validação do classificador

Foi executado o algoritmo *fuzzy C-means* para geração de 24 modelos de agrupamentos distintos para os dados contidos na base de treinamento (referente aos nove atributos citados no subtópico anterior). Posteriormente, foram calculados o PC e o índice *Xie-Beni* para cada modelo e, baseado nestes dois indicadores, foi selecionado aquele que melhor representou a base de dados. Na Figura 18 pode ser observada a representação gráfica dos resultados deste processo de seleção, atribuindo-se à X os valores encontrados para PC e *Xie-Beni* e à Y os 24 modelos de agrupamento gerados (variando de 2 a 25 centros de *clusters*).

Figura 18- Índices *Xie-Beni* e PC relativos aos 24 modelos de agrupamentos gerados



Fonte: Do autor (2020)

A medida *Xie-Beni* é um critério de validação representada pelo coeficiente entre o erro quadrático médio de todos os pontos em relação aos centros e pela distância média entre os *clusters*. A medida classificada como excelente é aquela ao qual este erro é pequeno, ao mesmo tempo que a distância entre centros de *clusters* é grande, sinalizando certa proximidade entre

os pontos de maior pertinência e distância daqueles de menor. Quanto mais baixo este índice, mais representativo é o modelo do agrupamento.

Baseando-se neste critério, observa-se certa sazonalidade a medida que a quantidade de centros de *clusters* aumenta, sinalizando a inexistência de uma correlação direta entre o número de *clusters* e otimização do modelo. Estas características podem se atrelar ao fato de que maiores quantidades *clusters* nem sempre levariam a uma melhor representatividade dos dados, pois mesmo que o erro quadrático relativo a cada ponto seja reduzido, as distâncias entre os *clusters* não necessariamente seriam aumentadas. O modelo de agrupamento que demonstrou melhor representatividade fundamentada neste critério foi aquele composto por 16 e 24 centros de *clusters*, que apresentaram índices abaixo de 0,1.

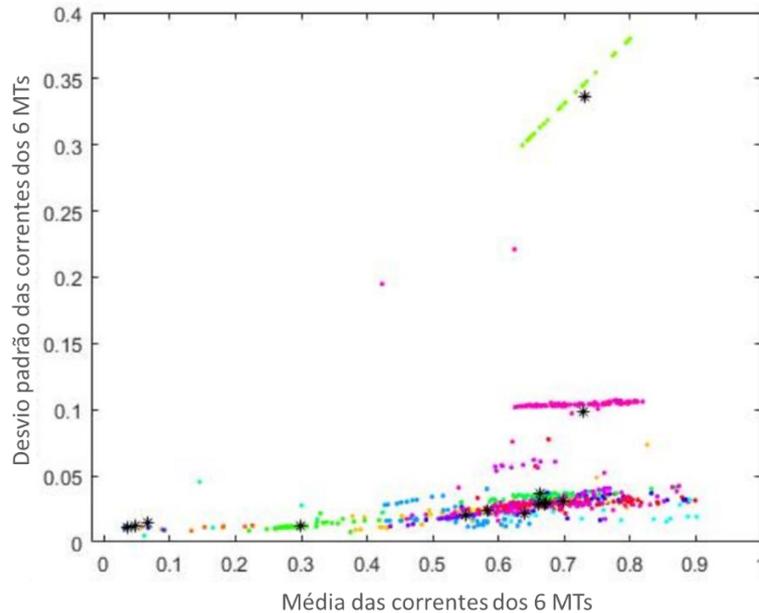
O PC baseia-se na quantidade de sobreposições existentes entre os *clusters* para avaliação do resultado obtido a partir de um algoritmo de agrupamento. Ao contrário do índice *Xie-Beni*, quanto maior este índice, mais representativo é o modelo analisado.

Observou-se neste critério que os valores dos coeficientes vinculados aos modelos de agrupamento foram sistematicamente reduzidos à medida que transcorreram aumentos nas quantidades dos *clusters*, porém, estabilizando-se a partir dos modelos compostos por mais de 15 centros. Tais características demonstraram que, para a base analisada, ampliou-se a quantidade de sobreposições dos dados a medida se obteve um aumento relativo ao número de *clusters*, no entanto, a variação nestas sobreposições passaram a ser irrelevantes entre os modelos compostos por mais de 15 centros. O modelo de agrupamento que apresentou melhor representatividade fundamentado no critério PC foi aquele composto por apenas dois *clusters*, obtendo um índice acima de 0.7.

Visto que, seria inviável a classificação dos quatro modos de falha baseando-se em um modelo composto por apenas dois *clusters*, esta seleção se fundamentou exclusivamente pelo índice *Xie-Beni*. Desta forma, como foram identificados dois modelos com este índice abaixo de 0.1, definiu-se por convenção que o classificador seria baseado naquele com menor número de *cluster*, no caso, o modelo composto por 16 centros.

Na Figura 19, pode ser observado o modelo de 16 *clusters* atribuídos ao “desvio padrão das correntes dos seis MTs” e a “média das correntes dos seis MTs” vinculados ao MF1 e MF2, gerado para a base de treinamento.

Figura 19- Modelo agrupamento 16 clusters gerado para o MF1 e MF2



Fonte: Do autor (2020)

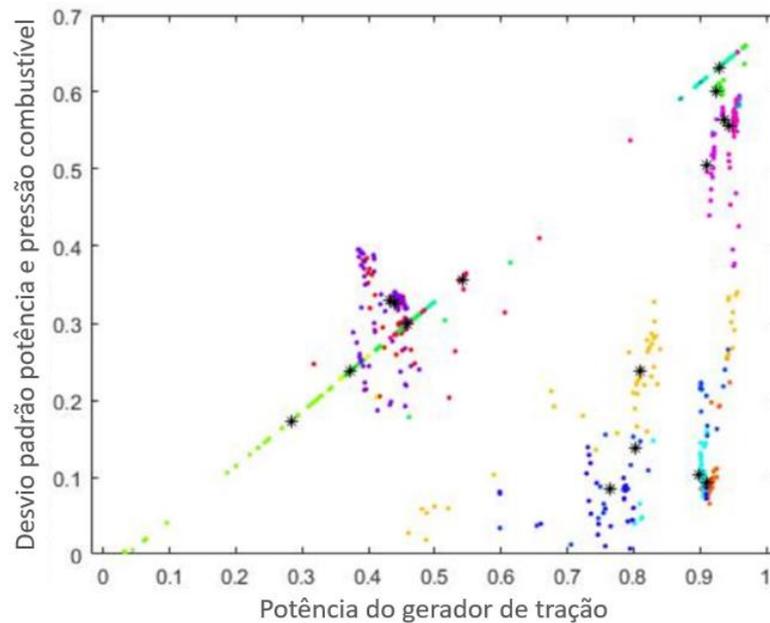
Considerando que estes dois modos de falha se manifestaram através de variações no desvio padrão relativo às correntes dos MTs, observa-se dois centros de *clusters* que podem estar vinculados a eles. Localizado na coordenada (0,72, 0,1), foi identificado um *cluster* destoado dos demais em razão de certo afastamento. Porém, somente este fato isolado não teria tanta relevância se não existisse neste *cluster* uma discrepância nos valores apresentados ao desvio padrão. Outro fato relevante é que o mesmo se localiza em uma zona onde os valores apresentados para a média dos valores das correntes são mais elevados, um padrão bastante singular observado ao MF1 (a discrepância no valor das correntes se encontravam justamente em pontos onde a locomotiva operava em menores velocidades e correntes mais elevadas). Conclui-se que este centro de *cluster* representa o modo de falha em questão e, portanto, foi considerado para a etapa de classificação.

No *cluster* localizado na coordenada (0,72, 0,34) observa-se características bastante similares às citadas para o MF1. Porém neste caso, a discrepância nos valores apresentados para o desvio padrão é significativamente superior. Acredita-se que este *cluster* corresponde às singularidades observadas para o MF2.

Na figura 20 observa-se o modelo de 16 *clusters* gerado para os atributos “potência do gerador de tração” e “desvio padrão entre a potência e pressão do combustível”, relacionado ao MF3. A principal característica observada para este modo de falha foi a elevação da pressão do combustível em níveis bem acima da média durante operações da locomotiva que demandavam maior capacidade de tração, ao mesmo tempo que a potência nominal da máquina não era

alcançada (potência nominal de 3000 HP). Desta forma, pressupõe-se que os centros de *clusters* vinculados ao MF3 se encontram em regiões onde os valores apresentados à potência do gerador de tração é mais elevada, ao mesmo tempo que existem discrepâncias nos valores atribuídos ao “desvio padrão entre a potência do gerador de tração e pressão do combustível”. No modelo gerado foi observada a existência de cinco centros de *clusters* que atendem tais quesitos, localizados na junção relativa aos seguimentos 0,9 a 1 do eixo X e 0,5 a 0,65 de Y. Para o processo de classificação, estes centros de *clusters* foram considerados para representar o modo de falha.

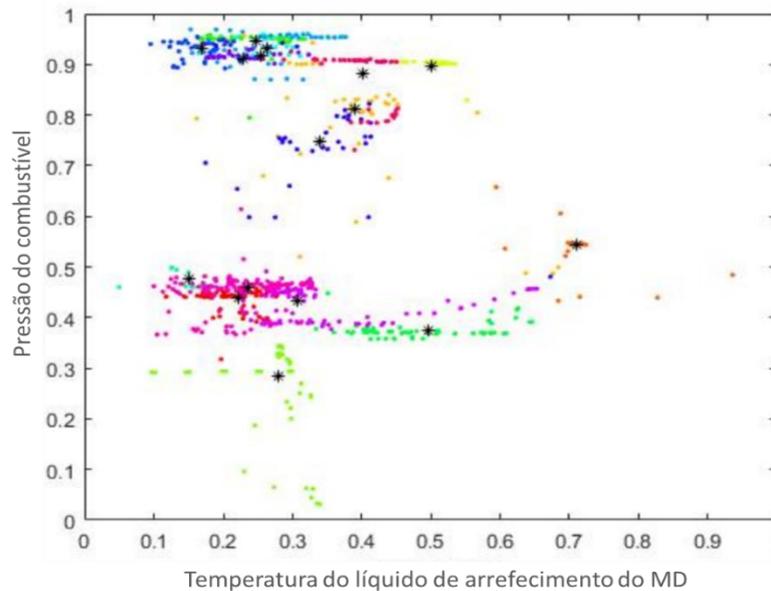
Figura 20- Modelo agrupamento 16 clusters gerado para o MF3



Fonte: Do autor (2020)

Por fim, na figura 21 está contemplado o modelo de 16 *clusters* gerado para os atributos “temperatura do líquido de arrefecimento do MD” e “pressão do combustível”, vinculados ao MF4. Por este modo de falha se tratar de uma conjuntura passível de classificação unicamente pelo atributo “temperatura do líquido de arrefecimento do MD”, acredita-se que estará associado ao mesmo aqueles *clusters* localizados em regiões do gráfico onde exista maior discrepância nos valores atribuídos à variável em questão. Assim sendo, foi detectado um centro de *cluster* localizado no ponto (0,70, 0,56) que apresentou tais características, levando a crer que ele representa o modo de falha.

Figura 21- Modelo agrupamento 16 clusters gerado para o MF4



Fonte: Do autor (2020)

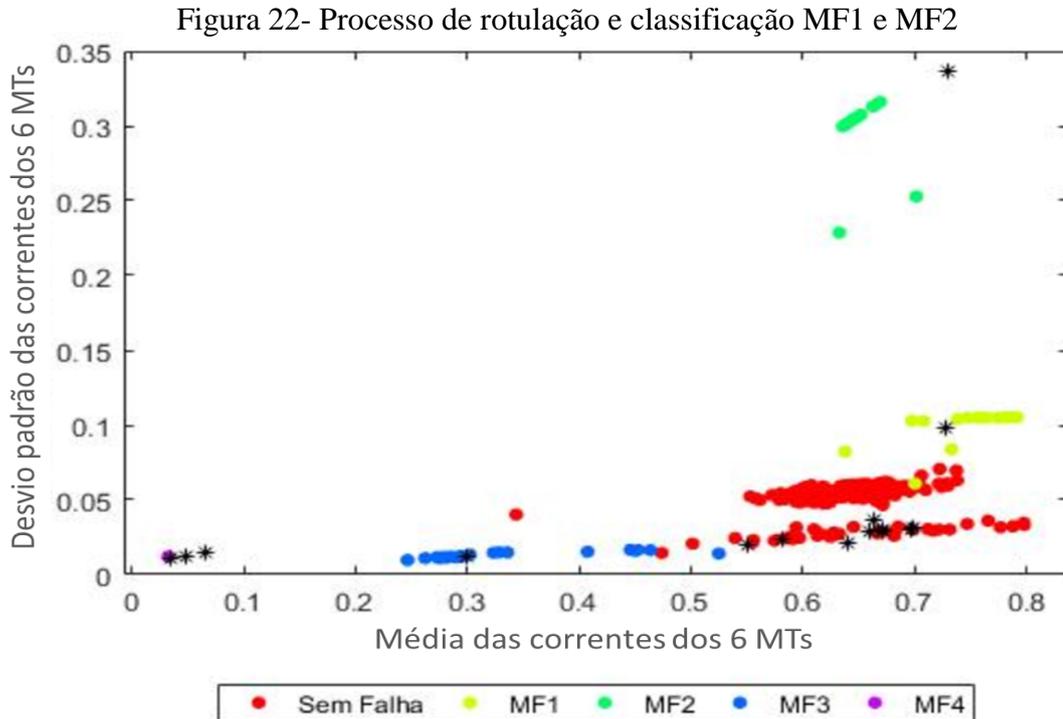
6.3 Resultados do processo de classificação

Nesta última sessão, foram exibidos os resultados referidos à rotulação e classificação dos dados contidos em uma terceira base, em função dos modelos de 16 *clusters* anteriormente selecionados. Esta etapa foi fundamentada nas medidas de similaridades de cada ponto aos centros de *clusters* e em valores de limiares relativos aos posicionamentos dos mesmos, delineados por conhecimento especialista. Posteriormente, foi calculada a acurácia do classificador pela comparação deste com um vetor contendo a classificação dos pontos de ocorrência baseada em análise humana.

Na Figura 21, pode ser observado o modelo executado na base de teste para a classificação do MF1 e MF2. A rotulação dos dados foi apresentada em função de sua pertinência aos centros de *cluster* classificados e representados através de cinco cores distintas, simbolizando os quatro modos de falha (e ausência destes). Ou seja, através desta representação, foi possível detectar se um dado está relacionado a algum dos modos de falha.

Para a classificação dos centros de *cluster* foram utilizados valores de limiares baseados nas observações de cada modelo gerado através da base de treinamento, amparado pelas singularidades encontradas em cada um dos modos de falha (abordadas no subtópico 5.3). Embasado nestas análises, definiu-se como limiar que o MF1 seria representado pelos *clusters* localizados entre 0,05 e 0,19 do eixo Y, relacionado ao desvio padrão das correntes dos seis

MTs. Nesta zona específica, foi classificado um centro de *cluster* que atende às singularidades observadas para o MF1 (conforme citado no subtópico anterior). Observa-se que os dados pertinentes a este foram corretamente rotulados, e identificados na cor amarela. Desta maneira, obteve-se a detecção e posterior classificação do MF1 para os dados da base de teste.

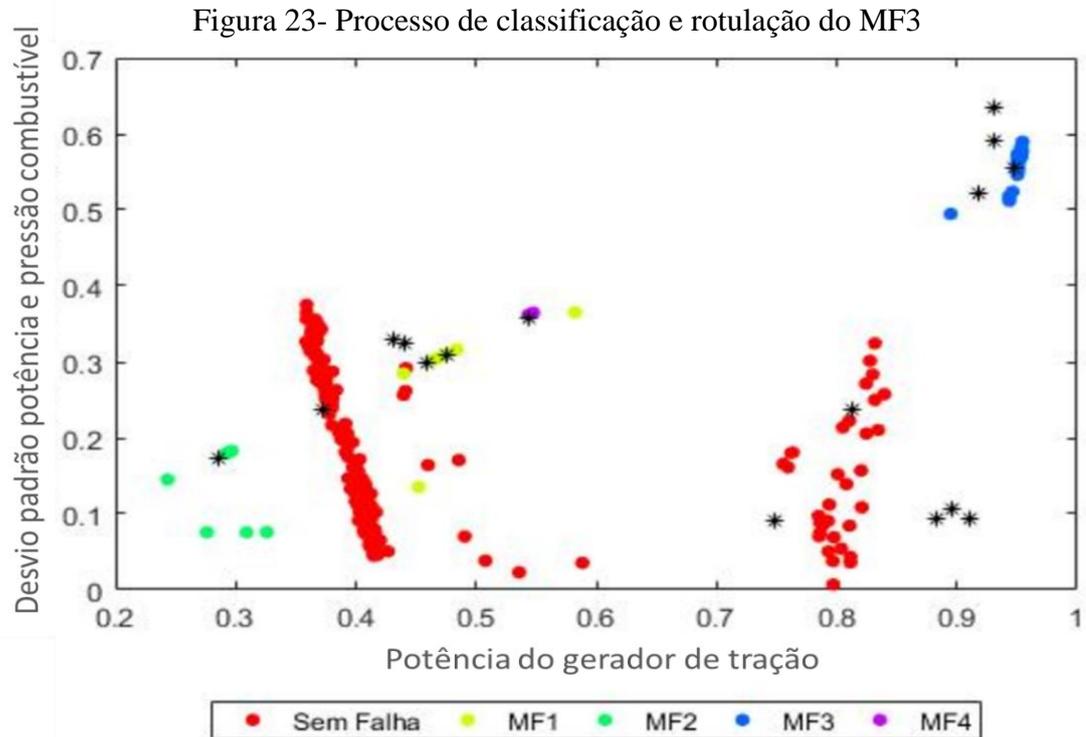


Fonte: Do autor (2020)

Considerando que o MF2 se difere do MF1 apenas pela amplitude nos valores alcançados para o desvio padrão, foi estabelecido que os centros de *clusters* localizados acima de 0,2 em Y, seriam vinculados a ele. Nesta zona específica foi encontrado um *cluster* que atende tais quesitos. Observa-se que os dados pertinentes ao *cluster* estão rotulados e identificados na cor verde, obtendo-se desta forma a identificação e classificação do MF2 para os dados da base de teste.

