

DIAGNÓSTICO DE FALHAS DE IGNIÇÃO EM MOTOR DIESEL MARÍTIMO
UTILIZANDO SINAIS DE VIBRAÇÃO E APRENDIZADO DE MÁQUINAS

Victor Nicodemus Guerra

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Oceânica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Oceânica.

Orientador: Ulisses Admar Barbosa Vicente Monteiro

Rio de Janeiro

Maio de 2023

DIAGNÓSTICO DE FALHAS DE IGNIÇÃO EM MOTOR DIESEL MARÍTIMO
UTILIZANDO SINAIS DE VIBRAÇÃO E APRENDIZADO DE MÁQUINAS

Victor Nicodemos Guerra

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA DA (COPPE) UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM CIÊNCIAS EM ENGENHARIA OCEÂNICA.

Orientador: Ulisses Admar Barbosa Vicente Monteiro

Aprovada por: Prof. Ulisses Admar Barbosa Vicente Monteiro
Prof. Ricardo Homero Ramírez Gutiérrez,
Eng. Dionísio Henrique Carvalho de Sá Só Martins,
Prof. Natanael Nunes de Moura Júnior.

RIO DE JANEIRO, RJ - BRASIL

MAIO DE 2023

Guerra, Victor Nicodemos

Diagnóstico de Falhas de Ignição em Motor Diesel Marítimo utilizando Sinais de Vibração e Aprendizado de Máquinas/ Victor Nicodemos Guerra. – Rio de Janeiro: UFRJ/COPPE, 2023.

X, 68 p.: il.; 29,7 cm.

Orientador: Ulisses Admar Barbosa Vicente Monteiro
Dissertação (mestrado) – UFRJ/ COPPE/ Programa de Engenharia Oceânica, 2023.

Referências Bibliográficas: p. 62-67.

1. Diagnóstico de Falhas. 2. Inteligência Artificial. 3. Falha de Ignição. I. Monteiro, Ulisses Admar Barbosa Vicente Monteiro. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Oceânica. III. Título.

DEDICATÓRIA

Ao meu filho, Bernardo.
À minha esposa, Giselle.

AGRADECIMENTOS

Ao meu filho, Bernardo, por ser a maior razão de alegria na minha vida;

À minha esposa, Giselle, pela paciência, apoio e compreensão durante a minha caminhada para desenvolver esta dissertação, especialmente nos momentos mais difíceis;

Aos meus pais, Sandra e Luiz Roberto, por sempre terem acreditado em mim;

Aos meus irmãos, Marcello e Thiago, pela amizade fraterna;

À minha avó nonagenária, Jeanette, pelos conselhos fundamentais para que eu pudesse seguir adiante;

Aos meus sogros, Glória e Henrique, por terem me oferecido o suporte necessário para que eu pudesse desenvolver esta dissertação;

Ao meu professor orientador, Ulisses, pela boa vontade e por sempre ter se mostrado disposto em me auxiliar para resolver diversos problemas que surgiram ao longo da elaboração da dissertação;

Aos professores Luiz Vaz, Ricardo Homero, Dionísio Martins e Brenno Moura, por também se mostrarem sempre dispostos a tirar quaisquer dúvidas que surgiram durante a dissertação;

Aos demais docentes e funcionários do LEME/LEDAV, pelo acolhimento ao longo do curso;

À Marinha do Brasil, pela oportunidade concedida à mim de poder realizar o curso de Mestrado em Engenharia Oceânica na COPPE/UFRJ.

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

DIAGNÓSTICO DE FALHAS DE IGNIÇÃO EM MOTOR DIESEL MARÍTIMO UTILIZANDO SINAIS DE VIBRAÇÃO E APRENDIZADO DE MÁQUINAS

Victor Nicodemos Guerra

Maio/2023

Orientador: Prof. Ulisses Admar Barbosa Vicente Monteiro, D.Sc.

Programa: Engenharia Oceânica

Este trabalho apresenta uma metodologia de diagnóstico de falhas de ignição em um motor Diesel, por meio de técnicas de Aprendizado de Máquinas (AM), com utilização de sinais de vibração. Além disso, estudou-se a quantidade mínima necessária de acelerômetros que permita que os algoritmos de AM mantenham um bom desempenho para diagnóstico de falhas. O banco de dados utilizado neste estudo é composto por sinais de vibração obtidos por meio de 15 acelerômetros instalados no motor. Três algoritmos de AM foram utilizados neste trabalho: *k-Nearest Neighbors (K-NN)*, *Random Forest (RF)* e *Support Vector Machines (SVM)*. Os resultados mostraram que estes algoritmos foram capazes de obter um *F1-Score* de 99,87%, 99,87% e 100%, respectivamente, para detecção e identificação de falhas de ignição. Quanto ao estudo que visa a redução do número de sensores, foram utilizados os métodos *Relief-F* e análise combinatória geral, com o segundo sendo capaz de mostrar que, com dois acelerômetros, foi possível alcançar um desempenho com *F1-Score* acima de 95%, que é o mínimo requerido, o que comprova a eficiência da metodologia utilizada neste estudo.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

MISFIRE DIAGNOSIS IN A MARINE DIESEL ENGINE USING VIBRATION
SIGNALS AND MACHINE LEARNING

Victor Nicodemos Guerra

May/2023

Advisor: Prof. Ulisses Admar Barbosa Vicente Monteiro, D.Sc.

Department: Oceanic Engineering

This work develops a method for misfire diagnosis in a Diesel engine using Machine Learning (ML) techniques and vibration signals. In addition, it performs the study of the minimum number of accelerometers necessary to allow the AM algorithms to maintain a good performance in misfire diagnosis. The database used in this study is composed of vibration signals obtained through 15 accelerometers installed in the engine. Three AM algorithms were used in this work: *K*-Nearest Neighbors (*K*-NN), Random Forest (RF) and Support Vector Machines (SVM). The results showed that these algorithms were able to obtain an F1-Score of 99.87%, 99.87% and 100%, respectively, for detection and identification of misfires. Regarding the study of the minimum number of sensors, two methods were used: Relief-F and general combinatorial analysis, with the second being able to show that, with two accelerometers, it was possible to achieve a misfire diagnosis performance with F1-Score above 95%, which is the minimum required, proving the efficiency of the methodology used in this study.

ÍNDICE

1	INTRODUÇÃO	1
1.1	Justificativas.....	3
1.2	Objetivos	3
1.3	Contribuições da Dissertação.....	3
1.4	Organização da Dissertação	4
2	REVISÃO BIBLIOGRÁFICA	6
2.1	Pesquisa Bibliométrica.....	6
2.2	Métodos para diagnóstico de falhas	7
2.3	Métodos de Aprendizado de Máquinas.....	10
3	BASES TEÓRICAS DOS FENÔMENOS DE VIBRAÇÃO NO NAVIO	12
3.1	Modos de vibrar da viga-navio	12
3.2	Fontes de excitação sobre a viga-navio.....	13
3.3	Excitações vibratórias provocadas por um Motor Diesel	14
3.4	Vibrações excessivas ocasionadas pela falha de ignição	18
4	BASES TEÓRICAS DOS MÉTODOS DE APRENDIZADO DE MÁQUINAS	21
4.1	Algoritmos de Classificação	22
4.1.1	K-Nearest Neighbors (K-NN).....	23
4.1.2	Support Vector Machine (SVM).....	24
4.1.3	Random Forest	27
4.1.4	Sumário dos Métodos de Aprendizado de Máquinas.....	28
4.2	Método de Extração de Características	31
4.3	Técnica de Aumento de Dados	32
4.4	Redução de Dimensionalidade.....	32
4.4.1	Relief-F	33
4.5	Método de Normalização de Características.....	35

5	METODOLOGIA	35
5.1	Condições de Contorno do Experimento	37
5.2	Aquisição dos Sinais	37
5.3	Processamento dos Sinais	39
5.4	Estruturação dos Dados.....	40
5.5	Separação dos Dados.....	40
5.6	Extração de Características	41
5.7	Remoção de <i>Outliers</i>	41
5.8	Seleção de Características	42
5.9	Escalonamento de Características	42
6	RESULTADOS E DISCUSSÕES	43
6.1	Detecção e Identificação de Falhas de Ignição	43
6.2	Estudo da Quantidade Mínima de Sensores.....	47
7	CONCLUSÃO	59
8	SUGESTÕES PARA TRABALHOS FUTUROS	61
9	REFERÊNCIAS BIBLIOGRÁFICAS.....	62
10	ANEXOS	68

LISTA DE SIGLAS

ACG	Análise Combinatória Geral
AM	Aprendizado de Máquinas
ANN	Redes Neurais Artificiais (do inglês <i>Artificial Neural Networks</i>)
BD	Banco de Dados
CNN	Redes Neurais Convolucionais
ED	Distância Euclidiana (do inglês <i>Euclidean Distance</i>)
FFT	Transformada Rápida de Fourier (do inglês <i>Fast Fourier Transform</i>)
FN	Falso Negativo
FP	Falso Positivo
IA	Inteligência Artificial
IND	Indefinido
IQR	Intervalo Interquartil (do inglês <i>Interquartile Range</i>)
K-NN	<i>K</i> -Nearest Neighbors
LEDAV	Laboratório de Ensaios Dinâmicos e Análise de Vibração
LSTM	<i>Long Short-Term Memory</i>
MCP	Motor de Combustão Principal
PMI	Ponto Morto Inferior
PMS	Ponto Morto Superior
RF	<i>Random Forest</i>
RMS	<i>Root Mean Square</i>
RNN	Redes Neurais Recorrentes
SVM	<i>Support Vector Machines</i>
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo

1 INTRODUÇÃO

Atualmente, o ambiente das indústrias é extremamente competitivo, com as empresas buscando otimizar os desempenhos de suas operações. Dentro do contexto dos avanços tecnológicos observados, a eficiência operacional tem se tornado fundamental, não apenas para o crescimento destas empresas, como também para sobrevivência das mesmas. Deste modo, o aumento do desempenho de operações das indústrias, de modo mais eficiente, é alcançado por meio de manutenções bem executadas e realizadas nos momentos certos, o que permite aumentar os níveis de disponibilidade e prontidão [1]. No contexto da indústria naval, a busca por uma maior eficiência operacional também é de suma importância, dada a relevância deste modal, uma vez que mais de 80% do volume de comércio global de mercadorias é transportado por via marítima [2], tendo o setor portuário brasileiro movimentado mais de 1,2 bilhão de toneladas no ano de 2022 [3].

De acordo com [4], embora as atividades de manutenção representem parte significativa dos custos operacionais gerais, paralizações não programadas de ativos navais acarretam perdas importantes de receita. Além disso, [4] também enfatiza que acidentes em navios podem afetar saúde, segurança e meio ambiente, tendo considerado que grande parte dos acidentes envolvendo o maquinário de navios pesqueiros são em decorrência da falta de manutenção. No caso de navios de guerra, a falta de manutenção representa não apenas um fardo para as tripulações, como também têm um efeito deletério na prontidão atual e futura destes meios [5]. Assim sendo, a manutenção é essencial para garantir uma alta disponibilidade e confiabilidade dos meios navais ao longo de sua vida útil operacional [4].

Quanto ao seu objetivo, é possível destacar três tipos de manutenção: a Manutenção Corretiva, que é aquela realizada após a ocorrência de uma falha ou defeito em um determinado item, com o objetivo de reestabelecer o seu funcionamento, a Manutenção Preventiva, que é realizada de forma programada, com o objetivo de evitar falhas e defeitos em um determinado item, sendo baseada em inspeções e manutenções periódicas, com base em critérios previamente estabelecidos, e por fim, a Manutenção Preditiva, que utiliza tecnologias e técnicas de monitoramento para identificar sinais de desgaste ou falhas iminentes em equipamentos ou máquinas, de modo a minimizar manutenções preventivas e corretivas, bem como garantir a qualidade do serviço que se deseja [6].

Nos dias de hoje, considera-se que a indústria está passando por sua quarta revolução: a chamada Indústria 4.0 [7], cujo conceito tem como base a interconexão entre máquinas, sistemas e pessoas, possibilitando a coleta e análise de grandes volumes de dados em tempo real, levando a uma melhoria na eficiência e produtividade das fábricas.

Neste contexto, a manutenção preditiva utiliza recursos baseados na Inteligência Artificial (IA), entre os quais consiste no monitoramento operacional por meio de sensores que coletam uma grande quantidade de dados, os quais são processados por meio de algoritmos de Aprendizado de Máquinas (AM). Estes, por sua vez, utilizam técnicas de reconhecimento de padrões que auxiliam no diagnóstico de falhas, mesmo em seu estágio inicial, subsidiando a tomada de decisões voltadas para evitar que estas falhas evoluam para condições mais severas, ou ainda desencadeiem outros tipos de falhas que possam comprometer o funcionamento do meio operacional.

A otimização proporcionada pela aplicação de técnicas de AM na tarefa de reconhecimento de falhas também pode possibilitar a utilização de menor número de sensores para aquisição de dados, sem prejuízo à capacidade de diagnosticar falhas, o que pode significar uma redução de custos com equipamentos a serem utilizados neste tipo de análise.

Falhas estruturais em navios podem decorrer de diversas causas, dentre elas a corrosão de elementos estruturais devido à falta de revestimento adequado, especialmente quando os mesmos são expostos à salinidade do mar, movimentos de esforços cíclicos sobre a estrutura do navio e vibrações excessivas [8], sendo esta última causada por fontes de excitação como as forças hidrodinâmicas atuando sobre o casco, as forças dinâmicas provocadas pelo sistema propulsivo e as forças e momentos advindos do funcionamento do Motor de Combustão Principal (MCP) [9].

Para o caso do motor, as fontes de excitação por ele geradas tem origem nas forças inerciais devido aos seus componentes mecânicos e nas forças e momentos internos devido aos desbalanceamentos das pressões no conjunto de cilindros do motor [9]. Esses desbalanceamentos são acentuados em casos de perda de ignição, quando um ou mais cilindros apresentam queima incompleta ou nula na câmara de combustível. Dependendo da severidade de falha de perda de ignição, a mesma pode retornar maiores níveis de vibração, que podem se propagar para a estrutura do navio [10].

Dito isto, o foco deste estudo está na detecção e identificação de falhas de ignição em um motor Diesel por meio do uso de algoritmos de AM, uma vez que se trata de uma técnica mais otimizada, capaz de entregar boas respostas quanto ao monitoramento da vida útil operacional de estruturas e equipamentos.

1.1 Justificativas

Este estudo é motivado pela necessidade de acompanhamento operacional dos meios navais, a fim de subsidiar decisões a serem tomadas no âmbito da manutenção preditiva, possibilitando minimizar a quantidade de intervenções nos meios e maximizar a sua vida útil operacional.

Adicionalmente, também há a necessidade de redução de custos com manutenção devido a eventuais paradas não programadas dos meios operativos.

A detecção e identificação de falhas em seu estágio inicial é de suma importância para as equipes responsáveis pela manutenção dos meios operativos, fato este que também motiva o estudo desta dissertação.

Além disso, existe o custo referente à utilização de equipamentos utilizados para a aquisição de dados a serem empregados na tarefa de diagnóstico de falhas. A possibilidade de redução deste custo com a utilização de menor quantidade de sensores, sem prejuízo à capacidade de diagnóstico, também motiva a condução desta pesquisa.

1.2 Objetivos

Este estudo possui dois objetivos. O primeiro deles é a detecção e identificação de falhas de perda de ignição em um motor Diesel através da utilização de algoritmos de AM, a fim de demonstrar a aplicabilidade do método utilizado para diagnóstico de falhas em estruturas e equipamentos, tendo em vista o seu ciclo de vida operacional. E o segundo é a realização de um estudo de utilização de menor número de sensores para aquisição de sinais que garanta um bom desempenho de classificação, a fim de possibilitar uma redução de custos com equipamentos utilizados neste tipo de análise.

1.3 Contribuições da Dissertação

Entre as contribuições desta dissertação está a possibilidade de auxiliar as equipes responsáveis pela tarefa de manutenção dos meios a identificar as falhas ainda em seu estágio inicial. Além disso, também é vislumbrada a possibilidade de aplicar o método

estudado à sistemas de monitoramento contínuo das condições estruturais e operacionais de embarcações, bem como na otimização da quantidade de sensores a serem utilizados na coleta de dados, com vistas à redução de custos com equipamentos.

1.4 Organização da Dissertação

O Capítulo 2 apresenta a Pesquisa Bibliométrica realizada para embasar a linha de pesquisa deste trabalho. Além disso, é apresentada também uma breve explicação acerca do fenômeno de falha de perda de ignição, que é objeto de estudo desta dissertação, bem como uma Revisão Bibliográfica acerca dos métodos utilizados para aquisição de sinais em motores que apresentam este tipo de falha, além das metodologias utilizadas quanto ao emprego de técnicas de AM para detecção e identificação de falhas.

As bases teóricas acerca dos fenômenos de vibração encontrados em navios são mostradas no Capítulo 3, abrangendo um breve estudo dos modos de vibração da viga navio, das fontes de excitação às quais o navio está sujeito e do fenômeno da ressonância. Além disso, é feita uma breve abordagem com relação aos efeitos de vibração causados pelo funcionamento do motor, tais como as forças e momentos que são provocados por esta fonte de excitação, bem como as suas ordens de vibração.

No Capítulo 4, são mostradas as bases teóricas dos métodos de AM, com uma breve explicação acerca das técnicas utilizadas em cada etapa da metodologia empregada para o diagnóstico de falhas, com abordagens acerca dos três algoritmos de classificação empregados nesta Dissertação (*K*-NN, SVM e *Random Forest*). Em seguida, são apresentadas as fórmulas estatísticas utilizadas para extrair as características no domínio do tempo, a técnica de aumento de dados empregada para mitigar o problema de alta dimensionalidade do Banco de Dados (BD), o método de redução de dimensionalidade utilizado para selecionar as características mais relevantes do BD e o método de normalização de características.

A metodologia detalhada que foi implementada neste estudo é descrita no Capítulo 5, tendo sido abordada a aquisição dos sinais de vibração, o pré-processamento e estruturação do BD, a extração das características, a remoção dos *outliers*, a seleção dos atributos mais relevantes para a tarefa de classificação e o escalonamento de características. Também são mostrados os critérios para divisão do BD em dados de treinamento e teste.

No Capítulo 6 são apresentados e discutidos os resultados obtidos para o primeiro objetivo (detecção e identificação de falhas), bem como para o segundo objetivo do trabalho (estudo da utilização de número menor de sensores), com as considerações finais sendo apresentadas no Capítulo 7 e as sugestões para trabalhos futuros sendo feitas no Capítulo 8. Por fim, no Capítulo 9 são apresentadas as referências bibliográficas que embasaram o desenvolvimento desta dissertação e no Capítulo 10 são apresentados os anexos.

2 REVISÃO BIBLIOGRÁFICA

Antes de abordar a revisão bibliográfica das referências utilizadas como base desta dissertação, será apresentada a pesquisa bibliométrica, a qual tem por objetivo mostrar a importância da linha de estudo adotada, indicando as diversas áreas correlatas, sendo uma boa ferramenta a ser utilizada para auxiliar pesquisadores na tomada de decisões quanto à área a ser estudada [11].

Em seguida, serão apresentados breves resumos acerca de trabalhos anteriores quanto aos diferentes métodos adotados para diagnóstico de falhas, bem como os métodos de AM utilizados.

2.1 Pesquisa Bibliométrica

Esta pesquisa bibliométrica foi feita visando verificar a quantidade de publicações, na área acadêmica, que tratam a respeito da utilização de técnicas de AM aplicadas aos casos de estudo de interesse deste trabalho. A pesquisa foi feita no dia 27 de abril de 2023 considerando-se a base de dados do site LENS.org.

Para realizar a busca, foi empregado o termo principal “Aprendizado de Máquinas” nos campos título, resumo, palavra-chave e campo de estudo. Além disso, a fim de pesquisar as aplicações do termo principal sobre os casos de estudo de interesse desta dissertação, também foram empregados os termos “Estrutura de Navio”, “Diagnóstico de Falhas”, “Falhas de Ignição” e “Motor Diesel Marítimo”, considerando os mesmos campos de busca. Todos os termos utilizados na pesquisa foram escritos na língua inglesa, uma vez que grande parte da produção acadêmica internacional é escrita neste idioma.

A pesquisa considerou a produção acadêmica realizada a partir de 2020 até a atualidade, conforme pode ser observado na Figura 2.1, onde os períodos são discriminados em diferentes cores. Os tipos de publicação considerados foram artigos, volumes e edições de periódicos, livros e seus capítulos. Deste modo, foram encontradas 1.465 publicações de interesse.

Os resultados apresentados na Figura 2.1 mostram que as técnicas de AM possuem aplicações nas áreas de interesse desta dissertação, como Diagnóstico de Falhas, Manutenção Preditiva, Análise de Vibração, Monitoramento da Condição Operacional,

Monitoramento da Condição Estrutural, entre outras, tendo sido observada também uma tendência de uso crescente de AM em produções científicas.

