



# CLASSIFICAÇÃO DE FALHAS DE INJEÇÃO EM UM MOTOR DIESEL MARÍTIMO USANDO SINAIS DE VIBRAÇÃO E REDES NEURAIS ARTIFICIAIS

Renato Bodanese

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  
Setembro de 2025

CLASSIFICAÇÃO DE FALHAS DE INJEÇÃO EM UM MOTOR DIESEL MARÍTIMO  
USANDO SINAIS DE VIBRAÇÃO E REDES NEURAIS ARTIFICIAIS

Renato Bodanese

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO  
LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE)  
DA 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

Aprovado por: Prof. Luis Domingues Tomé Jardim Tarrataca  
Prof. Ricardo Homero Ramirez Gutiérrez  
Prof. Ulisses Admar Barbosa Vicente Monteiro

RIO DE JANEIRO, RJ – BRASIL  
SETEMBRO DE 2025

Bodanese, Renato

Classificação de falhas de injeção em um motor Diesel marítimo usando sinais de vibração e redes neurais artificiais/ Renato Bodanese. – Rio de Janeiro: UFRJ/COPPE, 2025.

XV, 139 p.: il.; 29,7 cm.

Orientador: Ulisses Admar Barbosa Vicente Monteiro

Dissertação (mestrado) – UFRJ/COPPE/Programa de Engenharia Oceânica, 2025.

Referências Bibliográficas:p.135-139.

1. Falhas de injeção. 2. Motor Diesel. 3.Sinais de vibração. 4. Redes Neurais. I. Monteiro, Ulisses Admar Barbosa Vicente. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Oceânica. III.Título.

*Dedico esse trabalho a Deus, à minha família por acreditarem e me apoiarem na realização de mais esse sonho, compreendendo em todos os momentos minha ausência e dedicação voltados aos estudos.*



## **Agradecimentos**

Agradeço primeiramente a Deus, por me conceder saúde, sabedoria e força para vencer cada desafio ao longo desta jornada.

À minha esposa Juliana, minha parceira incondicional, pela paciência, compreensão e apoio constante. Sua presença foi essencial em cada etapa deste caminho.

À Marinha do Brasil, por oferecer mais uma oportunidade de qualificação profissional no Laboratório de Ensaaios Dinâmicos e Análise de Vibrações (LEDAV), na COPPE/UFRJ.

Ao meu orientador, Professor Ulisses Admar Barbosa Vicente Monteiro, cuja orientação ultrapassou os limites acadêmicos. Seu vasto conhecimento contribuiu de forma decisiva para o amadurecimento científico desta pesquisa. Sua amizade, generosidade, confiança e paciência foram fundamentais para que este trabalho se concretizasse. Muito mais que um orientador, tornou-se um verdadeiro amigo.

Ao Professor Luiz Vaz, por suas valiosas contribuições ao longo desta pesquisa e, em especial, por compartilhar sua profunda expertise teórica e prática no uso da inteligência artificial aplicada à classificação de falhas. Seus ensinamentos foram essenciais para o aprimoramento e consolidação dos conceitos que embasaram este trabalho.

Ao Professor Ricardo Homero Ramírez Gutiérrez, por suas valiosas observações, orientações e aconselhamentos ao longo desta jornada. Sua reconhecida expertise em motores Diesel e em Redes Neurais Artificiais foi essencial para o desenvolvimento desta pesquisa.

Aos professores, pesquisadores e demais integrantes do LEDAV, pelo acolhimento e apoio ao longo da pesquisa. Em especial, ao Hualber Lopes Berbet, cuja competência e disponibilidade foram cruciais para a fase experimental deste trabalho.

Aos CMG(EN) Carvalho, do extinto CPN, CMG(RM1-EN) Ítalo, CMG(RM1-EN) Mota e CMG(EN) Dinucci, do Arsenal de Marinha do Rio de Janeiro, por todo o suporte institucional e incentivo prestados. O respaldo dos senhores foi essencial para a conclusão desta dissertação.

Aos CF(EN) Marcelo Gomes e CF(EN) Gayer, pelos ensinamentos técnicos e práticos que foram fundamentais para minha formação na análise de assinaturas de vibração. As lições transmitidas por ambos, alicerçadas em sólida experiência e domínio técnico, ultrapassaram os livros. Seus ensinamentos não apenas instruíram, mas também inspiraram a aplicação prática do conhecimento adquirido.

Aos amigos CC(EN) Brenno, CC(EN) Guerra e Luiz Claudio, pelo companheirismo, pelas trocas de conhecimento e pelo incentivo constante. Ter compartilhado este percurso com vocês tornou a jornada muito mais enriquecedora.

A todos, o meu mais sincero agradecimento.

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

## CLASSIFICAÇÃO DE FALHAS DE INJEÇÃO EM UM MOTOR DIESEL MARÍTIMO USANDO SINAIS DE VIBRAÇÃO E REDES NEURAIS ARTIFICIAIS

Renato Bodanese

Setembro/2025

Orientador: Ulisses Admar Barbosa Vicente Monteiro

Programa: Engenharia Oceânica

A crescente demanda por estratégias efetivas de manutenção preditiva em sistemas navais impulsiona o desenvolvimento de técnicas avançadas para diagnóstico precoce de falhas. Esta dissertação apresenta uma metodologia para classificar automaticamente falhas de injeção tipo "single misfire" em motores Diesel marítimos, utilizando sinais de vibração e Redes Neurais Artificiais (RNAs).

A metodologia envolve a aquisição e análise de sinais de vibração coletados por acelerômetros instalados no motor Diesel MTU 12V4000C11, avaliados nos domínios do tempo, frequência e tempo-frequência. Características estatísticas como RMS, curtose, energia e entropia foram extraídas e utilizadas como entradas nos modelos de aprendizado supervisionado.

A otimização do sistema de aquisição e processamento de dados foi uma contribuição central, reduzindo o número de sensores sem perda significativa de precisão diagnóstica. A seleção e o posicionamento ideal dos acelerômetros foram baseados na relevância das características das assinaturas de vibrações para identificar falhas.

Resultados experimentais indicaram que as RNAs tiveram desempenho superior a 99% de F1-Score, apresentando alta precisão mesmo com menos sensores. A metodologia demonstrou-se eficaz e economicamente viável para aplicação em sistemas embarcados, beneficiando diretamente a manutenção preditiva na Marinha do Brasil.

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

Classification of injection faults in a marine Diesel engine using vibration signals and artificial neural networks

Renato Bodanese  
September/2025

Advisor: Ulisses Admar Barbosa Vicente Monteiro  
Department: Ocean Engineering

The growing demand for effective predictive maintenance strategies in naval systems is driving the development of advanced techniques for early failure diagnosis. This dissertation presents a methodology for automatically classifying single-misfire injection failures in marine diesel engines using vibration signals and Artificial Neural Networks (ANNs).

The methodology involves the acquisition and analysis of vibration signals collected by accelerometers installed in an MTU 12V4000C11 diesel engine, evaluated in the time, frequency, and time-frequency domains. Statistical characteristics such as RMS, kurtosis, energy, and entropy were extracted and used as inputs in supervised learning models.

Optimization of the data acquisition and processing system was a key contribution, reducing the number of sensors without significantly losing diagnostic accuracy. The selection and optimal positioning of the accelerometers were based on the relevance of vibration signature characteristics for fault identification. Experimental results indicated that ANNs achieved F1-scores above 99%, demonstrating high accuracy even with fewer sensors. The methodology proved effective and economically viable for application in embedded systems, directly benefiting predictive maintenance in the Brazilian Navy.