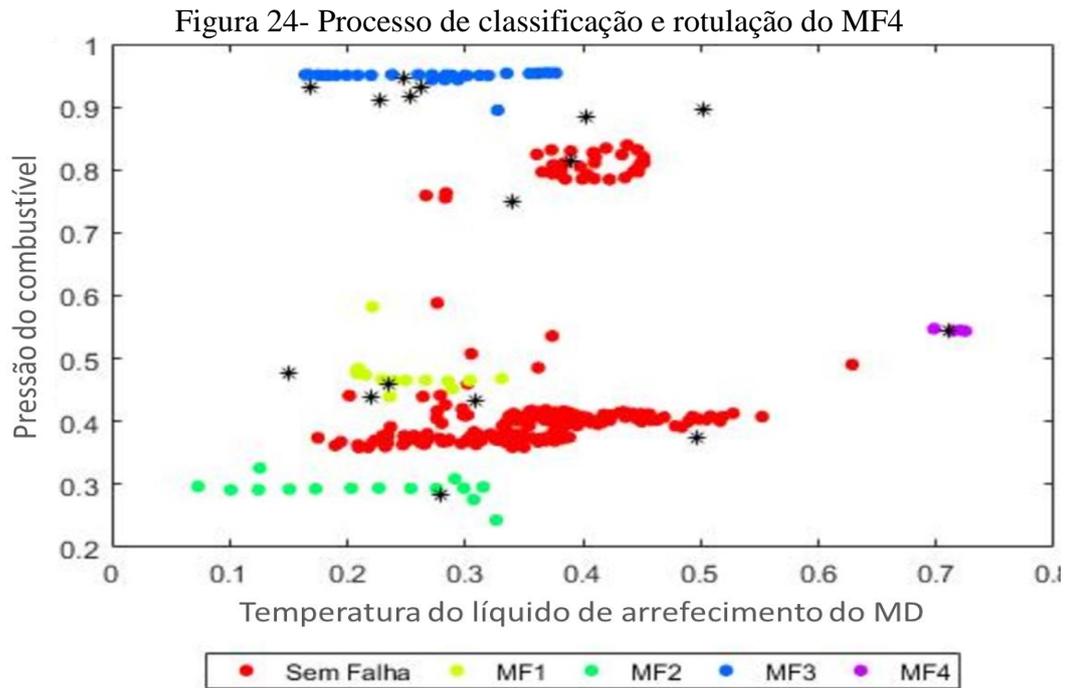
Na Figura 23 consta o modelo de 16 *clusters* atribuído ao MF3. Conforme mencionado no subtópico anterior, foram identificados cinco *clusters* que apresentaram características bastante singulares para o modo de falha, caracterizado por uma discrepância nos valores do desvio padrão entre a pressão de combustível e potência do gerador principal. Baseando-se nestas observações e nas singularidades detectadas ao modo de falha (abordadas no subtópico 5.3) foi definido por valor de limiar que todos os *clusters* localizados acima de 0,5 do atributo “desvio padrão entre a potência do gerador de tração e pressão do combustível” seriam

atribuídos ao MF3 e com base nesta classificação foram rotulados os dados que possuíam pertinência a este restrito grupo de *clusters*. Pode ser observado que estes dados estão identificados na cor azul, obtendo desta forma a identificação e classificação do MF3 para a base de teste.



Fonte: Do autor (2020)

E por fim, para o MF4, por estar vinculado apenas a uma única característica relativa à “temperatura do líquido de arrefecimento”, foram atribuídos a este os *clusters* que apresentaram certa discrepância nestes valores. Desta maneira, baseando-se nas observações relativas ao modelo e respaldando-se nas singularidades detectadas ao modo de falha (descritas no subtópico 5.3) foi convencionado que todos *clusters* localizados acima de 0,6 da variável citada seriam classificados como ocorrência do modo de falha em questão. Observa-se na Figura 24, a existência de um *cluster* que atende tais quesitos. Verifica-se que os dados pertinentes a ele foram rotulados e identificados através da cor roxa, obtendo-se desta maneira a detecção das ocorrências e a classificação do MF4 para a base de teste.



Fonte: Do autor (2020)

Os demais dados, que não possuem pertinências a nenhum dos clusters atribuídos aos quatro modos de falha, foram rotulados como “sem falha” e estão identificados pela cor vermelha. Com a obtenção da classificação e rotulação da base de teste para os modos de falha selecionados, esta última etapa do trabalho baseou-se em medir o valor da acurácia do classificador. Para isto, foi inserido no algoritmo um vetor contendo as amostras da base de teste classificadas através de uma análise baseada em conhecimento especialista. Posteriormente, este vetor foi comparado com as classificações executadas pelo algoritmo. Através da representação destes dados em uma matriz de confusão, foi possível avaliar a quantidade de acertos, de falsos positivos e falsos negativos relativo a cada um dos quatro modos de falha. Na Figura 25 pode ser observada esta matriz de confusão, atribuindo-se ao eixo horizontal a classificação baseada em análise humana (ocorrências reais) e ao eixo vertical a classificação efetuada pelo classificador.

Analisando a classificação obtida para o MF1, verificou-se através do eixo horizontal que foram atribuídos 13 pontos de ocorrência para o mesmo (acertos), porém, o classificador atribuiu 2 ocorrências indevidamente que deveriam ser classificadas como SF (falsos positivos). Através do eixo vertical, observa-se a ausência de falsos negativos para o MF1.

Figura 25- Matriz de confusão

Matriz de Confusão

Classificador Fuzzy	Real					Total	
	MF1	MF2	MF3	MF4	SF	Verdadeiros Positivos	Falsos Positivos
MF1	13 4.6%	0 0.0%	0 0.0%	0 0.0%	2 0.7%	13	13.3%
MF2	0 0.0%	13 4.6%	0 0.0%	0 0.0%	2 0.7%	13	13.3%
MF3	0 0.0%	0 0.0%	29 10.2%	0 0.0%	1 0.4%	29	3.3%
MF4	0 0.0%	0 0.0%	0 0.0%	4 1.4%	0 0.0%	4	0.0%
SF	0 0.0%	0 0.0%	0 0.0%	1 0.4%	220 77.2%	220	0.5%
	100% 0.0%	100% 0.0%	100% 0.0%	80.0% 20.0%	97.8% 2.2%	227	2.1%

Fonte: Do autor (2020)

Observando os resultados obtidos para o MF2, verificou-se que assim como para o MF1 o classificador obteve um erro relativo a 13,3% referente a falsos positivos, porém alcançou um resultado relativo a 0% de falsos negativos.

Para o MF3, observou-se um erro referente a 3,3% de falsos positivos, no entanto, o algoritmo apresentou 0% de falsos negativos.

E por fim, para o MF4, detectou-se 0% de erro relativo a falsos positivos, contudo apresentou 20% de falsos negativos.

Vale ressaltar que, se tratando as locomotivas de equipamentos de elevada complexidade sistêmica, é desejável que o algoritmo apresente a menor margem de erro possível tanto para os falsos positivos, quanto para falsos negativos, de forma a se obter a máxima otimização dos recursos de manutenção. Falsos positivos elevariam os custos de manutenção em razão de alocação de mão de obra, utilização de recursos dedicados e retenções indevidas para diagnóstico. Porém, falsos negativos poderiam levar a impactos operacionais em

razão das paradas não programadas das locomotivas pela instauração dos modos de falha não detectados pelo classificador. O algoritmo obteve um resultado geral de 97,9% de acurácia.

7 CONSIDERAÇÕES FINAIS

A metodologia RCA, conduzida nos moldes propostos neste trabalho, revelou-se uma importante ferramenta organizacional para o tratamento preliminar da base de ocorrências, possibilitando o reconhecimento sistêmico das falhas apresentadas ao grupo composto por 47 locomotivas, alvo deste estudo. Através de sua aplicação, foi possível classificar pontualmente um total de 97 falhas (apresentadas em um dado período) e a através desta classificação, estimar o comportamento sistêmico da frota. Ao todo, foram constatados 32 modos de falha de passível ocorrência a estes ativos.

A metodologia RCM, aplicada em conjunto com as ferramentas de análise de causa e efeito compreendidas no FMEA, possibilitou a definição de diretrizes para priorização dos modos de falha, baseando-se na representatividade destes ao processo produtivo. Ao final, foram designados quatro para a fundamentação do algoritmo classificador.

A utilização de tais metodologias, propiciou ao projeto certa fundamentação lógica, convertendo grandes quantidades de informações providas do meio produtivo, muitas das vezes imprecisas se analisadas isoladamente, em fundamentos determinantes para a construção do algoritmo. Através desta organização, foi possível determinar de uma forma otimizada os parâmetros de entrada e saída para o classificador, alinhado com as reais expectativas do meio produtivo.

O algoritmo classificador baseado no FCM apresentou uma boa assertividade para classificação dos quatro modos de falha selecionados, atingindo um nível de acurácia de 97,9%.

Para trabalhos futuros, objetiva-se o aprimoramento do algoritmo classificador através de uma nova etapa de treinamento, utilizando-se de uma base de dados mais expressiva (com maior volume de dados contendo informações inerentes aos modos de falha), de modo a obter um ajuste fino para as modelagens dos agrupamentos. Também se espera expandir a saída do algoritmo para os demais modos de falha, baseando na ordem de priorização obtida através da aplicação do RCA em conjunto com o RCM.

REFERÊNCIAS

- ABNT- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 5462:1994 - Confiabilidade e manutenibilidade – Terminologia**. CB-03 - Comitê Brasileiro de Eletricidade, CE-03:056.01 - Comissão de Estudo de Confiabilidade ,Rio de Janeiro:1994, 37 p.
- AGRAWAL, R. et al. **Automatic Subspace Clustering of High Dimensional Data for Data Mining Applications**, IBM Almaden Research Center, San Jose, 1998.
- AGUIAR, M. C. **Análise de Causa Raiz: levantamento dos métodos e exemplificação**. 2014. Dissertação (Mestrado) Pontifícia Universidade Católica, Rio de Janeiro, 2014.
- ALKAIM, J. L. **Metodologia para incorporar conhecimento intensivo às tarefas de manutenção centrada na confiabilidade aplicada em ativos de sistemas elétricos**. 2003. Tese (Doutorado), Universidade Federal de Santa Catarina, Florianópolis, 2003.
- ALVES, L. **Eficiência de métodos de agrupamento de dados na modelagem nebulosa Takagi-Sugeno**. 2007, Dissertação (Mestrado), Pontifícia Universidade Católica do Paraná, Curitiba, 2007.
- AMMERMAN, M. **The Root Cause Analysis Handbook: a simplified approach to identifying, correcting, and reporting workplace errors**. Portland: Productivity, 1998.
- ANKERST, M. et al. **OPTICS: Ordering Points To Identify the Clustering Structure**. Institute for computer Science, University of Munich, 1992
- ARAÚJO NETO, A. S.; NEGREIROS, M. Avaliação da performance de índices de similaridade aplicados ao agrupamento de objetos textuais. **Revista Brasileira de Computação Aplicada** (ISSN 2176-6649), Passo Fundo, v. 9, n. 4, p. 43-59, 2017.
- BALASKO, B.; ABONYI, J.; FEIL, B. **Fuzzy Clustering and Data Analysis Toolbox for use with Matlab**. Veszprem, Hungary: [S. n], p. 13-14, 2014.
- BAPTISTA, J. A. **A importância da análise de causa raiz (root cause analysis) na melhoria do desempenho da manutenção industrial**. 2007. Disponível em: <http://www.abraman.org.br/Arquivos/191/191.pdf> , acessado em: 20/11/2019.
- BARROS, P. Aprendizagem de Máquina: Supervisionada ou Não Supervisionada? Em: **Opensanca**, 2016. Disponível em: <https://medium.com/opensanca/aprendizagem-de-maquina-supervisionada-ou-n%C3%A3o-supervisionada-7d01f78cd80a> , Acessado em: 01/02/2020.
- BASSHUYSEN, R. V.; SCHAFER, F. **Internal combustion engine handbook: basics, components, systems and perspectives**. 1. ed., [S. l.]: Society of Automotive Engineers, 2004.
- BEZDEK, J C. et al. **Fuzzy models and algorithms for pattern recognition and image processing**. New York: Springer, 2005.

- BITTENCOURT, V. G. **Aplicação de técnicas de aprendizado de máquina no reconhecimento de classes estruturais de proteínas.** 2005. Dissertação (Mestrado), Universidade Federal do Rio Grande do Norte, Natal, 2005.
- BORBA, J. **Mecânica de locomotivas.** 3. ed., Espírito Santo: Pontifícia Universidade Católica, 2014.
- CARMO, D.A. do. **Detecção e diagnóstico de falhas em sistema de arrefecimento de motor diesel ferroviário.** 2018. Dissertação (Mestrado), Universidade Federal do Espírito Santo, Vitória, 2018.
- CASSIANO, K. M. **Análise de séries temporais usando Análise Espectral Singular (SSA) e clusterização de suas componentes baseada em densidade.** 2014. Tese (Doutorado) Pontifícia Universidade Católica, Rio de Janeiro, 2014.
- CAVALCANTI JUNIOR, N. L. **Clusterização baseadas em algoritmos.** 2006, Dissertação (Mestrado), Universidade Federal do Pernambuco, Recife, 2006.
- CERRI, R.; CARVALHO A.C.P.L.F.de. Aprendizado de máquina: breve introdução e aplicações. **Cadernos de Ciência & Tecnologia**, Brasília, v. 34, n. 3, p. 297-313, 2017.
- CHATTOPADHYAY, S.; PRATIHAR, D.K.; SARKAR, S. C. A comparative study of fuzzy c-means algorithm and entropy-based fuzzy clustering algorithms. **Computing and Informatics**, v.30, n. 4, p.701-720, 2011.
- COREMA. **Manual de manutenção do motor diesel 645E3B.** SEÇÃO 11- 84, 2006.
- COSTA, J. A. F. **Classificação automática e análise de dados por redes neurais auto-organizáveis.** 1999. Tese (Doutorado), Universidade de Campinas, Campinas, 1999.
- DEPARTMENT OF DEFENSE WASHINGTON DC. **Military Standard 1629A: Procedures for performing a failure mode, effects and criticality analysis.** Washington, EUA, 1980.
- DORNELES, V.; MATSCHULAT, E.; RODRIGUES, D. Análise de Modo e Efeito de falha Potencial. In: **FMEA – Apostila e tabelas Recomendadas para Severidade Ocorrência e Detecção.** São Leopoldo, 2010.
- DUAN, L. et al. A Local Density Based Spatial Clustering Algorithm with Noise. **IEEE International Conference on Systems, Man and Cybernetics**, Taipei, pp. 4061-4066, 2006.
- DUNN, S. Implementing a Computerized Maintenance Management System, Why most CMMS Implementations Fail to Provide the Promised Benefits. Maintenance Mini Conference. **The Plant Maintenance Resource Center**, Sydney, Australia 1997.
- ELECTROMOTIVE. **Centro de treinamento do cliente da Electro-Motive.** 2 ed, LaGrange, Illinois, 2010.
- EVARISTO, D. Locomotivas. **Brasil Ferroviário.** 2017. Disponível em: <<https://www.brasilferroviario.com.br/locomotivas>>, acessado em: 23/08/2018.

FACELI, K. et al. **Inteligência artificial: uma abordagem de aprendizado de máquina**. 1 ed, Rio de Janeiro: LTC, 2011.

FLEMING, P. V.; FRANÇA, S. R. R. Considerações Sobre a Implementação Conjunta de TPM e MCC na Indústria de Processos. TT044. In: **Anais CDRom do XII Congresso Brasileiro de Manutenção**. São Paulo, SP, 1997.

FORGY, E. W. Cluster analysis of multivariate data: efficiency versus interpretability of classifications. **Biometrics**, v. 21, n. 3, p. 768-769, 1965.

FTOUTOU, E.; CHOUCANE, M. Diesel engine injection faults' detection and classification utilizing unsupervised fuzzy clustering techniques. Proceedings of the Institution of Mechanical Engineers, Part C: **Journal of Mechanical Engineering Science**, p. 0954406219849089, 2019.

GITS, C.W. Design of Maintenance Concepts. **International Journal of Production Economics**, n. 24, 1992, p.217-226.