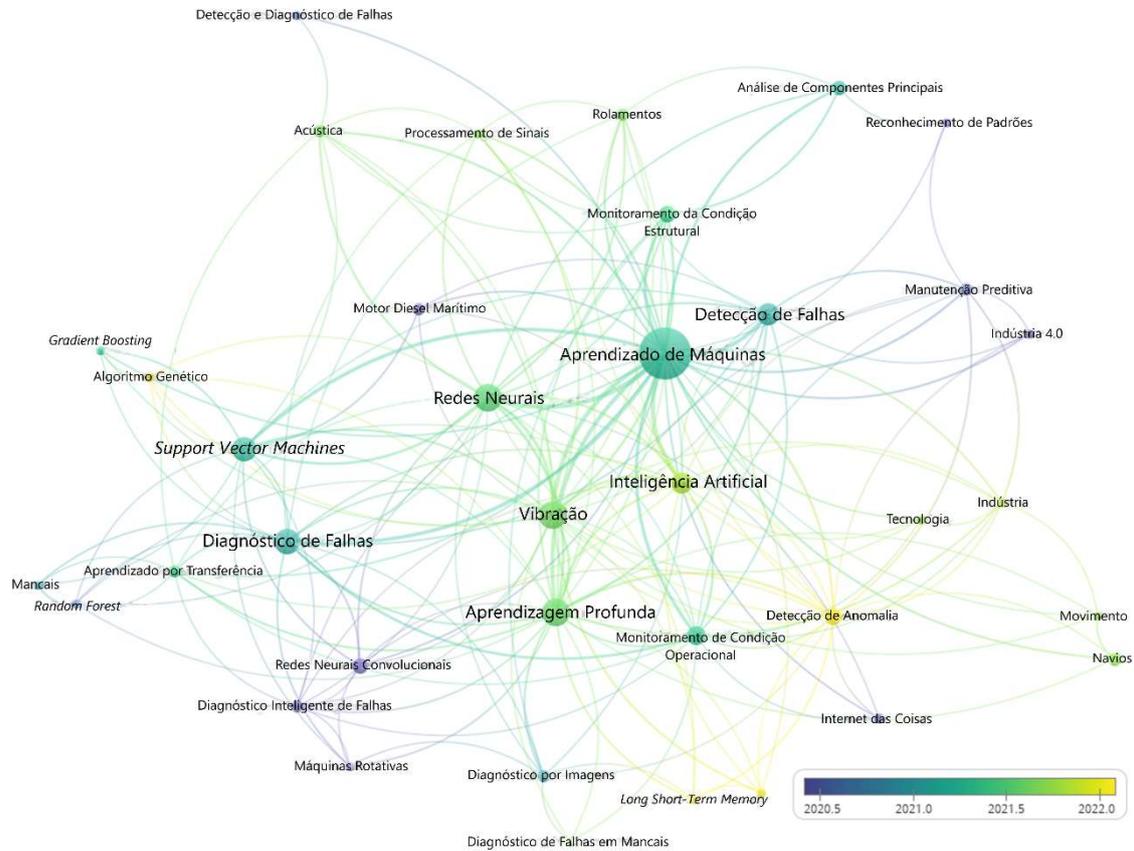


Figura 2.1. Pesquisa bibliométrica com mapa de coocorrência de palavras-chave.

Deste modo, essa pesquisa bibliométrica serve como um norte para a linha de pesquisa adotada nesta dissertação, uma vez que aponta a importância da utilização de técnicas de AM para não apenas o diagnóstico de falhas, como também para outras abordagens correlatas.

2.2 Métodos para diagnóstico de falhas

A falha de perda de ignição é um tipo de falha comum em Motores de Combustão Interna quando não há ignição ou há perda de chama por falta de combustível dentro dos cilindros do motor. Este tipo de falha pode ter várias causas, tais como: mistura ar/combustível muito pobre dentro da câmara de combustão, bicos injetores entupidos, anéis de segmento deteriorados, falha na vedação da válvula de admissão/escape, pressão incorreta na injeção, etc. Devido às inúmeras causas, a falha de perda de ignição é um dos problemas mais difíceis de diagnosticar e resolver [10].

Em relação à severidade de falha, [12] mencionaram que falhas de ignição em até dois cilindros são as mais comuns observadas. Porém, quando essa falha ocorre em mais de dois cilindros, uma elevada vibração no bloco do motor pode ser observada.

Para o caso de motores que utilizam *Common Rail*, quando não há queima de combustível em um determinado cilindro, as consequências podem se propagar para os demais cilindros, pois a quantidade de combustível distribuída pelo *Common Rail* pode se tornar desregulada. Quando isso acontece, uma maior quantidade de combustível é injetada nos cilindros onde não foi observada falha (de modo a manter a condição de operação), em detrimento àquele defeituoso.

De acordo com [13], ciclos de falha de ignição podem causar flutuações de velocidade e torque, bem como o desbalanceamento de forças. Além disso, falhas de ignição podem levar a outros problemas, como redução de potência (e, por consequência, redução do desempenho do navio) e aumento das emissões de gases poluentes, principalmente hidrocarbonetos e monóxido de carbono.

Considerando essas possíveis consequências, a detecção de falha de ignição é um dos mais importantes diagnósticos a serem realizados a bordo, sendo necessário também a identificação do cilindro específico em que ocorreu a falha [13].

Com relação aos métodos de detecção de falha de ignição, [14] propuseram o rastreamento da velocidade angular do virabrequim em um motor de ignição por centelha com quatro cilindros, com a utilização de um algoritmo otimizado de Observação de Controle Deslizante de Luenberger. Os resultados mostraram que esta técnica possibilitou o diagnóstico de falhas de ignição em regime transiente do motor.

Em [15] foi usado o sinal do codificador para construir formas de onda de velocidade angular instantânea para representar o sinal de vibração torcional, a fim de prever falhas de combustão nos cilindros de um motor Diesel de média rotação. No entanto, de acordo com [16], este método requer dispositivos capazes de medir mudanças mínimas na velocidade angular em casos de falha de ignição, além dos efeitos de variações aleatórias na aceleração durante a operação.

Em [17] foi proposta a análise da temperatura dos gases de escape de motores de combustão interna para detecção de falha de ignição, usando baixa taxa de amostragem, por meio de sensores de temperatura convencionais, usados para medir a temperatura dos

gases de exaustão para cada cilindro do motor. Deste modo, eles defendem que a técnica empregada se sobrepõe àquela que considera a medição de rotação do eixo de manivelas do motor, uma vez que, para motores com uma grande quantidade de cilindros, esta técnica não é tão efetiva, pois a contribuição do sinal de vibração relativo à falha de perda de ignição em um único cilindro é relativamente baixa. Os resultados alcançados foram uma taxa de alarme falso razoavelmente aceitável e uma taxa de detecção bem sucedida, suficiente para permitir o entendimento do comportamento dos sinais, facilitando a tomada de decisões quanto à necessidade de manutenção preditiva.

No entanto, este estudo esteve limitado apenas a motores operando em regime estacionário, sem considerar mudanças drásticas de carga. Além disso, [18] mencionaram que a técnica de análise de temperatura de exaustão dos gases é aplicável somente quando a taxa de falha de ignição induzida está acima de um determinado percentual.

Em [19] foi proposto o uso de um sensor piezoelétrico tradicional em motores Diesel para captar a variação de pressão dentro do cilindro com a análise da derivada dos sinais de pressão. Deste modo, quaisquer mudanças bruscas de pressão dentro do cilindro seriam amplificadas pela derivada dos respectivos sinais. Os resultados da metodologia foram então comparados com a análise termodinâmica clássica, tendo sido validados por meio de experimentos em motores Diesel, com a ressalva da necessidade de se realizar estudos adicionais voltados para a sua validação em casos de regime transiente de operação do motor, bem como as variações cíclicas.

Em [20] foi realizado um estudo comparativo entre duas metodologias para detecção de falhas de ignição em um motor de ignição por centelha de 4 tempos, sendo a primeira voltada para a análise de vibração, e a segunda, para a análise acústica dos ruídos do motor, tendo inferido que a análise de vibração é mais precisa do que a análise acústica.

Em [21] foram usados quatro sensores para monitoramento de sinais de vibração em um motor de automóvel com o objetivo de investigar diferentes níveis de severidade de falha de perda de ignição (em apenas um cilindro e simultânea em dois cilindros), bem como folgas excessivas nas válvulas, obtendo um desempenho para detecção de falhas com acurácia acima de 94%. Este último método tem se mostrado eficaz para a correta detecção de falhas de ignição, sendo amplamente utilizado.

Para o presente estudo, foi considerado o monitoramento do sinal de vibração por meio de acelerômetros piezoelétricos instalados no bloco do motor, por se tratar de uma técnica não intrusiva e de fácil instalação.

2.3 Métodos de Aprendizado de Máquinas

Na literatura, diversas técnicas podem ser aplicadas para o diagnóstico de falhas em motores diesel, tendo a aplicação de algoritmos de AM mostrado uma grande relevância neste contexto, uma vez que trabalham com características específicas para cada tipo de falha, minimizando assim o erro no diagnóstico.

Em [16] foram utilizadas Árvores de Decisão com algoritmo C4.5 para detecção de falha de ignição em um motor a gasolina de quatro cilindros e quatro tempos, com análise de sinais de vibração no domínio do tempo e extração de 8 (oito) características. Além disso, a seleção de características foi feita pelo próprio algoritmo C4.5 que possui a propriedade de *Gain Ratio*. O desempenho de classificação apontado por eles mostrou uma acurácia em torno de 95%. No entanto, de acordo com [22], o emprego de Árvores de Decisão pode apresentar alta variância nos valores resultantes de diagnóstico, embora esse problema possa ser mitigado por meio da utilização do método de comitê *Random Forests* (RF).

Em [23] foram utilizados cinco tipos de algoritmos baseados em Árvore de Decisão, incluindo o RF, para detecção de falha de ignição em um motor ciclo Otto, com análise de sinais de vibração no domínio do tempo. Eles extraíram oito características no domínio do tempo, tendo utilizado as técnicas de *Information Ratio* (IR) e a Redução de Entropia para seleção de características. Por fim, eles informam ter obtido um desempenho de classificação com acurácia de 100% para diferenciar condições normais de operação das condições com falha.

Em [24] foi proposto um sistema baseado em Support Vector Machines (SVM) para diagnóstico de falha de ignição em um motor Diesel marítimo de 16 cilindros tipo V, com as características sendo extraídas no domínio da frequência e por meio de um método de representação polar, onde o tamanho do raio é usado para indicar a localização e grau da falha. Os resultados mostraram boas precisões de classificação para condições normais e diferentes níveis de falha de ignição.

Em [21] foi considerado o uso de Redes Neurais Artificiais (ANN), SVM e *K-Nearest Neighbors* (*K-NN*) para detecção de diferentes tipos de falhas (falha de perda de

ignição em um cilindro, simultânea em dois cilindros e folga excessiva em válvulas) em motores de combustão, com base em monitoramento multissensorial de sinal de vibração. A análise dos sinais foi feita no domínio da frequência, com a conversão dos sinais obtidos no domínio do tempo por meio do uso da Transformada Rápida de Fourier (FFT). Os três métodos empregados retornaram uma acurácia de classificação acima de 95%.

Em [25], os sinais de vibração foram decompostos em ondaletas (*wavelets*) antes da extração de características, que foi feita tanto no domínio do tempo quanto no domínio do tempo-frequência. Em seguida, utilizaram Ganho de Informação e *Relief-F* como métodos de seleção e hierarquização de características antes de empregar SVM e RF para identificação de falhas em rolamentos. Eles obtiveram uma eficiência de validação cruzada de 98,38% ao empregar o algoritmo de AM RF e o método de seleção de características *Relief-F*.

Este estudo visa investigar problemas de vibração em navios, com foco na detecção e identificação de falhas de ignição em um Motor de Combustão Interna de 12 cilindros do tipo V, através do emprego de algoritmos de AM sobre os dados de vibração, obtidos por acelerômetros colocados no bloco do motor, com análise dos sinais no domínio do tempo. Os seguintes métodos foram considerados para a classificação de falhas de ignição: *K-NN*, SVM e RF.

Além disso, este trabalho também abrange a avaliação do desempenho de diagnóstico de falhas, após a aplicação do método *Relief-F* para seleção de características, visando a redução de dimensionalidade dos dados e a possibilidade de utilização de menor número de sensores para aquisição de sinais, sem prejuízo à capacidade de diagnóstico.

3 BASES TEÓRICAS DOS FENÔMENOS DE VIBRAÇÃO NO NAVIO

A vibração estrutural é o resultado das forças de excitação e das propriedades dinâmicas da estrutura, sendo regida pela equação geral do movimento demonstrada na Eq. (3.1):

$$M\ddot{x}(t) + C\dot{x}(t) + Kx(t) = f(t) \quad (3.1)$$

onde: M, C e K são as matrizes de massa, amortecimento e rigidez, respectivamente, $\ddot{x}(t)$ é o vetor de aceleração, $\dot{x}(t)$ é o vetor de velocidade, $x(t)$ é o vetor de deslocamento e $f(t)$ é o vetor da forças.

Vibrações em navios podem resultar em falha por fadiga de membros estruturais ou de componentes de equipamentos, podendo afetar adversamente o desempenho de equipamentos vitais de bordo, aumentar os custos de manutenção e aumentar drasticamente o desconforto de passageiros e tripulação [9]. O pior dos casos de vibração é quando ocorre a ressonância, situação em que a frequência de excitação da fonte coincide com a frequência natural da estrutura.

A seguir, será feita uma breve explicação a respeito dos modos de vibrar de um navio e sobre as principais fontes de excitação sobre um navio.

3.1 Modos de vibrar da viga-navio

Os modos de vibrar da viga-navio são similares aos de uma viga de extremidades livres (Figura 3.1), cuja frequência natural está descrita na Eq. (3.2) [9]:

$$f = \frac{\alpha_n}{2\pi} \sqrt{\frac{EIg}{\mu L^4}} \quad (3.2)$$

onde L é o comprimento da viga, E é o Módulo de Elasticidade, I é o Momento de Inércia da Área Transversal da Viga, μ é o peso por unidade de comprimento (incluindo-se a massa adicional hidrodinâmica), g é a aceleração da gravidade, n é o número de nós e α_n varia de acordo com o descrito na Tabela 3.1.

Tabela 3.1 Valores de α em função da quantidade de nós do modo de uma viga com extremidades livres.

n	α
2	22,3733
3	61,6728
4	120,9034
5	199,8594

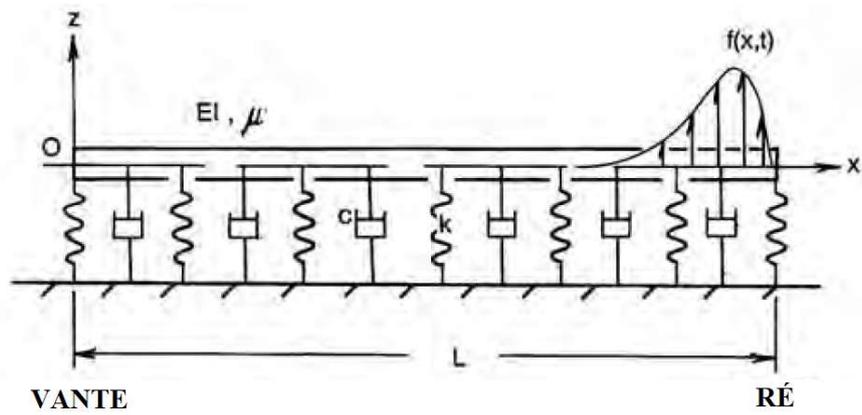


Figura 3.1. Modelo da viga navio (adaptado de [26])

Uma alternativa ao procedimento de medição com análise modal para a estimativa das frequências naturais é a realização de um modelo da embarcação considerando-se a formulação da viga com extremidades livres, acrescentando-se neste caso os efeitos da massa adicional. Os modos de vibração vertical de um navio estão demonstrados na Figura 3.2.

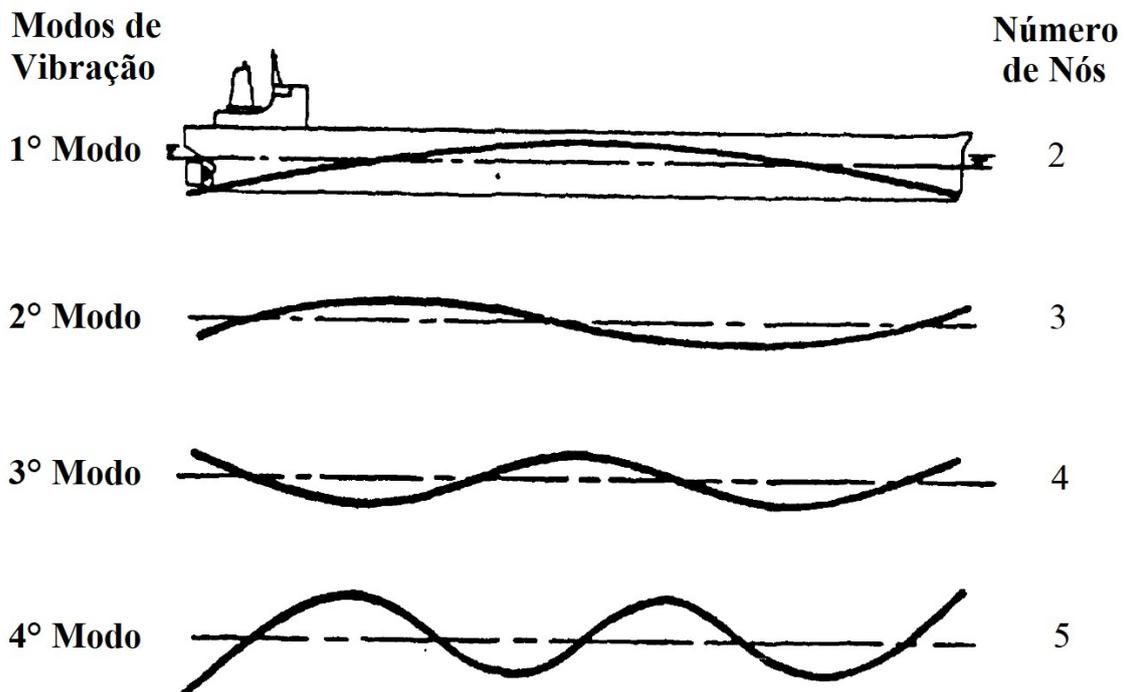


Figura 3.2. Modos de vibração vertical da viga-navio (adaptado de [9])

3.2 Fontes de excitação sobre a viga-navio

As principais fontes de excitação sobre a viga-navio são:

- MCP: forças e momentos internos em função dos desbalanceamentos devido às pressões dentro dos cilindros [9], bem como as forças inerciais das partes rotacionais do motor [27];

- Propulsão: forças dinâmicas que atuam sobre o casco por meio dos mancais do eixo propulsor ou diretamente através das pás do propulsor [9];

- Ondas sobre o casco: forças provocadas devido à ação hidrodinâmica das ondas do mar sobre o casco.

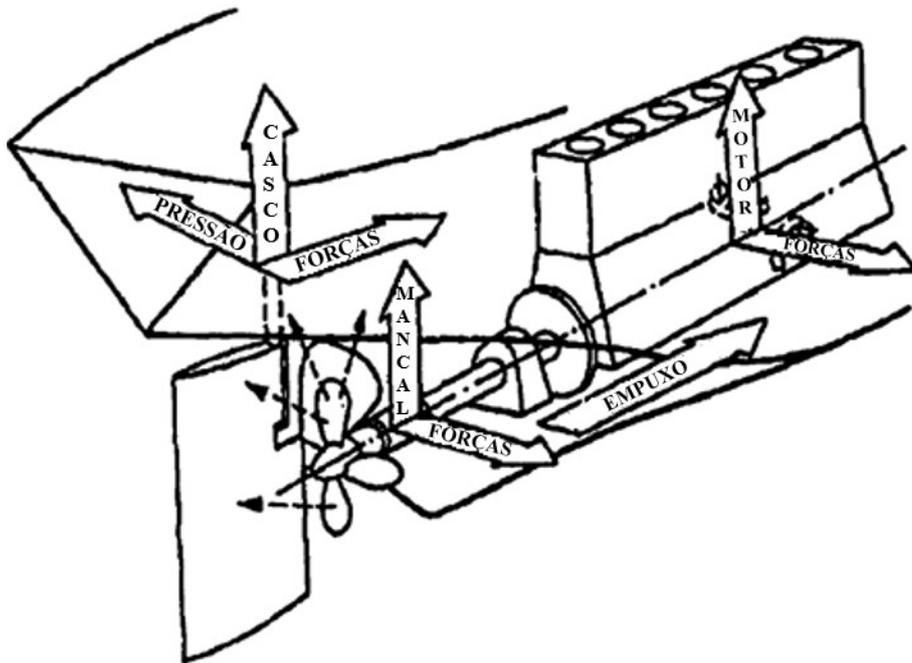


Figura 3.3. Fontes de Excitação Principais [9].

Este trabalho irá focar nas fontes de excitação originadas pelo MCP.

3.3 Excitações vibratórias provocadas por um Motor Diesel

O desbalanceamento de MCP é uma das maiores fontes de vibração excessiva, podendo desenvolver forças de excitação na faixa de frequência de interesse de equipamentos e estruturas localizados nas proximidades. Motores Diesel de baixa, média ou alta rotação, de dois ou quatro tempos, geram significativas vibrações devido às forças e momentos acoplados, as quais irão depender da rotação do motor e do número de cilindros. Estas forças e momentos podem excitar tanto o próprio motor como também a sua base, a viga navio e outras estruturas no interior do navio [28];

Com relação às forças e momentos que agem sobre o MCP, são geralmente consideradas as três componentes de força periódicas e as três componentes de momentos periódicos que atuam na base do motor. No entanto, uma vez que a componente de força periódica ao longo do eixo do motor é zero [26], apenas duas componentes de forças e momentos aparecem atuando (Figura 3.4).

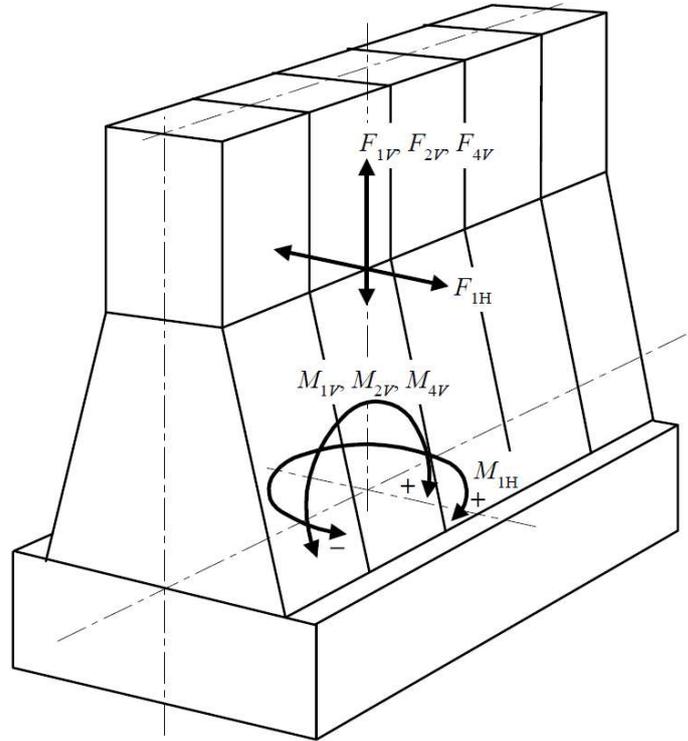


Figura 3.4. Forças e Momentos externos agindo sobre o MCP [27].