# Sumário

SUMÁRIO .....	9
LISTA DE FIGURAS .....	12
LISTA DE TABELAS .....	14
1. INTRODUÇÃO .....	16
1.1 MOTIVAÇÃO .....	17
1.2 OBJETIVOS .....	18
1.3 CONTRIBUIÇÕES DA DISSERTAÇÃO .....	19
1.4 ORGANIZAÇÃO DA DISSERTAÇÃO .....	19
2. REVISÃO BIBLIOGRÁFICA .....	22
3. FUNDAMENTAÇÃO TEÓRICA .....	34
3.1. ANÁLISE DAS ASSINATURAS DE VIBRAÇÃO .....	34
3.1.1. RELAÇÃO ENTRE O DOMÍNIO DO TEMPO E O DOMÍNIO DA FREQUÊNCIA NA ANÁLISE DE VIBRAÇÃO .....	34
3.1.2. ESTATÍSTICA APLICADA AO PROCESSAMENTO DE SINAIS .....	36
3.1.3. ANÁLISE DE OUTLIERS .....	38
3.1.4. “MALDIÇÃO DA DIMENSIONALIDADE” .....	39
3.2. EXTRAÇÃO DE CARACTERÍSTICAS .....	41
3.3. RELIEF-F - SELEÇÃO DE VARIÁVEIS E REDUÇÃO DE DIMENSIONALIDADE .....	46
3.4. FUNDAMENTOS DE APRENDIZADO DE MÁQUINA .....	49
3.4.1. APRENDIZADO SUPERVISIONADO E GENERALIZAÇÃO DE MODELOS .....	49
3.4.2. O DILEMA <i>BIAS-VARIANCE</i> NO CONTEXTO DO APRENDIZADO SUPERVISIONADO .....	50
3.4.3. DIVISÃO DOS DADOS EM CONJUNTOS DE TREINAMENTO, VALIDAÇÃO E TESTE .....	51
3.4.4. REGULARIZAÇÃO - L2 (RIDGE) E L1 (LASSO) .....	53
3.5. REDES NEURAIS ARTIFICIAIS (RNAs) .....	55
3.5.1. ESTRUTURA E FUNDAMENTOS MATEMÁTICOS: TEOREMA DA APROXIMAÇÃO UNIVERSAL .....	55
3.5.2. ESTRUTURA E FUNCIONAMENTO DE REDES NEURAIS <i>FEEDFORWARD</i> .....	57
3.5.3. FUNÇÕES DE ATIVAÇÃO E CUSTO .....	59

3.5.4.	REDES NEURAIS DE FUNÇÃO DE BASE RADIAL (RBF) .....	61
3.5.5.	ALGORITMOS DE OTIMIZAÇÃO PARA TREINAMENTO DE REDES NEURAIS .....	63
3.6.	MÉTRICAS DE AVALIAÇÃO DE DESEMPENHO .....	65
3.6.1.	PRECISÃO (PRECISION) .....	65
3.6.2.	SENSIBILIDADE (RECALL).....	66
3.6.3.	ACURÁCIA (ACCURACY) .....	66
3.6.4.	F1-SCORE .....	67
4.	METODOLOGIA .....	68
4.1.	PRÉ-PROCESSAMENTO DE DADOS .....	68
4.2.	PROCESSAMENTO DE DADOS.....	70
4.3.	REDES NEURAIS ARTIFICIAIS.....	71
5.	ESTUDO DE CASO .....	74
5.1	CARACTERIZAÇÃO DO CONJUNTO MOTOR DIESEL E DINAMÔMETRO .....	74
5.1.1.	INJEÇÃO ELETRÔNICA PILOTO E OTIMIZAÇÃO DA COMBUSTÃO .....	78
5.1.2.	INJETORES ELETRÔNICOS UNITÁRIOS .....	78
5.2	DETROIT DIESEL DIAGNOSTIC LINK (DDDL) .....	79
5.3	SISTEMA DE AQUISIÇÃO DE DADOS .....	81
5.3.1.	ARQUITETURA DO SISTEMA DE AQUISIÇÃO.....	82
5.3.2.	TRANSDUTORES INSTALADOS .....	83
5.4	SOFTWARE DE AQUISIÇÃO .....	84
5.5	PROCEDIMENTO EXPERIMENTAL .....	85
5.6	UTILIZAÇÃO FUTURA DOS DADOS COLETADOS EM 1800 RPM.....	88
6.	RESULTADOS E DISCUSSÕES .....	90
6.1	APRESENTAÇÃO GERAL DOS DADOS .....	90
6.2	RESULTADOS NO DOMÍNIO DO TEMPO.....	90
6.2.1.	DESEMPENHO COM DIFERENTES QUANTIDADES DE CARACTERÍSTICAS E ACELERÔMETROS .....	90
6.2.2.	FREQUÊNCIA E CONTRIBUIÇÃO DOS ACELERÔMETROS MAIS RELEVANTES.....	94
6.2.3.	RANQUEAMENTO DAS 27 CARACTERÍSTICAS ESTATÍSTICAS NO DOMÍNIO DO TEMPO.....	102

6.3	RESULTADOS NO DOMÍNIO DA FREQUÊNCIA .....	102
6.3.1.	ANÁLISE COMPARATIVA DE DESEMPENHO COM DIFERENTES QUANTIDADES DE CARACTERÍSTICAS E ACELERÔMETROS .....	102
6.3.2.	FREQUÊNCIA E CONTRIBUIÇÃO DOS ACELERÔMETROS MAIS RELEVANTES .....	106
6.3.3.	RANQUEAMENTO DAS 27 CARACTERÍSTICAS ESTATÍSTICAS NO DOMÍNIO DA FREQUÊNCIA .....	114
6.4	RESULTADOS NO DOMÍNIO TEMPO-FREQUÊNCIA .....	115
6.4.1.	DESEMPENHO COM DIFERENTES QUANTIDADES DE CARACTERÍSTICAS E ACELERÔMETROS .....	115
6.4.2.	FREQUÊNCIA E CONTRIBUIÇÃO DOS ACELERÔMETROS MAIS RELEVANTES .....	118
6.4.3.	RANQUEAMENTO DAS 54 CARACTERÍSTICAS ESTATÍSTICAS NO DOMÍNIO DA TEMPO-FREQUÊNCIA .....	126
7.	CONCLUSÕES .....	133
8.	SUGESTÕES PARA TRABALHOS FUTUROS .....	134
9.	REFERÊNCIAS BIBLIOGRÁFICAS .....	135