GOMIDE, F. A. C.; GUDWIN, R.R.; TANSCHKEIT, R. Conceitos fundamentais da teoria de conjuntos fuzzy, lógica fuzzy e aplicações. In: **Sixth International fuzzy Systems Association World Congress/ Tutorials - IFSA95**, p. 01 – 38, 1995.

GRAY, J.; URSPRUNG R. Random Safety, Auditing, Root Cause Analysis, Failure Mode and Effects Analysis. **Clinics in Perinatology**, v.37, ed. 1 p. 141-65. 2010.

GRITSH, C. Patent 7.213.520 B2 – diesel Electric Locomotive. **United states Patent**, p. 1-5, 2007.

GUSTAFSON, D. E.; KESSEL, W. C. Fuzzy clustering with fuzzy covariance matrix. In: **Proceedings of the IEEE Control and Decision Conference**, San Diego, p. 761-766, 1979.

HORTA, D. **Algoritmos e técnicas de validação em agrupamento de dados multi-representados, agrupamento possibilístico e bi-agrupamento**. 2013, Tese (Doutorado), Universidade de São Paulo, São Carlos, 2013.

JAIN, A. K.; DUBES, R. C. **Algorithms for clustering data**. New Jersey: Prentice-Hall Advanced Reference Series, 1988.

KARDEC, P.; NASCIF, J. **Manutenção – Função estratégica**. Rio de Janeiro: Qualitymark, 1999.

KLEN, A. M. **Algoritmo para agrupamento de descontinuidades em famílias baseado no método fuzzy k-means**. 2015. Tese (Doutorado), Universidade Federal de Ouro Preto, Ouro Preto, 2015.

KLIR, G. J.; YUAN, B.; CLAIR, U. S. **Fuzzy Set Theory: Foundations and Applications**. United States of America: Prentice Hall, 1997.

LADEIRA, C.M. **Desenvolvimento de um sistema de alimentação de combustível para motores diesel-Gás**. 2005, Dissertação (Mestrado), Pontifícia Universidade Católica, Rio de Janeiro, 2005.

LEI, Y. **Intelligent fault diagnosis and remaining useful life prediction of rotating machinery**, [S.l.]: Butterworth-Heinemann, 376 p. 2016.

LI, C. S. The Improved Partition Coefficient. **Procedia Engineering**, v. 24, p.534-538, 2011. 10.1016/j.proeng.2011.11.2691.

LINDEN, R. Técnicas de Agrupamento. **Revista de Sistemas de Informação da Faculdade Salesiana Maria Auxiliadora**, n.4, p.18-36, 2009.

LNER – LONDON NORTH EASTERN RAILWAY. **The Gresley A4 Pacifics**, 2007. Disponível em: <<https://www.lner.info/locos/A/a4.php>>, acessado em: 20/08/2019.

LUCATELLI, M. V. **Proposta de aplicação da manutenção centrada em confiabilidade em equipamentos médico-hospitalares**. 2002. Tese (Doutorado), Universidade Federal de Santa Catarina, Florianópolis, 2002.

MAGDI, K. K.; JÄÄSKELÄINEN, H. Diesel Fuel Injection. **Diesel Net Technology Guide**, 2013.

MATA FILHO, J. N., MIRANDA, C. F. LIMA, C. E. Manutenção Baseada em Confiabilidade e Controle de Custos de Manutenção – Um Time de Sucesso na Indústria Aeronáutica. In: **Anais CD-Rom do XIII Congresso Brasileiro de Manutenção**. Salvador, 1998.

MICROSOFT. **Tarefas de aprendizado de máquina no ML.NET**. Disponível em: <https://docs.microsoft.com/pt-br/dotnet/machine-learning/resources/tasks> , acessado em: 04/02/2020.

MITCHELL, T. M. **Machine Learning**. [S.l.] : McGraw HILL, 1997.

MONKS, J. G. **Administração da Produção**. São Paulo:MacGraw Hill, 1989, p.466.

MOTA, V. C. **Modelagem fuzzy, geoestatística e estatística na avaliação de sistema de confinamento para bovinos no modelo *Compost Barn***. 2018, Tese (Doutorado) Universidade Federal de Lavras, Lavras, 2018.

MOUBRAY, J. **Reliability-Centered Maintenance**. 2. ed., [S.l.]: Industrial Pr, 1997, 423 p.

OLIVEIRA, L. A. D. **Investigação baixa confiabilidade baterias de aplicação em locomotivas diesel-elétricas**. 2015, Trabalho de conclusão de curso (Especialização), Pontifícia Universidade Católica, Divinópolis, 2015.

ORTEGA, N. R. S. **Aplicação da Teoria de Conjuntos Fuzzy a problemas da Biomedicina**. 2001, Tese (Doutorado), Universidade de São Paulo, São Paulo, 2001.

PADILHA, V. A.; CARVALHO, A. C. P. L. F. **Mineração de Dados em Python**. São Paulo: Universidade de São Paulo, 2017.

PEREIRA, J. C. **Motores e geradores:Princípios de funcionamento, instalação, operação e manutenção de grupos diesel geradores**. [S.l. : s.n.], 49 p., 2007.

PRATI, R.C. **Novas abordagens em aprendizado de máquina para a geração de regras, classes desbalanceadas e ordenação de casos.** 2006. Tese (Doutorado), Universidade de São Paulo, São Paulo, 2006.

RENTERÍA, A. R. **Estimação de probabilidade Fuzzy a partir de dados imprecisos.** 2006, Tese (Doutorado), Pontifícia Universidade Católica, Rio de Janeiro, 2006.

RIBEIRO, T. Classificação Fuzzy de Padrões Não-Motores e Indicação da Severidade da Doença de Parkinson. In: **Fuzz-ieee 2017**, Universidade Federal de Lavras, Lavras, 2017.

RIGNEL, D.G. S.; CHENCI, G.P.; LUCAS, C.A. Uma introdução a Lógica fuzzy. **Revista Eletrônica de Informação e Gestão Tecnológica**, v.1, n.1, 2011.

SAKURADA, E. Y. **As técnicas de Análise do Modos de Falhas e seus Efeitos e Análise da Árvore de Falhas no desenvolvimento e na avaliação de produtos.** 2001. Dissertação (Mestrado), Universidade Federal de São Carlos, 2001.

SANDER, C. Tipos de FMEA: como as equipes operam dentro da empresa. **CAE Treinamentos.** 2019. Disponível em: <<https://caetreinamentos.com.br/blog/fmea/tipos-de-fmea>>, acessado em: 20/11/2019.

SANTOS, G. S; VARELA, C. A. **Noções Básicas de Motores a diesel.** 1. ed., Seropédica, RJ: Universidade Federal Rural do Rio de Janeiro, p.5-11, 2010.

SILVA, A. A. V. et al.. Sistema fuzzy para diagnóstico de hérnias da região inguinal. In: **Anais do Congresso brasileiro de Sistema fuzzy-CBSF**, 2, Natal. SBMAC, 2012. p. 919-931.

SILVA, E. C. N. **Sistemas Fluido Mecânicos.** In: Apostila de Pneumática, Departamento de Engenharia Mecatrônica e de Sistemas Mecânicos, Escola Politécnica da Universidade de São Paulo, São Paulo, 2002.

SILVA, M.M. **Uma Abordagem Evolucionária Para o Aprendizado Semi-Supervisionado em Máquinas de Vetores de Suporte.** 2008. Trabalho de Conclusão de Curso (Especialização), Universidade Federal de Minas Gerais, Belo Horizonte, 2008.

SIQUEIRA, K. T. Tutela Responsável de Ativos Físicos. In: **Anais do III Seminário Brasileiro de Confiabilidade na Manutenção.** São Paulo, SP.p. 111-120, 2000.

SOUTO et al. Técnicas de aprendizado de máquina para problemas de biologia molecular. In: **III Jornada de Atualização em Inteligência Artificial.** [S.l.]: SBC, p.103-152, 2003.

TANSCHKEIT, R. **Sistemas fuzzy.** Departamento de Engenharia Elétrica, Pontifícia Universidade Católica, Rio de Janeiro, 2012.

TOLEDO, J. C.; AMARAL, D. C. **FMEA - Análise do Tipo e Efeito de Falha.** GEPEQ – Grupo de Estudos e Pesquisa em Qualidade, Universidade Federal de São Carlos, São Carlos, SP, 2008.

WAGNER, A. **Extração de Conhecimento a partir de Redes Neurais aplicada ao problema da Cinemática Inversa na Robótica**. 2003, Dissertação (Mestrado), Universidade do Vale do Rio dos Sinos, Porto Alegre, 2003.

WU, X. et al. Top 10 algorithms in data mining. **Knowledge and Information Systems**. 14, p. 1-37, 2008.

YANG, Q. et al. Fault diagnosis based on fuzzy c-means algorithm of the optimal number of clusters and probabilistic neural network. **International Journal of Intelligent Engineering & Systems**, v. 4, n. 2, p. 51-59, 2011.

YATSKIV, I.; GUSAROVA L. Results validation methods analyzed by Ansis. In: **Proceedings of the RelStat International Conference**. [S. l], 2006.

YEN, J.; LANGARI, R. **Fuzzy Logic: Intelligence, Control, and Information**. United States of America: Prentice Hall, EUA, 1999.

VALE, M. N.do. **Agrupamentos de Dados: Avaliação de Métodos e Desenvolvimento de Aplicativo para Análise de Grupos**. 2005, Dissertação (Mestrado), Pontifícia Universidade Católica, Rio de Janeiro, 2005.

VALOR DA LOGISTICA INTEGRADA – VLI. **Base perfil de perdas 2018**, Departamento de Engenharia de locomotivas, Divinópolis, 2018.

XIE, X. L.; BENI, G. A validity measure for fuzzy clustering. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v.13, n. 8, p. 841-847, 1991.

ZHU, X.; GOLDBERG, A. B. Introduction to semisupervised learning. **Synthesis lectures on artificial intelligence and machine learning**, 3(1):1–130, 2009.

ZORZATE, E. H. et al. Aplicação e Comparação entre os Métodos Fuzzy C-Means/ Lógica Fuzzy e Redes SOM/Rough Sets na Obtenção de Curvas de Demanda para Consumidores de Baixa Tensão. In: **XVII Seminário Nacional de Distribuição de Energia Elétrica**, Belo Horizonte, 2006.

APÊNDICE A – Locomotivas diesel-elétricas e seus sistemas

De uma forma macro, uma locomotiva arquitetura diesel-elétrica pode ser subdividida em 13 sistemas distintos: Motor a combustão; admissão de ar; arrefecimento; combustível; lubrificação; excitação e controle de potência; propulsão; frenagem dinâmica; pneumática; estrutura; sistema de iluminação; sistema de partida e carga de bateria; sistema de transmissão mecânico.

Cada sistema está brevemente detalhado a seguir. O nível de profundidade apresentado em cada tópico variará em acordo com as necessidades do estudo. Importante ressaltar que em razão deste estudo ser direcionado a uma frota específica de locomotivas AC-DC, será dado maior ênfase a este tipo de arquitetura.

1 Motor a combustão

Basshuysen e Schafer (2004) definiram os motores a combustão como mecanismos capazes de converter a energia química resultante de uma mistura inflamável de gases e combustível em energia mecânica. Define-se por motores a combustão interna ou motor endotérmico as máquinas que fazem esta conversão dentro de câmaras fechadas, através do deslocamento retilíneo de um ou mais pistões, que por sua vez transmitirá este movimento para um eixo girante.

Segundo Ladeira (2005), os motores de combustão interna se baseiam no princípio de expansão e compressão alcançados pela variação da temperatura dos gases, definidos nas literaturas como ciclos termodinâmicos. Por esta razão, este tipo de motor se distingue dos motores de combustão externa, onde o processo de combustão ocorre externamente ao motor. Um motor de combustão interna pode apresentar uma ou mais câmaras de combustão.

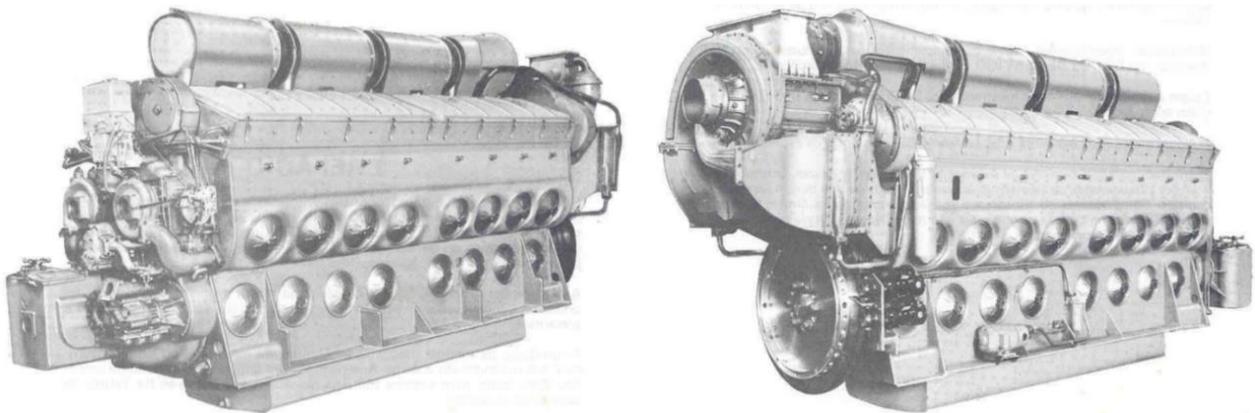
Borba (2014) alegou que apesar dos motores a combustão interna funcionarem baseados nos princípios das leis da termodinâmica, eles diferenciam entre si quanto as seguintes classificações:

- a) **Tipo de combustível:** diesel, gasolina; álcool, híbridos, entre outros;
- b) **Aplicação:** estacionários, industriais, veiculares ou Marítimos.
- c) **Compressão nos cilindros:** variação da taxa de compressão no cilindro;
- d) **Quantidade de cilindro:** podem variar de um a dezenas de cilindros;

- e) **Disposição dos cilindros:** alinhados horizontalmente; 45 ° em V;
- f) **Potência:** são comercializados motores que variam de poucos HP a mais de 100.000 HP;
- g) **Ciclo de trabalho:** 2 ou 4 tempos;
- h) **Modo de admissão:** aspirado, soprado ou turboalimentado;
- i) **Sistema de arrefecimento:** refrigerado a água ou a ar.

Pode ser observado na Figura 26 as características, estrutura física e classificações de um motor a combustão modelo 645E3B, aplicado em locomotivas frota SD40 fabricante EMD. Trata-se de um motor com potência máxima de 3.600 HP, 2 tempos de operação, 16 cilindros em V, taxa de compressão 14,5:1, rotação nominal do eixo virabrequim variante entre 200 RPM (marcha lenta) a 900 RPM (rotação em oitavo ponto).

Figura 26- Motor a combustão modelo 645E3B

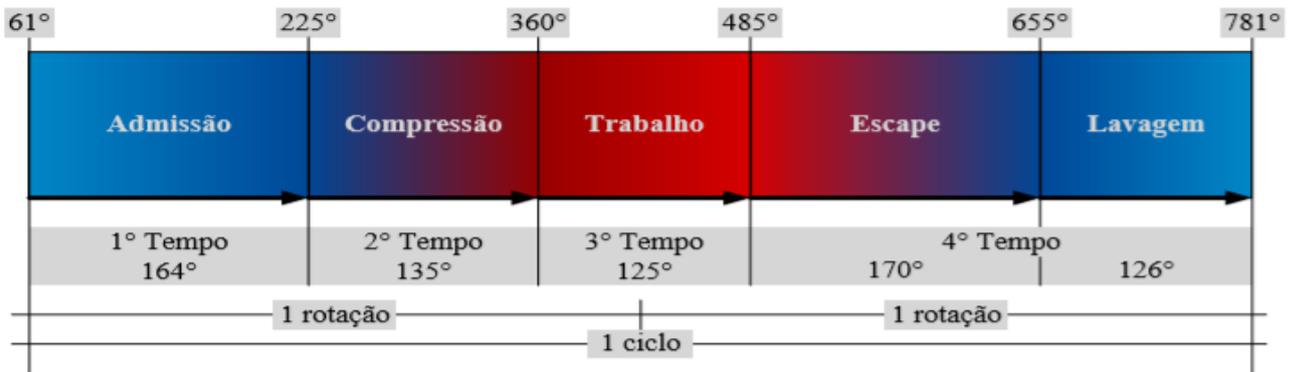


Fonte: Corema, 2006

1.1 Funcionamento motor diesel e interação entre seus conjuntos

O ciclo de trabalho de um motor quatro tempos corresponde ao movimento de quatro cursos do pistão, equivalente a duas rotações do eixo virabrequim, conforme representado na Figura 27.