A Figura 3.4 mostra as forças verticais de primeira, segunda e quarta ordens (F_{1V} , F_{2V} e F_{4V} , respectivamente), a força horizontal (ou lateral) de primeira ordem (F_{1H}), os momentos verticais de primeira, segunda e quarta ordens (M_{1V} , M_{2V} e M_{4V} , respectivamente) e o momento horizontal de primeira ordem (M_{1H}). As forças e momentos de primeira ordem ocorrem na frequência de rotação da linha de eixo, enquanto que as forças e momentos de segunda e quarta ordens ocorrem em frequências equivalentes aos respectivos múltiplos da rotação da linha de eixo.

Com relação às forças de excitação originadas do MCP, existem dois tipos diferentes que podem ser associados ao seu funcionamento:

- Forças inerciais originadas das acelerações dos componentes do motor que possuem movimentos rotativos e alternativos;

- Forças causadas pela pressão dos gases devido ao processo de combustão.

A Figura 3.5 [29] mostra os efeitos de ambos os tipos de excitações principais advindos do MCP, bem como o nível de complexidade associado a cada um desses efeitos citados.

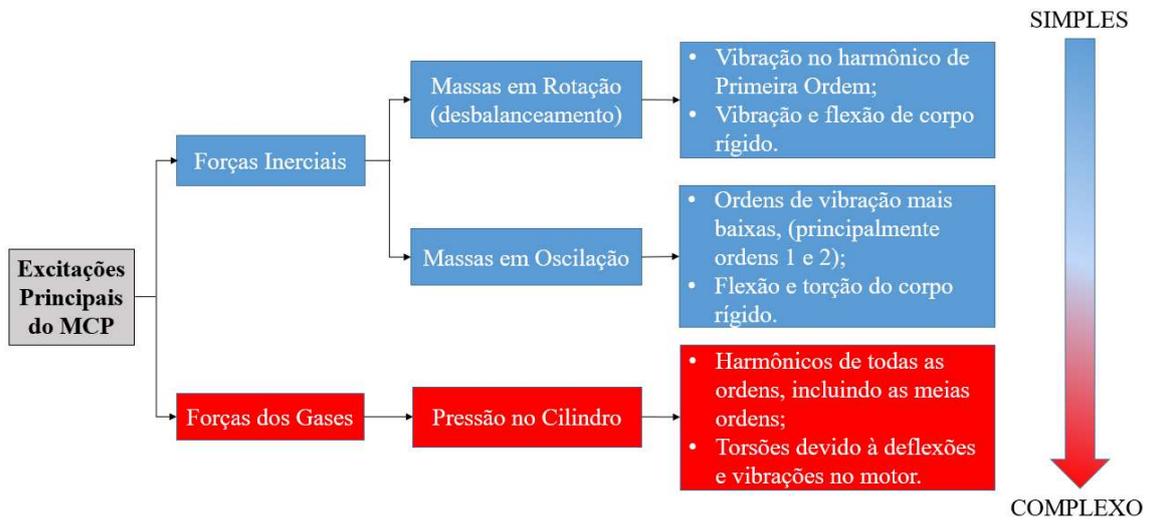


Figura 3.5. Forças de excitações principais do MCP (adaptado de [29]).

Com relação às forças inerciais, a Figura 3.6 mostra as componentes de forças e torques inerciais atuantes no pistão (força F_{IP}), na biela (forças F_{ICx} e F_{ICy} , além do torque T_{IG}) e no virabrequim (torque T_{IS}).

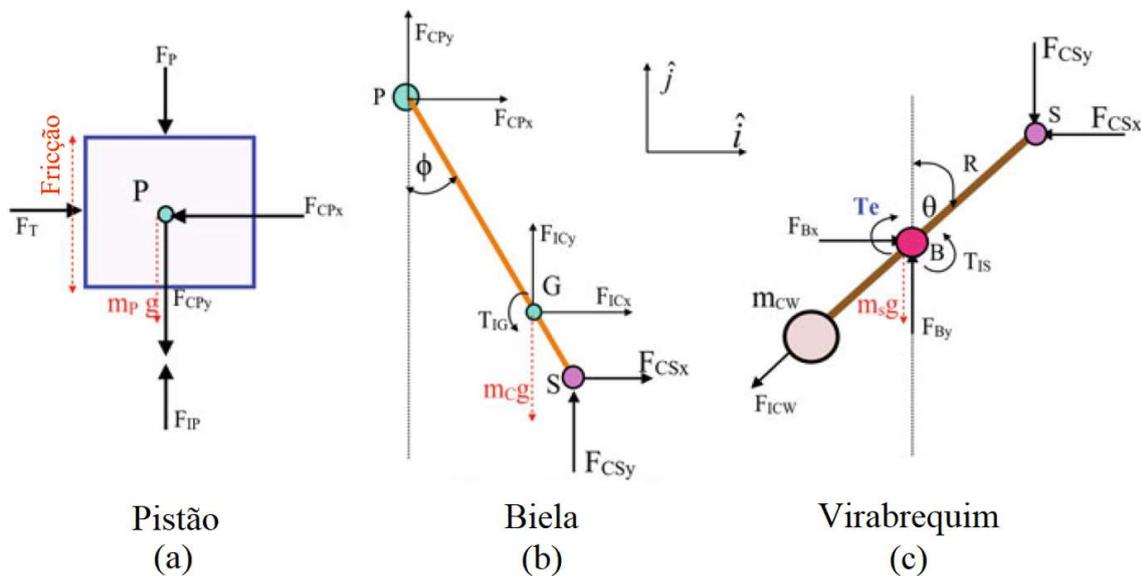


Figura 3.6. Digrama de forças livres nos seguintes elementos rotativos do motor: (a) pistão; (b) biela; (c) virabrequim (adaptado de [13]).

As forças causadas pela pressão dos gases devido ao processo de combustão agem sobre a cruzeta do motor, sendo um resultado das forças de reação transversais em função da ordem de queima, dependendo também da quantidade de cilindros do motor. Essas forças de reação agem de forma acoplada, conforme mostrado na Figura 3.7, sendo classificadas como acoplamento “H” e acoplamento “X”. O primeiro caso deriva do movimento periódico do motor, quando a sua parte superior está em fase oposta à parte em contato com a base. Já no segundo caso, a parte de vante do motor age em fase oposta à parte de ré do mesmo [27].

Quando a frequência destas forças se aproxima da frequência natural da base do motor, a mesma entra em ressonância, gerando vibrações locais na estrutura no fundo da Praça de Máquinas. No entanto, o risco de ressonância pode ser mitigado com o uso de estais laterais ou suportes que conectam a estrutura da parte superior do motor à estrutura do navio [27].

No entanto, para motores com número par de cilindros, como os que utilizam 6 ou 8 cilindros em linha e os que utilizam 12 ou 16 cilindros em “V”, as manivelas são arranjadas de forma simétrica, de modo que as massas em movimento mantêm umas às outras balanceadas. Com isso, esses tipos de motores são os ditos “externamente balanceados”, não apresentando as forças acopladas explicitadas no parágrafo anterior [29]. Porém, em casos de falhas de ignição no interior dos cilindros destes motores, aparecem desbalanceamentos de momentos, e estas forças acopladas voltam a ser observadas.

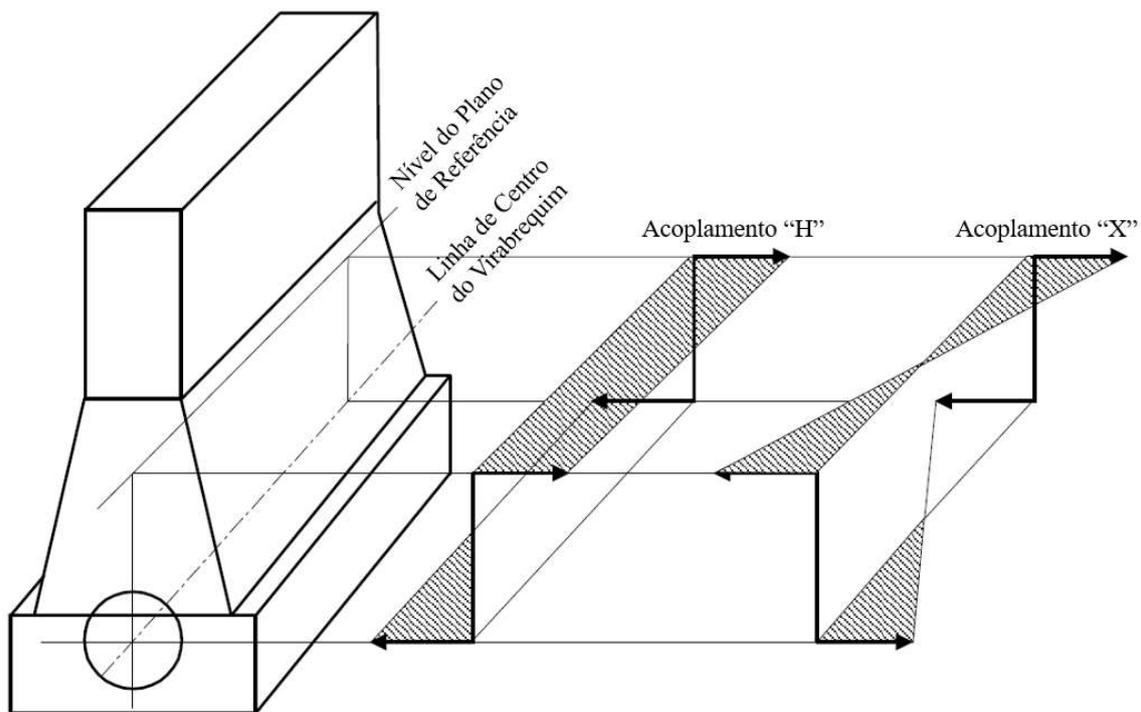


Figura 3.7. Forças acopladas em “H” e em “X” decorrentes das forças dos gases dentro dos cilindros do MCP 2018 [27].

Na fase de projeto do navio, todas as abordagens mencionadas anteriormente devem ser consideradas, a fim de que as frequências de excitação do motor não coincidam com as frequências naturais da viga-navio. No entanto, ainda que estas condições sejam atendidas, é importante salientar que eventuais falhas que surjam ao longo da vida operacional do motor podem influenciar nos níveis de vibração do motor, podendo acarretar em eventuais danos não apenas à estrutura do próprio equipamento, como também à estrutura do navio, em casos extremos.

Entre as falhas comuns que podem causar vibrações excessivas do motor, destacam-se a folga incorreta nas válvulas, batidas de pistão e falhas de injeção de combustível [30]. Nesta dissertação, será abordada a falha de injeção de combustível, com foco na falha de ignição, e como a mesma pode ocasionar estas vibrações excessivas.

3.4 Vibrações excessivas ocasionadas pela falha de ignição

O arranjo das partes rotativas e alternativas do motor é feito de maneira que as massas em movimento se mantenham balanceadas. Ou seja, na condição normal de operação do motor, os momentos gerados pela queima de combustível no interior dos cilindros estão em equilíbrio.

No entanto, em caso de falha de ignição em qualquer um dos cilindros, a pressão interna no cilindro onde existe a falha é menor que a dos demais cilindros (Figura 3.8), de modo que o seu momento também será diferente dos demais, o que gera um desbalanceamento de momentos que, por sua vez, origina excitações maiores no motor.

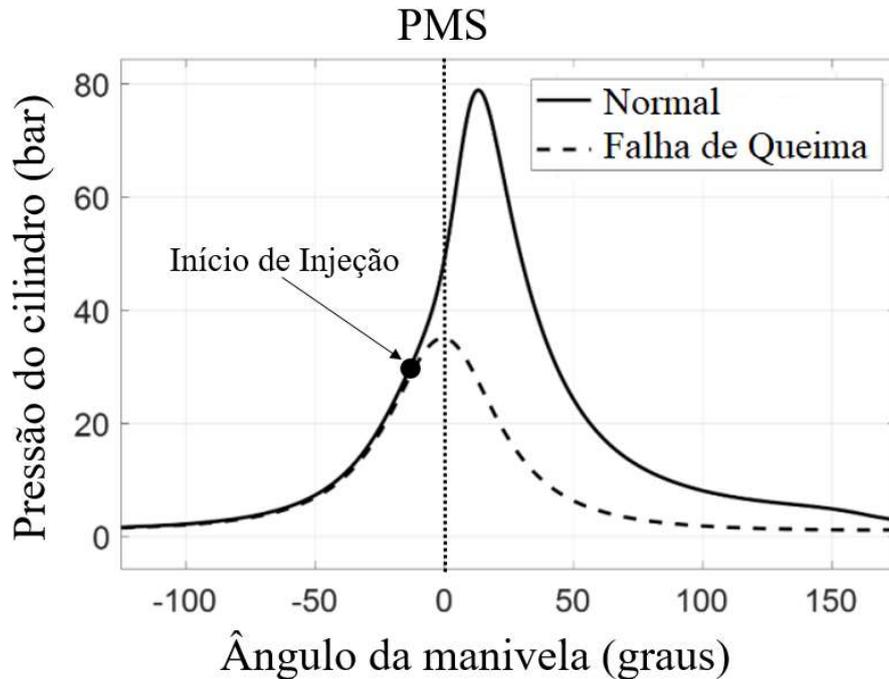


Figura 3.8. Pressões no interior do cilindro em casos de operação normal e falha de perda de ignição

Os Motores de Combustão Interna mais modernos são dotados de sistema de controle eletrônico, através do qual é feito o ajuste da quantidade de combustível que é injetada nos cilindros em tempo real, de modo evitar que haja uma injeção excessiva de combustível que possa acarretar em um excesso de combustível não queimado, que por sua vez resulta em perda de potência, aumento no consumo de combustível e emissão de poluentes [10].

Em casos de falhas de ignição, quando a queima dentro de um cilindro é incompleta ou inexistente, o sistema redistribui o fluxo de combustível para os demais cilindros. Com isso, a rotação do motor se mantém inalterada, mesmo com a adição de mais combustível, o que significa que o motor continua operando na mesma frequência, e as suas meias-ordens de frequência também se mantêm as mesmas. O que se altera, em caso de falhas de ignição, são as amplitudes de resposta nas frequências de excitação, as

quais não podem exceder um certo grau de severidade (Anexo A), sob o risco de danificação do motor, podendo inclusive afetar a estrutura do navio.

A falha de ignição precisa ser identificada o quanto antes para que o seu nível de severidade não evolua a ponto de causar elevados níveis de vibração, nocivos à estrutura do motor e, por consequência, do navio, o que motiva a necessidade de se realizar diagnósticos precoces. Assim, este estudo irá abordar diagnóstico de falhas de ignição em um motor Diesel por meio de IA, com a utilização de algoritmos de AM. Estas ferramentas têm se mostrado de extrema utilidade no diagnóstico de falhas, bem quanto ao monitoramento da vida útil operacional de estruturas e equipamentos.

4 BASES TEÓRICAS DOS MÉTODOS DE APRENDIZADO DE MÁQUINAS

O AM pode ser dividido nas seguintes categorias: Aprendizado Supervisionado, Aprendizado Não Supervisionado e Aprendizado por Reforço [31], conforme demonstrado na Figura 4.1. Seguem abaixo as explicações sucintas sobre cada uma das categorias citadas:

- Aprendizado Supervisionado: quando o algoritmo é treinado com um conjunto de dados rotulados (ou classificados), de modo que o mesmo seja capaz de aprender a mapear os dados de entrada para as saídas (respostas). Se subdivide em dois grandes grupos de algoritmos: os de regressão (trabalham com variáveis contínuas) e os de classificação (trabalham com variáveis categóricas);

- Aprendizado Não Supervisionado: quando o algoritmo é treinado com um conjunto de dados não rotulados, com o objetivo de encontrar padrões e estruturas nos dados sem a necessidade de conhecimento prévio destes rótulos. Suas principais subdivisões são: algoritmos de Clusterização (trabalham com agrupamento dos dados com base em suas similaridades ou diferenças) e algoritmos de redução de dimensionalidade (trabalham com o objetivo de reduzir o número de variáveis em um BD, visando a simplificação de análise);

- Aprendizado por Reforço: quando o algoritmo é treinado para aprender a tomar ações em um ambiente dinâmico, onde o mesmo é retroalimentado positivamente ou negativamente de acordo com as ações tomadas, tendo como objetivo a maximização da recompensa a longo prazo.



Figura 4.1. Principais subdivisões do Aprendizado de Máquinas.

As técnicas de AM têm grande importância no diagnóstico de falhas. Diante disso, é importante entender o embasamento teórico das técnicas utilizadas, para compreender seu potencial de aplicação aos estudos em curso.

Para a tarefa de detecção e identificação de falha, foram empregados algoritmos Supervisionados de Classificação, uma vez que se trata de variáveis categóricas (neste caso, falha ou não falha), enquanto que para o estudo de utilização de menor quantidade de acelerômetros foi empregada a técnica de Redução de Dimensionalidade, com a redução do número de variáveis de um BD, de modo a considerar apenas aquelas que tenham a maior relevância, eliminando aquelas que pouco ou nada contribuam na capacidade de classificação.

4.1 Algoritmos de Classificação

Os três algoritmos de classificação utilizados para detecção e identificação de falha de perda de ignição estão descritos neste item. Ao final, é apresentando um sumário

dos métodos utilizados, onde são elencadas as vantagens e desvantagens de cada um deles.

4.1.1 *K-Nearest Neighbors (K-NN)*

K-NN é um método de aprendizagem baseado em instâncias que foi desenvolvido para permitir a análise de características em casos onde era difícil estabelecer aproximações paramétricas de densidades de probabilidade [32]. É um dos métodos mais simples e eficazes para a classificação de padrões [33]. O *K-NN* pode ser usado tanto como um classificador quanto como um método de regressão, embora seja comumente utilizado com um algoritmo de classificação.

No método *K-NN* podem ser utilizadas diversas métricas de distância para procurar as k amostras próximas a uma determinada amostra não rotulada [34]. Entre estas métricas estão aquelas referentes às categorias de distância do tipo *Minkovsky* ou L_p [33], cujas respectivas equações descritas na Tabela 4.1, onde a e z são as coordenadas de dois pontos diferentes na dimensão i do espaço euclidiano, r é um valor positivo e n é um número positivo que representa a magnitude total do espaço euclidiano.

Tabela 4.1 Equações referentes às Métricas de Distância do tipo *Minkovsky* ou L_p

Nome da Métrica de Distância	Equação
Minkowski	$MD(a, z) = \sqrt[r]{\sum_{i=1}^n a_i - z_i ^r}$
Euclideana	$ED(a, z) = \sqrt{\sum_{i=1}^n a_i - z_i ^2}$
City Block	$CB(a, z) = \sum_{i=1}^n a_i - z_i $
Chebyshev	$CD(a, z) = \max_i a_i - z_i $

O rótulo majoritário das k amostras será atribuído à amostra não rotulada, conforme ilustrado na Figura 4.2. A distância e a similaridade entre os exemplos testados e treinados são dois parâmetros que possuem um papel importante nos algoritmos *K-NN*, com bastante impacto no desempenho de classificação do mesmo [35].

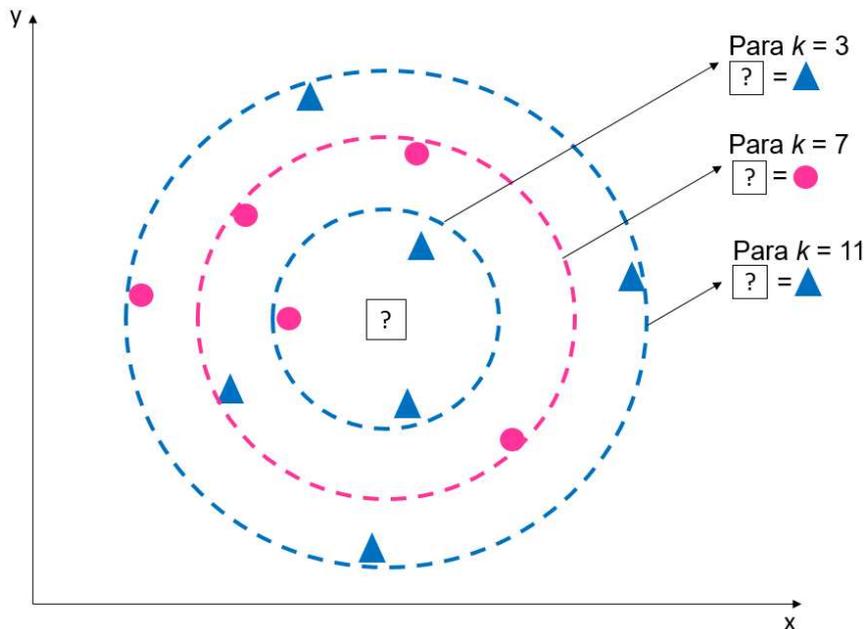


Figura 4.2. Esquema do algoritmo K -NN para classificação (adaptado de [34]).

A escolha da quantidade de k -vizinhos define a aproximação usada para determinar a classe da amostra não rotulada. Para vizinhanças pequenas, a predição é local e o K -NN tende a se sobreajustar. Porém, para k maiores, o algoritmo tende a generalizar, e padrões das pequenas aglomerações são ignorados [35].

4.1.2 *Support Vector Machine (SVM)*

SVM é um modelo de aprendizado supervisionado usado para classificação e regressão. A ideia principal dos SVMs está nos limites que separam duas ou mais classes em um espaço dimensional que varia de acordo com a quantidade de características utilizadas. Por exemplo, se um determinado BD é composto por duas características, a sua representação gráfica será bidimensional, e as amostras estarão limitadas a este espaço. Neste caso, uma linha reta será utilizada para separar as amostras nas classes desejadas. De modo análogo, se um BD possui três características, a sua representação será tridimensional, e um plano será utilizado para discriminar as amostras de acordo com as classes de interesse [36]. Tanto a linha reta quanto o plano se comportam como limites que separam as classes. Estes limites são chamados de hiperplanos, e a sua dimensão irá variar conforme de acordo com a quantidade de características do BD.