## Lista de Figuras

Figura 1 - Diagrama da Relação entre o Domínio do Tempo e o Domínio da Frequência .....	36
Figura 2 - Comportamento da Função $1/(p(1-p))$ .....	53
Figura 3 - Fluxograma Geral da Metodologia para Classificação de Falhas de Injeção em Motor Diesel utilizando Sinais de Vibração e Redes Neurais Artificiais.....	68
Figura 4 - Pontos de instalação dos acelerômetros.....	69
Figura 5 - Vista Geral do Motor MTU 12V4000 e do Dinamômetro Prüftechnik BFBg 2h .....	74
Figura 6 - Esquema de um Sistema Common Rail. Fonte: BASSHUYSEN; SCHÄFER (2004). ....	77
Figura 7 - Ciclo de Injeção Multipulso do Sistema Common Rail Controlado por DDEC IV. Fonte: Rolls-Royce. ....	78
Figura 8 - Interface gráfica do software Detroit Diesel Diagnostic Link.....	80
Figura 9 - Tela da Janela de Corte de Injeção de Combustível, do DDDL, no Cabeçote A3 ou 3V ...	81
Figura 10 - Vista do Conjunto Motor-Dinamômetro.....	82
Figura 11 - Instalação do Tacômetro e do Sistema Torque Track.....	83
Figura 12 - Disposição dos acelerômetros nos cabeçotes e no bloco do motor MTU 12V4000C11 ...	84
Figura 13 - Interface gráfica do software LabVIEW™ utilizada para aquisição de sinais de vibração do motor MTU 12V4000C11 .....	85
Figura 14 - Comparativo de F1-Score - Domínio do Tempo .....	91
Figura 15 - F1-Score e Tempo de Processamento (Domínio do Tempo - 27 Características).....	92
Figura 16 - Melhores F1-Score e Tempo de Processamento por Cenário no Domínio do Tempo .....	93
Figura 17 - Localização dos Acelerômetros Mais Relevantes (Domínio do Tempo) .....	95
Figura 18 - Frequência de seleção dos melhores acelerômetros (Domínio do Tempo) .....	95
Figura 19 - Matriz de Confusão do melhor resultado obtido no Domínio do Tempo.....	98
Figura 20 - Função de custo por entropia cruzada durante o processo de treinamento da RNA no Domínio do Tempo.....	99
Figura 21 - Gradiente x Épocas no Domínio do Tempo.....	100
Figura 22 - Histograma de Erros no Domínio do Tempo.....	101
Figura 23 - Ranqueamento das 27 Características no Domínio do Tempo .....	102
Figura 24 - F1-Score por N° de Características - Domínio da Frequência.....	103
Figura 25 - F1-Score x Tempo de Processamento (Domínio da Frequência - 27 Características) ....	105
Figura 26 - F1-Score e Tempo de Processamento por Cenário no Domínio da Frequência .....	105
Figura 27 - Localização dos acelerômetros no motor Diesel (bancada A em destaque).....	107



Figura 28 - Frequência de seleção dos melhores acelerômetros no Domínio da Frequência.....	107
Figura 29 - Matriz de Confusão do melhor resultado obtido no Domínio da Frequência.....	110
Figura 30 - Função de custo por entropia cruzada durante o processo de treinamento da RNA no Domínio da Frequência .....	111
Figura 31 - Gradiente x Épocas no Domínio da Frequência .....	112
Figura 32 - Histograma de Erros no Domínio da Frequência.....	113
Figura 33 - Ranqueamento das 27 Características no Domínio da Frequência.....	115
Figura 34 - F1-Score por Número de Características no Domínio Tempo-Frequência .....	116
Figura 35 - F1-Score e Tempo de Processamento no Domínio Tempo-Frequência (54 Características) .....	117
Figura 36 - F1-Score e Tempo de Processamento por Cenário no Domínio Tempo-Frequência .....	118
Figura 37 - Localização dos Acelerômetros com melhores desempenhos .....	119
Figura 38 - Frequência de seleção dos melhores acelerômetros no Domínio Tempo-Frequência.....	120
Figura 39 - Matriz de Confusão do melhor resultado obtido no Domínio Tempo-Frequência.....	122
Figura 40 - Função de custo por entropia cruzada durante o processo de treinamento da RNA no Domínio Tempo-Frequência.....	123
Figura 41 - Gradiente x Épocas no Domínio Tempo-Frequência .....	124
Figura 42 - Histograma de Erros no Domínio Tempo-Frequência.....	125
Figura 43 - Ranqueamento das 54 Características no Domínio da Tempo-Frequência .....	126
Figura 44 - Melhores F1-Scores por Domínio de Análise.....	127
Figura 45 - Gráfico Radar Plot comparando os 3 Domínios Estudados.....	128

## Lista de Tabelas

Tabela 1 - Falhas em motores Diesel eletrônicos organizadas por natureza (mecânicas, elétricas, eletrônicas, estruturais/instalação e operacionais/combustão), com referências de base da literatura técnica. ....	22
Tabela 2 - Características Estatísticas Extraídas no Domínio do Tempo .....	42
Tabela 3 - Características Estatísticas Extraídas no Domínio da Frequência.....	44
Tabela 4 - Principais componentes da arquitetura da Rede Neural Artificial adotada.....	72
Tabela 5 - Especificações Técnicas – Motor Diesel MTU 12V4000C11 .....	75
Tabela 6 - Dimensões / Peso Aproximado .....	76
Tabela 7 - Centro de Gravidade (Motor Seco) .....	76
Tabela 8 - Dados de Desempenho do MTU 12V4000C11.....	76
Tabela 9 - Dados Técnicos do Dinamômetro .....	76
Tabela 10 - Cenários Simulados e Utilizados.....	86
Tabela 11 - Cenários Simulados e Não Utilizados .....	87
Tabela 12 - Intervalos de Hiperparâmetros Utilizados na Modelagem com RNA.....	90
Tabela 13 - Resultados com melhores acelerômetros nos cenários avaliados no Domínio do Tempo	94
Tabela 14 - Precisões de Treinamento, Validação e Testes obtidas no Domínio do Tempo em diferentes configurações de número de acelerômetros e características estatísticas .....	96
Tabela 15 - Resultados com melhores acelerômetros nos cenários avaliados no Domínio da Frequência .....	106
Tabela 16 - Precisões de Treinamento, Validação e Testes obtidas no Domínio da Frequência em diferentes configurações de número de Acelerômetros e Características Estatísticas .....	109
Tabela 17 - Resultados com melhores acelerômetros nos cenários avaliados no Domínio Tempo-Frequência .....	119
Tabela 18 - Precisões de Treinamento, Validação e Testes obtidas no Domínio Tempo-Frequência em diferentes configurações de número de Acelerômetros e Características Estatísticas .....	121
Tabela 19 - Métricas de Desempenho por Domínio.....	128
Tabela 20 - Comparação de desempenho entre GUERRA (2023) e o presente estudo utilizando 3 acelerômetros no Domínio do Tempo .....	131

## SIGLAS

<b>Sigla</b>	<b>Definição</b>
2DCNN-LSTM	Arquitetura híbrida 2D-CNN + LSTM
ANN	Artificial Neural Network
CNN	Convolutional Neural Network (Rede Neural Convolucional)
CWT	Continuous Wavelet Transform (Transformada Wavelet Contínua)
DBSCAN	Density-Based Spatial Clustering of Applications with Noise
EMD	Empirical Mode Decomposition (Decomposição Empírica de Modo)
FAR	False Alarm Rate
FDI	Fault Diagnosis and Isolation
FDR	Fault Detection Rate
FEM	Finite Element Method (Método dos Elementos Finitos)
FFT	Fast Fourier Transform (Transformada Rápida de Fourier)
HDA	Hierarchical Decision Architecture
ICA	Independent Component Analysis (Análise de Componentes Independentes)
K-NN	K-Nearest Neighbors
LOF	Local Outlier Factor
LSTM	Long Short-Term Memory (Rede Neural Recorrente de Memória de Longo e Curto Prazo)
RBF	Radial Basis Function (Rede Neural de Função de Base Radial)
RF	Random Forest
RNA	Rede Neural Artificial
RNN	Recurrent Neural Network (Rede Neural Recorrente)
STFT	Short-Time Fourier Transform (Transformada de Fourier de Curto Tempo)
SVM	Support Vector Machine
TDC	Top Dead Center (Ponto Morto Superior)
XGBoost	Extreme Gradient Boosting

# 1. INTRODUÇÃO

O percurso histórico da análise de vibrações acompanha, de forma bastante próxima, o avanço das ciências físicas e matemáticas desde o Renascimento. Nos séculos XVII e XVIII, nomes como Galileu Galilei, Robert Hooke, Isaac Newton, Leonhard Euler, Daniel Bernoulli e Jean le Rond d'Alembert ajudaram a construir os fundamentos da disciplina. Galileu, por exemplo, ao estudar o movimento pendular, demonstrou que o período de oscilação de um pêndulo independe da amplitude (para pequenas oscilações), descoberta que deu origem tanto aos relógios de pêndulo quanto a modelos matemáticos de sistemas oscilatórios simples (DRAKE, 1978). Pouco depois, Hooke formulou a lei que leva seu nome, estabelecendo a relação linear entre força e deformação e abrindo caminho para a modelagem elástica de sistemas vibratórios (TIMOSHENKO, 1983).