Figura 27- Relação ângulo do eixo virabrequim versus ciclo de um motor quatro tempos



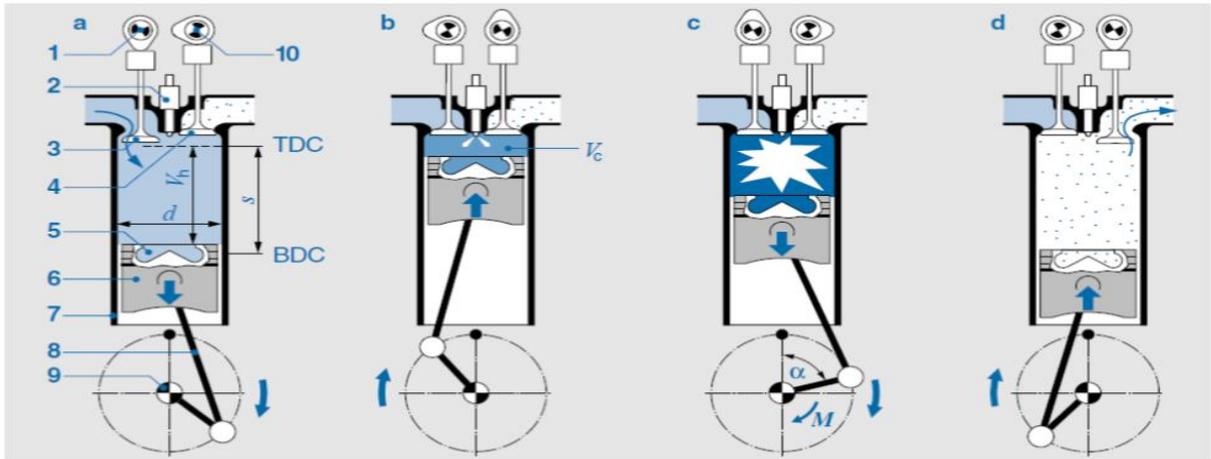
Fonte: Borba (2014)

As válvulas de admissão são abertas quando o eixo virabrequim atinge a posição de rotação em 61° em relação ao ponto superior, e fechadas quando o mesmo atinge a posição 225° , onde começa o ciclo de compressão. Em 360° ocorre a explosão, caracterizado por ciclo de trabalho. As válvulas de descarga são abertas na posição 655° , liberando os gases de combustão para atmosfera, caracterizado por ciclo de lavagem.

Na Figura 28, está representada de forma mais detalhada a sequência de operação de cada ciclo de um motor de quatro tempos. Observa-se nesta Figura as seguintes etapas: (a) tempo de admissão, (b) tempo de compressão, (c) combustão e (d) tempo de exaustão. Também se destaca a localização física dos principais itens montados ao conjunto de força: (1) came da válvula de admissão, (2) bico injetor, (3) válvula de admissão, (4) válvula de exaustão, (5) câmara de combustão, (6) pistão, (7) parede dos cilindros, (8) biela, (9) virabrequim, (10) came de válvula de exaustão.

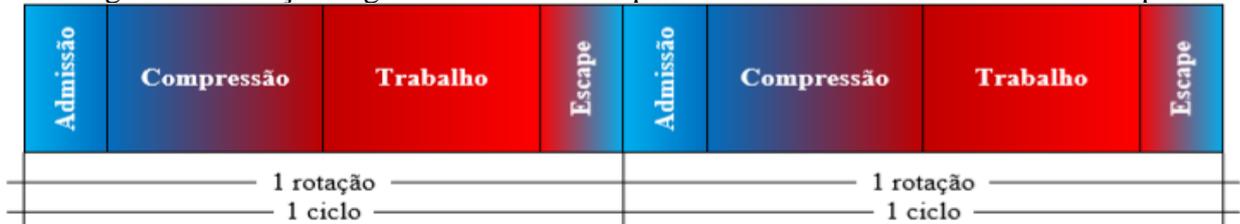
No motor diesel a dois tempos, o ciclo de reação entre combustível e o comburente se dá em apenas dois cursos do pistão, correspondente a uma volta no eixo virabrequim, conforme esquematizado na Figura 29. Diferente dos motores 4 tempos, este tipo de motor possui o ciclo de admissão e compressão em apenas uma volta do virabrequim (180° de posicionamento) e o ciclo de trabalho e escape nos 180° restantes. Na Figura 30, está representada de uma forma detalhada a sequência de operação de cada ciclo de um motor dois tempos.

Figura 28- Ciclo de um motor quatro tempos



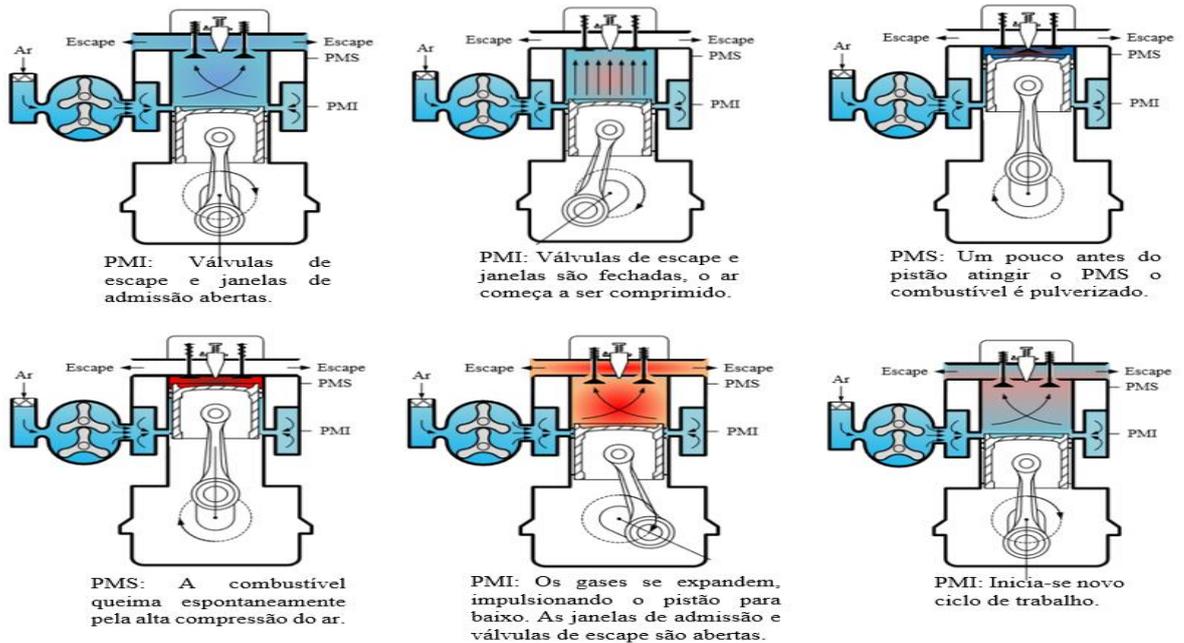
Fonte: Reif (2014)

Figura 29- Relação ângulo do eixo virabrequim versus ciclo de um motor dois tempos



Fonte: Borba (2014)

Figura 30- Sequência de operação de um motor dois tempos



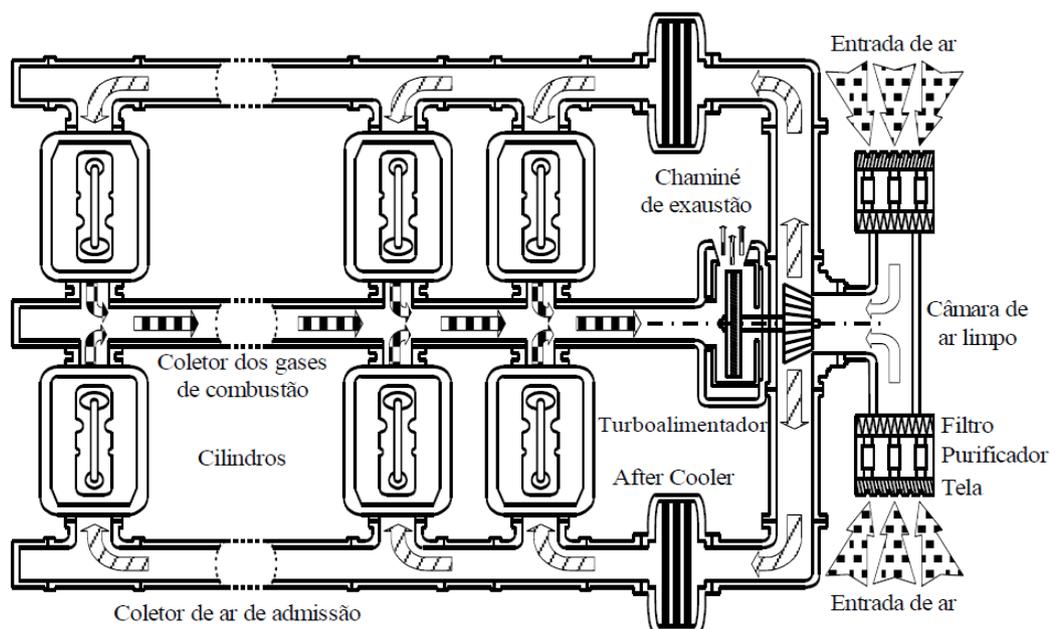
Fonte: Borba (2014)

2 Sistema de admissão de ar

Define-se por sistema de admissão todos os itens e mecanismos contidos em um motor a combustão interna que finda aspirar o ar atmosférico do lado externo para o interior dos cilindros, de modo a inicializar um novo ciclo de trabalho. Motores a combustão interna de elevada potência demandam maiores quantidades de ar para esta função. Desta maneira, é eventualmente necessária a aplicação de dispositivos auxiliares, que visam aumentar a vazão de ar do sistema. Estes dispositivos são denominados turbo-compressores ou turbo-alimentadores.

O turbo-compressor, é uma unidade independente constituída por um eixo onde em uma de suas extremidades está posicionado o rotor quente (turbina a gás) e na outra um rotor frio (compressor). O rotor quente impulsionado pela energia cinética armazenada nos gases de exaustão (antes de sua descarga para atmosfera) irá acionar o rotor frio, que por sua vez impulsionará o ar atmosférico para o interior dos cilindros (FIGURA 31). Este dispositivo é utilizado essencialmente para aumentar a potência do motor (COREMA, 2006).

Figura 31 - Sistema de admissão de ar locomotiva diesel-elétrica



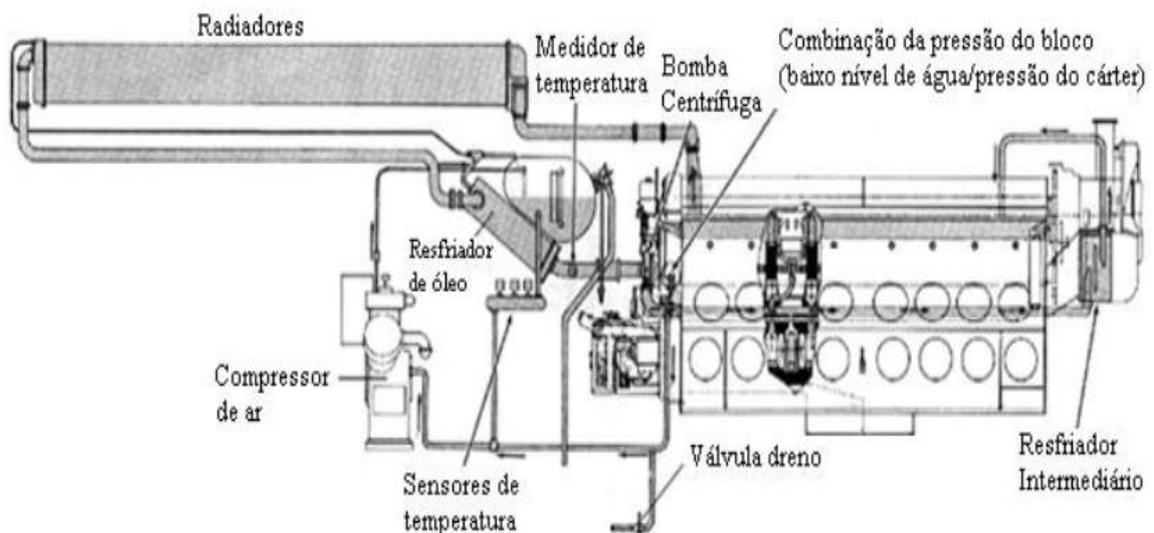
Fonte: Borba (2014)

3 Sistema de arrefecimento

O sistema de arrefecimento tem por função a manutenção da temperatura nominal de trabalho do motor diesel durante sua operação. Motores trabalhando em condições ideais de temperatura (definidos por projeto) tendem a consumir menos combustível. Os motores de grande porte, são em quase toda a sua totalidade refrigerados por fluidos de arrefecimento. Esses fluidos são geralmente compostos de água e aditivos necessários para aumentar seu ponto de ebulição, a temperatura de congelamento e evitar corrosões das tubulações (DO CARMO, 2018).

A circulação do líquido refrigerante por todo o sistema é realizada mediante uma ou duas bombas tipo centrífugas, instaladas no bloco do motor diesel. O eixo da bomba é acionado pela a extremidade livre do eixo virabrequim por um sistema de acoplamento de engrenagens (BORBA, 2014). Após a circulação por todo o bloco absorvendo o calor gerado do motor diesel, o líquido refrigerante deverá ser resfriado de modo a efetuar novos ciclos de refrigeração, estando incumbido para esta finalidade dispositivos intitulados radiadores (FIGURA 32). Locomotivas diesel-elétricas podem dispor de um ou mais radiadores, dependendo da potência do motor, região de operação entre outros fatores.

Figura 32- Sistema de arrefecimento de uma locomotiva diesel-elétrica



Fonte: Borba (2014)

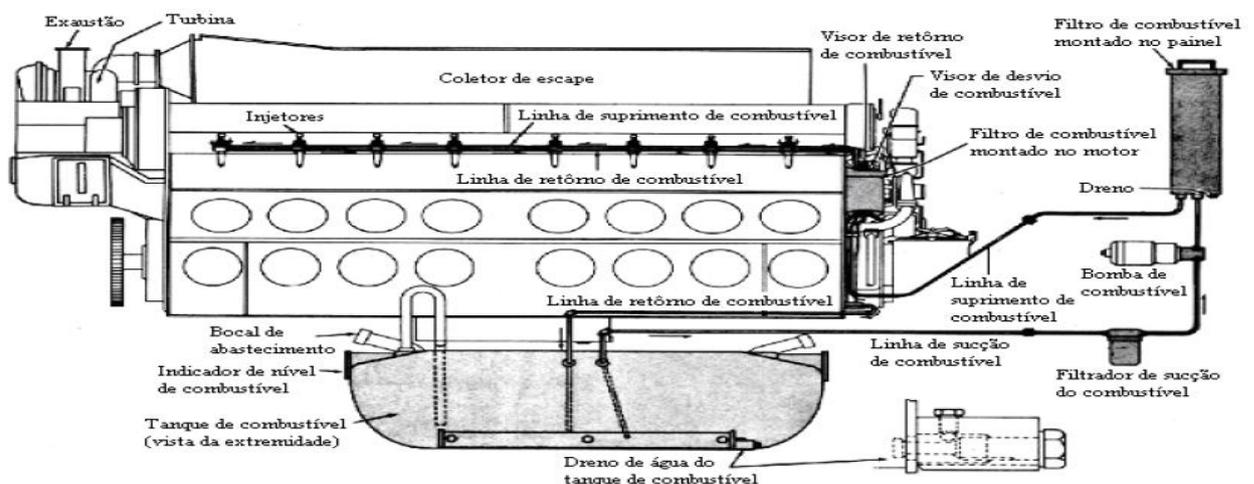
4 Sistema de combustível (injeção)

O propósito principal do sistema de combustível é transferir o combustível do tanque até o interior dos cilindros, na quantidade certa e no momento correto. Porém, o controle destas duas variáveis não garantirá boa eficiência do motor, necessitando também que este sistema seja capaz de atomizar eficientemente o combustível e facilitar sua mistura com o ar (MAGDI; JAASKELAINEN, 2013).

O combustível inicialmente, está armazenado em tanques específicos, localizados na plataforma inferior da locomotiva, fixado por parafusos e hastes existentes em suas extremidades, sendo transportado do tanque até os bicos injetores por uma bomba de deslocamento constante, denominada bomba de transferência. O acionamento desta bomba é dado via motor elétrico, comandado por relés contidos no sistema de comando e controle da locomotiva (COREMA, 2006).

Após o transporte aos bicos injetores, o combustível será injetado de forma pulverizada no interior dos cilindros, através de componentes denominados injetores. O injetor é composto por uma bomba de alta pressão e um bico injetor, unificados em um só componente ou separados entre si (FIGURA 33). Os motores diesel aplicados nas locomotivas diesel-elétricas, dispõe de injetores localizados e assentados no centro de cada cabeçote, com o bico pulverizador ligeiramente projetado abaixo do furo de assentamento (COREMA, 2006).