O melhor hiperplano é aquele que é capaz de separar as classes com uma distância máxima, a qual é conhecida como Margem Classificadora Máxima ou *Hard Margin SVM* [37], sendo definida pela Eq. (4.1) [38]:

$$D(x) = \mathbf{w} \cdot \mathbf{x}_i + b, \quad i = 1, \dots, m. \quad (4.1)$$

onde \mathbf{w} é o vetor perpendicular ao hiperplano, \mathbf{x} é o vetor da amostra i , b é o viés e m é o número total de amostras. Ao alterar b , é feito o deslocamento paralelo do hiperplano.

Neste algoritmo, as classes são separadas em zonas, cujos limites são definidos pelas amostras mais próximas da Margem Classificadora Máxima. Esses pontos são chamados de vetores de suporte e definem os hiperplanos limítrofes (Figura 4.3). A distância entre eles pode ser assumida de acordo com a Eq. (4.2):

$$D_m = \frac{2}{\|\mathbf{w}\|} \quad (4.2)$$

Para maximizar D_m , ou seja, a distância entre esses limites, $\|\mathbf{w}\|$ deve ser minimizado. O esquema de classificação SVM, considerando duas classes, é representado na Figura 4.3.

Porém, na prática, os dados adquiridos dos experimentos contêm ruído, o que impossibilita a separação linear entre as classes. Por isso, a hipótese da margem máxima não pode ser aplicada [37]. Para mitigar esse problema, o algoritmo desenvolvido por [39] considerou a possibilidade de aliviar as condições de contorno na Eq. (4.1) para situações em que era necessário, permitindo assim a classificação errada de algumas amostras nos dados de treinamento [37]. Assim, os hiperplanos de contorno podem ser definidos pela Eq. (4.3):

$$y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0 \quad (4.3)$$

onde ξ é a variável que introduz uma folga positiva que mede o quão distante uma amostra está de sua classe original.

O hiperplano separador ótimo pode ser obtido pela minimização da Eq. (4.4):

$$\min \left[\frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i \right] \quad (4.4)$$

onde C é o Termo de Regularização que trata do equilíbrio entre a maximização da margem e a minimização do erro de treinamento [40].

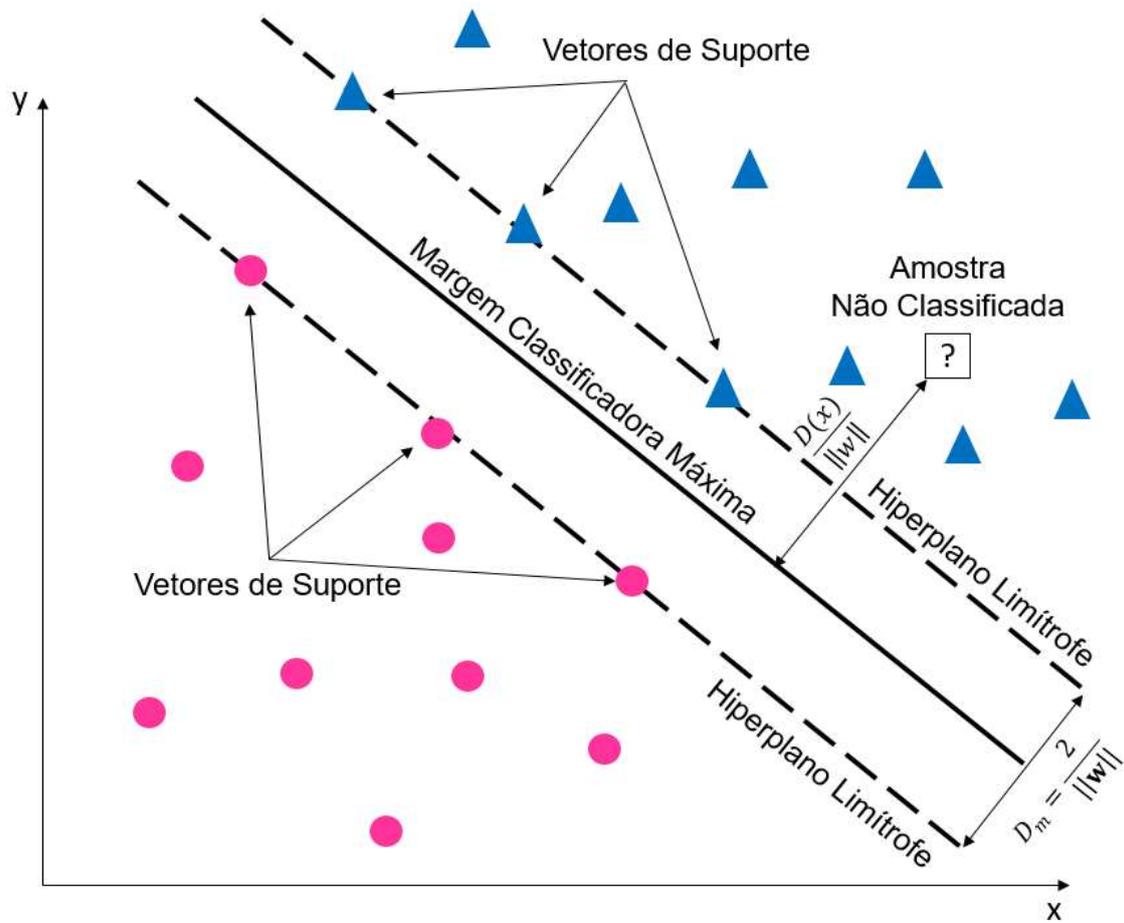


Figura 4.3. Esquema de classificação do SVM, considerando duas classes (adaptado de [39]).

Para dados que não podem ser separados linearmente, é adotado o truque de *kernel* [36], o qual consiste em aumentar a dimensão do espaço de características para torná-lo separável em um espaço de dimensão superior (Figura 4.4). Entre as principais funções de *kernel* estão as dos tipos: lineares, polinomiais e gaussianas, conforme Tabela 4.2 [42].

Tabela 4.2 Funções de *kernel*

Forma Funcional de <i>kernel</i>	Equação
Linear	$K(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i * \mathbf{x}_j$
Polinomial	$K(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(\frac{\ \mathbf{x}_i - \mathbf{x}_j\ ^2}{2\sigma^2}\right)$
Gaussiana	$K(\mathbf{x}_i, \mathbf{x}_j) = (1 + \mathbf{x}_i * \mathbf{x}_j)^p$

onde K é a função *kernel*, \mathbf{x} é o vetor de características e σ define a largura do kernel.

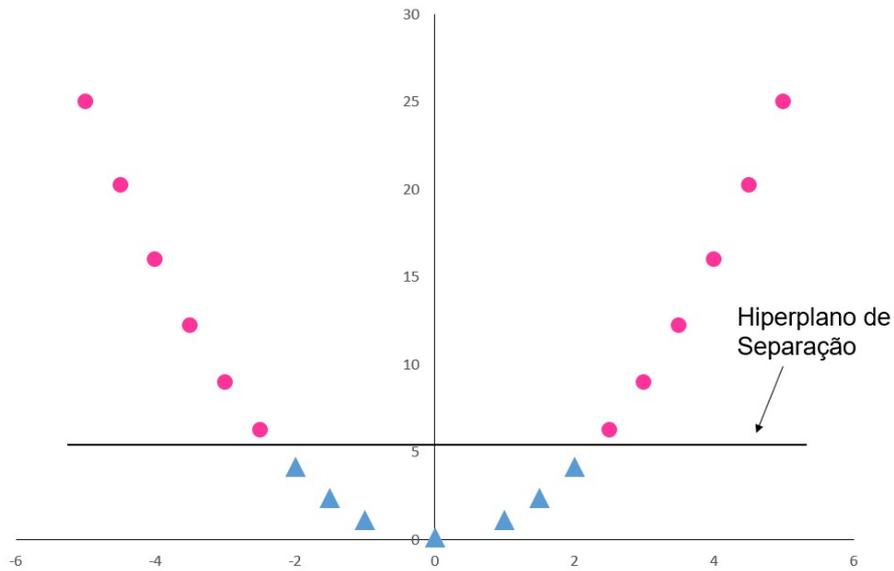


Figura 4.4. Representação do truque de *kernel* em 2 dimensões (adaptado de [36])

4.1.3 Random Forest

Random Forest é um algoritmo de aprendizado em comitê que utiliza várias árvores de decisão e é utilizado para tarefas de regressão e classificação [41] [43]. A predição de resposta de cada árvore representa um voto (Figura 4.5). Em seguida, é criado um comitê de árvores, através do algoritmo de Bagging [44], que consiste em gerar vários subconjuntos de observações, com reposição no conjunto de treinamento, permitindo a criação de modelos independentes, com a escolha de diferentes atributos para criar diferentes nós de árvore. A organização em forma de comitê do RF reduz o viés gerado pelo uso de apenas uma árvore de decisão.

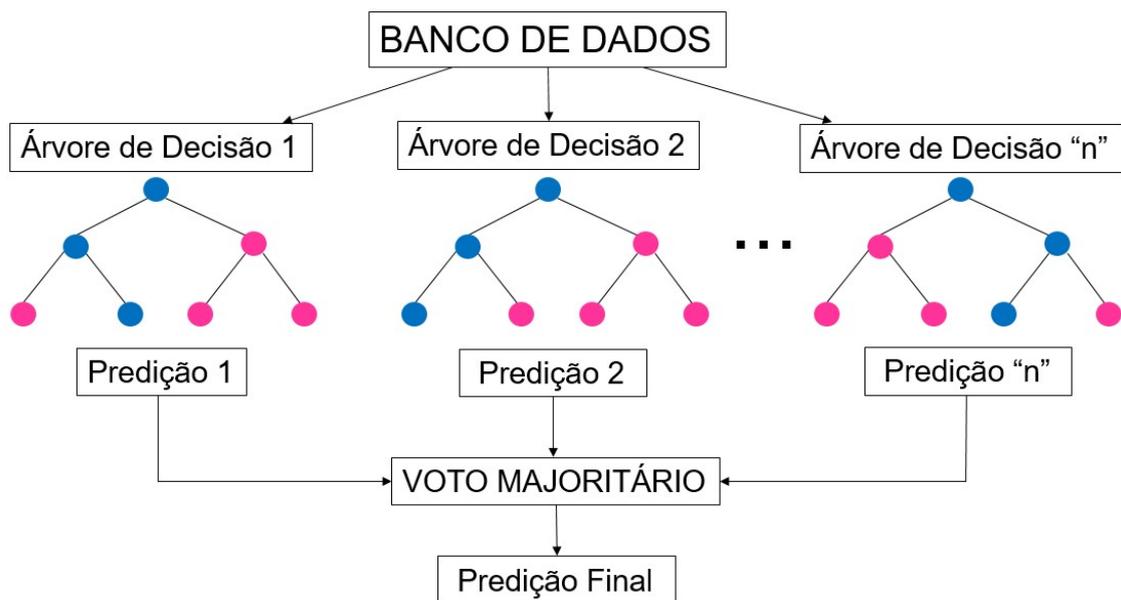


Figura 4.5 Estrutura geral de um algoritmo de RF (adaptado de [45])

4.1.4 Sumário dos Métodos de Aprendizado de Máquinas

Com base no que foi apresentado nos Itens 4.1.1 a 4.1.3, foi feito um sumário dos métodos de AM, sendo apresentadas, da Tabela 4.3 à Tabela 4.5, as vantagens e desvantagens destes algoritmos empregados neste trabalho.

Apesar de ser um método com desempenho lento, o K -NN foi adotado para uma primeira abordagem, uma vez que possui uma implementação simples, com poucos hiperparâmetros a serem otimizados. A adoção do SVM foi motivada por sua capacidade de resolver sistemas não lineares, sendo eficaz em espaços dimensionais elevados e não tendo tendência ao sobreajuste. A RF foi utilizada devido à sua capacidade de lidar com parâmetros não lineares, bem como de reduzir o sobreajuste. Os três classificadores mencionados têm a vantagem de serem robustos a ruído.

Tabela 4.3 Vantagens e desvantagens do método *K*-NN

Método	Vantagens	Desvantagens
<i>K</i> -NN	<p>Robustez à ruídos [46];</p> <p>Fácil de Implementar [46];</p> <p>Poucos hiperparâmetros a serem otimizados [46];</p>	<p>Se houverem muitas amostras no conjunto de dados, pode apresentar lentidão [46];</p> <p>Não faz a generalização do conjunto de dados de treinamento [32].</p>

Tabela 4.4 Vantagens e desvantagens do método SVM

Método	Vantagens	Desvantagens
SVM	<p>Eficácia em espaços com altas dimensões [47];</p> <p>Eficácia quando o número de características é maior que o número de amostras [47];</p> <p>É versátil, uma vez que diferentes funções <i>kernel</i> podem ser utilizadas [47];</p> <p>Capacidade de resolver sistemas não lineares e desconhecidos [40];</p> <p>Robustez à ruídos e sem sobreajuste [40].</p>	<p>Uma vez que o SVM é um método essencialmente voltado para a classificação binária, pode não ser ideal para problemas multiclasse. Entretanto, para esses casos, podem ser utilizadas as classificações pareadas [40];</p> <p>Nos casos em que o número de características é muito maior que o de amostras, a escolha das funções <i>kernel</i> e o termo de regularização é crucial [47].</p>

Tabela 4.5 Vantagens e desvantagens do método *Random Forest*

Método	Vantagens	Desvantagens
<i>Random Forest</i>	Não são sensíveis ao escalonamento dos valores dos atributos [48];	
	Ambos os sinais discretos e contínuos são igualmente bem processados [48];	
	Possuem métodos para construção de árvores que podem ser utilizados em BD com valores de atributos faltantes [48];	Tamanho grande dos modelos resultantes [48];
	Possuem métodos para verificação da relevância individual das características em um modelo [48];	O tempo de classificação aumenta para conjuntos de dados de entrada maiores [46].
	Habilidade de processar dados com uma grande quantidade de características e classes de forma eficiente [48];	
	Robustez à ruídos [43];	

4.2 Método de Extração de Características

Para este trabalho, a extração de características foi feita no domínio do tempo, por meio de fórmulas estatísticas aplicadas sobre um vetor de amostras, conforme demonstrado na Tabela 4.6.

Tabela 4.6 Características extraídas no domínio do tempo (baseado em [49])

Característica	Definição	Característica	Definição
1.Média	$MÉDIA = \frac{1}{N} \sum_{i=1}^N x_i$	10.Assimetria	$ASM = \frac{1}{N} \sum_{i=1}^N \left(\frac{(x_i - MÉDIA)}{DPD} \right)^3$
2.Variância	$VAR = \frac{1}{N} \sum_{i=1}^N (x_i - MÉDIA)^2$	11.Mediana	$MEDIANA = mediana(x_i)$
3.RMS	$RMS = \sqrt{\frac{1}{N} \left[\sum_{i=1}^N (x_i)^2 \right]}$	12.Soma	$SOMA = \sum_{i=1}^N x_i$
4.Desvio Padrão	$DPD = \sqrt{VAR}$	13.Entropia	$ENTROPIA = - \sum_{i=1}^N p(c_i) \log_2 p(c_i)$
5.Curtose	$CUR = \frac{1}{N} \sum_{i=1}^N \left(\frac{(x_i - MEAN)}{DPD} \right)^4 - 3$	14.Energia	$ENERGIA = \sum_{i=1}^N x_i ^2$
6.Erro Padrão	$EPD = \frac{DPD}{\sqrt{N}}$	15.Fator de Crista	$FC = \frac{max}{RMS}$
7.Valor Mínimo	$MIN = \min\{x_i\}$	16.Clearence Factor	$CF = \frac{max}{\frac{1}{N} \sum_{i=1}^N (x_i)^2}$
8.Pico	$PICO = \max(abs\{x_i\})$	17.Fator de Forma	$FF = \frac{RMS}{\frac{1}{N} \sum_{i=1}^N x_i }$
9.Pico-a-Pico	$PAP = \max\{x_i\} - \min\{x_i\}$	18.Fator de Impulso	$FI = \frac{max}{\frac{1}{N} \sum_{i=1}^N x_i }$

onde x_i é o valor referente a cada amostra i do vetor de amostras, no domínio do tempo; N é o comprimento do vetor de amostras; e $p(c_i)$ é a probabilidade de x_i ser equivalente aos valores possíveis da sequência c_i [49].

Ao aplicar a fórmula estatística sobre o vetor de amostras, o resultado vai gerar uma instância, de modo que uma característica será gerada a cada fórmula aplicada. Logo, se forem aplicadas 18 fórmulas estatísticas, serão extraídas 18 características para cada vetor de amostras.

4.3 Técnica de Aumento de Dados

Quando um BD possui uma quantidade baixa de instâncias, pode ser observada uma alta dimensionalidade do conjunto de dados após a extração de características. Essa situação ocorre quando o número de características é muito maior que o número de instâncias, podendo trazer alguns problemas como alta variância e sobreajuste [50].

Para mitigar esse problema, são empregadas técnicas de aumento de dados [49]. Para este trabalho, foi considerada a técnica de partição dos sinais, que consiste em dividir um BD original em subconjuntos com menor quantidade de amostras [51], aumentando a quantidade de instâncias do BD, conforme Eq. (4.5):

$$f_v = n_c * n_p * n_s \quad (4.5)$$

onde f_v é a quantidade de instâncias, n_c é o número de classes; n_p é o número de partições e n_s é a quantidade de cenários de medição para os quais foram obtidos os BD.

4.4 Redução de Dimensionalidade

Existem algumas razões para a redução da dimensionalidade, como a redução na quantidade de informações a serem armazenadas para alcançar desempenhos mais eficientes [52], a remoção de características irrelevantes e redundantes [53] e o aumento da velocidade de treinamento e predição do algoritmo [54].

Para este estudo, foi considerado o método *Relief-F*, uma vez que são capazes de estimar corretamente a qualidade dos atributos em problemas com forte dependência entre os mesmos, além de serem robustos e tolerantes a ruídos [55].

4.4.1 *Relief-F*

O método baseado em filtro *Relief-F* é uma extensão do algoritmo *Relief* original [56]. A versão original escolhe aleatoriamente uma amostra do BD e depois localiza o vizinho mais próximo da mesma classe e de diferentes classes. Em seguida, o algoritmo compara os valores da instância amostrada com os atributos do vizinho mais próximo, atribuindo pesos de importância de modo que o atributo mais bem pontuado seja capaz de distinguir melhor as instâncias de diferentes classes.

A vantagem do *Relief-F*, em relação à versão original, é a capacidade de lidar com problemas multiclasse, maior robustez e capacidade de lidar com dados ruidosos e incompletos [56]. Além disso, esta técnica tem um viés baixo, permite interações entre características e pode detectar dependências locais que outros métodos não conseguem [57].

O fluxograma do algoritmo *Relief-F* está demonstrado na Figura 4.6 [55], onde k_{prox} é o vizinho mais próximo, k é a quantidade de vizinhos mais próximos, A é a matriz que representa os valores dos atributos, v é o vetor peso, i é o índice das instâncias, j é o índice das características, q é a quantidade de instâncias e h é a quantidade de características.