As contribuições de Newton e Euler, cada um à sua maneira, trouxeram a formalização matemática da dinâmica e da teoria de vigas e barras (THOMSON, 1981). Ao mesmo tempo, Bernoulli explorava as cordas vibrantes e seus modos naturais, enquanto d'Alembert elaborava a equação de onda, pilares da teoria ondulatória (RAYLEIGH, 1877). Essas descobertas criaram a base que, séculos depois, permitiria o desenvolvimento de métodos modernos de medição e de estratégias de prevenção de falhas estruturais.

No século XIX, a obra de Fourier introduziu a ideia de decompor sinais em séries de harmônicos, um conceito que só ganharia total força no século XX com a Transformada Rápida de Fourier (FFT), desenvolvida por Cooley e Tukey em 1965, revolucionando a análise espectral. Nesse mesmo período, Lord Rayleigh consolidava a análise modal ao formalizar os conceitos de frequências naturais e modos normais em sua obra *The Theory of Sound* (RAYLEIGH, 1877). Somaram-se a isso a formulação matemática do oscilador harmônico e os estudos sobre amortecimento estrutural, viscoso e aerodinâmico (EWINS, 2000), que trouxeram a análise vibratória para mais perto da engenharia prática.

Com o avanço dos computadores na segunda metade do século XX, a disciplina deu um salto ainda maior. Métodos numéricos, como o dos Elementos Finitos (FEM), permitiram a análise de sistemas com múltiplos graus de liberdade, geometrias complexas e condições de contorno arbitrárias (ZIENKIEWICZ; TAYLOR, 2000).

Já no século XXI, a análise de vibrações deixou de ser uma área restrita à física e à matemática para se integrar à ciência de dados e à inteligência artificial. Redes neurais

convolucionais e recorrentes (CNNs e LSTMs), por exemplo, vêm sendo aplicadas diretamente em sinais brutos, reconhecendo padrões sem a necessidade de extração manual de características. Trabalhos recentes mostram a aplicação dessas arquiteturas tanto em mancais de motores elétricos (HUU et al., 2025), como em modelos híbridos que combinam transformadas espectrais e redes profundas (PRAWIN, 2024). Também despontam abordagens probabilísticas, como redes Bayesianas e métodos não paramétricos, capazes de lidar com incertezas e prever falhas com maior antecedência (GU et al., 2025; TABANDEH; GARDONI, 2021; DIAZDELAO et al., 2013).

Essa evolução é, cada vez mais, multidisciplinar. A análise de vibrações hoje conversa com a ciência dos materiais, explorando correlações entre microestrutura e resposta dinâmica; com a robótica, por meio do uso de drones e robôs escaladores para coleta de dados em locais de difícil acesso (TIAN et al., 2022); e com a ciência de dados, que oferece algoritmos para extrair significado de sinais altamente complexos.

Olhando para o futuro, a integração com tecnologias emergentes, como gêmeos digitais, sistemas ciberfísicos e Internet das Coisas (IoT), deve transformar a análise de vibrações em uma das principais ferramentas de monitoramento inteligente. A possibilidade de simular cenários operacionais em tempo real, prever a integridade estrutural de embarcações e realizar diagnósticos automáticos com base em sensores distribuídos indica que estamos diante de um campo que não apenas acompanha, mas impulsiona a engenharia do futuro.

Desta forma, o foco do presente estudo é propor um sistema de classificação de falhas de injeção em motores Diesel marítimos com elevada acurácia e otimizar o processo de aquisição de dados, reduzindo a necessidade de sensores físicos sem comprometer a confiabilidade diagnóstica.

## **1.1 Motivação**

A crescente demanda por estratégias de manutenção baseadas em condição nos sistemas navais tem impulsionado o desenvolvimento de métodos robustos para detecção e diagnóstico precoce de falhas. Neste contexto, esta pesquisa propõe uma abordagem baseada na análise de sinais de vibração provenientes de máquinas alternativas, com foco na viabilidade de sua aplicação em ambientes operacionais da Marinha do Brasil. A automação do processo de diagnóstico, por meio de técnicas de processamento de sinais e aprendizado de máquina, visa reduzir a dependência de avaliações subjetivas realizadas por operadores humanos, mitigando erros de interpretação e aumentando a confiabilidade

do monitoramento da integridade estrutural dos sistemas mecânicos embarcados (WANG et al., 2022; ZHANG et al., 2021). A utilização de sinais de vibração como fonte primária de informação diagnóstica é amplamente validada na literatura como uma ferramenta sensível e não invasiva, especialmente eficaz na detecção de falhas em componentes móveis, como mancais, válvulas e pistões (JARDINE et al., 2006; LEI et al., 2018).

Adicionalmente, a pesquisa investiga a possibilidade de otimização do sistema de aquisição de dados por meio da redução do número de sensores físicos, sem comprometimento da acurácia diagnóstica, com o objetivo de diminuir custos operacionais e facilitar a implementação em plataformas navais. Tal proposta está alinhada com tendências contemporâneas de monitoramento de condição baseado em sensores inteligentes e técnicas de compressão de informação (JIA et al., 2020).

Ao integrar tais metodologias em um sistema de manutenção preditiva, espera-se aumentar significativamente a disponibilidade operacional dos meios, reduzir falhas inesperadas e promover uma gestão mais eficiente do ciclo de vida dos ativos, contribuindo para a consolidação de uma doutrina de manutenção centrada na confiabilidade dentro do escopo da engenharia naval moderna.

## **1.2 Objetivos**

O objetivo central desta pesquisa é desenvolver e validar uma abordagem baseada em algoritmos de inteligência artificial, com ênfase em Redes Neurais Artificiais (RNAs), para a detecção e identificação de falhas de injeção em motores Diesel, especificamente falhas do tipo “single misfire” (perda de combustão em um único cilindro). Para isso, são utilizados sinais de vibração no Domínio do Tempo e da Frequência, adquiridos por meio de acelerômetros instalados diretamente no bloco e nos cabeçotes do motor Diesel.

A escolha desses tipos de sinais visa explorar seu alto grau de sensibilidade a anomalias mecânicas e seu potencial como ferramenta não invasiva para o diagnóstico de falhas. Em paralelo, a pesquisa busca reduzir a complexidade e o custo do sistema de aquisição por meio da minimização do número de sensores utilizados, bem como do número de características extraídas dos sinais, sem comprometer a acurácia da classificação.

A integração desses elementos visa propor uma solução eficiente, de baixo custo e tecnicamente viável para aplicação em sistemas embarcados de monitoramento de condição, contribuindo para estratégias de manutenção preditiva em motores de

combustão interna utilizados em ambientes operacionais críticos, como os da Marinha do Brasil.