Figura 33 - Sistema de combustível de uma locomotiva diesel-elétrica



Fonte: Borba (2014)

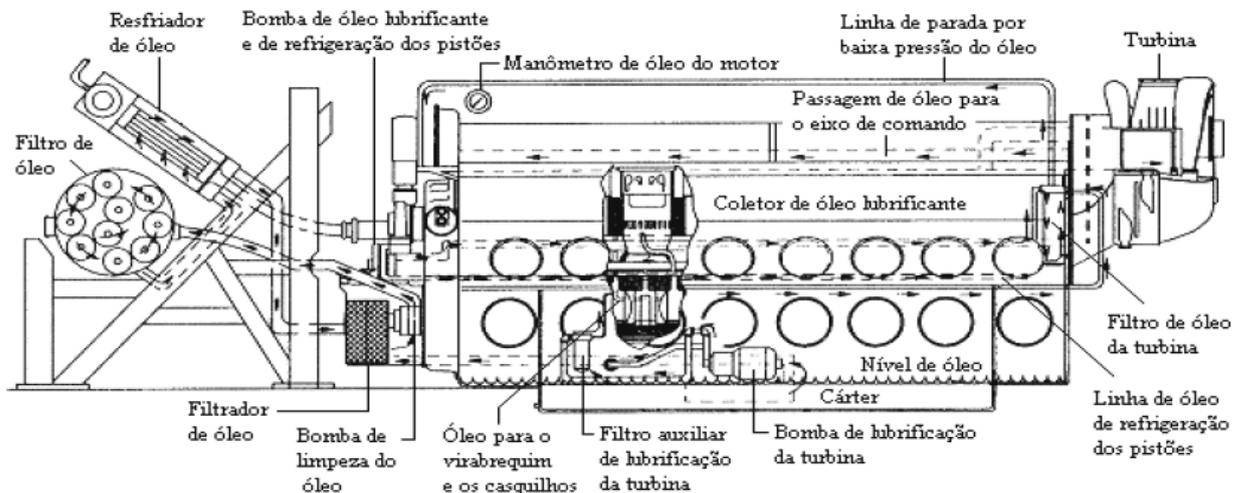
5 Sistema de lubrificação

Além da função de manter as partes móveis separadas entre si, o sistema de lubrificação tem a função de auxiliar no arrefecimento, proteger os componentes mecânicos de impactos, corrosões e contribuir com a limpeza interna do motor (BASSHUYSEN; SCHAFFER, 2004). O sistema de lubrificação dos motores aplicados às locomotivas diesel-elétricas consiste em uma combinação de três circuitos distintos, cada um contendo sua própria bomba, ambas acionadas mecanicamente pelo eixo virabrequim, sendo eles: circuito de lubrificação principal, circuito de refrigeração dos pistões e sistema de limpeza do óleo (COREMA, 2006).

Inicialmente, o óleo é armazenado em um reservatório fabricado em aço denominado cárter, que além de ter a função de reservatório do óleo lubrificante, também serve de apoio para o bloco do motor na estrutura da locomotiva. Janelas de inspeção localizadas em sua lateral (direcionadas para cada um dos cilindros) dão acesso às partes internas do motor (COREMA, 2006).

Uma primeira bomba, denominada bomba de limpeza, é acionada pela engrenagem de acionamento do motor diesel, succionando continuamente o óleo do cárter através de um filtro metálico de malha grossa. Posteriormente, o óleo irá passar por um segundo filtro confeccionado em papel plissado, efetuar a troca calor com o líquido de arrefecimento no resfriador de óleo e atingir simultaneamente a bomba principal e a de resfriamento dos pistões, para então ser bombeado através destes circuitos (FIGURA 34) (BORBA, 2014).

Figura 34- Sistema de lubrificação de uma locomotiva diesel-elétrica



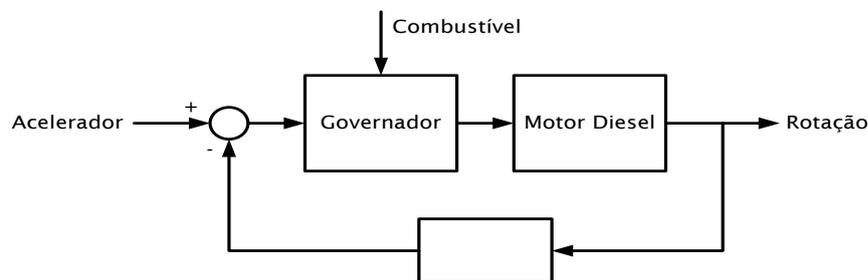
Fonte: Borba (2014)

6 Sistema de excitação e controle de potência

De acordo com Borba (2014), as necessidades e particularidades do tráfego ferroviário exigem das locomotivas um correto e preciso controle de tração para diferentes condições operacionais, como por exemplo: arrancadas, acelerações, estabilidade da velocidade e frenagem dinâmica dos trens. Nestas condições um sistema denominado excitação e controle deverá proporcionar uma regulação suave, exata, estável e de boa resposta às demandas do operador.

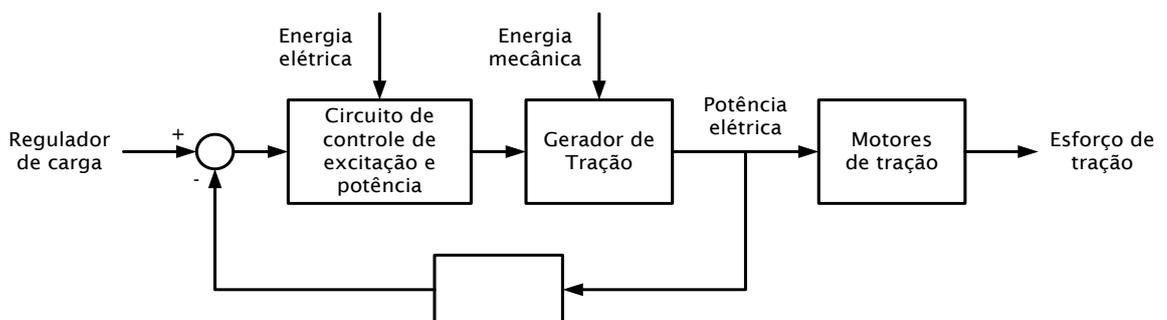
O sistema de excitação e controle é o principal elemento para produção de energia nos geradores de uma locomotiva. É ele que irá controlar a capacidade de carga do motor diesel, a capacidade de carga do gerador de tração, assim como a tensão e corrente dissipada nos motores de tração. O grupo motor-gerador é composto de duas malhas fechadas. A primeira, tem por elemento principal o motor diesel, atuando diretamente no controle de sua rotação (FIGURA 35). Na segunda, o gerador de tração é o elemento principal, onde sua potência de saída é controlada através de sua corrente de campo. (FIGURA 36).

Figura 35 - Sistema de controle motor diesel de uma locomotiva diesel-elétrica AC-DC



Fonte: Borba (2014)

Figura 36- Sistema de controle gerador de tração de uma locomotiva diesel-elétrica AC-DC



Fonte: Borba (2014)

7 Sistema de propulsão

O sistema de propulsão está relacionado a todos os componentes de geração, comando, transmissão e distribuição de potência elétrica de uma locomotiva diesel-elétrica, assim como suas respectivas cargas. Na grande maioria dos casos, este circuito opera com tensões nominais de até 1.500 volts e correntes próximas dos 700 amperes. Geralmente o sistema de propulsão é dotado de um gerador de tração, um gerador companheiro, bancadas retificadoras, chaves de transferência, contadores e motores de tração (FIGURA 37).

Nas locomotivas AC-DC o gerador de tração é que uma máquina síncrona trifásica, com tensão e frequência variantes. Possui o circuito de campo rotativo e o de armadura estacionário. O circuito estacionário é composto por três enrolamentos ligados em estrela, já o rotativo consiste de bobinas ligadas em série, alimentadas por uma fonte CC. O controle do campo é realizado pelo sistema de excitação e controle, descrito no subtópico anterior. O número de polos deste alternador, irá variar em acordo com o projeto e especificações de cada modelo de locomotiva. (BORBA, 2014).

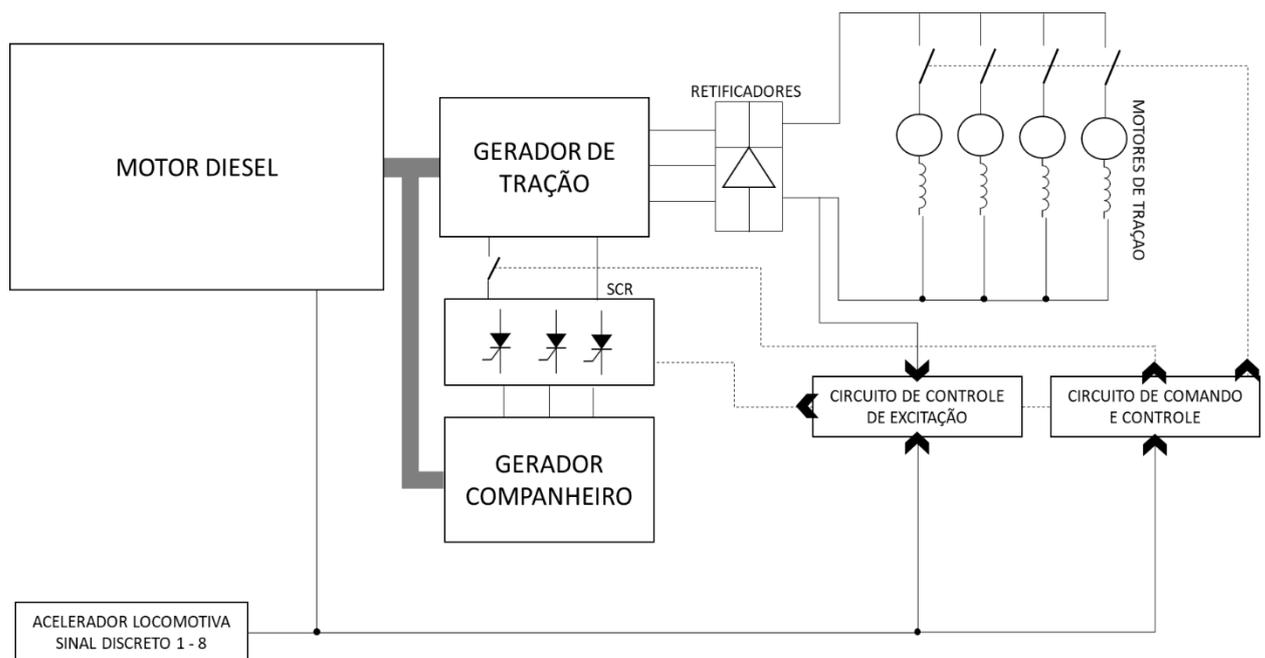
O gerador companheiro está acoplado ao mesmo eixo do gerador de tração, acionado pelo eixo virabrequim do motor diesel. Sua função é alimentar o campo do gerador tração (pós-retificação) e acionar algumas cargas secundárias necessárias ao funcionamento do motor diesel, como por exemplo: motores dos ventiladores dos radiadores, motor do soprador de ar para arrefecimento do sistema de propulsão, motor do exaustor de inércia, entre outras cargas, variando com o modelo da locomotiva. Trata-se de uma máquina síncrona trifásica (assim como o gerador de tração), com o campo rotativo alimentado pelo circuito de comando da locomotiva (ELECTROMOTIVE, 2010).

A tensão trifásica do gerador de tração será fornecida diretamente à bancada retificadora, onde será convertida em tensão contínua (retificador 6 pulsos) e posteriormente alimentará o conjunto motores de tração. Os retificadores são compostos por diodos projetados para operarem em alta tensão e corrente, conectados de modo a constituírem uma ponte trifásica de onda completa. O calor gerado no retificador é arrefecido por ventilação forçada, proveniente do circuito de arrefecimento do sistema de propulsão. As chaves de transferência elétricas e contadores de potência são responsáveis pelo fechamento e manobras do circuito entre o gerador de tração e os motores de tração.

Denominam-se motores de tração, os motores elétricos aplicados aos eixos dos rodeiros de uma locomotiva diesel-elétrica, alimentados pela bancada retificadora. São dedicados exclusivamente a tração e frenagem dinâmica da locomotiva. Normalmente são instalados em

cada um dos eixos dos rodeiros existentes nos truques, caracterizados por uma construção compacta e robusta em função das limitações de espaço onde operam. A transmissão de rotação entre o eixo destes motores e o rodeiro se dá por duas engrenagens (pinhão e coroa). Sua acomodação é concebida por meio de suspensão, ou seja, são apoiados diretamente ao eixo por mancais de fricção ou rolamentos. O arrefecimento destes motores se dá pela ventilação forçada, existindo em cada motor dutos de borracha sanfonados, que conduzirá o ar produzido pelos sopradores para seu interior. Normalmente, os motores tração possuem vida curta (próxima dos 5 anos), por estarem sujeitos à agressivas condições de operação. Locomotivas projetadas antes da década de 90 utilizam motores de corrente contínua, em função da necessidade de um torque elevado e um preciso controle. (BORBA, 2014). Verifica-se na Figura 37 um esquemático simplificado de uma locomotiva diesel-elétrica AC-DC.

Figura 37- Esquema simplificado sistema de propulsão locomotivas AC-DC



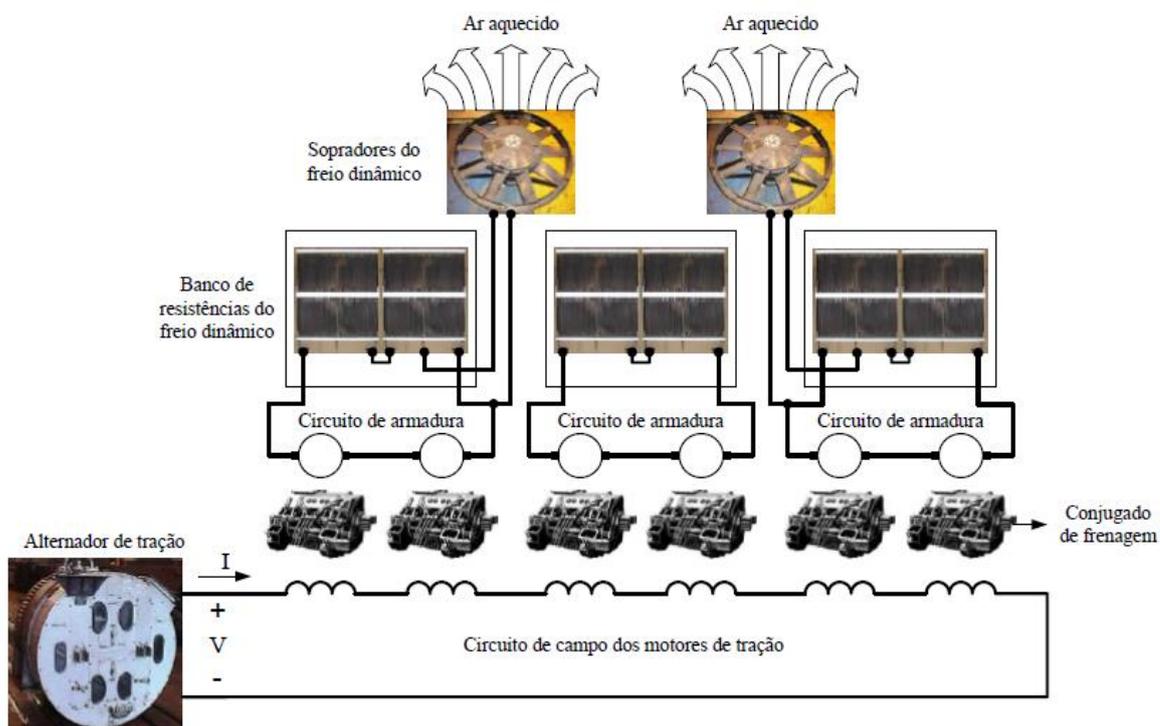
Fonte: do autor (2020)

8 Sistema de frenagem dinâmica

Na frenagem dinâmica os motores de tração passam a operar como geradores, com o intuito de aumentar a precisão de controle do trem por meio da aceleração negativa da locomotiva, auxiliando também nas frenagens. A energia produzida será dissipada na forma de calor em um banco de resistências, conectadas aos terminais das armaduras do motor. Durante

a frenagem dinâmica, as bobinas de campo dos motores de tração são ligadas em série pela manobra das chaves de transferência, e alimentadas pela bancada retificadora. A produção de energia nos circuitos de armadura será dissipada em um banco de resistência, possibilitando um controle de frenagem pela interação dos campos magnéticos (FIGURA 38) (BORBA, 2014). O sistema de frenagem dinâmica é composto por: chaves de transferência, circuito de comando e controle, grades de resistência, ventiladores das grades de resistência e contatores.

Figura 38- Circuito simplificado da frenagem dinâmica de uma locomotiva diesel-elétrica AC-DC



Fonte: Borba (2014)

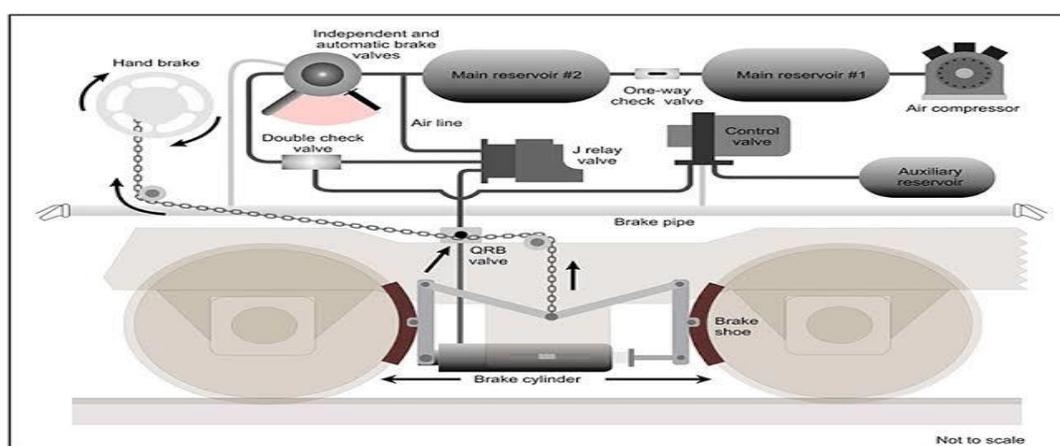
9 Sistema pneumático

Define-se por pneumática, o ramo da engenharia que se destina ao estudo da aplicação do ar comprimido como fonte de energia (SILVA, 2002). Nas locomotivas diesel-elétricas, este sistema está diretamente atribuído aos freios da locomotiva e vagões, equipamentos periféricos como buzina, sinos, limpadores de para-brisa e acionamento de chaves de transferência contidos no sistema de propulsão.