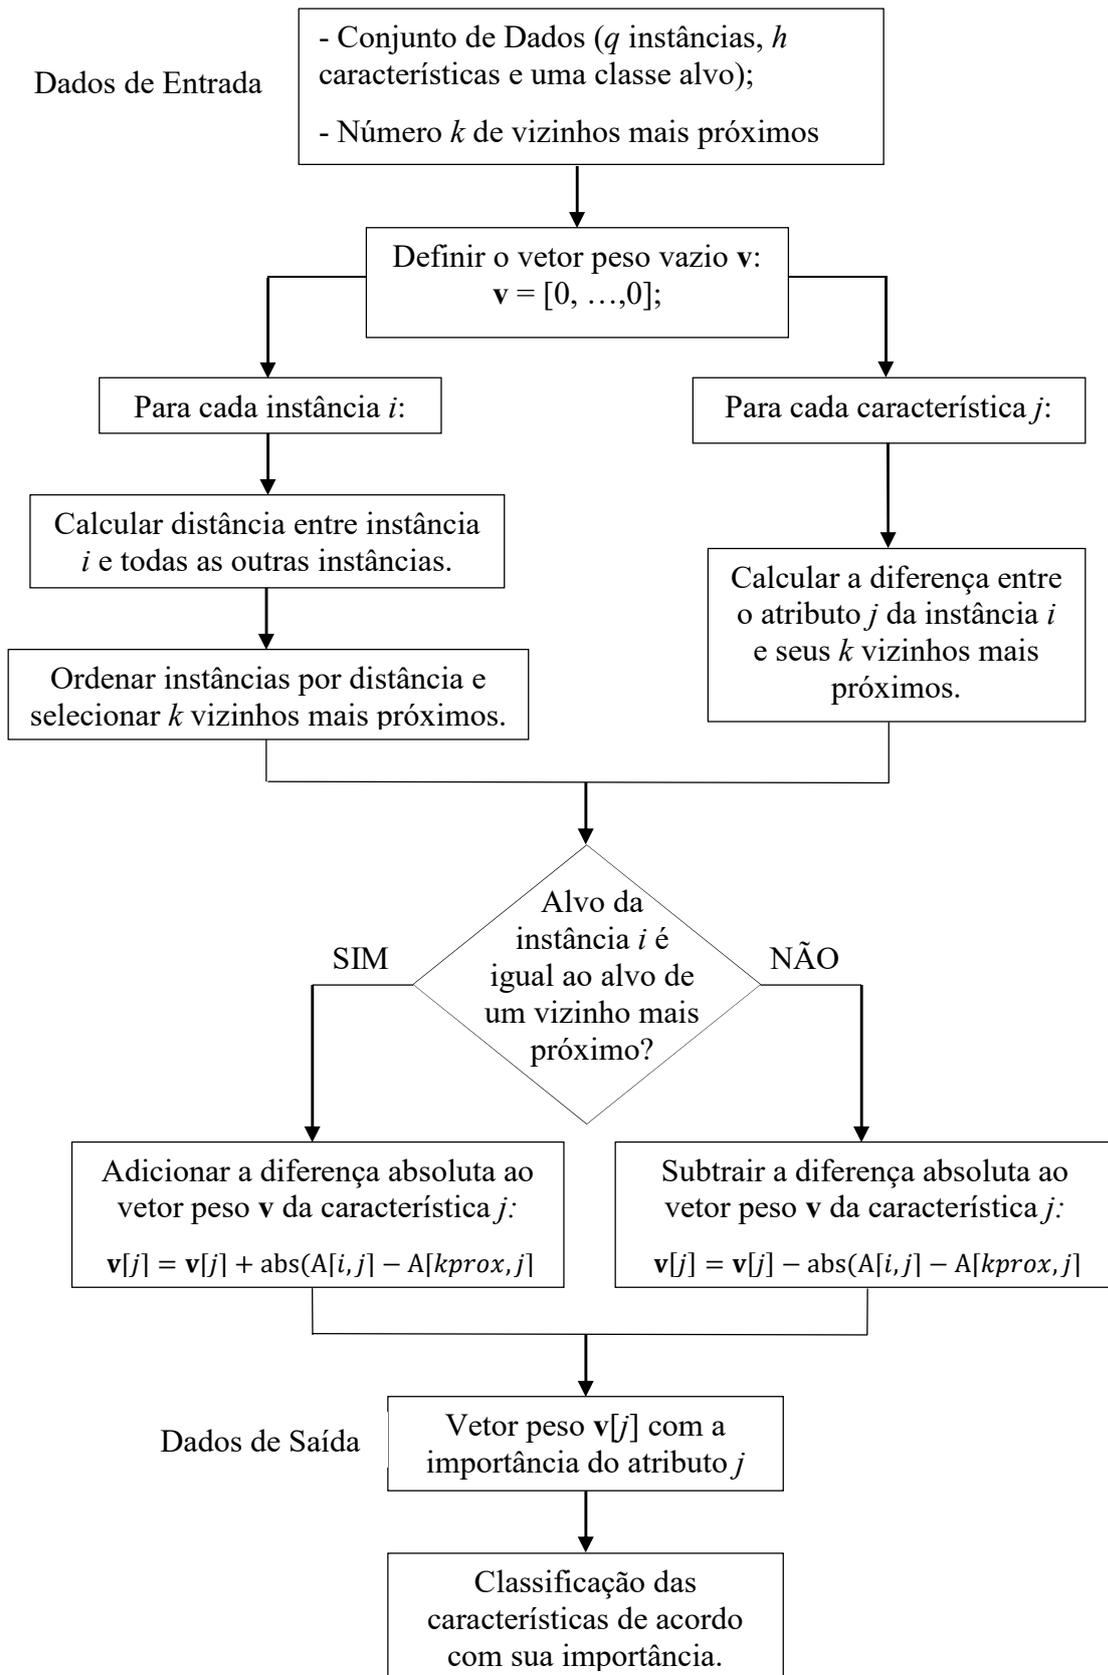


Figura 4.6 Fluxograma do algoritmo *Relief-F*.

4.5 Método de Normalização de Características

Para este trabalho foi utilizada a técnica Min-Max, uma vez que é um método de normalização de características recomendado para dados sem *outliers* [58], tendo sido empregada após o processo de remoção dos *outliers*. Esta técnica consiste em escalonar os valores de uma característica para uma faixa entre um valor mínimo de 0 e um valor máximo de 1. Todos os demais valores das características são escalados proporcionalmente a esta faixa. A equação para o método de escala Min-Max é definida na Eq. (4.6)

$$x_{fs} = \frac{(x_o - x_{min})}{(x_{max} - x_{min})} \quad (4.6)$$

onde x_{fs} é o valor escalonado da característica, x_o é o valor original da característica; x_{min} é o valor mínimo da característica e x_{max} é o valor máximo da característica.

5 METODOLOGIA

O roteiro da metodologia é ilustrado na Figura 5.1. Primeiramente, foi realizado um teste de bancada do motor para a coleta de sinais a serem utilizados como dados de entrada. Em seguida, esses dados adquiridos foram pré-processados, com os sinais sendo organizados em diferentes grupos. Depois disso, o BD foi dividido em conjuntos de dados de treinamento e teste. As características foram extraídas no domínio do tempo e os *outliers* foram removidos. Em seguida, foi feita a seleção das características e, para finalizar a etapa de pré-processamento, os dados foram normalizados por meio do escalonamento de características (exceto para *Random Forest*, conforme descrito na Tabela 4.5).

Após a etapa de pré-processamento, os dados foram preparados para serem processados por algoritmos de AM. Foi feita a validação cruzada, onde parte do conjunto de dados de treinamento foi separado em k -folds para avaliar o desempenho do algoritmo de AM. Depois que o modelo mostrou desempenho satisfatório, o mesmo foi usado no conjunto de dados de teste para detecção e identificação de falha de ignição.

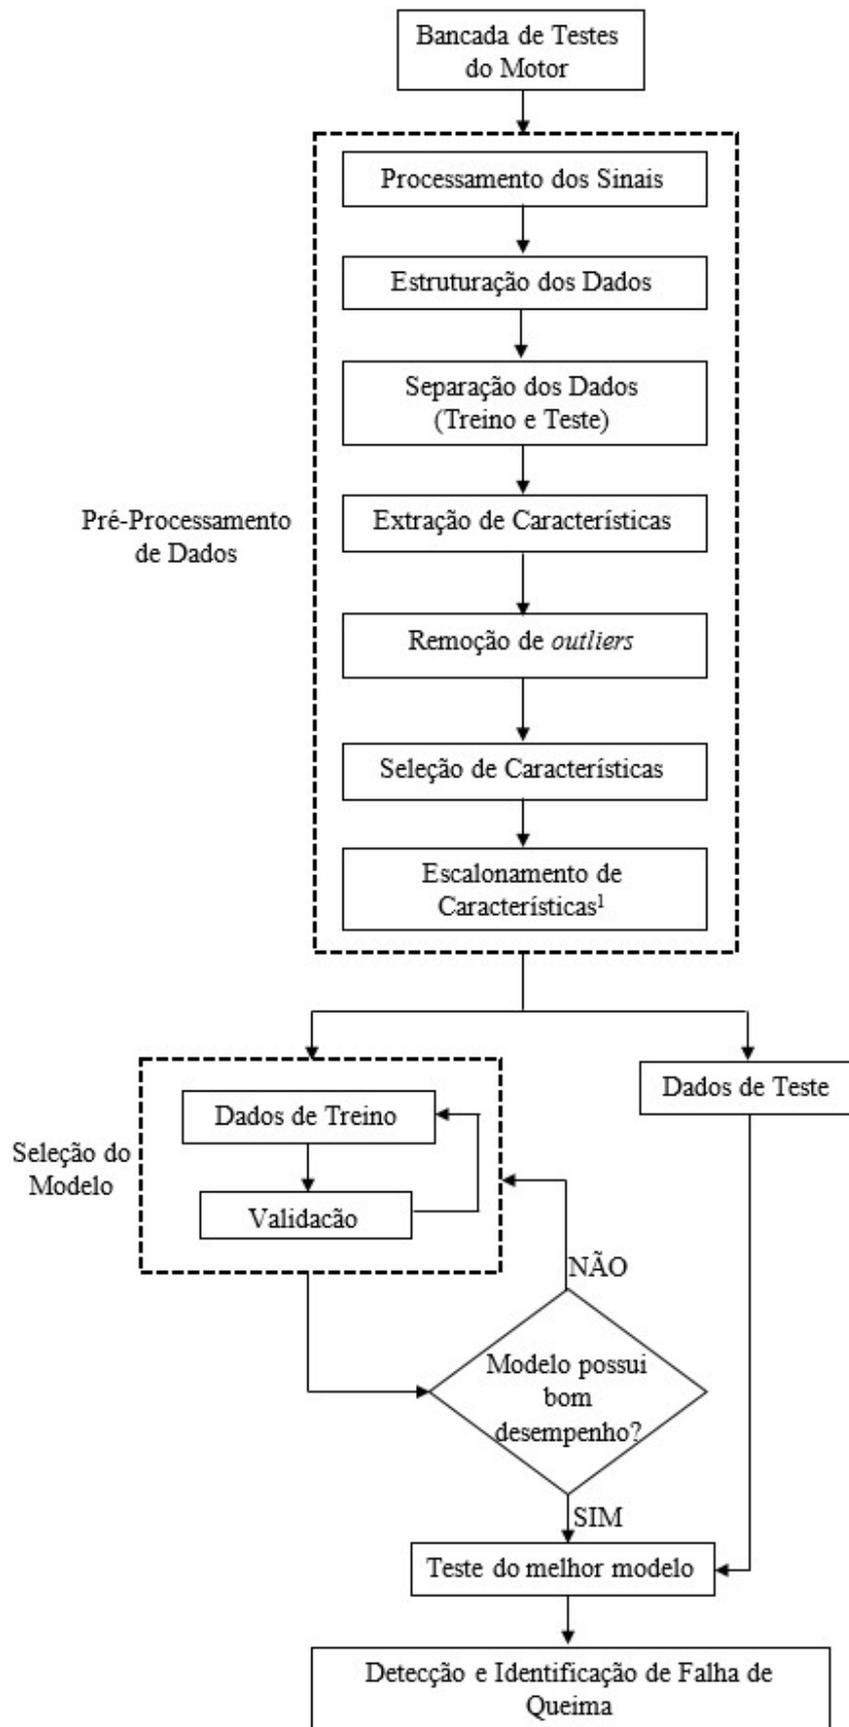


Figura 5.1 Fluxograma da metodologia proposta para detecção e identificação de falhas de ignição.

5.1 Condições de Contorno do Experimento

Para a realização do experimento, foram adotadas as seguintes condições de contorno:

- Falha de perda de ignição em apenas um cilindro por vez (*Single Misfires*);
- Falha induzida por meio do corte da injeção de combustível, o que significa a não existência de queima na câmara de combustão. A definição desta condição de contorno reduz o número de possíveis causas para falha de perda de ignição (como por exemplo: injetores completamente entupidos).

O experimento foi conduzido pela equipe técnica do LEDAV (Laboratório de Ensaios Dinâmicos e Análise de Vibração).

5.2 Aquisição dos Sinais

O procedimento experimental foi realizado em um Motor Diesel MTU 12V4000 [59], cujas especificações estão apresentadas na Tabela 5.1.

Tabela 5.1 Especificações do Motor MTU12V4000

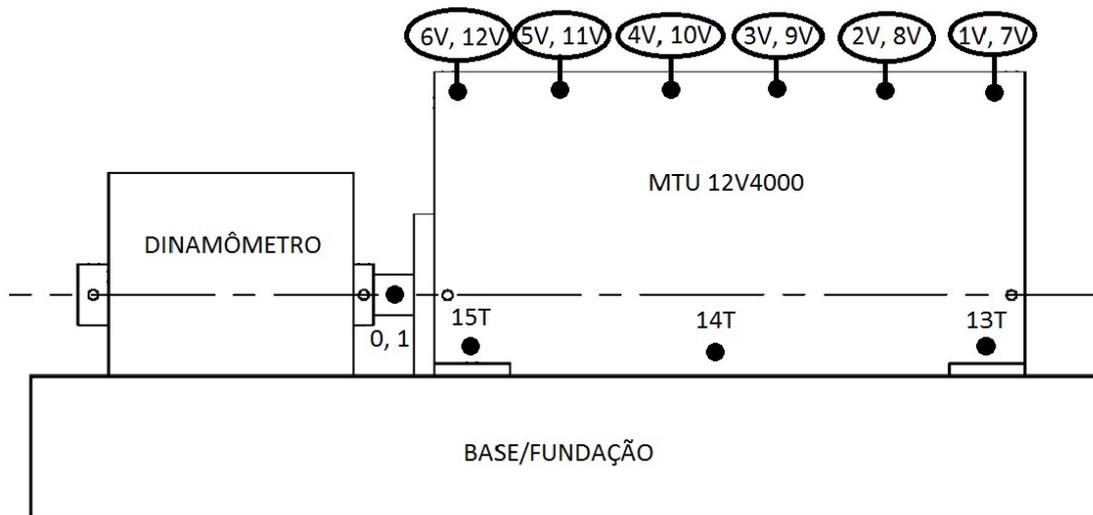
Fabricante / Série	MTU/12V4000
Tipo	T1237k11
Nº de Cilindros / Nº de Tempos	12 cilindros em V / 4 tempos
Combustível	Diesel
Ordem de Queima	A1-B2-A5-B4-A3-B1-A6-B5-A2-B3-A4-B6
Potência Nominal	1193 kW
Rotação Nominal	1900 RPM
Torque Máximo	7595 N*m
Comprimento do curso	190 mm
Diâmetro interno do cilindro	165 mm

Para o teste de bancada, foram instalados no bloco do motor 15 acelerômetros piezoelétricos para obter os sinais de vibração, com cada acelerômetro sendo instalado no cabeçote de cada um dos 12 cilindros do motor (Figura 5.2), e os três acelerômetros restantes sendo instalados na base do motor, conforme a representação esquemática na Figura 5.3.

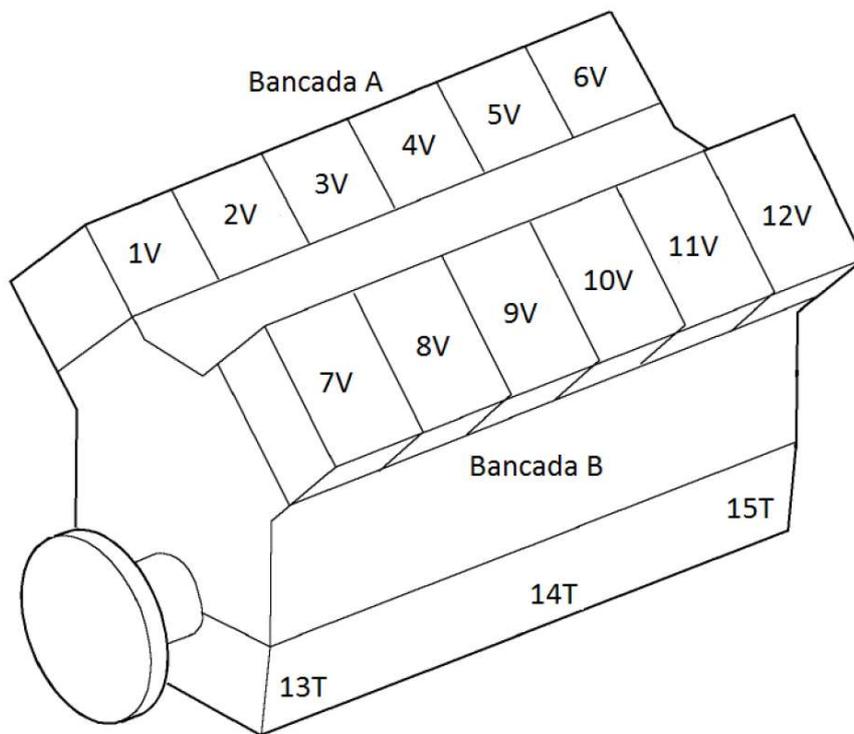


Figura 5.2 Indicação de instalação de seis acelerômetros em um dos bordos do bloco do Motor Diesel MTU/12V4000

Os sinais foram extraídos considerando 13 condições operacionais diferentes: operação normal e operação com falha de ignição induzida em de cada um dos 12 cilindros, um por vez. O sinal obtido passou por um conversor analógico-digital e foi armazenado como um conjunto de dados, e a frequência de aquisição das amostras foi de 10240 Hz. Esta taxa foi escolhida de modo a garantir o maior número de amostras possível.



(a)



(b)

Figura 5.3. Indicação do posicionamento dos 15 acelerômetros no Motor Diesel MTU/12V4000: (a) vista lateral e (b) vista isométrica.

5.3 Processamento dos Sinais

Para remoção de ruído, foi utilizado o filtro tipo passa-faixa. De acordo com a norma [60], geralmente as principais frequências de excitação de máquinas alternativas estão na faixa de 2 Hz a 1000 Hz. Além disso, foi aplicada uma função de remoção de tendências lineares nos sinais obtidos, para todos os conjuntos de dados. A análise dos sinais de vibração foi realizada no domínio do tempo.

5.4 Estruturação dos Dados

As medições foram feitas considerando diferentes valores de torque na mesma rotação. A variação de torque foi feita através da injeção de maior quantidade de combustível. Esses dados foram agrupados em diferentes cenários operacionais, conforme Tabela 5.2.

Tabela 5.2 Cenários de Operação considerados na Aquisição de Dados

Cenário	Rotação (RPM)	Torque (N*m)	Potência (kW)
Nº1	1500	850	127,5
Nº2	1500	2040	306
Nº3	1500	3272	409

5.5 Separação dos Dados

Antes de ser feita a extração das características, o conjunto de dados foi dividido em duas partes: 80% dos dados foram destinados ao treinamento do algoritmo de AM e os 20% restantes foram destinados ao teste [61]. Conforme mencionado, as medições foram feitas para uma condição normal e 12 condições de falha de ignição, em três diferentes cenários de operação, resultando em um conjunto de dados com 13 classes, com cada uma delas possuindo três instâncias associadas.

Em seguida, foi realizado o aumento do BD por meio do método da partição de sinais. Uma vez que foi adquirida uma grande quantidade de amostras nas medições, foi possível realizar várias subdivisões nos vetores de amostras, sem perder informações importantes. Assim, o conjunto de dados de treinamento, bem como o conjunto de dados de teste, foram particionados.

Para o conjunto de dados de treinamento, foram feitas várias partições diferentes, conforme descrito na Tabela 5.3, com o objetivo de buscar a subdivisão ótima, ou seja, a que possibilita os melhores resultados de classificação após a aplicação dos algoritmos de AM. Para o conjunto de dados de teste, foi considerada uma divisão de 20 partes, a fim de manter uma proporção inferior a 30% em relação ao conjunto de dados de treinamento.

Tabela 5.3 Particionamento de Sinais dos Dados de Treino

Nº de Partições	Nº de Instâncias
80	3120
90	3510
100	3900
110	4290
120	4680

5.6 Extração de Características

Dezoito características foram extraídas no domínio do tempo, a partir dos dados coletados. Foi extraída uma quantidade relativamente grande de características com o objetivo de se ter uma avaliação inicial do desempenho dos algoritmos quanto à capacidade de classificação, sob essa configuração, antes de serem aplicadas as técnicas de seleção de características, onde foram consideradas aquelas com maior relevância para a tarefa de classificação. As características extraídas estão descritas na Tabela 4.6.

Para este trabalho, as características extraídas foram associadas a cada um dos acelerômetros. Por exemplo, se um determinado estudo considera o uso de cinco características, então as mesmas são multiplicados pelo número de sensores, que neste caso é 15. Ou seja, $5 \times 15 = 75$.

5.7 Remoção de *Outliers*

Os *outliers* foram identificados pelo método do Intervalo Interquartil (IQR). Em seguida, foram substituídos pelo método de Winsorização [62], que substitui os valores extremos (localizados além dos limites superior e inferior) pelo limite correspondente (Figura 5.4). Ou seja, se for um valor extremamente baixo, será substituído pelo limite inferior, e se for um valor extremamente superior, será substituído pelo limite superior.

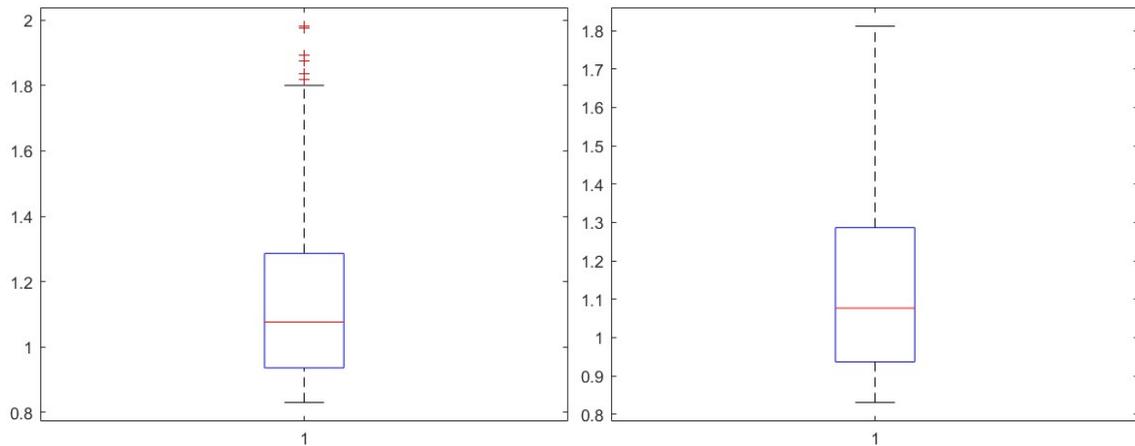


Figura 5.4. Exemplo de aplicação do método de Winsorização para definição do limite superior, com escala genérica em representação *boxplot*.

5.8 Seleção de Características

Depois de extrair as características, o passo seguinte foi analisar quais as mais relevantes para as classificações. Este procedimento foi muito útil principalmente para o segundo objetivo deste trabalho, uma vez que foi implementado para reduzir a dimensionalidade do conjunto de dados, permitindo um bom desempenho de classificação com menos informações, exigindo assim menor tempo para realização desta tarefa.

5.9 Escalonamento de Características

Esta técnica foi considerada apenas para os métodos de classificação K -NN e SVM, que são sensíveis ao escalonamento. Já para o método de comitê RF, a referida técnica não foi considerada, uma vez que este método de classificação é robusto ao uso de características não escalonadas [63].