### **1.3 Contribuições da Dissertação**

As contribuições desta dissertação concentram-se em avanços metodológicos e práticos no campo do diagnóstico de falhas em motores de combustão interna, com ênfase na aplicabilidade em sistemas navais operacionais. Primeiramente, propõe-se uma abordagem inovadora para a identificação automática de falhas de injeção do tipo single misfire em motores Diesel, utilizando sinais de vibração no Domínio do Tempo como principal fonte de informação diagnóstica. Essa escolha fundamenta-se em seu caráter não invasivo, alta sensibilidade a anomalias mecânicas e ampla aceitação na literatura técnica como meio eficaz de monitoramento de integridade estrutural.

Em paralelo, a dissertação avança na direção da otimização do sistema de aquisição de dados, propondo uma metodologia de minimização tanto do número de sensores (acelerômetros) quanto das características extraídas, mantendo a acurácia classificatória. Isso resulta em um sistema mais econômico e de fácil implementação, crucial para viabilizar sua adoção em meios navais.

Além disso, é realizada uma análise sistemática de posicionamento dos sensores no bloco do motor, buscando maximizar a representatividade dos sinais adquiridos com o menor número de dispositivos. A integração dessas contribuições não apenas fortalece o uso de inteligência artificial no monitoramento de condição, mas também consolida uma arquitetura de diagnóstico automatizado com potencial de aplicação em ambientes reais, contribuindo diretamente para a modernização das estratégias de manutenção preditiva da Marinha do Brasil.

### **1.4 Organização da Dissertação**

O Capítulo 2 reúne a revisão bibliográfica, abordando métodos de monitoramento de condição em motores Diesel, técnicas de detecção de falhas de injeção com sinais de vibração e a aplicação de algoritmos de aprendizado de máquina nesse contexto. São analisadas contribuições relevantes da literatura que validam o uso de sinais de vibração como ferramenta diagnóstica não invasiva e sua correlação com parâmetros de combustão e desempenho do motor.

No Capítulo 3 são apresentados os fundamentos teóricos que sustentam a pesquisa. Discute-se a relação entre os domínios do tempo e da frequência na análise de vibração, os princípios da estatística aplicados ao processamento de sinais e a influência de outliers nos modelos preditivos. Também são explorados conceitos como a maldição da dimensionalidade, técnicas de extração de características, algoritmos de seleção de variáveis (Relief-F) e fundamentos de aprendizado supervisionado, incluindo o dilema *bias-variance* e os métodos de regularização L1 e L2.

O Capítulo 4 descreve a metodologia adotada, estruturada em três blocos principais: pré-processamento dos sinais de vibração (com filtragem, detrending, segmentação e data augmentation), processamento dos dados (tratamento de outliers, seleção de características e sensores via Relief-F e normalização dos dados) e modelagem com Redes Neurais Artificiais (RNA). São detalhados os principais componentes da arquitetura utilizada, incluindo a função de ativação radial (RBF), o algoritmo de treinamento e a otimização bayesiana de hiperparâmetros.

O Capítulo 5 apresenta o estudo de caso, baseado no motor Diesel marítimo MTU 12V4000C11 acoplado a um dinamômetro. Descreve-se a instrumentação com 15 acelerômetros instalados nos cabeçotes e no bloco, o sistema de aquisição de dados com placas NI 9234 e software LabVIEW™, e a indução controlada de falhas de injeção por meio do software Detroit Diesel Diagnostic Link (DDDL). Foram simuladas 39 condições experimentais, incluindo operação normal e falhas individuais em cada cilindro, resultando em uma base robusta de dados de vibração para treinamento e validação das RNAs.

No Capítulo 6 são apresentados e discutidos os resultados obtidos em três domínios de análise (Tempo, Frequência e Tempo-Frequência). Os experimentos mostram que, mesmo com configurações enxutas de sensores e características, foi possível alcançar F1-Scores superiores a 99%, confirmando a robustez da metodologia. A análise também evidenciou o impacto da maldição da dimensionalidade quando há excesso de atributos ou sensores, bem como a relevância da posição dos acelerômetros, com destaque para aqueles instalados sobre os cabeçotes dos cilindros.

O Capítulo 7 traz a conclusão do trabalho, ressaltando a contribuição da dissertação no desenvolvimento de um sistema inteligente, otimizado e de baixo custo computacional para diagnóstico de falhas de injeção em motores Diesel marítimos. Destaca-se a aplicabilidade da solução para sistemas embarcados em tempo real e o desempenho competitivo frente a algoritmos clássicos (SVM, K-NN e Random Forest).



Também são indicadas perspectivas para pesquisas futuras, como a expansão da metodologia para outros tipos de falhas mecânicas e a integração em sistemas autônomos de monitoramento.

Por fim, a dissertação é complementada pelas Referências Bibliográficas (Capítulo 8) que sustentam a teoria da pesquisa.

## 2. REVISÃO BIBLIOGRÁFICA

A seguir são apresentados trabalhos que serviram como embasamento para o desenvolvimento deste trabalho, onde são descritos detalhes de forma resumida da elaboração e resultados de diversos pesquisadores. Os assuntos tratados serão: métodos de diagnóstico de falhas de injeção, métodos de monitoração da condição de motor Diesel, métodos de detecção de falhas em injetores de motores a Diesel através da análise de vibração e o uso de sinais de vibração para monitorar o desempenho de um motor a combustão interna.

No contexto da literatura técnica e acadêmica, diversos autores destacam que motores Diesel eletrônicos estão sujeitos a diferentes tipos de falhas, que podem comprometer tanto o desempenho quanto a confiabilidade do sistema. Essas falhas podem ser de natureza mecânica, elétrica, eletrônica, estrutural ou operacional, abrangendo desde desgaste de componentes móveis até defeitos em sensores e atuadores controlados pela unidade de gerenciamento eletrônico. A Tabela 1 sintetiza as principais falhas reportadas na literatura, apresentando uma visão organizada e referenciada das ocorrências mais comuns em motores Diesel eletrônicos.

*Tabela 1 - Falhas em motores Diesel eletrônicos organizadas por natureza (mecânicas, elétricas, eletrônicas, estruturais/instalação e operacionais/combustão), com referências de base da literatura técnica.*

Falhas em motores Diesel eletrônicos	Referência bibliográfica
<b>Falhas mecânicas:</b> desgaste de pistões, anéis, válvulas e bronzinas; perda de compressão; falha de lubrificação; travamento; falha em turbocompressor; trincas em cabeçote/bloco; válvulas queimadas ou mal assentadas	Heywood, J. B. (2018). <i>Internal Combustion Engine Fundamentals, 2nd Ed.</i> McGraw-Hill
<b>Falhas operacionais/combustão:</b> falhas de injeção (entupimento/desgaste); combustível contaminado; “wet stacking” (combustão incompleta em baixa carga); detonação/pré-ignição anômala	Shirazi, S. A., et al. (2018). Mechanical Systems and Signal Processing; Zhao, H. (2009). Advanced Direct Injection Combustion Engine Technologies and Development. Woodhead

<b>Falhas elétricas:</b> bateria e alternador defeituosos; mau contato em cabos e conectores; curtos em chicotes expostos a calor e vibração	Robert Bosch GmbH. (2004). Diesel Engine Management: Systems and Components. Wiley
<b>Falhas eletrônicas:</b> sensores defeituosos (pressão, temperatura, rotação/cames); atuadores falhando (EGR, injetores); ECU/ECM com erro de firmware, sobreaquecimento ou memória corrompida; problemas de sincronização de sensores	Mollenhauer, K., & Tschoeke, H. (2010). Handbook of Diesel Engines. Springer
<b>Falhas de instalação/estruturais:</b> desalinhamento de eixos e suportes; vedação deficiente em juntas; fixação inadequada de sensores; ressonâncias estruturais causando vibração e trincas.	Stone, R. (2012). Introduction to Internal Combustion Engines, 4th Ed. Palgrave Macmillan

CHARLES et al. (2009) propuseram um método para detectar as vibrações torcionais do virabrequim de motores a Diesel, a fim de monitorar e melhorar o desempenho do motor em tempo real.