As locomotivas diesel-elétricas possuem dois diferentes sistemas de freio pneumático: O freio independente (para frenagem apenas das locomotivas de forma isolada, por intermédio

de atuadores pneumáticos, timoneiras mecânicas e sapatas de atrito) e o freio automático (para carregamento dos reservatórios e pilotagem das válvulas atuadoras contidas nos vagões, para frenagem de toda a composição). Observa-se na Figura 39 que os reservatórios 1 e 2 são responsáveis por alimentar todo o circuito. Um manipulador contendo dois comandos independentes é responsável pela pilotagem tanto da válvula de controle do freio automático (*control valve*), quanto a válvula relé (*relay valve*) do freio independente. Estas válvulas irão pressurizar o cilindro de freio com o ar contido no reservatório 2, que por sua vez atuará em cima da timoneria mecânica, pressionando as sapadas sobre as rodas. A pilotagem do freio automático é feita através de um encanamento denominado encanamento geral, acoplado aos vagões da composição. Este reservatório é também responsável pelo abastecimento dos reservatórios contidos em cada vagão, assim como pilotagem das válvulas de controle existente nos mesmos, atuando diretamente na frenagem da composição.

Figura 39- Sistema freio pneumático de uma locomotiva



Fonte: Borba (2014)

10 Estrutura

A estrutura está relacionada à toda infraestrutura física utilizada na construção de uma locomotiva, podendo ser considerado o principal sistema, por proporcionar a integração de todos os demais. Possui a função de alojar e suportar a cabine e todos os componentes montados na locomotiva, assim como receber as forças de tração dos truques, distribuindo-as para os vagões e demais materiais rodantes tracionados pela locomotiva. Está englobado neste sistema: A cabine, o chassi, os parafusos de choque e tração (engates), a testeira e freio de estacionamento.

11 Sistema de iluminação

Como o próprio nome diz, o sistema de iluminação está vinculado a todos os itens, circuitos e componentes dedicados a iluminação das cabines, sinalizações, faróis e demais fontes artificiais de luz existentes em uma locomotiva. Este sistema é composto pelos seguintes conjuntos: Farol brilhante, farol oscilante, iluminação da cabine, painel de controle do motor, iluminação do pedestal de alavancas e iluminação do compartimento do motor diesel.

12 Sistema de partida e carga de bateria

As locomotivas diesel-elétricas possuem um banco de baterias, que tem por função primária a partida de seu motor diesel. Após partida, o gerador auxiliar passa a produzir energia para alimentar o circuito de comando e cargas secundárias. Outra função deste gerador é recarregar novamente o banco de bateria que sofreu descarga durante a ignição, completando um ciclo de carga e descarga (OLIVEIRA, 2015). O sistema de partida está atrelado a todos os componentes, circuitos e atuadores responsáveis pelo o ciclo de partida e recarregamento dos bancos de bateria aplicados às locomotivas. Neste sistema estão atribuídos os seguintes conjuntos: circuito de força, conjunto de baterias, controle de partida, gerador auxiliar, motor de partida e regulador de tensão do gerador auxiliar.

13 Sistema de transmissão

As operações das locomotivas diesel-elétricas em trens, demandam certos elementos que possibilitem a conversão do conjugado gerado nos rodeiros (pelos motores de tração) em esforço trator. Para esta finalidade existe o sistema de transmissão mecânico, responsável por converter este conjugado em força linear nos engates (esforço trator). Este sistema é composto pelos rodeiros e truques ferroviários.

Os rodeiros são compostos por duas rodas, um eixo central, uma engrenagem e dois mancais. As rodas se diferenciam por suas particularidades construtivas, podendo ser fabricadas em aço forjado, laminado ou fundido. Suas propriedades devem atender as especificações da norma internacional AAR M-107. São inseridas aos eixos pelo processo de interferência mecânica. Geralmente se adotam os seguintes diâmetros de especificação: 36” (914mm), 40” (1.016mm) ou 42” (1.066,8mm). Os eixos são construídos em aço forjado, obedecendo a norma internacional AAR M101. A resistência a cisalhamento das mangas de eixo definirá a

quantidade de carga e peso que a locomotiva poderá suportar. Os mancais são montados nas mangas de eixo do rodeiro (extremidade dos rodeiros). São dispositivos anti-atrito sob os quais o eixo irá girar, ficando retidos entre as aberturas da aranha do truque, suportando todo o peso da locomotiva. Os mancais são classificados em acordo com o rolamento utilizado: rolamentos tipo rolos cilíndricos ou rolamento do tipo cartuxo. O sistema de engrenamento entre motores de tração e rodeiros é feito pelo intermédio de duas engrenagens: pinhão (fixada ao eixo dos motores de tração) e coroa (fixada ao eixo do rodeiro). A engrenagem coroa, fabricada em aço médio-carbono, possui tratamento térmico para seu endurecimento estrutural, apresenta a forma cilíndrica e os dentes retos. Dispõem de um furo central, não chavetado e é montado ao eixo do rodeiro pelo processo de prensagem a frio, fixada somente pela interferência entre ambos. O pinhão também possui a forma cilíndrica, e são fabricados em aço médio carbono tratado termicamente. Fabricado com um furo cônico central, é montado a quente aos eixos dos motores de tração sem intermédio de chaveta, também fixada unicamente pela interferência entre ambos (BORBA, 2014).

A função principal dos truques é sustentar o peso da locomotiva e fornecer meios de transmitir a potência gerada nos motores de tração aos trilhos. Sua estrutura é arquitetada para suportar todas as tensões resultantes dos choques de rodagem produzidas por anormalidades existentes ao longo da via, absorvendo e isolando os impactos para não serem transmitidos à plataforma e equipamentos fixados à mesma (BORBA, 2014). Os truques podem ser classificados pelo número de eixos contidos ou sua flexibilidade:

a) Número de eixos:

- **Truque B:** formado por dois rodeiros em uma única estrutura (FIGURA 40);
- **Truque C:** formado por três rodeiros em uma única estrutura (FIGURA 41);
- **Truque D:** formado por quatro rodeiros em uma única estrutura (FIGURA 42).

b) Flexibilidade:

- **Rígidos:** composto por apenas um bloco rígido (FIGURA 42);
- **Articulados:** composto por dois blocos articulados (FIGURA 43).

Figure 40- Truque B



Fonte: Borba (2014)

Figure 41- Truque C



Fonte: Borba (2014)

Figure 42- Truque D rígido



Fonte: Borba (2014)

Figure 43- Truque articulado (B - B)



Fonte: Borba (2014)

APÊNDICE B – Classificações utilizadas para definição dos modos de falha

Quadro 5- Classificações classe de falha para sintoma padronizado

1. Acusando Motor diesel (MD) quente	2. Farol queimado
3. Apagando MD por baixa pressão de água	4. MD não mantém ligado
5. Apagando MD por baixa pressão de óleo	6. Não mantém aplicação pelo MFA
7. Aterramento circuito de potência	8. Não repõe penalidade de freio
9. Baixa aderência	10. Perda de tração
11. Baixa eficiência freio dinâmico	12. Perda freio dinâmico
13. Baixa isolamento circuito de comando	14. Sobrecarga MT
15. Baixa isolamento circuito de potência	16. Sobrepressão no cárter
17. Baixa potência	18. Travamento de rodeiro
19. Excesso de potência	20. Vazamento de ar do RP
21. Falha no sistema de arejamento	22. Vazamento de óleo diesel

Fonte: Do autor (2020)

Quadro 6- Classificações classe de falha para sistema

1. Motor a combustão	2. Frenagem dinâmica
3. Admissão de ar	4. Pneumática
5. Arrefecimento	6. Estrutura
7. Combustível	8. Iluminação
9. Lubrificação	10. Partida e carga de bateria
11. Excitação e controle de potência	12. Transmissão mecânica
13. Propulsão	

Fonte: Do autor (2020)

Quadro 7- Classificações classe de falha para conjunto (continua)

1. Conjunto bloco	2. Ventilador das grades de resistência
3. Conjunto de força	4. Contatores de potência
5. Conjunto eixo de comando	6. Compressor
7. Conjunto escapamento ou exaustão	8. Controle do compressor
9. Conjunto governador	10. Secador de ar
11. Conjunto compartimento de inércia	12. Válvulas
13. Conjunto caixa de ar ou coletor de admissão	14. Acionamento de freio
15. Conjunto turboalimentador	16. Alarme sonoro
17. Conjunto aftercooler	18. Limpador de para-brisas
19. Conjunto de bomba de água	20. Acessórios pneumáticos
21. Conjunto radiador	22. Cabine
23. Conjunto tanque de expansão	24. Chassi
25. Conjunto ventilador elétrico	26. Aparelho de choque e tração
27. Sistema de combustível	28. Testeira
29. Conjunto tanque de combustível	30. Freio de estacionamento
31. Conjunto filtros de combustível	32. Farol brilhante
33. Conjunto bomba de transferência	34. Farol oscilante

Quadro 7- Classificações classe de falha para conjunto (Conclusão)

35. Conjunto injetor	36. Iluminação cabine
37. Conjunto cárter	38. Pannel de controle do motor
39. Conjunto bombas de óleo	40. Iluminação das alavancas
41. Conjunto filtros de óleo	42. Iluminação compartimento MD
43. Conjunto computador e módulos digitais	44. Circuito de força
45. Controle de aceleração	46. Conjunto baterias
47. Controle de excitação	48. Controle de partida
49. Regulador de carga	50. Gerador auxiliar
51. Gerador de tração	52. Motor de partida
53. Gerador companheiro	54. Regulador de tensão
55. Bancada retificadora	56. Gerador auxiliar
57. Chaves de transferência e contadores	58. Rodeiro
59. Motor de tração	60. Truque ferroviário
61. Grades de resistência	

Fonte: Do autor (2020)

Quadro 8 - Classificações classe de falha para item

1. Alternador principal conjunto	2. Junta das tubulações
3. Bico do areeiro	4. Mangueira
5. Bico injetor	6. Mola do porta escovas MT
7. Bobina chave MB	8. Motor de tração conjunto
9. Bobina contator de fechamento de campo gerador de tração	10. Motor do ventilador das resistências
11. Bomba combustível - Motor elétrico	12. Motor do ventilador radiador
13. Bomba combustível – Rolamento	14. MT - Rolamento lado pinhão
15. Cabeçote conjunto	16. Pannel / módulo 69 e 70
17. Campo MT	18. Pinhão MT
19. Capacitor bancada retificadora	20. Radiador conjunto
21. Cartão eletrônico (cartão 04)	22. Resfriador de ar
23. Cartão eletrônico (cartão 06)	24. Rodeiro - Rolamento cartuxo
25. Cartão eletrônico (cartão 13)	26. Selo bomba d'agua
27. Cartão eletrônico (cartão 2)	28. Sensor de temperatura
29. Circuito bomba combustível – Disjuntor	30. Transdutor de corrente gerador de tração
31. Colmeia do radiador	32. Transdutor de corrente MT
33. Comando - Cabo / fiação	34. Transdutor tensão AR10
35. Conexões	36. Tubulação
37. Conjunto de força - Camisa	38. Tubulação de areia
39. Controle de campo do alternador	40. Turbina - Embreagem
41. Diodo bancada retificadora	42. Turbina - Roda quente
43. Elemento de filtro de combustível	44. Válvula 26C
45. Farol conjunto	46. Válvula de aplicação P2-A
47. GA - Cabo fiação	48. Válvula eletropneumática
49. Grade resistência BKG conjunto	50. Vedação da camisa

Fonte: Do autor (2020)

APÊNDICE C – Classificação das causas técnicas das falhas (RCA)

Quadro 9- Classificação das causas técnicas das falhas baseado na metodologia RCA

DATA	HORA DA NOTA	LOCOMOTIVA	FROTA	ANÁLISE PONTUAL		CLASSE DE FALHA			
				SINTOMA PADRONIZADO	SINTESE ANÁLISE / DIAGNÓSTICO	SISTEMA	CONJUNTO	ITEM	PROBLEMA
06/01/2018	16:33:00	9504	SD40	Baixa isolamento circuito de potência	Detectado desgaste acentuado nas escovas do MT6, vindo a causar faiscamento e flash over.	Propulsão	Motor de tração	Escovas	Baixa isolamento
15/01/2018	10:18:27	9479	SD40	Travamento de rodeiro	Detectado falha no rolamento do MT6 lado pinhão.	Propulsão	Motor de tração	MT - Rolamento lado pinhão	Travado
16/01/2018	06:55:00	9520	SD40	Acusando MD quente	Apresentou MD quente dentro do túnel. Nada foi constatado. Foi medido delta de temperatura entre entrada e saída da água no radiador, detectado troca de calor comprometida do radiador (baixa eficiência). Foi necessária a troca do mesmo.	Arrefecimento	Radiador	Radiador conjunto	Baixa eficiência troca calor
17/01/2018	07:51:50	9477	SD40	Acusando MD quente	Apresentou MD quente dentro do túnel. Nada foi constatado. Foi medido delta de temperatura entre entrada e saída da água no radiador, detectado troca de calor comprometida do radiador (baixa eficiência). Foi necessária a troca do mesmo.	Arrefecimento	Radiador	Radiador conjunto	Baixa eficiência troca calor
17/01/2018	07:51:50	9506	SD40	Sobrecarga MT	Nada constatado durante atendimento.	NACO	NACO	NACO	NACO
18/01/2018	01:25:00	9484	SD40	Baixa isolamento circuito de potência	Capacitor do circuito de SNOBER de uma das fases de saída do alternador principal em curto.	Propulsão	Bancada retificadora	Diodo bancada retificadora	Curto circuito
21/01/2018	02:51:31	9552	SD40	Acusando MD quente	Foi medido delta de temperatura entre entrada e saída da água no radiador, detectado troca de calor comprometida do radiador (baixa eficiência). Foi necessária a troca do mesmo.	Arrefecimento	Radiador	Radiador conjunto	Baixa eficiência troca calor
22/01/2018	15:38:00	9523	SD40	Baixa potência	Baixo fluxo de combustível no circuito de baixa pressão em função da contaminação e obstrução dos filtros de combustível.	Combustível	Filtro primário	Elemento de filtro de combustível	Obstruído

DATA	HORA DA NOTA	LOCOMOTIVA	FROTA	ANÁLISE PONTUAL		CLASSE DE FALHA			
				SINTOMA PADRONIZADO	SINTESE ANÁLISE / DIAGNÓSTICO	SISTEMA	CONJUNTO	ITEM	PROBLEMA
23/01/2018	23:10:44	9477	SD40	Perda de tração	Encontrado avaria intermitente no transdutor de tensão do alternador principal.	Excitação e controle	Controle de excitação	Transdutor tensão AR10	Não comunica
26/01/2018	23:17:00	9506	SD40	Perda de tração	Travamento intermitente do cartão 6 (entrada e saídas digitais).	Excitação e controle	Controle de excitação	Cartão eletrônico	Descalibrado
30/01/2018	03:18:23	9490	SD40	Acusando MD quente	Apresentou MD quente dentro do túnel. Nada foi constatado. Foi medido delta de temperatura entre entrada e saída da água no radiador, detectado troca de calor comprometida do radiador (baixa eficiência). Foi necessária a troca do mesmo.	Arrefecimento	Circuito comando e controle	Sensor de temperatura	Quebrado
31/01/2018	03:18:21	9496	SD40	Baixa aderência	Areiro entupido em função de obstrução por pedras (contaminação da areia).	Propulsão	Controle de aderência	Bico do areiro	Obstruído
01/02/2018	13:06:46	9474	SD40	Apagando MD por baixa pressão de água	Vazamento na junta do radiador lado auxiliar e mangote do tanque de expansão furado.	Arrefecimento	Tubulação / mangueira	Junta das tubulações	Rompida
01/02/2018	13:28:04	9477	SD40	Não mantém aplicação pelo MFA	Encontrado vazamento na válvula P2A.	Pneumático	Válvula	Válvula de aplicação P2-A	Vazamento de ar
04/02/2018	20:01:17	9498	SD40	Baixa aderência	Transdutor do M1 se encontrava descalibrado, levando a diferença da corrente deste motor em relação aos demais.	Propulsão	Controle de aderência	Transdutor de corrente MT	Descalibrado
09/02/2018	00:46:00	9521	SD40	Apagando MD por baixa pressão de água	Foi encontrado vazamento de água na junta trapezoidal do radiador.	Arrefecimento	Tubulação / mangueira	Junta das tubulações	Rompida
12/02/2018	11:41:36	9515	SD40	Sobrecarga MT	Nada constatado	NACO	NACO	NACO	NACO
15/02/2018	00:37:00	9551	SD40	Baixa aderência	Detectado bobinas de campo do MT5 aterrado.	Propulsão	Motor de tração	Campo MT	Aberto
17/02/2018	22:51:24	9507	SD40	Baixa aderência	Detectado obstrução do areiro lado direito.	Propulsão	Controle de aderência	Bico do areiro	Obstruído
19/02/2018	10:14:06	9552	SD40	Travamento de rodeiro	Detectado rolamento do MT5 lado pinhão travado.	Propulsão	Motor de tração	MT - Rolamento lado pinhão	Travado
20/02/2018	19:06:54	9515	SD40	MD não mantém ligado	Gerador auxiliar não produz. Retorno FCA estava interrompido no TB1 no borne 26, logo, foram feitos reparos na fiação.	Partida e carga de bateria	Gerador auxiliar	GA - Cabo fiação	Interrompido