6 RESULTADOS E DISCUSSÕES

Este capítulo é destinado a mostrar os resultados e discussões acerca da capacidade da metodologia empregada em cumprir os dois principais objetivos deste estudo:

- Detectar e identificar falhas de ignição em um Motor de Combustão Interna 12V4000;
- Estudar a utilização de menor número de acelerômetros que mantenham um bom desempenho de diagnóstico de falhas, através de técnicas de redução de dimensionalidade.

6.1 Detecção e Identificação de Falhas de Ignição

Para detecção e identificação de falhas de ignição, os três métodos de AM mencionados (K -NN, SVM e RF) foram empregados para predizer as classes (normal ou falha de ignição em cada um dos 12 cilindros). Observou-se o desempenho de cinco diferentes partições do conjunto de dados para treinamento, conforme ilustrado na Tabela 5.3, com a utilização de 18 características.

Os hiperparâmetros utilizados em cada um dos três métodos de classificação estão descritos na Tabela 6.1. Para a validação cruzada, foi considerada a técnica k -fold estratificado, com $k=5$. Assim, do montante de 80% destinado ao treinamento, 20% foi reservado para validação, ao longo de 5 ciclos.

Antes de se iniciar a avaliação de desempenho da capacidade de diagnóstico de falhas dos algoritmos de classificação, é importante definir qual será a métrica utilizada para tal. As principais métricas utilizadas neste sentido estão descritas abaixo:

Acurácia: mede a proporção de instâncias classificadas corretamente em relação ao total, sendo a métrica mais básica e simples de avaliação de desempenho. Entretanto, pode ser enganosa quando há desequilíbrio entre as classes. A sua formulação é dada conforme a Eq. (6.1) abaixo:

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN} \quad (6.1)$$

onde VP são os verdadeiros positivos, VN os verdadeiros negativos, FP os falsos positivos e FN os falsos negativos.

Especificidade: mede a proporção de verdadeiros negativos em relação ao total de negativos reais, ou seja, mede a capacidade do modelo de identificar corretamente os casos que não pertencem à classe positiva. É calculada conforme a equação Eq. (6.2):

$$Especificidade = \frac{VN}{VN + FP} \quad (6.2)$$

Precisão: mede a quantidade de instâncias classificadas como positivas que de fato são positivas, ou seja, a quantidade de verdadeiros positivos com relação ao número de respostas totais positivas. É uma métrica importante quando o custo de uma classificação errada de uma classe é alto, como por exemplo, aferir que um motor está com defeito quando na verdade não tem. Sua formulação é dada pela Eq. (6.3) abaixo:

$$Precisão = \frac{VP}{VP + FP} \quad (6.3)$$

Sensibilidade: também conhecida como *recall* ou revocação, mede a proporção de instâncias positivas que foram corretamente identificadas como positivas, sendo uma métrica importante quando as consequências de um falso negativo são graves, como por exemplo, aferir que um motor está operando normalmente quando na verdade apresenta falhas. Sua formulação é dada pela Eq. (6.4) que se segue:

$$Sensibilidade = \frac{VP}{VP + FN} \quad (6.4)$$

F1-Score: é uma média harmônica entre a precisão e a sensibilidade. É uma métrica útil quando tanto a precisão quanto a sensibilidade são importantes. É dada pela Eq. (6.5):

$$F1\ Score = \frac{2 * Precisão * Sensibilidade}{Precisão + Sensibilidade} \quad (6.5)$$

A métrica considerada para avaliação da capacidade de classificação é o *F1-Score*, pois leva em consideração tanto a precisão quanto a sensibilidade, métricas que, para esta análise, são importantes.

Quanto ao requisito mínimo para que um desempenho de classificação seja considerado satisfatório, [64] considerou *F1-Score* mínimo de 90%. No entanto, visando alcançar um desempenho de classificação ainda melhor, este trabalho considerou que o *F1-Score* não pode ser menor que 95%

A Tabela 6.2 mostra o *F1-Score* de cada um dos três algoritmos de AM, bem como o tempo de predição para uma amostra, de modo a mensurar, de forma mais assertiva, o tempo de resposta do algoritmo para retornar uma predição. De acordo com esta tabela, K-NN, SVM e RF alcançaram um *F1-Score* de 99,87%, 100% e 99,87%, respectivamente, para uma configuração de conjunto de dados com 80 partições e 18 características. Isso significa que os métodos empregados possuem excelente capacidade de detecção e identificação de falhas de ignição.

Tabela 6.1 Hiperparâmetros utilizados em cada método de classificação empregado neste estudo

Método	Hiperparâmetros	
	Nº de Vizinhos:	De 1 a 10, com incremento de 1 em 1
K-NN	Métrica de Distância:	Euclideana
	Regularização de Hiperparâmetros:	<i>Grid Search</i>
	Termo de Regularização “C”:	De 2^{-5} a 2^{15} , com passos na quarta potência
SVM	Função <i>kernel</i> :	Gaussiana
	Ordem Polinomial da função <i>kernel</i> :	3
	Nº de Árvores	De 1 a 30, com incremento de 1 em 1
Random Forest	Técnica para Geração de Árvores	Índice de impureza de Gini
	Regularização de Hiperparâmetros:	<i>Grid Search</i>

Para o método K-NN, a métrica de distância utilizada foi a Distância Euclidiana (ED), uma vez que foi a que retornou os melhores resultados entre as demais métricas (demonstradas na Tabela 4.1) testadas. O número máximo de vizinhos foi estabelecido como sendo 10, uma vez que um eventual uso de maior número de vizinhos não retornou um desempenho que justificasse um maior tempo gasto com processamento

computacional, sem contar o risco de generalização de resposta de predição que o algoritmo pode retornar em virtude de uma quantidade maior de vizinhos utilizada. Por fim, foi considerada a Regularização de Hiperparâmetros por meio do Grid Search pois, embora seja um tipo de busca exaustiva, esta opção retorna garante que seja escolhido o melhor número de vizinhos

Já para o método SVM, foi utilizada a função *kernel* gaussiana com ordem polinomial 3, uma vez que esta configuração retornou os melhores resultados, se comparada com as demais funções utilizadas (conforme Tabela 4.2). A variação do termo de regularização C foi feita com ajustes exponenciais na quarta potência a fim de buscar, de forma mais rápida e otimizada, o melhor ajuste de margem de hiperplano.

Com relação aos hiperparâmetros utilizados no *Random Forest*, foi considerada uma quantidade máxima de 30 árvores pois, assim como foi observado no algoritmo K-NN quanto ao número máximo de vizinhos, uma maior quantidade de árvores não retornou um desempenho significativo que justificasse um maior esforço computacional. E para este mesmo caso, também foi realizada a busca exaustiva, a fim de garantir a melhor quantidade de árvores neste intervalo. A técnica utilizada para geração de árvores foi o índice de impureza de Gini, uma vez que este método foi mais eficiente, para o presente caso, se comparado com o critério da Entropia.

Para SVM, observou-se que o *F1-Score* foi de 100% para todas as partições analisadas. Embora esses ótimos resultados possam sugerir um possível sobreajuste, vale lembrar que este risco foi mitigado pelo aumento de dados (conforme descrito no item 5.5) e validação cruzada do conjunto de dados de treinamento. Além disso, trabalhos anteriores [24] também foram capazes de alcançar 100% de precisão para classificação considerando operação normal e falha de ignição total.

A utilização de 18 características, porém, implica em um extenso conjunto de dados, pois cada característica foi multiplicada pela quantidade de acelerômetros. Logo, foram utilizados 270 atributos nessas análises, resultando em um alto custo computacional. Para amenizar esse problema, a redução de dimensionalidade foi aplicada, possibilitando assim o uso de um menor número de atributos sem perder a capacidade de classificação, subsidiando a decisão de eliminar sensores menos essenciais, que é o segundo objetivo deste estudo.

Tabela 6.2 *F1-Score* para Banco de Dados com 18 Características

Nº de Partições	K-NN		SVM		RF	
	<i>F1-Score</i> (%)	Tempo (s)	<i>F1-Score</i> (%)	Tempo (s)	<i>F1-Score</i> (%)	Tempo (s)
80	99,87	0,0026915	100	0,000806	99,87	0,000388
90	99,74	0,0032461	100	0,000765	88,58	7,36E-05
100	99,87	0,0031457	100	0,000735	38,1	0,000106
110	99,74	0,0035323	100	0,001179	IND	-
120	100	0,0043258	100	0,00078	IND	-

Uma observação precisa ser feita para os casos onde foram observados, na Tabela 6.2 acima, resultados indefinidos (IND): isto acontece quando, durante o processo de classificação, não são observados verdadeiros positivos (VP) nem falsos negativos (FN), ou seja, ambos tem valor igual a zero. Quando isto acontece, a métrica Sensibilidade aponta para um valor indefinido. Com isso, o *F1-Score* também assume um valor indefinido. Neste caso, isto significa que o RF não desempenhou bem para algumas configurações de BD.

6.2 Estudo da Quantidade Mínima de Sensores

A principal ideia por trás do estudo da quantidade mínima de sensores, capazes de garantir uma capacidade de classificação acima da mínima requerida, envolve o ranqueamento das características [65]. As técnicas de seleção de características são baseadas em pontuações que são imputadas a cada atributo, de forma a mensurar a sua relevância. Deste modo, o *Relief-F* foi usado para hierarquizar as 18 características no domínio do tempo para todas as cinco partições do conjunto de dados de treinamento. Conforme ilustrado na Figura 6.1, para cada uma das cinco partições, foram observados diferentes ranqueamentos de características, o que significa que a importância das mesmas pode mudar à medida que a quantidade de instâncias varia.

Em seguida, foi estudada a influência do número de características na qualidade do desempenho de classificação. Em outras palavras, foi verificado se o uso de menor quantidade de atributos manteria a capacidade dos algoritmos de AM de fazer classificações corretas, exigindo menor esforço computacional.

Para tanto, foram feitas simulações com as nove e as cinco características melhor ranqueadas. Para efeitos de comparação com conjunto de dados onde não foi aplicada a redução de dimensionalidade, também foram feitas simulações para 18 características. Lembrando que cada uma das três simulações mencionadas considerou as cinco partições

do conjunto de dados de treinamento, resultando na análise de 15 configurações de BD ao total.

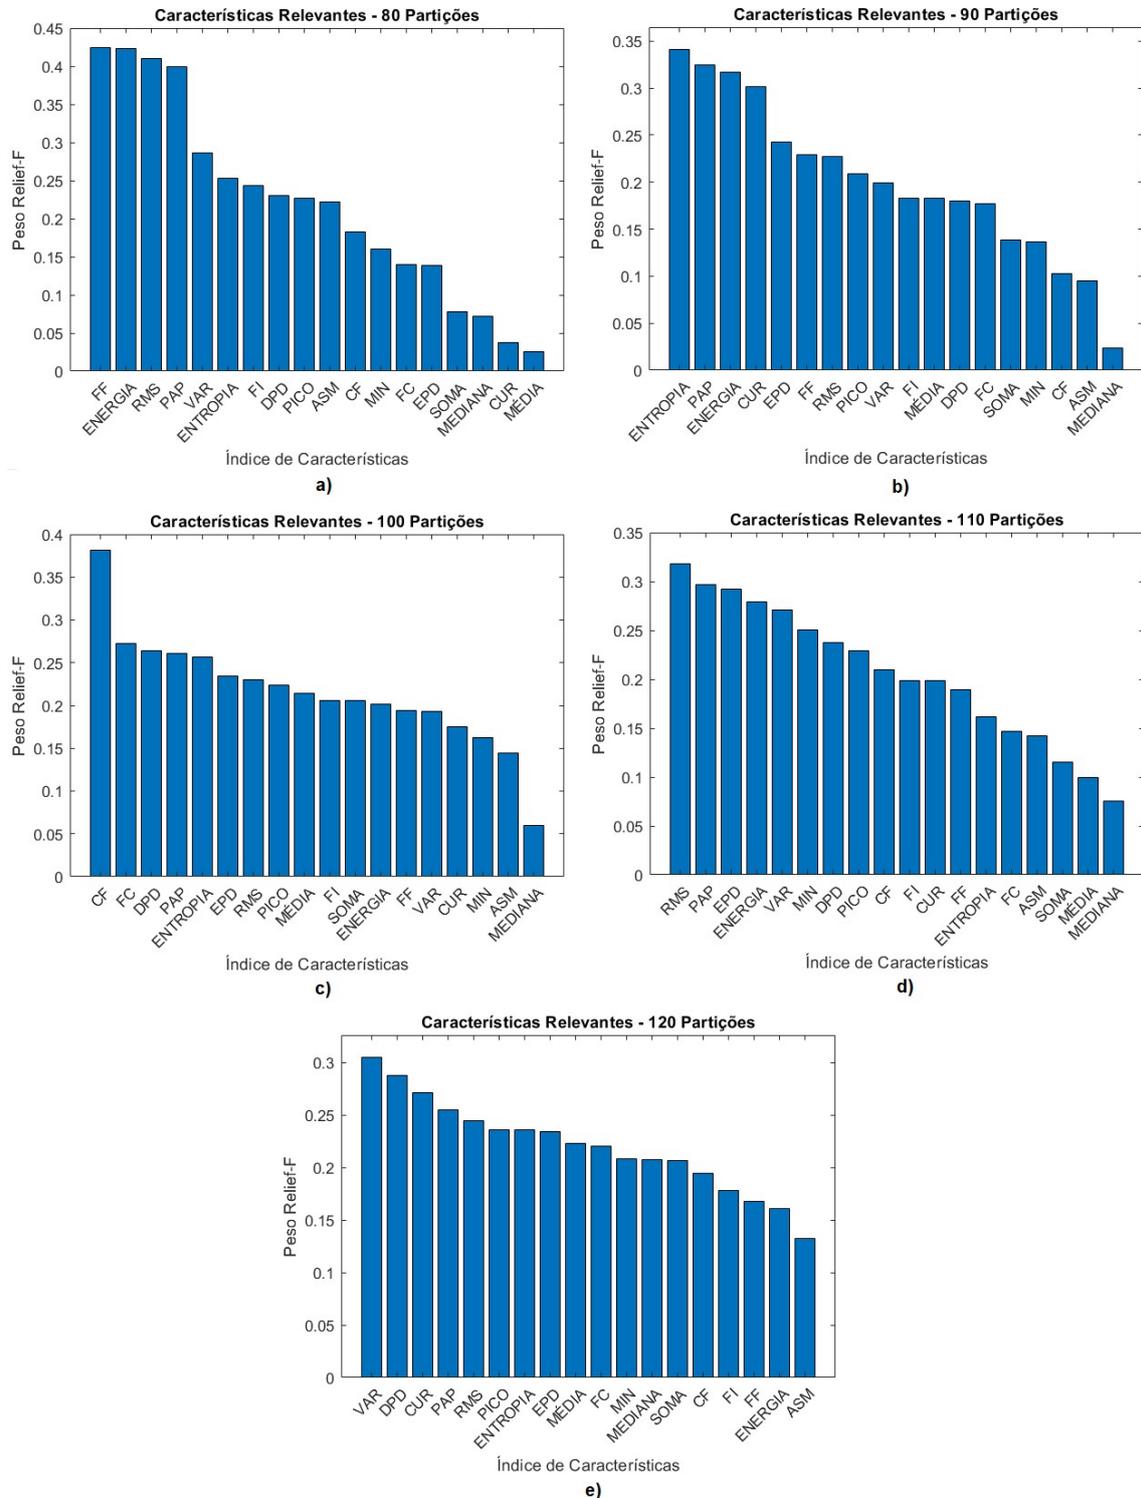


Figura 6.1. Ranqueamento de Características, com emprego do “Relief-F”, para: a) 80 partições b) 90 partições c) 100 partições d) 110 partições e) 120 partições

Conforme explicado anteriormente, um dos objetivos deste trabalho é avaliar a possibilidade de utilização de menor número de sensores para aquisição de sinais e, ao mesmo tempo, possibilitar que se consiga obter, por meio de algoritmos de classificação, uma boa capacidade preditiva. Até agora, para tal objetivo, foi utilizada a técnica de redução de dimensionalidade *Relief-F*, através da qual a quantidade de características originalmente utilizadas foi reduzida para um número que mantivesse a boa capacidade de classificação, com conseqüente redução do tempo despendido na operação.

A etapa seguinte a este processo é a eliminação de acelerômetros até uma quantidade mínima que garanta um desempenho de classificação dentro do limite mínimo requerido. Para este passo, foi utilizado novamente o *Relief-F*, de modo a classificar os acelerômetros em termos de importância para classificação, com base no ranking de características. Uma vez que estas estão associadas a cada acelerômetro, suas pontuações foram somadas para cada sensor, que foram ordenados em ordem decrescente, com o mais relevante obtendo a melhor pontuação. A Figura 6.2 mostra os acelerômetros sendo classificados em ordem de importância de acordo com os pesos atribuídos pelo método *Relief-F*, para cada uma das 15 configurações de BD.

A fim de verificar qual o número mínimo ótimo de sensores que possibilite ao classificador o desempenho mínimo requerido de o *F1-Score* acima de 95%, foram feitas simulações considerando a menor configuração de BD (80 partições com 5 características). A Tabela 6.3 mostra o *F1-Score* que cada um dos três algoritmos de AM obteve, dada quantidade de acelerômetros utilizados, lembrando que estes foram ranqueados em nível de importância conforme o critério do *Relief-F*. E a Figura 6.3 mostra como se comporta a capacidade preditiva destes algoritmos à medida em que são eliminados os sensores.

Os resultados mostraram que, para esta configuração de BD, foi possível obter um *F1-Score* mínimo requerido após serem eliminados 11 acelerômetros. Ou seja, o número mínimo de sensores alcançado, neste caso, foi quatro.

No entanto, este resultado não pode ser considerado definitivo ainda, haja vista terem sido realizadas simulações com apenas uma configuração de BD. Deste modo, as análises foram estendidas para as demais configurações, a fim de verificar se, para alguma delas, é possível se chegar a uma quantidade ainda menor de acelerômetros. Visto que uma simulação semelhante a feita anteriormente seria muito exaustiva e desnecessária de

ser replicada para as demais 14 configurações de BD, a análise de desempenho dos algoritmos se iniciou a partir da eliminação de 11 sensores em diante.

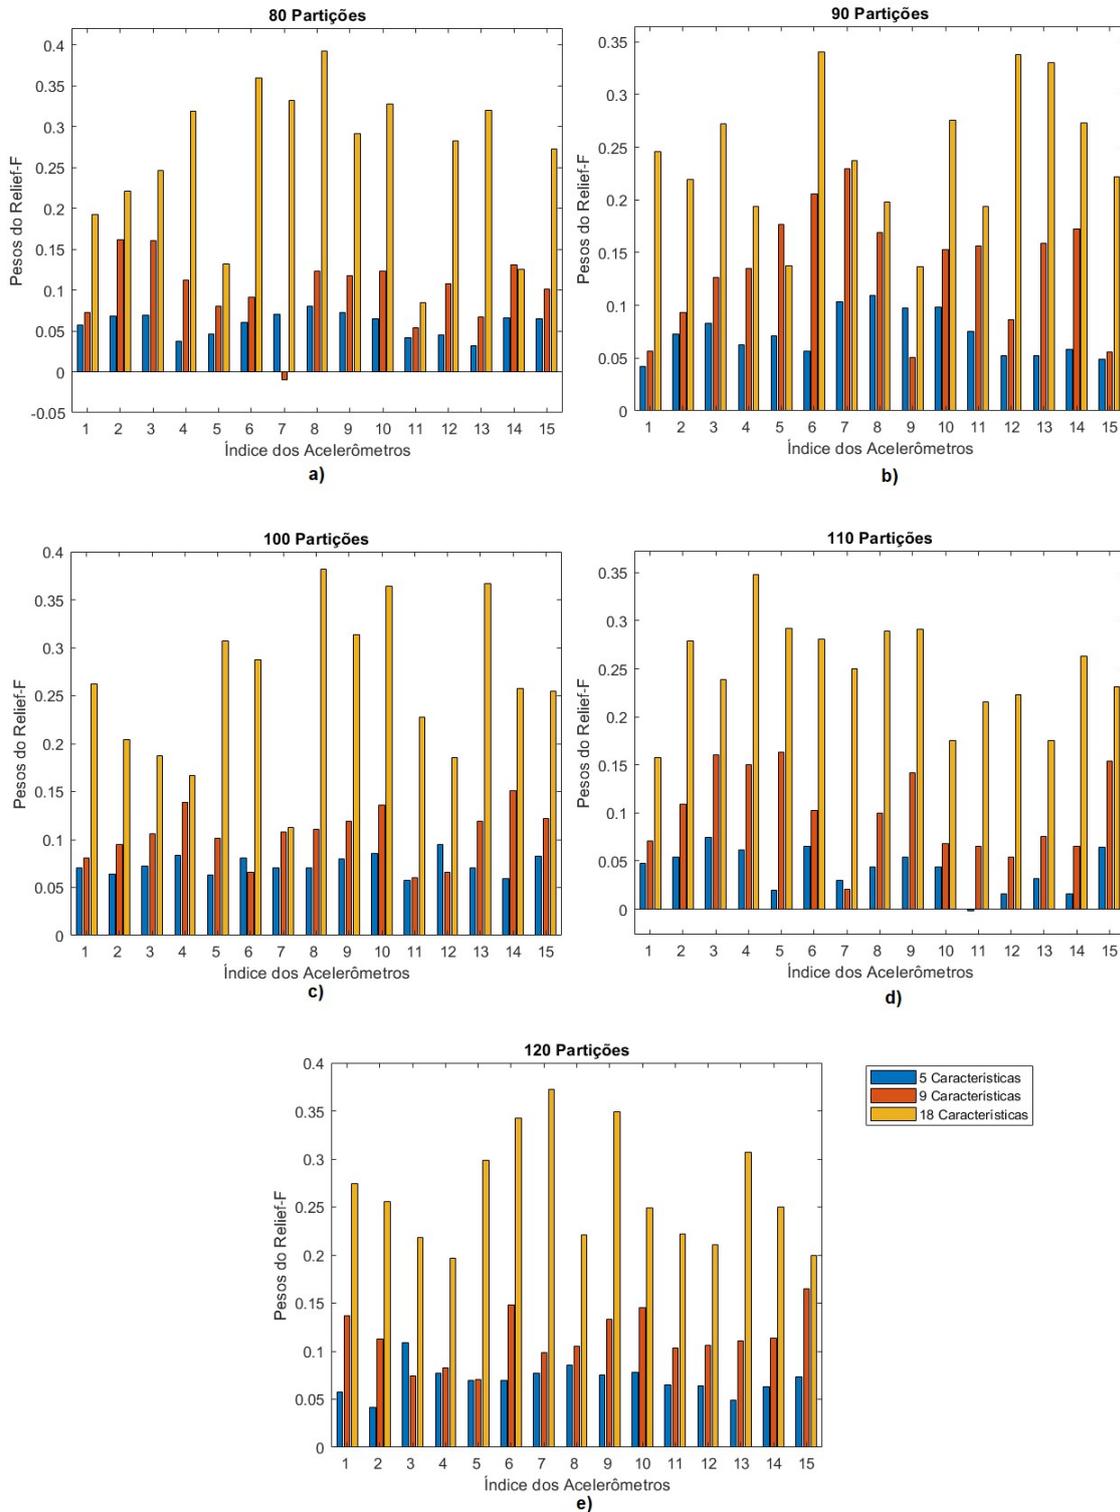


Figura 6.2. Ranqueamento dos acelerômetros, pelo método *Relief-F*, para: a) 80 partições b) 90 partições c) 100 partições d) 110 partições e) 120 partições