Os autores explicam que as vibrações torcionais do virabrequim estão diretamente relacionadas às características da combustão do motor, como o tempo de início da combustão, a taxa de combustão e a estabilidade da combustão. Assim, a medição das vibrações torcionais pode fornecer informações úteis sobre a qualidade da combustão e o desempenho do motor.

Para medir as vibrações torcionais do virabrequim, os autores utilizaram sensores de vibração fixados no virabrequim e em outras partes do motor. Eles analisaram as vibrações torcionais em diferentes condições de operação e correlacionaram as vibrações com as características da combustão medidas por outros sensores do motor, como sensores de pressão e temperatura.

Os resultados mostraram que as vibrações torcionais do virabrequim podem ser usadas para monitorar e diagnosticar as características da combustão em motores a Diesel em tempo real. Os autores sugerem que a técnica de diagnóstico pode ser usada para

melhorar o desempenho do motor, ajustando os parâmetros de controle do motor com base nas informações fornecidas pelas vibrações torcionais do virabrequim.

CHEN et al. (2015) aprimoraram um método de diagnóstico de falhas de ignição em motores de combustão interna, com base em modelos de simulação. Os autores explicam que a detecção precoce e precisa de falhas de ignição é essencial para o desempenho e a eficiência do motor, além de minimizar danos ao motor e reduzir emissões de poluentes. No entanto, as técnicas atuais de diagnóstico são limitadas pela complexidade do sistema e pela variabilidade das condições de operação.

O método proposto pelos autores baseia-se em modelos de simulação do motor que incluem os efeitos da combustão, fluidodinâmica e termoquímica. O modelo é calibrado com dados experimentais para fornecer uma simulação precisa do motor e sua operação sob diferentes condições de operação.

O método de diagnóstico usa um algoritmo de detecção de falhas que analisa os sinais de sensores do motor para detectar desvios dos valores esperados, indicando uma falha de ignição. Os sinais de sensor são comparados com as previsões do modelo de simulação para identificar a causa da falha de ignição, como o tempo de ignição ou a quantidade de combustível injetada.

Os resultados experimentais mostraram que o método proposto tem melhor desempenho do que as técnicas atuais de diagnóstico de falhas de ignição em motores de combustão interna. Os autores concluem que o uso de modelos de simulação pode melhorar significativamente a precisão e a eficácia do diagnóstico de falhas de ignição em motores de combustão interna, permitindo melhorias no desempenho e na eficiência do motor.

GAWANDE (2012) trata de um método de detecção de falhas em motores Diesel, utilizando o torque do motor e a medição da massa de ar. O método utiliza o torque do motor e a massa de ar para identificar possíveis falhas, como problemas de combustão, desgaste de pistões e falhas no sistema de injeção de combustível. Para isso, o método analisa as variações dessas grandezas em diferentes condições de operação do motor, e utiliza um modelo matemático para identificar as falhas.

O artigo apresenta os resultados da aplicação do método em um motor Diesel de quatro tempos, e os resultados mostraram que o método foi capaz de identificar as falhas com alta precisão. Além disso, o método proposto é não invasivo e pode ser facilmente aplicado em motores Diesel, já que as grandezas utilizadas para a detecção das falhas são fáceis de medir.

JUNG (2015) desenvolveu um algoritmo de detecção de falhas de ignição em motores de combustão interna, utilizando análise quantitativa de desempenho de diagnóstico de falhas (FDI). O algoritmo proposto utiliza um modelo matemático do motor, juntamente com técnicas de análise de sinais, para identificar possíveis falhas de ignição. O desempenho do algoritmo é avaliado utilizando métricas de desempenho de diagnóstico de falhas, como a taxa de detecção de falhas (FDR) e a taxa de falso alarme (FAR).

Os resultados da validação experimental mostram que o algoritmo proposto é capaz de detectar com sucesso as falhas de ignição em diferentes condições de operação do motor, com uma taxa de detecção de falhas superior a 90% e uma taxa de falso alarme abaixo de 1%.

A principal contribuição do artigo é apresentar um algoritmo de detecção de falhas de ignição preciso e confiável, que pode ser útil para melhorar a eficiência energética e a confiabilidade de motores de combustão interna. Além disso, o uso de métricas quantitativas de desempenho de diagnóstico de falhas ajuda a avaliar objetivamente o desempenho do algoritmo e a compará-lo com outros métodos existentes.

KLINCHAEAM (2009) descreve um método para monitorar a condição de um pequeno motor a gasolina de quatro tempos usando sinais de vibração. O artigo começa discutindo a importância da monitorização de condições em motores a combustão interna e os métodos disponíveis para fazer isso. Em seguida, o autor apresenta uma visão geral do motor de quatro tempos usado no estudo, juntamente com a configuração experimental e as técnicas de medição utilizadas.

O método proposto para monitorar a condição do motor é baseado na análise do espectro de frequência dos sinais de vibração. As características do espectro são usadas para identificar padrões que indicam a condição do motor. Os autores usam o algoritmo de aprendizado de máquina SVM para classificar os padrões do espectro de frequência em três classes: normal, problema mecânico e problema de combustão.

Os resultados mostram que o método proposto é capaz de identificar com precisão a condição do motor, mesmo com níveis baixos de vibração. O método também é capaz de detectar problemas em estágios iniciais, o que pode permitir a manutenção preventiva antes que ocorram danos mais graves.

MEDEIROS et al. (2018) apresentaram uma técnica para detecção de falhas em injetores de motores a Diesel, utilizando a análise de vibração e nível de pressão sonora.

O objetivo do estudo é identificar falhas nos injetores de combustível em estágios iniciais, antes que essas falhas afetem o desempenho do motor e aumentem as emissões poluentes. O artigo apresenta resultados experimentais de testes realizados em um motor a Diesel com diferentes graus de contaminação nos injetores.

Os resultados mostram que a técnica proposta é capaz de identificar com precisão as falhas nos injetores de combustível. O estudo é uma contribuição importante para o campo da detecção de falhas em motores a Diesel, podendo ajudar na prevenção de problemas de desempenho e emissões em motores a Diesel.

SHIRAZI (2018) aborda a detecção de falhas na injeção de combustível em motores Diesel usando análise de vibração. O artigo propõe um método para detectar falhas em injetores de combustível, que podem levar a problemas como consumo excessivo de combustível, emissões poluentes e perda de potência.

O método proposto usa sensores de vibração para medir a resposta do motor em diferentes frequências e extrai características de vibração relevantes para a detecção de falhas na injeção de combustível. Os autores do artigo apresentam resultados experimentais que demonstram a eficácia do método proposto em detectar falhas em injetores de combustível em um motor Diesel.

TAGHIZADEH-ALISARAEI (2018) propuseram um método para detecção de falhas nos injetores de combustível em motores a Diesel, usando análise de vibração. O método proposto envolve o uso de um algoritmo de análise de componentes independentes (ICA) para decompor o sinal de vibração em componentes independentes, que são analisados em termos de sua energia e distribuição de frequência para identificar quaisquer anomalias nas características do sinal.