DATA	HORA DA NOTA	LOCOMOTIVA	FROTA	ANÁLISE PONTUAL		CLASSE DE FALHA			
				SINTOMA PADRONIZADO	SINTESE ANÁLISE / DIAGNÓSTICO	SISTEMA	CONJUNTO	ITEM	PROBLEMA
21/02/2018	21:48:00	9481	SD40	Baixa aderência	Sistema de areiamento avariado. Encontrado abertura da bobina de acionamento de um dos injetores de areia.	Propulsão	Controle de aderência	Válvula eletropneumática	Bobina aberta
21/02/2018	14:37:37	9507	SD40	Apagando MD por baixa pressão de água	Conjunto de força 16 passando água entre cabeçote e cilindro.	Motor de combustão	Conjunto de força	Vedação da camisa	Vazando água
22/02/2018	23:00:00	9551	SD40	Baixa aderência	Encontrado MT5 com campo aterrado.	Propulsão	Motor de tração	Campo MT	Aberto
24/02/2018	10:24:21	9509	SD40	Baixa aderência	Encontrado mangueira dos areiros furada.	Propulsão	Controle de aderência	Tubulação de areia	Furada
02/03/2018	04:34:35	9507	SD40	Travamento de rodeiro	Encontrado MT1 com rolamento lado pinhão travado	Propulsão	Motor de tração	MT - Rolamento lado pinhão	Travado
05/03/2018	00:49:00	9481	SD40	Baixa aderência	Encontrado reservatório de areia vazio (falha operacional).	Propulsão	Controle de aderência	Falha operacional	Falha operacional
06/03/2018	04:23:00	9506	SD40	Perda do freio dinâmico	Encontrado avaria no cartão 4 (entradas e saídas digitais).	Excitação e controle	Controle de excitação	Cartão eletrônico	Queimado
08/03/2018	05:50:00	9521	SD40	MD não mantém ligado	Encontrado quebra das palhetas do turbo (o mesmo veio a travar).	Admissão de ar	Turbo alimentador	Turbina - Roda quente	Travado
09/03/2018	08:00:00	9496	SD40	Baixa aderência	Encontrado obstrução no bico do areeiro frontal lado direito.	Propulsão	Controle de aderência	Bico do areeiro	Obstruído
13/03/2018	10:40:32	9519	SD40	MD não mantém ligado	Encontrado quebra do conjunto de força 11.	Motor de combustão	Conjunto de força	Conjunto de força - Camisa	Trincado
18/03/2018	14:00:00	9479	SD40	Apagando MD por baixa pressão de água	Conjunto de força 14 e 15 passando água, ocasionando baixo nível no tanque de expansão.	Motor de combustão	Conjunto de força	Vedação da camisa	Vazando água
19/03/2018	06:30:57	9523	SD40	Baixa aderência	Detectado desequilíbrio de corrente entre os motores de tração em função da descalibração dos transdutores ferentes aos motores de tração 1 e 2.	Propulsão	Controle de aderência	Transdutor de corrente MT	Descalibrado
22/03/2018	05:05:00	9477	SD40	Apagando MD por baixa pressão de água	Baixo nível de água no tanque de expansão em função de um vazamento na bomba d'água.	Arrefecimento	Bomba de água	Selo bomba d'água	Vazando água
23/03/2018	21:52:15	9470	SD40	Apagando MD por baixa pressão de água	Baixo nível de água em função da colmeia do radiador furada.	Arrefecimento	Radiador	Colmeia do radiador	Furada
29/03/2018	14:15:03	9494	SD40	Perda de tração	Encontrado avaria nos módulos 69 e 70.	Excitação e controle	Controle de excitação	Cartão eletrônico	Descalibrado

DATA	HORA DA NOTA	LOCOMOTIVA	FROTA	ANÁLISE PONTUAL		CLASSE DE FALHA			
				SINTOMA PADRONIZADO	SINTESE ANÁLISE / DIAGNÓSTICO	SISTEMA	CONJUNTO	ITEM	PROBLEMA
29/03/2018	14:09:18	9506	SD40	Apagando MD por baixa pressão de água	Detectado baixo nível de água no radiador em função de vazamento no tubo de sela.	Arrefecimento	Tubulação / mangueira	Junta das tubulações	Rompida
31/03/2018	22:17:19	9507	SD40	Baixa aderência	Motor de tação 03 com campo aberto.	Propulsão	Motor de tração	Campo MT	Aberto
31/03/2018	09:24:43	9514	SD40	MD não mantém ligado	Detectado quebra do turbo alimentador.	Admissão de ar	Turbo alimentador	Turbina - Roda quente	Travado
31/03/2018	22:28:34	9519	SD40	Perda do freio dinâmico	Diagnosticado linha 2PS14 da TB1EA com terminal rompido.	Frenagem dinâmica	Circuito comando e controle	Comando - Cabo / fiação	Interrompido
05/04/2018	04:00:17	9519	SD40	Perda do freio dinâmico	Encontrado motor do ventilador das grades do FD queimado.	Arrefecimento	Ventilador elétrico	Motor do ventilador das grades de resistência BKGs	Queimado
06/04/2018	04:47:00	9552	SD40	Baixa aderência	Foi encontrado pinhão do MT04 solto	Propulsão	Motor de tração	Pinhão MT	Solto
07/04/2018	14:01:26	9515	SD40	Perda de tração	Diodo e fusível da fase R queimado (mau contato no terminal de ligação ao diodo).	Propulsão	Bancada retificadora	Diodo bancada retificadora	Queimado
11/04/2018	11:55:13	9484	SD40	Baixa eficiência freio dinâmico	Encontrado grade de resistência BKGs queimadas	Frenagem dinâmica	Grades de resistência BKG	Grade resistência BKG conjunto	Queimado
12/04/2018	04:20:37	9512	SD40	Baixa potência	Baixo fluxo de combustível no circuito de baixa pressão em função da contaminação e obstrução dos filtros de combustível.	Combustível	Filtro primário	Elemento de filtro de combustível	Obstruído
19/04/2018	09:22:22	9506	SD40	Baixa aderência	MT5 com pinhão solto, em função de sua centrifugação pela soltura do pinhão.	Propulsão	Motor de tração	Pinhão MT	Solto
21/04/2018	21:55:36	9552	SD40	Vazamento de ar do reservatório principal	Vazamento na junta do resfriador de ar do compressor.	Pneumático	Compressor	Resfriador de ar	Vazamento de ar
04/05/2018	19:55:22	9470	SD40	Apagando MD por baixa pressão de óleo	Diluição de óleo lubrificante por contaminação óleo combustível. Encontrado bico injetor 11 com vazamento pelo copo.	Motor de combustão	Conjunto de força	Bico injetor	Vedação deficiente

DATA	HORA DA NOTA	LOCOMOTIVA	FROTA	ANÁLISE PONTUAL		CLASSE DE FALHA			
				SINTOMA PADRONIZADO	SINTESE ANÁLISE / DIAGNÓSTICO	SISTEMA	CONJUNTO	ITEM	PROBLEMA
05/05/2018	08:06:51	9507	SD40	Perda de tração	Pela telemetria da locomotiva onde foi verificado que houve falha na leitura dos 24V do cartão 8 e uma falha de leitura 9, onde não realizava a leitura dos transdutores dos motores 2, 4, 6. Em segundo atendimento substituído cartão 13 e normalizou.	Excitação e controle	Controle de excitação	Cartão eletrônico	Descalibrado
08/05/2018	19:28:57	9507	SD40	Perda de tração	Pela telemetria da locomotiva onde foi verificado que houve falha na leitura dos 24V do cartão 8 e uma falha de leitura 9, onde não realizava a leitura dos transdutores dos motores 2, 4, 6. Em segundo atendimento substituído cartão 13 e normalizou.	Excitação e controle	Controle de excitação	Cartão eletrônico	Descalibrado
13/05/2018	02:58:42	9490	SD40	Baixa aderência	Análise do Evento: Locomotiva helper 9490-SD40, estava no trem K08 quando apresentou deslize de rodas em LRNP no KM 0. Foi diagnosticado cabo solto no ITC do motor de tração 02 e fixado cabo. Análise Técnica: Cabo branco do ITC rompido na solda. Falta de leitura da corrente causou o sintoma de deslize de rodas apresentado na locomotiva.	Propulsão	Controle de aderência	Transdutor de corrente MT	Mau contato
14/05/2018	04:07:03	9506	SD40	Baixa aderência	MT5 com armadura danificada pela centrifugação em função da soltura do pinhão.	Propulsão	Motor de tração	Pinhão MT	Solto
08/06/2018	06:21:31	9525	SD40	Sobrecarga MT	Nada constatado durante atendimento.	NACO	NACO	NACO	NACO
09/06/2018	06:39:00	9474	SD40	Perda de tração	Chave de transferência MB não estava fechando em função da queima de sua bobina.	Propulsão	Chave de transferência magnética	Bobina chave MB	Queimado
09/06/2018	15:57:08	9507	SD40	Baixa potência	Baixo fluxo de combustível no circuito de baixa pressão em função da contaminação e obstrução dos filtros de combustível.	Combustível	Filtro primário	Elemento de filtro de combustível	Obstruído

DATA	HORA DA NOTA	LOCOMOTIVA	FROTA	ANÁLISE PONTUAL		CLASSE DE FALHA			
				SINTOMA PADRONIZADO	SINTESE ANÁLISE / DIAGNÓSTICO	SISTEMA	CONJUNTO	ITEM	PROBLEMA
19/06/2018	01:39:41	9506	SD40	MD não mantém ligado	Detectado queima do motor da bomba de combustível.	Combustível	Bomba de transferência	Bomba combustível - Motor elétrico	Queimado
21/06/2018	22:16:46	9504	SD40	Baixa aderência	Transdutor do motor de tração 06 com regulagem fora das especificações. Regulados transdutores de todos os motores de tração.	Propulsão	Controle de aderência	Transdutor de corrente MT	Descalibrado
22/06/2018	23:59:56	9504	SD40	Baixa aderência	Transdutor do motor de tração 06 com regulagem fora das especificações. Regulados transdutores de todos os motores de tração.	Propulsão	Controle de aderência	Transdutor de corrente MT	Descalibrado
23/06/2018	11:02:00	9510	SD40	Falha no sistema de areiamento	Encontrado mangueira de um dos areeiros furada.	Propulsão	Controle de aderência	Tubulação de areia	Furada
28/06/2018	23:31:15	9525	SD40	Perda de tração	Encontrado transdutor de corrente do alternador principal avariado.	Excitação e controle	Controle de excitação	Transdutor de corrente AR10	Não comunica
26/07/2018	08:49:07	9525	SD40	Apagando MD por baixa pressão de água	Detectado que o conjunto de força 11 estava passando gases para o sistema de arrefecimento (oscilando pressão de água).	Motor de combustão	Conjunto de força	Vedação da camisa	Vazando água
02/08/2018	06:02:23	9525	SD40	Apagando MD por baixa pressão de água	Vazamento de água no conjunto de força 13.	Motor de combustão	Conjunto de força	Vedação da camisa	Vazando água
04/08/2018	12:39:18	9514	SD40	Baixa eficiência freio dinâmico	Falha no transdutor de corrente do MT 04	Propulsão	Controle de aderência	Transdutor de corrente MT	Mau contato
23/08/2018	17:34:47	9481	SD40	Apagando MD por baixa pressão de água	Vazamento de água na tubulação de entrada da caixa de expansão.	Motor de combustão	Conjunto de força	Vedação da camisa	Vazando água
23/08/2018	01:27:18	9508	SD40	Perda de tração	Falha de comunicação entre cartões do rack de microprocessamento.	Excitação e controle	Controle de excitação	Cartão eletrônico	Descalibrado
28/08/2018	02:17:00	9539	SD40	Perda do freio dinâmico	Circuito de dissipação de potência gerada na armadura aberto em função da queima de uma das grades BKG.	Frenagem dinâmica	Grades de resistência BKG	Grade resistência BKG conjunto	Queimado

DATA	HORA DA NOTA	LOCOMOTIVA	FROTA	ANÁLISE PONTUAL		CLASSE DE FALHA			
				SINTOMA PADRONIZADO	SINTESE ANÁLISE / DIAGNÓSTICO	SISTEMA	CONJUNTO	ITEM	PROBLEMA
30/08/2018	23:12:08	9508	SD40	Baixa aderência	Encontrado pinhão do MT6 solto.	Propulsão	Motor de tração	Pinhão MT	Solto
03/09/2018	08:23:00	9476	SD40	Baixa isolamento circuito de potência	Mola do porta escovas superior do MT5 solta, tocando a carcaça.	Propulsão	Motor de tração	Mola do porta escovas MT	Solto
03/09/2018	13:42:28	9520	SD40	Farol queimado	Detectado farol dianteiro com filamento queimado.	Iluminação	Farol brilhante	Farol conjunto	Queimado
04/09/2018	19:14:55	9476	SD40	Baixa aderência	Motor de tração 03 com campo aberto.	Propulsão	Motor de tração	Campo MT	Aberto
07/09/2018	03:52:40	9506	SD40	MD não mantém ligado	Embregem do turbo se encontrava quebrado.	Admissão de ar	Turbo alimentador	Turbina - Embregem	Quebrado
09/09/2018	13:10:00	9516	SD40	Perda de tração	Falha na bobina do contator GF	Propulsão	Contator de potência	Bobina contator GF	Queimado
10/09/2018	20:54:00	9496	SD40	Não mantém aplicação pelo MFA	Encontrado vazamento na válvula 26C (vazamento no reservatório equilibrante).	Pneumático	Válvula	Válvula 26C	Vazamento de ar
12/09/2018	08:25:13	9520	SD40	Apagando MD por baixa pressão de óleo	Detectado vazamento de óleo no conjunto de força 11.	Motor de combustão	Conjunto de força	Cabeçote conjunto	Trincado
19/09/2018	22:00:00	9524	SD40	Excesso de potência	Módulo ZFD avariado (controle do campo gerador principal)	Excitação e controle	Controle de excitação	Controle de campo do alternador	Valor alterado
28/09/2018	00:38:26	9523	SD40	Apagando MD por baixa pressão de água	Diagnosticada mangueira de referência para o sensor do sistema de arrefecimento estourada (mangueira do transdutor).	Arrefecimento	Tubulação / mangueira	Junta das tubulações	Rompida
30/09/2018	19:51:59	9514	SD40	Nada constatado	Nada constatado	NACO	NACO	NACO	NACO
03/10/2018	02:26:42	9522	SD40	Baixa aderência	Detectado transdutor do MT2 descalibrado.	Propulsão	Controle de aderência	Transdutor de corrente MT	Descalibrado
05/10/2018	21:13:00	9484	SD40	Não repõe penalidade de freio	Dectado tubulação 3 quebrada no flange (tudo de saída da P2A).	Pneumático	Acessório	Tubulação	Quebrado
06/10/2018	05:03:19	9522	SD40	Baixa aderência	Detectado transdutor do MT2 descalibrado.	Propulsão	Controle de aderência	Transdutor de corrente MT	Descalibrado
07/10/2018	02:14:00	9490	SD40	Vazamento de óleo Diesel	Encontrado vazamento de óleo no visor do óleo combustível. O mesmo foi substituído.	Lubrificação	Tubulação / mangueira	Conexões	Solto
07/10/2018	23:48:00	9496	SD40	Baixa aderência	Encontrado falha no transdutor de corrente do MT5, descalibrado.	Propulsão	Controle de aderência	Transdutor de corrente MT	Descalibrado