Tabela 6.3 *F1-Score* para Banco de Dados com 80 Partições e 5 Características

Nº de Sensores Eliminados	<i>F1-Score</i> (%)		
	<i>K-NN</i>	<i>SVM</i>	<i>RF</i>
0	99,36	100	99,87
1	99,49	99,87	100
2	99,23	99,87	99,74
3	97,47	99,74	99,36
4	96,96	99,74	99,36
5	97,84	99,49	99,36
6	97,6	99,62	98,97
7	97,72	99,49	99,23
8	96,71	98,98	98,72
9	97,72	98,73	98,46
10	96,71	98,85	98,46
11	95,94	97,61	96,91
12	89,52	92,46	92,3
13	82,2	83,82	88,93
14	47,33	48,33	62,76
15	0	0	0%

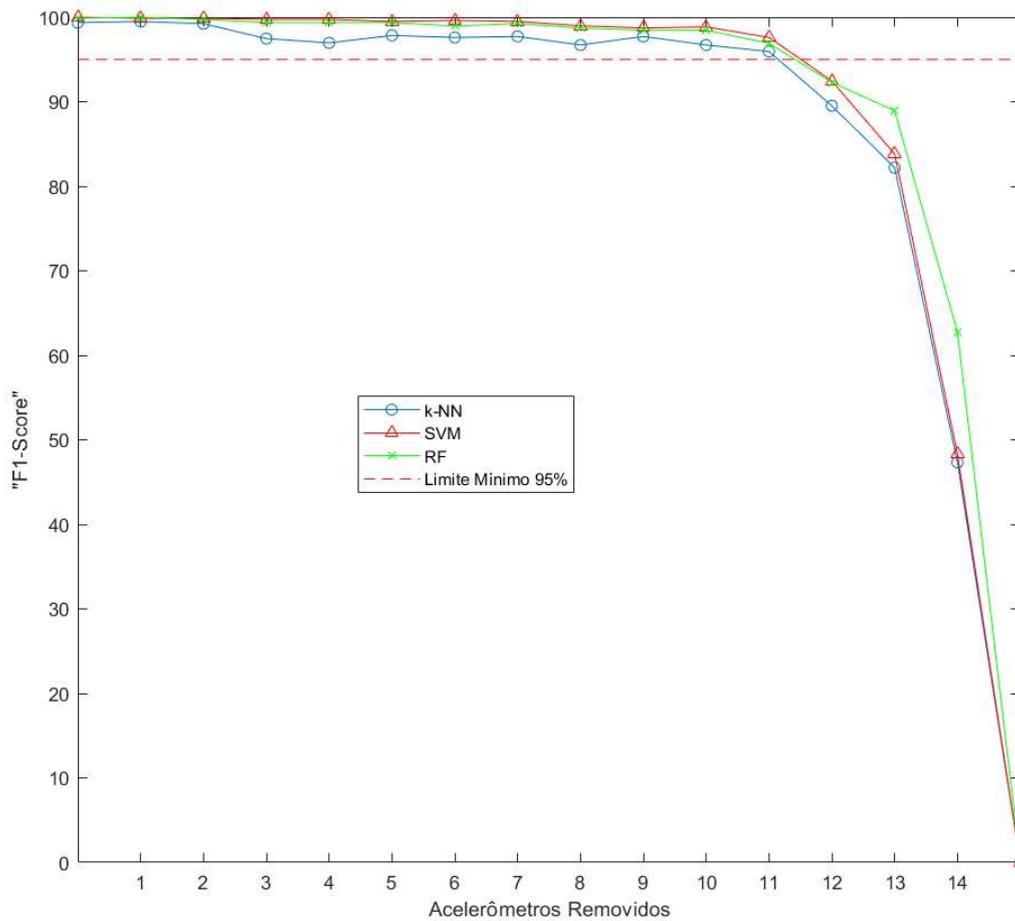


Figura 6.3. Desempenho da capacidade preditiva os algoritmos de AM, em termos de *F1-Score*, à medida que são removidos os acelerômetros, para um BD de 80 partições e 5 características.

A Tabela 6.4 mostra o desempenho de classificação para todas as configurações de BD após a remoção de 11 acelerômetros, enquanto que na Tabela 6.5 o mesmo é feito após serem retirados 12 sensores.

Tabela 6.4 *F1-Score* com 11 acelerômetros removidos

Nº de Partições	<i>F1-Score (%)</i>								
	5 Características			9 Características			18 Características		
	K-NN	SVM	RF	K-NN	SVM	RF	K-NN	SVM	RF
80	95,94	97,61	96,91	88,29	94,75	94,97	95,01	99,84	98,46
90	95,95	96,05	IND	97,05	98,45	47,16	96,4	99,1	68,71
100	85,48	93,02	IND	81,51	93,64	IND	97,95	99,1	30,05
110	87,29	89,08	IND	80,02	85,62	IND	95,89	98,58	IND
120	93,77	91,41	96,15	73,18	85,38	IND	97,69	98,98	IND

Tabela 6.5 *F1-Score* com 12 acelerômetros removidos

Nº de Partições	<i>F1-Score (%)</i>								
	5 Características			9 Características			18 Características		
	K-NN	SVM	RF	K-NN	SVM	RF	K-NN	SVM	RF
80	89,52	92,46	92,3	82,52	90,46	90,01	91,63	93,95	95,04
90	88,4	91,74	IND	96,15	95,34	46,98	93,39	97,36	46,98
100	81,74	90,76	IND	74,28	84,67	IND	94,98	98,07	IND
110	76,9	78,12	IND	73,72	80,29	IND	93,32	97,2	IND
120	86,11	85,24	92,34	74,34	81,12	IND	95,31	96,78	IND

Na Tabela 6.5, pode-se verificar um desempenho superior a 95% nas seguintes situações:

- Com 90 partições e 9 características, para os algoritmos K-NN e SVM;
- Com 90 partições e 18 características, para o algoritmo SVM;
- Com 100 partições e 18 características, para o algoritmo SVM;
- Com 110 partições e 18 características, para o algoritmo SVM;
- Com 120 partições e 18 características, para o algoritmo SVM;

Estes resultados mostraram que, após a remoção de 12 acelerômetros, os três sensores restantes são capazes de possibilitar uma boa capacidade para diagnosticar falhas de ignição, uma vez que seus desempenhos estão acima do limite mínimo requerido para *F1-Score*.

Conforme demonstrado na Figura 6.2, o ranqueamento dos acelerômetros pelo método *Relief-F* pode variar para diferentes configurações de BD. Deste modo, os três sensores selecionados foram aqueles melhores ranqueados, de acordo com a Tabela 6.6.

Tabela 6.6 Seleção dos sensores, pelo método *Relief-F*, conforme configuração dos BD

Nº de Partições	Nº de Características	Sensores Selecionados	<i>F1-Score</i> (%)	Método
90	9	nº7, nº6 e nº5	96,15	<i>K-NN</i>
90	18	nº6, nº12 e nº13	97,36	<i>SVM</i>
100	18	nº8, nº13 e nº10	98,07	<i>SVM</i>
110	18	nº4, nº5 e nº9	97,2	<i>SVM</i>
120	18	nº7, nº9 e nº6	96,78	<i>SVM</i>

Vale lembrar, no entanto, que este resultado é fruto de um ranqueamento de sensores feito com base nos critérios do método *Relief-F*. Embora esta técnica de redução de dimensionalidade seja consagrada, ainda assim foi considerada, neste trabalho, a utilização de um método alternativo, não apenas para fins de comparação, mas também para verificar se é possível utilizar uma quantidade ainda menor de acelerômetros.

Dito isto, foi considerado o método da Análise Combinatória Geral (ACG), através da qual foram feitas combinações de todos os sensores, com aumento progressivo da quantidade de acelerômetros a serem combinados, até que se chegasse a um número mínimo de sensores, que possibilitasse uma capacidade de classificação de falhas acima do limite mínimo de 95% de *F1-Score*.

O algoritmo utilizado para realizar as classificações, no âmbito da análise pela ACG, foi o *SVM*, uma vez que o mesmo retornou um desempenho de classificação superior aos algoritmos *K-NN* e *RF* na tarefa de detecção e identificação de falha de ignição.

A ACG foi iniciada considerando a utilização de apenas um único sensor por vez. Os resultados estão representados na Figura 6.23, onde é possível observar o *F1-Score* para cada acelerômetro utilizado individualmente. Embora não tenha sido possível alcançar a capacidade mínima requerida para classificação de falhas com a utilização de apenas um sensor, é importante notar que, em alguns casos, o *F1-Score* chegou a valores

acima de 80%, o que demonstra a capacidade de certos sensores em fornecer informações relevantes para classificação.

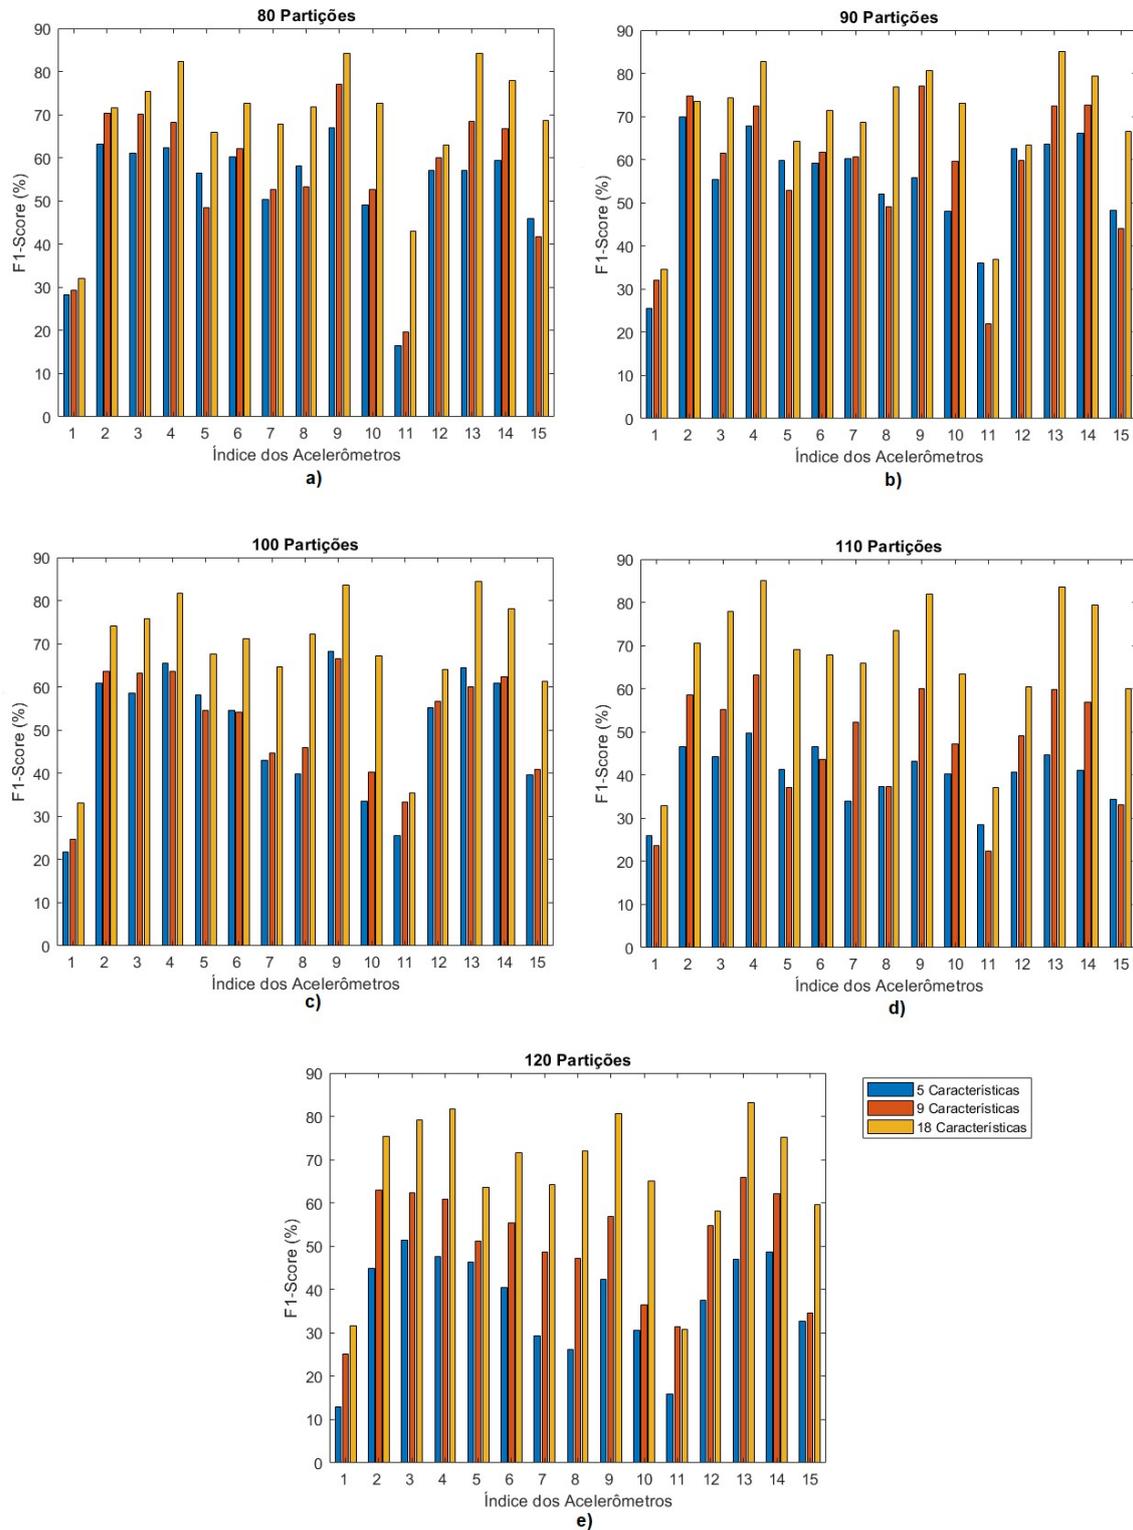


Figura 6.4. Desempenho de classificação individual dos acelerômetros para: a) 80 partições b) 90 partições c) 100 partições d) 110 partições e) 120 partições

A partir desta informação, foi possível ranquear os sensores, de forma decrescente, quanto à sua capacidade de classificação, ao serem analisados individualmente. Este ranqueamento foi utilizado como critério para determinar a importância dos acelerômetros pelo método ACG.

A análise prosseguiu considerando uma combinação dos 15 sensores, utilizando dois por vez. Com isso, foram realizadas 105 combinações, para cada uma das 15 configurações de BD. Desta vez, foi possível encontrar pares de sensores que, quando utilizados em conjunto, alcançaram um desempenho superior a 95%.

Da Tabela 6.7 à Tabela 6.9 são mostrados os desempenhos de classificação do SVM, em termos de *F1-Score*, bem como o respectivo tempo de resposta de predição para uma instância, quando utilizados apenas dois sensores, selecionados sob o critério da ACG. Estas tabelas mostraram um desempenho superior a 95%, nas seguintes situações:

- Com 80 partições e 18 características, utilizando os sensores nº9 e nº13
- Com 90 partições e 9 características, utilizando os sensores nº2 e nº9
- Com 90 partições e 18 características, utilizando os sensores nº4 e nº13
- Com 100 partições e 18 características, utilizando os sensores nº9 e nº13
- Com 110 partições e 18 características, utilizando os sensores nº4 e nº13
- Com 120 partições e 18 características, utilizando os sensores nº4 e nº13

Foi observado que os pares de sensores que possibilitaram a melhor capacidade de classificação eram compostos pelos acelerômetros mais importantes, conforme critério estabelecido para o ACG. Com isso, foi verificado que não há a necessidade de ser feita a análise das 105 combinações de sensores, bastando combinar apenas os mais importantes, o que significou uma otimização do processo de busca da melhor combinação de sensores pelo método ACG.

Ainda de acordo com essas tabelas, foi feita uma comparação da ACG com o *Relief-F*, considerando a seleção dos melhores pares de sensores conforme os respectivos critérios de importância, tendo sido observado que o critério de seleção pela ACG superou o do *Relief-F* na maioria dos casos, não apenas em termos de capacidade de classificação, mas também quanto ao tempo de resposta de predição para uma instância.

Tabela 6.7 Desempenho de classificação para 2 sensores com utilização do SVM em um Banco de Dados com 5 características

SVM para 5 características						
Nº Partições	<i>Relief-F</i>			ACG		
	Sensores	<i>F1-Score (%)</i>	Tempo (s)	Sensores	<i>F1-Score (%)</i>	Tempo (s)
80	n°8; n°9	87,95	6,201E-05	n°9; n°2	91,51	8,08846E-05
90	n°8; n°7	77,45	0,0006927	n°2; n°4	90,62	5,81359E-05
100	n°12; n°10	73,59	9,431E-05	n°9; n°4	90,8	6,64282E-05
110	n°4; n°5	66,58	0,0001432	n°4; n°2	75,72	0,000117333
120	n°3; n°8	70,46	0,0001132	n°3; n°14	80,98	0,000275264

Tabela 6.8 Desempenho de classificação para 2 sensores com utilização do SVM em um Banco de Dados com 9 características

SVM para 9 características						
Nº Partições	<i>Relief-F</i>			ACG		
	Sensores	<i>F1-Score (%)</i>	Tempo (s)	Sensores	<i>F1-Score (%)</i>	Tempo (s)
80	n°2; n°3	85,07	6,664E-05	n°9; n°2	94,65	6,27936E-05
90	n°7; n°6	86,25	9,343E-05	n°9; n°2	96,36	5,96551E-05
100	n°14; n°4	80,45	9,331E-05	n°9; n°2	89,92	0,0000828
110	n°5; n°3	69,37	8,088E-05	n°4; n°9	89,03	6,77282E-05
120	n°15; n°6	68,47	0,0001085	n°13; n°2	89,55	0,000107968

Tabela 6.9 Desempenho de classificação para 2 sensores com utilização do SVM em um Banco de Dados com 18 características

SVM para 18 características						
Nº Partições	<i>Relief-F</i>			ACG		
	Sensores	<i>F1-Score (%)</i>	Tempo (s)	Sensores	<i>F1-Score (%)</i>	Tempo (s)
80	n°8; n°6	89,2	8,986E-05	n°9; n°13	96,93	8,12936E-05
90	n°6; n°12	86,03	9,956E-05	n°13; n°4	96,68	8,25833E-05
100	n°8; n°13	94,46	9,234E-05	n°13; n°9	96,92	8,89231E-05
110	n°4; n°5	92,7	0,0001054	n°4; n°13	96,67	9,08538E-05
120	n°7; n°9	94	0,0001052	n°13; n°4	95,64	0,000174871

Além disso, as duplas de sensores selecionados pelo critério do *Relief-F* não alcançaram o *F1-Score* mínimo requerido de 95% em nenhum dos casos. Por outro lado, em seis situações distintas, os pares de acelerômetros selecionados pelo critério da ACG conseguiram garantir um desempenho de classificação acima do requerido. Este resultado demonstra a possibilidade de se utilizar dois entre 15 sensores e ainda assim manter uma boa capacidade de detecção e identificação de falhas de ignição.

Por fim, avaliou-se qual das combinações de sensores deveria ser considerada. Na análise vigente, três pares diferentes de sensores alcançaram *F1-Score* acima de 95%: n°2

com n°9; n°4 com n°13; e n°9 com n°13. O critério adotado para selecionar o melhor par de acelerômetros foi o menor tempo de resposta de predição, que foi observado ao se utilizar os sensores n°2 e n°9, para um conjunto de dados com 90 partições e 9 características. Um gráfico de radar detalhando o desempenho obtido após o uso da combinação selecionada de sensores é apresentado na Figura 6.5.

No entanto, uma ressalva precisa ser feita quanto à aplicabilidade prática dos métodos mencionados. Enquanto que no método ACG foi necessário dispendir um tempo para analisar cada sensor por vez para estabelecer um critério de importância, o método *Relief-F* já possui, na estrutura do seu algoritmo, a capacidade de ordenar características conforme as suas capacidades em realizar classificações, sendo portanto mais prático e exequível que a ACG neste aspecto.

Deste modo, considerando que o *Relief-F* também apresentou uma capacidade de reduzir consideravelmente o número de sensores, além do menor tempo total necessário para realizar treinamentos se comparado com a ACG, este método se apresenta como uma ferramenta com ótima viabilidade para ser utilizada na tarefa de redução da quantidade de acelerômetros a serem utilizados para captação de sinais, tendo em vista a sua praticidade de aplicação.