Os autores do artigo apresentaram resultados experimentais que demonstraram a eficácia do método proposto na detecção de falhas nos injetores de combustível em um motor a Diesel. Além disso, eles compararam os resultados com outras técnicas de detecção de falhas de injetores e mostraram que o método proposto é mais preciso e eficaz do que as técnicas existentes.

NARAYAN et al. (2019) investigaram a possibilidade de usar sinais de acelerômetro para monitorar a combustão em motores de combustão interna. No artigo, os autores descrevem como usaram um acelerômetro para medir as vibrações do motor durante o ciclo de combustão. Eles analisaram as características dessas vibrações, como amplitude, frequência e tempo de duração, e as correlacionaram com a qualidade da combustão. Para fazer isso, os autores realizaram uma série de testes em um motor de

quatro tempos e analisaram os sinais do acelerômetro em diferentes condições de operação do motor.

Os resultados do estudo mostraram que os sinais do acelerômetro podem ser usados para monitorar a qualidade da combustão em motores de combustão interna. Os autores também compararam os resultados obtidos usando sinais do acelerômetro com os resultados obtidos usando outros métodos de monitoramento de combustão, como a medição da pressão do cilindro, e mostraram que os sinais do acelerômetro podem ser tão precisos quanto outros métodos mais tradicionais.

JOHNSSON et al. (2006) apresentaram um método para reconstruir a pressão do cilindro em motores de combustão interna a partir de sinais de vibração e velocidade. Os autores usaram uma rede de função de base radial (RBF) complexa para mapear os sinais de vibração e velocidade do motor para a pressão do cilindro. A rede foi treinada usando dados experimentais coletados de um motor de quatro tempos.

Os resultados mostraram que o método proposto pode ser usado para reconstruir a pressão do cilindro com alta precisão. Os autores também compararam seus resultados com os obtidos usando outros métodos de reconstrução de pressão, como o método de filtragem de Kalman, e mostraram que o método proposto apresentou melhor desempenho.

BUSINARO et al. (2015) apresentaram uma metodologia baseada em acelerômetros para estimar parâmetros de combustão em motores de combustão interna. Os autores propõem um modelo matemático que relaciona os sinais de aceleração do motor com a pressão média indicada e a taxa de liberação de energia no cilindro. O modelo é validado experimentalmente em um motor de quatro tempos, usando um sensor de pressão para calibrar os parâmetros do modelo.

Os resultados mostram que a metodologia proposta é capaz de estimar a pressão média indicada e a taxa de liberação de energia com boa precisão em uma ampla gama de condições de operação do motor. Além disso, a metodologia apresenta vantagens em relação a métodos convencionais, pois não requer a instalação de sensores intrusivos no cilindro.

ZHU et al. (2007) apresentaram uma metodologia para estimar a pressão no cilindro de um motor Diesel usando sinais de vibração do cabeçote do motor. Os autores propõem um modelo matemático que relaciona a pressão no cilindro com os sinais de vibração do cabeçote. A técnica é baseada em um método de análise de séries temporais chamado método de decomposição empírica (EMD), que é capaz de separar os diferentes

componentes dos sinais de vibração. O modelo é testado em um motor Diesel de quatro tempos e os resultados mostram que a metodologia é capaz de estimar a pressão no cilindro com precisão. Além disso, a técnica proposta apresenta vantagens em relação a métodos convencionais, pois não requer a instalação de sensores intrusivos no cilindro.

DEJONG (1986) discutiu o uso de sinais de vibração para monitorar o desempenho de um motor de combustão interna. O autor apresenta um método para analisar os sinais de vibração gerados pelo motor e identificar possíveis falhas no sistema. O método envolve a utilização de sensores de vibração colocados em diferentes pontos do motor, que registram os sinais de vibração durante a operação. Os sinais são então analisados em termos de sua amplitude, frequência e forma de onda para identificar padrões que indicam possíveis falhas, como desequilíbrio no motor ou problemas com os sistemas de lubrificação e combustível.

O autor também discute a importância do monitoramento contínuo do motor para evitar falhas catastróficas que possam levar a danos no motor ou acidentes. Ele sugere que o uso de sinais de vibração pode ser uma ferramenta útil para a detecção precoce de falhas, permitindo que sejam tomadas medidas corretivas antes que a falha se torne crítica.

LYON (1988) apresentou um método para detectar e isolar falhas em motores a Diesel por meio do monitoramento de sinais de vibração. O autor propõe um sistema de análise de vibração baseado em computador para a identificação de padrões característicos de falhas em um motor. O método emprega técnicas de análise espectral e estatística para detectar anomalias nos sinais de vibração do motor, que são causados por falhas em componentes individuais. Esses padrões são então comparados com uma biblioteca de padrões previamente identificados para isolar a falha. O autor testou o método em um motor Diesel de quatro cilindros e demonstrou a eficácia da técnica na detecção e localização de falhas em componentes individuais do motor, incluindo injetores de combustível, bombas de óleo e válvulas de admissão e escape.

MACIÁN et al. (2005) apresenta uma metodologia para detecção de falhas de injeção em motores Diesel com base na análise de frequência da velocidade instantânea do turbocompressor. A abordagem proposta utiliza a transformada de Fourier para extrair informações espectrais da vibração do turbocompressor e analisa a presença de harmônicos relacionados com o número de cilindros do motor. Com base na análise dos componentes espectrais, a metodologia pode detectar falhas de injeção em cilindros individuais e até mesmo identificar o tipo de falha.



A técnica proposta é validada em um motor Diesel de quatro cilindros, demonstrando alta eficácia na detecção de falhas de injeção. Além disso, o artigo apresenta uma técnica de correção de falhas de injeção por meio da variação do sinal de controle da bomba de combustível, baseada na identificação do tipo de falha. Os resultados experimentais mostram que a abordagem proposta é capaz de corrigir as falhas de injeção detectadas com precisão.

Vibration Signal Analysis for Condition Monitoring of Diesel Engines" de Ferdinando Tagliatella-Scafati e Mario Lavorgna descreve uma abordagem para monitorar o estado de motores Diesel por meio da análise de sinais de vibração. O objetivo do estudo é desenvolver uma metodologia eficiente de monitoramento de motores Diesel que possa detectar falhas em estágios iniciais, permitindo a manutenção preventiva e reduzindo custos.

Os autores propõem um método de análise de sinais de vibração baseado em três etapas: (1) extração de características dos sinais, (2) seleção das características mais importantes e (3) classificação das amostras de sinais de vibração em classes saudáveis ou não saudáveis. A extração de características é realizada por meio de técnicas de processamento de sinal, como transformada de Fourier, transformada Wavelet e análise de componentes principais. A seleção das características mais importantes é feita utilizando algoritmos de seleção de características, e a classificação é realizada por meio de algoritmos de aprendizado de máquina, como a regressão logística e as redes neurais.

Os resultados do estudo mostram que a abordagem proposta pode ser eficaz para detectar falhas em motores Diesel com base em sinais de vibração. A precisão da metodologia proposta foi avaliada em um experimento com um motor Diesel em funcionamento, onde foi possível detectar falhas de maneira eficiente. O estudo sugere que a análise de sinais de vibração pode ser uma ferramenta útil para o monitoramento e manutenção de motores Diesel.