DATA	HORA DA NOTA	LOCOMOTIVA	FROTA	ANÁLISE PONTUAL		CLASSE DE FALHA			
				SINTOMA PADRONIZADO	SINTESE ANÁLISE / DIAGNÓSTICO	SISTEMA	CONJUNTO	ITEM	PROBLEMA
09/10/2018	02:25:43	9485	SD40	Baixa isolamento circuito de potência	Encontrado alternador principal aterrado (AR10).	Propulsão	Alternador	Alternador principal conjunto	Baixa isolamento
10/10/2018	04:10:50	9479	SD40	Apagando MD por baixa pressão de água	Trinca no cabeçote do CF9.	Motor de combustão	Conjunto de força	Vedação da camisa	Vazando água
12/10/2018	00:32:10	9484	SD40	MD não mantém ligado	Disjuntor da bomba de combustível avariado (desarmando).	Combustível	Circuito comando e controle	Circuito bomba combustível - Disjuntor	Desgaste interno
12/10/2018	20:02:00	9508	SD40	Baixa isolamento circuito de potência	Baixa isolamento no campo do MT1.	Propulsão	Motor de tração	Motor de tração conjunto	Baixa isolamento
14/10/2018	10:13:15	9496	SD40	Baixa aderência	Encontrado transdutor do MT6 descalibrado.	Propulsão	Controle de aderência	Transdutor de corrente MT	Descalibrado
16/10/2018	23:08:13	9490	SD40	Apagando MD por baixa pressão de óleo	Vazamento de óleo na bomba (rolamento estourado).	Lubrificação	Bomba de pressão	Bomba combustível - Rolamento	Travado
16/10/2018	08:01:05	9508	SD40	Baixa isolamento circuito de potência	Encontrado baixa isolamento no campo do MT1	Propulsão	Motor de tração	Motor de tração conjunto	Baixa isolamento
17/10/2018	03:20:00	9522	SD40	Baixa potência	Baixo fluxo de combustível no circuito de baixa pressão em função da contaminação e obstrução dos filtros de combustível.	Combustível	Filtro primário	Elemento de filtro de combustível	Obstruído
17/10/2018	19:37:59	9539	SD40	Baixa potência	Baixo fluxo de combustível no circuito de baixa pressão em função da contaminação e obstrução dos filtros de combustível.	Combustível	Filtro primário	Elemento de filtro de combustível	Obstruído
22/10/2018	19:37:21	9506	SD40	Perda de tração	Conector do transdutor de corrente do alternador frouxo.	Excitação e controle	Controle de excitação	Transdutor de corrente AR10	Mau contato
23/10/2018	18:25:56	9504	SD40	Travamento de rodeiro	Princípio de incêndio na caixa hyatt do MT5. Aquecimento devido ter caído pavio da mexa.	Propulsão	Motor de tração	MT - Rolamento lado pinhão	Travado
25/10/2018	07:00:37	9470	SD40	Baixa aderência	Motor de tação 03 com campo aberto.	Propulsão	Motor de tração	Campo MT	Aberto
25/10/2018	23:46:36	9495	SD40	Nada constatado	Nada constatado	NACO	NACO	NACO	NACO
27/10/2018	06:31:36	9476	SD40	Nada constatado	Nada constatado	NACO	NACO	NACO	NACO

DATA	HORA DA NOTA	LOCOMOTIVA	FROTA	ANÁLISE PONTUAL		CLASSE DE FALHA			
				SINTOMA PADRONIZADO	SINTESE ANÁLISE / DIAGNÓSTICO	SISTEMA	CONJUNTO	ITEM	PROBLEMA
27/10/2018	15:40:35	9484	SD40	Baixa eficiência freio dinâmico	Encontrado queima de uma das grades de resistência BKGs	Frenagem dinâmica	Grades de resistência BKG	Grade resistência BKG conjunto	Queimado

Fonte: Do autor (2020).

APÊNDICE D – Classificação dos modos de falha (RCM)

Quadro 10- Classificação dos modos de falha pelo método RCM

MODO DE FALHA Sintoma padronizado + (conjunto / item)	Nº DE EVENTOS	EFEITO DA FALHA	PESO EFEITO	TO	VISIBILIDADE		CONSEQUÊNCIA CEF			S	IS	VM	FP	FPRIO
					E	O	S	O	E					
Baixa aderência (controle de aderência / transdutor de corrente)	9	Perda parcial operacionalidade da máquina, possibilidade de seguir até próximo posto de manutenção.	1	9%		x		x		OO	3	3	5	4,18
Baixa aderência (MT / Campo aberto)	5	Perda parcial operacionalidade da máquina, possibilidade de seguir até próximo posto de manutenção.	1	5%		x		x		OO	2	6	5	3,09
Baixa potência / Filtro primário combustível / Elemento do filtro	5	Perda parcial operacionalidade da máquina, possibilidade de seguir até próximo posto de manutenção.	2	5%		x		x		OO	2	4	3	2,47
Acusando MD quente / Ventilador elétrico / Motor do ventilador do radiador	5	Perda total da operacionalidade da máquina, com possibilidade de corretiva no local, porém necessita de liberação com alguma restrição.	4	5%	x		x			EO	4	1	2	1,65
Perda de tração (bancada retificadora / diodo retificador)	2	Perda total da operacionalidade da máquina, sem possibilidade de corretiva no local (REBOQUE).	5	2%		x		x		OO	2	1	4	0,82
Apagando por baixa pressão de água (radiador / colmeia do radiador)	1	Perda total da operacionalidade da máquina, sem possibilidade de corretiva no local (REBOQUE).	5	1%		x		x		OO	2	3	2	0,62
Apagando por baixa pressão de água (tubulação / junta das tubulações)	4	Perda total da operacionalidade da máquina, porém com possibilidade de corretiva no local (liberação sem restrição).	3	4%	x			x		OO	2	1	2	0,49
Baixa aderência (controle de aderência / tubulação de areia)	4	Perda total da operacionalidade da máquina, porém com possibilidade de corretiva no local (liberação sem restrição).	3	4%	x			x		OO	2	1	2	0,49
Baixa eficiência do freio dinâmico (grades de resistência BKG / grade de resistência conjunto)	2	Perda total da operacionalidade da máquina, com possibilidade de corretiva no local, porém necessita de liberação com alguma restrição.	4	2%		x		x		OO	2	1	2	0,33
Apagando por baixa pressão de água (bomba de água / selo da bomba)	1	Perda total da operacionalidade da máquina, sem possibilidade de corretiva no local (REBOQUE).	5	1%		x		x		OO	2	1	3	0,31
Perda de tração (bancada retificadora / diodo retificador)	2	Perda total da operacionalidade da máquina, porém com possibilidade de corretiva no local (liberação sem restrição).	3	2%		x		x		OO	2	1	2	0,25

MODO DE FALHA Sintoma padronizado + (conjunto / item)	Nº DE EVENTOS	EFEITO DA FALHA	PESO EFEITO	TO	VISIBILIDADE		CONSEQUÊNCIA CEF			S	IS	VM	FP	FPRIO
					E	O	S	O	E					
Perda do freio dinâmico (ventilador elétrico / motor do ventilador)	1	Perda total da operacionalidade da máquina, com possibilidade de corretiva no local, porém necessita de liberação com alguma restrição.	4	1%		x		x		OO	2	2	1	0,16
Perda de tração (controle de excitação / transdutor de tensão do gerador de tração)	1	Perda total da operacionalidade da máquina, porém com possibilidade de corretiva no local (liberação sem restrição).	3	1%		x		x		OO	2	1	2	0,12
Baixa aderência (MT / Pinhão solto)	4	Perda total da operacionalidade da máquina, com possibilidade de corretiva no local, porém necessita de liberação com alguma restrição.	4	4%		x	x			OO	2	0	5	0,00
Apagando por baixa pressão de água (conjunto de força / vedação camisa)	7	Perda total da operacionalidade da máquina, sem possibilidade de corretiva no local (REBOQUE).	5	7%		x		x		ES	5	0	4	0,00
MD não mantém ligado (turbina / roda quente)	3	Perda total da operacionalidade da máquina, sem possibilidade de corretiva no local (REBOQUE).	5	3%		x		x		OO	2	0	3	0,00
MD não mantém ligado (Bomba de combustível / Bomba de combustível motor elétrico)	1	Perda total da operacionalidade da máquina, porém com possibilidade de corretiva no local (liberação sem restrição).	3	1%		x		x		OS	6	0	1	0,00
MD não mantém ligado (Gerador auxiliar / cabo fiação)	1	Perda total da operacionalidade da máquina, porém com possibilidade de corretiva no local (liberação sem restrição).	3	1%		x		x		OO	2	0	1	0,00
Acusando MD quente / Circuito comando e controle / Sensor de temperatura	1	Perda total da operacionalidade da máquina, porém com possibilidade de corretiva no local (liberação sem restrição).	3	1%		x		x		EO	4	0	1	0,00
Perda do freio dinâmico (Grade de resistência / Grade de resistência conjunto)	1	Perda total da operacionalidade da máquina, com possibilidade de corretiva no local, porém necessita de liberação com alguma restrição.	4	1%		x		x		OO	2	0	1	0,00
Perda de tração (Controle de excitação / Contator GF)	1	Perda total da operacionalidade da máquina, porém com possibilidade de corretiva no local (liberação sem restrição).	3	1%		x		x		OO	2	0	1	0,00
Baixa aderência (controle de aderência / válvula eletropneumática)	1	Perda total da operacionalidade da máquina, porém com possibilidade de corretiva no local (liberação sem restrição).	3	1%	x			x		EO	4	0	1	0,00

MODO DE FALHA Sintoma padronizado + (conjunto / item)	Nº DE EVENTOS	EFEITO DA FALHA	PESO EFEITO	TO	VISIBILIDADE		CONSEQUÊNCIA CEF			S	IS	VM	FP	FPRIO
					E	O	S	O	E					
Perda de tração (controle de excitação / cartão eletrônico)	5	Perda total da operacionalidade da máquina, porém com possibilidade de corretiva no local (liberação sem restrição).	3	5%		x		x		OO	2	0	1	0,00
Perda de tração (Chave de transferência magnética / bobina da chave MB)	1	Perda total da operacionalidade da máquina, porém com possibilidade de corretiva no local (liberação sem restrição).	3	1%		x		x		OO	2	0	1	0,00
Baixa isolamento circuito de potência (MT / campo)	3	Perda total da operacionalidade da máquina, com possibilidade de corretiva no local, porém necessita de liberação com alguma restrição.	4	3%		x		x		OO	2	0	1	0,00
Baixa isolamento circuito de potência (MT / Mola do orta escovas)	1	Perda total da operacionalidade da máquina, com possibilidade de corretiva no local, porém necessita de liberação com alguma restrição.	4	1%		x		x		OO	2	0	1	0,00
Baixa isolamento circuito de potência (Bancada retificadora / Diodo retificador)	1	Perda total da operacionalidade da máquina, porém com possibilidade de corretiva no local (liberação sem restrição).	3	1%		x		x		OO	2	0	1	0,00
Baixa isolamento circuito de potência (Alternador principal / alternador principal conjunto)	1	Perda total da operacionalidade da máquina, sem possibilidade de corretiva no local (REBOQUE).	5	1%		x		x		OO	2	0	1	0,00
MD não mantém ligado (Bomba de combustível / circuito da bomba de combustível)	1	Perda total da operacionalidade da máquina, porém com possibilidade de corretiva no local (liberação sem restrição).	3	1%	x			x		EO	4	0	1	0,00
Perda do freio dinâmico (Controle de excitação / cartão eletrônico)	1	Perda total da operacionalidade da máquina, porém com possibilidade de corretiva no local (liberação sem restrição).	3	1%		x		x		OO	2	0	1	0,00
Perda do freio dinâmico (Comando e controle / cabo fiação)	1	Perda total da operacionalidade da máquina, porém com possibilidade de corretiva no local (liberação sem restrição).	3	1%		x		x		OO	2	0	1	0,00
Travamento de rodeiros (MT / Rolamento lado pinhão)	5	Perda total da operacionalidade da máquina, sem possibilidade de corretiva no local (REBOQUE).	5	5%		X	X			OS	6	0	3	0,00

Nota: (TO) taxa de ocorrência; (CEF) causa e efeito; (S) severidade; (IS) índice de severidade; (VM) parâmetros passíveis de monitoramento; (FP) fator de predição; (FPRIO) fator de priorização; (MT) motor de tração; (MD) motor diesel.

Fonte: Do autor (2020).

APÊNDICE E – Linguagem algoritmo classificador

```

%% Exibindo Resultados Extração de Características

% Extração de Características: Corrente dos Motores de Tração MF2
figure;
subplot(3,1,1),
plot(dado_filtrado(:,4)), hold on, plot(dado_filtrado(:,5)), ...
    plot(dado_filtrado(:,6)), plot(dado_filtrado(:,7)), plot(dado_filtrado(:,8)),...
    plot(dado_filtrado(:,9));
title('Extração de Características: Corrente dos Motores de Tração')
ylabel('a')
subplot(3,1,2), plot(vetor_medial);
ylabel('b')
subplot(3,1,3), plot(desvio_corrente1);
xlabel('Amostras')
ylabel('c')

% Extração de Características: Pressão e Potência Gerador Principal MF3
figure;
subplot(3,1,1), plot(dado_norm(:,3)), hold on, plot(dado_norm(:,2))
title('Extração de Características: Pressão e Potência Gerador Principal')
ylabel('a')
subplot(3,1,2), plot(media_janela(:,3)), hold on, plot(media_janela(:,2))
ylabel('b')
subplot(3,1,3), plot(desvio_pressao_potencia);
ylabel('c')
xlabel('Amostras')

% Extração de Características: Temperatura (MF4)
figure;
subplot(2,1,1), plot(dado_filtrado(:,1)),

```

```

title('Extração de Características: Temperatura')
ylabel('(a)')
subplot(2,1,2), plot(media_janela(:,1));
ylabel('(b)')
xlabel('Amostras')

%% EXIBIÇÃO DE RESULTADOS CLUSTERIZAÇÃO - TREINAMENTO,
% NÃO HÁ A ETAPA DE CLASSIFICAÇÃO, APENAS PARA VISUALIZAÇÃO DOS
CLUSTERS
% CRIADOS PELO MELHOR MODELO DE CLASSIFICADOR

% Apenas para exibir dados
M=dist(dados_treinamento, centros_melhor');
M=M';
Min_dis = min(M);
Max_dis = max(M');

n_exibe = length(dados_treinamento);

for n=1:n_exibe
    for i= 1:n_cluster_melhor
        if (M(i,n) == Min_dis(n))
            grupo_exibe(n) = i;
        end
    end
end

%Exibindo Variáveis relacionadas ao MF2
% Temperatura
figure;
gscatter(dados_treinamento(:,5),dados_treinamento(:,6),grupo_exibe), hold on,

```

```
scatter(centros_melhor(:,5),centros_melhor(:,6),'*k')
xlabel('Corrente M1')
ylabel('Desvio Padrão Motor 1')
legend('off')
```

```
%Exibindo Variáveis relacionadas ao MF3
%Pressão do Diesel e Potência do Motor
```

```
figure;
gscatter(dados_treinamento(:,3),dados_treinamento(:,4),grupo_exibe), hold on,
scatter(centros_melhor(:,3),centros_melhor(:,4),'*k')
xlabel('Pressão do Diesel')
ylabel('Potência do Gerador Principal')
legend('off')
```

```
figure;
gscatter(dados_treinamento(:,3),dados_treinamento(:,2),grupo_exibe), hold on,
scatter(centros_melhor(:,3),centros_melhor(:,2),'*k')
xlabel('Desvio de Médias Potência e Pressão')
ylabel('Potência do Gerador Principal')
legend('off')
```

```
figure;
gscatter(dados_treinamento(:,2),dados_treinamento(:,4),grupo_exibe), hold on,
scatter(centros_melhor(:,2),centros_melhor(:,4),'*k')
xlabel('Pressão do Diesel')
ylabel('Desvio de Médias Potência e Pressão')
legend('off')
```

```
%Exibindo Variáveis relacionadas ao MF4
%Temperatura
```

```

figure;
gscatter(dados_treinamento(:,1),dados_treinamento(:,3),grupo_exibe), hold on,
scatter(centros_melhor(:,1),centros_melhor(:,3), '*k')
xlabel('Temperatura')
ylabel('Pressão do Diesel')
legend('off')

```

```
%% Exibição de RESULTADOS CLUSTERIZAÇÃO - TESTE!!!!!!!
```

```
%Exibindo Variáveis relacionadas ao MF2
%Temperatura
```

```

figure;
gscatter(dados_teste(:,5),dados_teste(:,6),classe), hold on,
scatter(centros_melhor(:,5),centros_melhor(:,6), '*k')
xlabel('Corrente M1')
ylabel('Desvio Padrão Motor 1')
legend('Sem Falha','MF1','MF2','MF3','MF4')

```

```
%Exibindo Variáveis relacionadas ao MF3
%Pressão do Diesel e Potência do Motor
```

```

figure;
gscatter(dados_teste(:,3),dados_teste(:,4),classe), hold on,
scatter(centros_melhor(:,3),centros_melhor(:,4), '*k')
xlabel('Pressão do Diesel')
ylabel('Potência do Gerador Principal')
legend('Sem Falha','MF1','MF2','MF3','MF4')

```

```

figure;
gscatter(dados_teste(:,3),dados_teste(:,2),classe), hold on,

```

```
scatter(centros_melhor(:,3),centros_melhor(:,2),'*k')
xlabel('Desvio de Médias Potência e Pressão')
ylabel('Potência do Gerador Principal')
legend('Sem Falha','MF1','MF2','MF3','MF4')
```

```
figure;
gscatter(dados_teste(:,2),dados_teste(:,4),classe), hold on,
scatter(centros_melhor(:,2),centros_melhor(:,4),'*k')
xlabel('Pressão do Diesel')
ylabel('Desvio de Médias Potência e Pressão')
legend('Sem Falha','MF1','MF2','MF3','MF4')
```

```
%Exibindo Variáveis relacionadas ao MF4
```

```
%Temperatura
```

```
figure;
gscatter(dados_teste(:,1),dados_teste(:,3),classe), hold on,
scatter(centros_melhor(:,1),centros_melhor(:,3), '*k')
xlabel('Temperatura')
ylabel('Pressão do Diesel')
legend('Sem Falha','MF1','MF2','MF3','MF4')
```