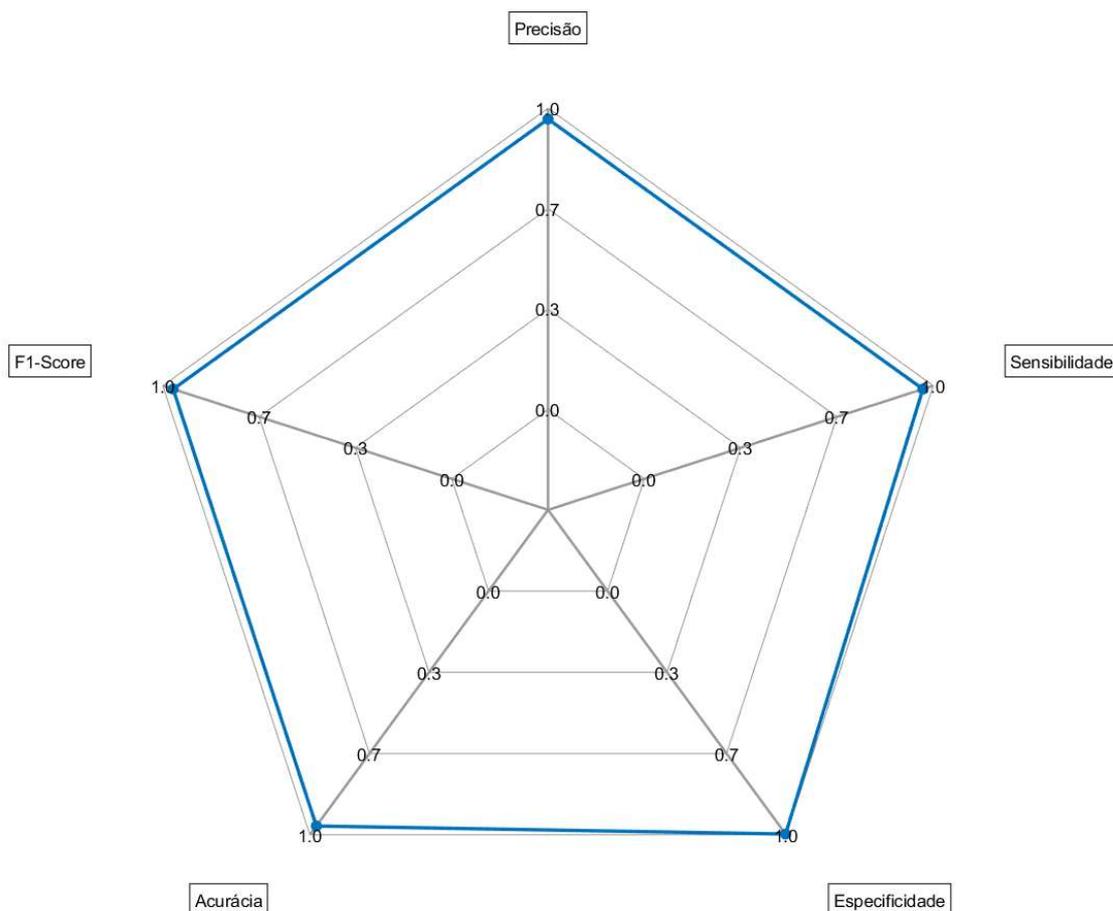


Figura 6.5. Gráfico tipo radar para classificação de falhas ao se utilizar os sensores n^o2 e n^o9 em uma configuração de Banco de Dados com 90 partições e 9 características.

Apesar de [66] afirmar ser difícil, senão impossível, encontrar o melhor posicionamento de sensores devido à complexidade da estrutura do motor, além do fato de a localização da falha do motor ser desconhecida, este estudo foi capaz de apontar posições de sensores que poderiam retornar um bom desempenho para diagnóstico de falhas.

No entanto, os resultados mostraram que outras combinações de sensores atingiram o desempenho mínimo requerido para classificação, o que significa que posicionamentos diferentes de sensores podem retornar classificações satisfatórias. Assim, o posicionamento ótimo dependerá do tipo de falha, do tipo de sensor usado e da metodologia empregada para detecção e identificação de falha de ignição.

7 CONCLUSÃO

Para o primeiro objetivo deste trabalho, os resultados foram consistentes, com um excelente desempenho de todos os três modelos de AM analisados para detectar e identificar falha de perda de ignição, com *K*-NN, SVM e RF retornando, para um conjunto de dados de 18 características com 80 partições, um *F1-Score* de 99,87%, 100% e 99,87%, respectivamente. No entanto, o tamanho do conjunto de dados analisado era muito grande, o que implicava em altos custos computacionais.

Para mitigar este problema, o método *Relief-F* foi utilizado para selecionar e ranquear as características, possibilitando a criação de novas configurações de BD mais enxutas, sendo uma com nove características e outra com cinco, as quais, quando utilizadas como dados de entrada pelos algoritmos de AM, possibilitaram que estes mantivessem um bom desempenho de classificação.

A partir daí, o segundo passo foi buscar uma redução da quantidade de sensores utilizados para captar os sinais de vibração, sem que isso comprometesse a boa capacidade de classificação dos algoritmos de AM utilizados neste trabalho. Novamente, o *Relief-F* foi utilizado, desta vez para ranquear os acelerômetros em ordem de importância quanto à capacidade de fornecer informação relevante para classificação. Através deste método, foi possível chegar à uma quantidade mínima de três sensores, para uma configuração de BD mínima com 90 partições e 9 características.

No entanto, para efeitos de comparação e de tentativa de se chegar a um número ainda menor de sensores, foi considerado também o método da ACG, através da qual foram feitas combinações com os 15 acelerômetros, variando gradativamente, de forma crescente, a quantidade de sensores combinados, até que a combinação possibilitasse atingir o desempenho de classificação mínimo requerido. Este processo foi realizado para cada uma das 15 configurações de BD. Dito isto, iniciou-se a análise considerando a utilização de apenas um sensor por vez, o que possibilitou verificar a capacidade individual de cada sensor em realizar classificações. A partir deste resultado, foi possível ranquear os acelerômetros conforme o seu desempenho de *F1-Score*, tendo isto sido utilizado como critério de importância segundo o método ACG. Ao serem realizadas as combinações dos 15 sensores, dois de cada vez, aplicadas em cada um dos 15 BD, foram observadas seis situações onde o par de sensores, quando combinados, alcançaram um *F1-Score* acima do mínimo requerido. O critério de seleção do melhor par de

acelerômetros foi o menor tempo de resposta de predição, que foi observado ao se utilizar os sensores n°2 e n°9, para um conjunto de dados com 90 partições e 9 características.

Além disso, foi observado que os melhores pares de sensores eram compostos pelos acelerômetros melhor ranqueados de acordo com o critério de importância da ACG, o que significou uma possibilidade de otimização deste método com o intuito de reduzir o tempo de processamento.

Embora, os resultados tenham mostrado que o critério de seleção de sensores por meio da ACG tenha sido capaz de permitir o uso de dois acelerômetros, bem como obter um desempenho de classificação melhor se comparado com a dupla de acelerômetros selecionados pelo método *Relief-F*, ressalva precisa ser feita quanto à aplicabilidade prática dos métodos mencionados. Enquanto que no método ACG foi necessário dispendir um tempo para analisar cada sensor por vez para estabelecer um critério de importância, o método *Relief-F* já possui, na estrutura do seu algoritmo, a capacidade de ordenar características conforme as suas capacidades em realizar classificações, sendo portanto mais prático e exequível que a ACG neste aspecto.

Por fim, os resultados descritos no parágrafo anterior mostraram ainda que diferentes combinações de pares de sensores são capazes de possibilitar, aos algoritmos de AM, desempenhos de classificação acima do requerido, de modo que a posição dos sensores ótimos pode variar de acordo com o tipo de falha, o tipo de sensor usado e a metodologia empregada para detecção e identificação de falha de perda de ignição (estruturação de dados, seleção de características, escolha do método de classificação, etc.).

8 SUGESTÕES PARA TRABALHOS FUTUROS

Como sugestão para trabalhos futuros, podem ser feitas pesquisas que abordem a extração de características, do mesmo BD utilizado nesta dissertação, no domínio da frequência (com foco nas fases de picos de frequência) e no domínio do tempo-frequência, a fim de verificar a capacidade desses atributos extraídos para interpretar os sinais. Também podem ser realizados estudos no intuito de aprimorar ainda mais o método ACG, visando uma maior redução do tempo de processamento. Quanto aos métodos de AM, sugere-se o estudo da aplicação de técnicas mais modernas, como por exemplo, as Redes Neurais Convolucionais (CNN) e as Redes Neurais Recorrentes (RNN), sendo esta última com foco na arquitetura *Long Short-Term Memory* (LSTM). Outra sugestão é estudar casos com múltiplas falhas de ignição em Motores de Combustão Interna, com o desenvolvimento de métodos de detecção e identificação dessas falhas.

Outras linhas de estudo podem se basear na aplicação de algoritmos de AM em BD obtidos por meio de outros métodos de monitoramento de condição de operação, como por exemplo: análise da qualidade do óleo de motores Diesel, com o objetivo de identificar e detectar possíveis desgastes em determinados componentes que, caso não tratados, possam acarretar em falhas graves; análise de BD contendo imagens obtidas em inspeções estruturais de navios, com a aplicação de CNN para classificação destas imagens, de modo a possibilitar um diagnóstico da condição estrutural dos meios navais.

9 REFERÊNCIAS BIBLIOGRÁFICAS

- [1] PESSANHA, C. “A manutenção preditiva”. **Revista Marítima Brasileira**, v. 138, n. 04/06, p. 164-164, 2018;
- [2] UNCTAD. **Review of maritime transport 2022**. UN, 2022;
- [3] AGÊNCIA NACIONAL DE TRANSPORTES AQUAVIÁRIOS. *Desempenho Aquaviário 2022*. Disponível em: <<https://www.gov.br/antag/pt-br/noticias/2023/setor-portuario-movimenta-mais-de-1-2-bilhao-de-toneladas-em-2022>>. Acesso em: 09 jul. 2023, 17:30:32;
- [4] ERUGUZ, A.; TAN, T.; VAN HOUTUM, G. A survey of maintenance and service logistics management: Classification and research agenda from a maritime sector perspective. **Computers & Operations Research**, v. 85, p. 184-205, 2017;
- [5] WILLIAMS, C. M.; HESTER, P. T. “A readiness decision model for canceling navy ship maintenance availabilities”. In: **Applications of Management Science**. Emerald Publishing Limited, 2017. p. 147-166;
- [6] ASSOCIAÇÃO DAS NORMAS TÉCNICAS, **NBR 5462 - Confiabilidade e manutenibilidade**, ABNT, Rio de Janeiro, 1994;
- [7] SCHWAB, K. **The Fourth Industrial Revolution**. World Economic Forum, 2016;
- [8] PARUNOV, J.; GARBATOV, Y. “Ship Structures”. **Journal of Marine Science and Engineering**, v. 10, n. 3, p. 374, 2022;
- [9] NOONAN, E. F., **Ship vibration design guide**. In: Report n° SSC-350, Ship Structure Committee, Annapolis MD , 1989;
- [10] MERHIGE, R. *Engine misfire largely to blame for vibration onboard*. Triton, 2016. Disponível em: <<https://www.the-triton.com/2016/09/engine-misfire-largely-to-blame-for-vibration-onboard>>. Acesso em: 20 dez. 2022, 20:12:20.
- [11] GUIMARÃES, A.; MOREIRA, P.; BEZERRA, C. Modelos de inovação: Análise bibliométrica da produção científica. **Brazilian Journal of Information Science: Research trends**, v. 15, p. e02106-e02106, 2021;
- [12] TAO, J. et. al., **Intelligent fault diagnosis of diesel engines via extreme gradient**

boosting and high-accuracy time–frequency information of vibration signals.

Sensors, v. 19, n. 15, p. 3280, 2019.

- [13] MAURYA, R. K.; MAURYA, L.; LUBY. **Reciprocating engine combustion diagnostics**. Cham, Switzerland: Springer International Publishing, 2019;
- [14] ZHENG, T. et al., “Real-time combustion torque estimation and dynamic misfire fault diagnosis in gasoline engine”. **Mechanical Systems and Signal Processing**, v. 126, p. 521-535, 2019;
- [15] CHARLES, P. et al. “Detecting the crankshaft torsional vibration of diesel engines for combustion related diagnosis”. **Journal of sound and vibration**, v. 321, n. 3-5, p. 1171-1185, 2009;
- [16] DEVASENAPATI, S. B.; SUGUMARAN, V.; RAMACHANDRAN, K. I. “Misfire identification in a four-stroke four-cylinder petrol engine using decision tree”. **Expert systems with applications**, v. 37, n. 3, p. 2150-2160, 2010;
- [17] TAMURA, M. et al. “Misfire detection on internal combustion engines using exhaust gas temperature with low sampling rate”. **Applied Thermal Engineering**, v. 31, n. 17-18, p. 4125-4131, 2011;
- [18] ZHANG, P. et al. “Misfire detection of diesel engine based on convolutional neural networks”. **Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering**, v. 235, n. 8, p. 2148-2165, 2021;
- [19] LUJAN, J. M. et al. “A methodology for combustion detection in diesel engines through in-cylinder pressure derivative signal”. **Mechanical systems and signal processing**, v. 24, n. 7, p. 2261-2275, 2010;
- [20] FIRMINO, J. L. et al. “Misfire detection of an internal combustion engine based on vibration and acoustic analysis”. **Journal of the Brazilian Society of Mechanical Sciences and Engineering**, v. 43, n. 7, p. 336, 2021;
- [21] JAFARIAN, K. et al. “Misfire and valve clearance faults detection in the combustion engines based on a multi-sensor vibration signal monitoring”. **Measurement**, v. 128, p. 527-536, 2018;
- [22] FRATELLO, M.; TAGLIAFERRI, R. “Decision trees and random forests”.

Encyclopedia of Bioinformatics and Computational Biology: ABC of Bioinformatics, v. 374, 2018;

- [23] SHARMA, A.; SUGUMARAN, V.; DEVASENAPATI, S. B. “Misfire detection in an IC engine using vibration signal and decision tree algorithms”. **Measurement**, v. 50, p. 370-380, 2014;
- [24] ZHANG, M. et al. “Intelligent diagnosis of V-type marine diesel engines based on multifeatures extracted from instantaneous crankshaft speed”. **IEEE Transactions on Instrumentation and Measurement**, v. 68, n. 3, p. 722-740, 2018;
- [25] VAKHARIA, V.; GUPTA, V. K.; KANKAR, P. K. “Efficient fault diagnosis of ball bearing using ReliefF and Random Forest classifier”. **Journal of the Brazilian Society of Mechanical Sciences and Engineering**, v. 39, n. 8, p. 2969-2982, 2017;
- [26] VORUS, W. S., PAULLING, J. R., **The Principles of Naval Architecture Series**. 1 ed. New Jersey, The Society of Naval Architects and Marine Engineers, 2010;
- [27] AMERICAN BUREAU OF SHIPPING. **Guidance notes on ship vibration**. American Bureau of Shipping, 2018;
- [28] INDIAN REGISTER OF SHIPPING. **Guidelines on Identification of Vibration Issues and Recommended Remedial Measures on Ships**. Indian Register of Shipping, July, 2021;
- [29] TIENHAARA, H., **Guidelines to engine dynamics and vibration**. Wärtsilä Corporation, p. 20-25, 2004;
- [30] THARANGA, KL P. et al., **Diesel engine fault diagnosis with vibration signal**. Journal of Applied Mathematics and Physics, v. 8, n. 9, p. 2031-2042, 2020;
- [31] KAUR, S.; JINDAL, S. “A Survey on Machine Learning Algorithms”. **International Journal of Innovative Research in Advanced Engineering (IJIRAE)**, v. 3, n. 11, p. 2349-2763, 2016;
- [32] TAUNK, K. et al. “A brief review of nearest neighbor algorithm for learning and classification”. In: **International Conference on Intelligent Computing and Control Systems (ICCS)**. IEEE, p. 1255-1260, May. 2019;

- [33] ABU A. et al. "Effects of distance measure choice on k-nearest neighbor classifier performance: a review". **Big data**, v. 7, n. 4, p. 221-248, 2019;
- [34] LEI, Y. et al. "Applications of machine learning to machine fault diagnosis: A review and roadmap". **Mechanical Systems and Signal Processing**, v. 138, p. 106587, 2020;
- [35] KRAMER, O., **Dimensionality reduction with unsupervised nearest neighbors**. Berlin: Springer, 2013;
- [36] NOBLE, W. S. "What is a support vector machine?". **Nature biotechnology**, v. 24, n. 12, p. 1565-1567, 2006;
- [37] MAMMONE, A.; TURCHI, M.; CRISTIANINI, N., "Support vector machines". **Wiley Interdisciplinary Reviews: Computational Statistics**, v. 1, n. 3, p. 283-289, 2009;
- [38] BOSER, B. E.; GUYON, I. M.; VAPNIK, V. N. "A training algorithm for optimal margin classifiers". In: **Proceedings of the fifth annual workshop on Computational learning theory**. 1992. p. 144-152;
- [39] CORTES, C.; VAPNIK, V. Support-vector networks. **Machine learning**, v. 20, p. 273-297, 1995;
- [40] UKIL, A. **Intelligent systems and signal processing in power engineering**. Springer Science & Business Media, 2007;
- [41] CUTLER, A.; CUTLER, D. R.; STEVENS, J. R. "Random forests". **Ensemble machine learning: Methods and applications**, p. 157-175, 2012;
- [42] SAVAS, C.; DOVIS, F. "The impact of different kernel functions on the performance of scintillation detection based on support vector machines". **Sensors**, v. 19, n. 23, p. 5219, 2019;
- [43] BREIMAN, L. "Random forests". **Machine learning**, v. 45, p. 5-32, 2001;
- [44] BREIMAN, Leo. "Bagging predictors". **Machine learning**, v. 24, p. 123-140, 1996;
- [45] VERIKAS, A.; GELZINIS, A.; BACAUSKIENE, M. "Mining data with random forests: A survey and results of new tests". **Pattern recognition**, v. 44, n. 2, p. 330-

- 349, 2011;
- [46] BOATENG, E. Y.; OTOO, J.; ABAYE, D. A. “Basic tenets of classification algorithms K-nearest-neighbor, support vector machine, random forest and neural network: a review”. **Journal of Data Analysis and Information Processing**, v. 8, n. 4, p. 341-357, 2020;
- [47] BOISBERRANGER J. et al. *Support Vector Machines*: Scikit-learn, 2022. Disponível em: <https://scikit-learn.org/stable/modules/svm.html>. Acesso em: 16 dez. 2022, 12:20:12;
- [48] NAZARENKO, E.; VARKENTIN, V.; POLYAKOVA, T. Features of application of machine learning methods for classification of network traffic (features, advantages, disadvantages). In: **2019 International Multi-Conference on Industrial Engineering and Modern Technologies (FarEastCon)**. IEEE, 2019. p. 1-5;
- [49] MARTINS, D. H.C.S.S. et al. Hybrid data augmentation method for combined failure recognition in rotating machines. **Journal of Intelligent Manufacturing**, p. 1-19, 2022;
- [50] HASTIE, T. et al. **The elements of statistical learning: data mining, inference, and prediction**. New York: springer, 2009;
- [51] HASSANAT, A. B. et al. “RDPVR: Random data partitioning with voting rule for machine learning from class-imbalanced datasets”. **Electronics**, v. 11, n. 2, p. 228, 2022;
- [52] JOVIĆ, A.; BRKIĆ, K.; BOGUNOVIĆ, N. “A review of feature selection methods with applications”. In: **38th International convention on information and communication technology, electronics and microelectronics (MIPRO)**. Ieee. p. 1200-1205, May, 2015;
- [53] ZHOU, H.F. et al. “A feature selection algorithm of decision tree based on feature weight”. **Expert Systems with Applications**, v. 164, p. 113842, 2021;
- [54] PHYU, T. Z.; OO, N. N. “Performance comparison of feature selection methods”. In: **MATEC web of conferences**. EDP Sciences. p. 06002, 2016;

- [55] ROBNIK-ŠIKONJA, M.; KONONENKO, I. “Theoretical and empirical analysis of ReliefF and RReliefF”. **Machine learning**, v. 53, p. 23-69, 2003;
- [56] KONONENKO, I. et al. “Estimating attributes: Analysis and extensions of RELIEF”. In: **ECML**. p. 171-182. 1994;
- [57] BOLÓN-CANEDO, V.; SÁNCHEZ-MAROÑO, N.; ALONSO-BETANZOS, A. A review of feature selection methods on synthetic data. **Knowledge and information systems**, v. 34, p. 483-519, 2013;
- [58] DE AMORIM, L.; CAVALCANTI, G.; CRUZ, R. “The choice of scaling technique matters for classification performance. **Applied Soft Computing**, v. 133, p. 109924, 2023”;
- [59] MTU DETROIT DIESEL. Surface Mining 12V4000 – T1237K11. Detroit: MTU Detroit Diesel, 2016. 20p;
- [60] INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. **ISO 10816-6: Mechanical vibration - Evaluation of machine vibration by measurements on non-rotating parts - Part 6: Reciprocating machines with power ratings above 100 Kw**. Genève. Dec 1995;
- [61] GHOLAMY, A.; KREINOVICH, V.; KOSHELEVA, O. “Why 70/30 or 80/20 relation between training and testing sets: A pedagogical explanation”. 2018;
- [62] BLAINE, B. E. "Winsorizing." **The SAGE Encyclopedia of Educational Research, Measurement and Evaluation**, p 1817-1818, 2018;
- [63] SINGH, D.; SINGH, B. “Feature wise normalization: An effective way of normalizing data”. **Pattern Recognition**, v. 122, p. 108307, 2022;
- [64] CHEN, S. K. et al. “Machine learning for misfire detection in a dynamic skip fire engine”. **SAE International Journal of Engines**, v. 11, n. 6, p. 965-976, 2018;
- [65] URBANOWICZ, R. J. et al. “Relief-based feature selection: Introduction and review”. **Journal of biomedical informatics**, v. 85, p. 189-203, 2018;
- [66] XI, W. et al. “A feature extraction and visualization method for fault detection of marine diesel engines”. **Measurement**, v. 116, p. 429-437, 2018.