THARANGA et al. (2020) apresentam um estudo aprofundado sobre o uso de sinais de vibração para diagnóstico de falhas em motores Diesel, explorando como diferentes fenômenos internos, como variação de pressão de combustão, desequilíbrios mecânicos e falhas de componentes móveis, geram assinaturas vibracionais características. O trabalho destaca a relevância do ponto morto superior (TDC) como referência fundamental para correlacionar eventos de combustão, abertura e fechamento de válvulas e injeção de combustível ao longo do ciclo do motor.

O estudo aborda especificamente três falhas comuns: folga excessiva de válvulas, fenômeno de *piston slap* (impacto do pistão contra o cilindro) e falhas de injeção de combustível. Para cada uma delas, os autores descrevem como essas anomalias afetam a assinatura de vibração do motor e apresentam técnicas de análise no Domínio do Tempo e do ângulo do eixo de manivelas para sua identificação. Além disso, enfatizam a importância de métodos de separação de fontes e extração de características para distinguir sinais de combustão de ruídos mecânicos, aumentando a precisão do diagnóstico.

Os resultados discutidos indicam que o monitoramento por vibração, quando devidamente correlacionado a diagramas de sincronismo de válvulas e injeção, permite detectar e classificar falhas com alta confiabilidade, representando uma alternativa viável e menos intrusiva em relação a sensores de pressão diretos. O estudo contribui para o avanço da manutenção preditiva em motores Diesel, fornecendo diretrizes práticas para correlacionar assinaturas vibracionais com condições de operação e falhas específicas.

MORAES et al. (2024) apresentam uma metodologia inovadora para classificação de falhas em motores Diesel com base na análise de sinais de vibração no Domínio do Tempo, utilizando técnicas de processamento de sinais e CNN. O estudo parte do desafio de superar limitações de métodos tradicionais de diagnóstico, que exigem desligamentos dispendiosos e alto conhecimento técnico para interpretar medições complexas, como termografia e ultrassom.

A proposta utiliza dados simulados de vibração torcional do virabrequim de um motor marítimo de seis cilindros, gerados por modelos termodinâmicos e de massa concentrada validados com dados do fabricante. As condições simuladas incluem operação normal e três falhas representativas: redução da pressão de admissão de ar, queda de pressão de compressão e falhas na quantidade de combustível injetado. Esses sinais são processados por transformada de Fourier de curto prazo (STFT) e transformada wavelet contínua (CWT), convertendo-os em espectrogramas e escalogramas que alimentam uma CNN para a classificação automática das falhas.

Os resultados mostraram acurácia de 96,5% para dados processados via STFT e 92,2% para dados via CWT, mantendo desempenho acima de 70% mesmo sob condições de ruído elevado (até 40%). A pesquisa demonstra o potencial do uso combinado de transformadas tempo-frequência e CNN para diagnósticos robustos e em tempo real, oferecendo uma alternativa mais acessível e menos intrusiva para monitoramento preditivo de motores Diesel em ambientes industriais.

GUERRA (2023) conduziu um estudo voltado ao diagnóstico de falhas de ignição em motores Diesel marítimos utilizando sinais de vibração combinados a técnicas de Aprendizado de Máquinas (AM). A pesquisa, motivada pela necessidade de soluções eficazes em manutenção preditiva no setor naval, visou reduzir custos operacionais e ampliar a disponibilidade das embarcações por meio da detecção precoce de falhas. Para isso, foram coletados sinais de vibração por meio de quinze acelerômetros piezoelétricos instalados no bloco do motor, abrangendo condições normais de funcionamento e falhas induzidas pelo corte da injeção de combustível.

O processamento dos dados incluiu extração de dezoito características estatísticas no Domínio do Tempo, normalização e remoção de outliers, seguido da aplicação de algoritmos de classificação supervisionada, como K-NN, RF e SVM. Os resultados evidenciaram elevado desempenho dos modelos, alcançando F1-Score próximo a 100%, demonstrando a eficiência da abordagem proposta para identificação e classificação das falhas.

Um diferencial importante do trabalho foi a análise sobre a redução do número de sensores necessários para o diagnóstico. Com o uso do método Relief-F e análise combinatória, verificou-se que apenas dois acelerômetros seriam suficientes para manter a acurácia acima de 95%, o que viabiliza a aplicação do método em contextos reais, nos quais a simplicidade da instrumentação e o menor custo são fatores decisivos.

Assim, o estudo de GUERRA (2023) representa uma contribuição significativa para a área de monitoramento e diagnóstico de motores marítimos, evidenciando o potencial das técnicas de aprendizado de máquina em aplicações práticas e reforçando sua importância para o desenvolvimento de estratégias modernas de manutenção preditiva no ambiente naval.

AYANKOSO et al. (2024) realizaram uma análise comparativa detalhada sobre o uso de sinais de vibração e corrente elétrica para o diagnóstico de falhas em motores de indução, aplicando técnicas de aprendizado profundo e de aprendizado de máquina. O estudo teve como foco avaliar se os sinais de corrente, os quais possuem menores custo e instalação não intrusiva, poderiam substituir de forma eficaz os sinais de vibração que seriam mais onerosos e complexos de instalar. As falhas investigadas incluíram desalinhamento e defeitos em rolamentos, sendo os experimentos conduzidos em várias condições de carga e velocidade para garantir a diversidade dos cenários industriais.

A metodologia envolveu a aplicação de redes neurais convolucionais unidimensionais e bidimensionais diretamente sobre os sinais brutos, além de algoritmos

de aprendizado de máquina clássicos, como RF e Extreme Gradient Boosting (XGBoost). Estes últimos foram treinados com características extraídas por meio da transformada rápida de Fourier (FFT) e da decomposição por wavelet discreta (DWT). Os resultados mostraram que os sinais de vibração apresentaram desempenho significativamente superior, atingindo acurácia próxima a 100% na classificação das falhas, enquanto os sinais de corrente, mesmo após processamento avançado, atingiram acurácia máxima de 87,41%.

Os achados reforçam que, embora os sinais de corrente possam ser considerados promissores em cenários que priorizam simplicidade e baixo custo, os sinais de vibração continuam sendo mais eficazes para a detecção de falhas mecânicas em motores de indução. Este estudo contribui para o avanço da literatura ao esclarecer as vantagens e limitações de cada abordagem, fornecendo subsídios para decisões mais informadas na implementação de sistemas de monitoramento preditivo.

NEUPANE et al. (2025) realizaram uma revisão extensa e atualizada sobre métodos de diagnóstico de falhas em máquinas baseados em dados, destacando o impacto do avanço dos sensores industriais e do crescimento do *big data* na área de manutenção preditiva. Os autores analisam como essas tecnologias têm viabilizado diagnósticos mais rápidos e precisos, favorecendo a detecção precoce de falhas e a otimização do desempenho de sistemas industriais complexos.

O estudo abrange tanto abordagens tradicionais, fundamentadas em modelos físicos e especialistas, quanto técnicas avançadas de aprendizado de máquina e aprendizado profundo, CNNs, redes recorrentes (RNN), autoencoders e novas metodologias como *Transfer Learning*, *Reinforcement Learning* e *Federated Learning*. Além disso, os autores apresentam uma taxonomia detalhada das técnicas existentes, discutindo seus pontos fortes e limitações, bem como desafios práticos, como a escassez e o desequilíbrio de dados, sinais ruidosos e a dificuldade de generalização dos modelos em diferentes cenários operacionais.

Outro aspecto relevante do trabalho é a análise de diversas bases de dados classificando-as de acordo com o tipo de sinal (vibração, corrente, acústico ou térmico) e sua aplicação em diagnóstico e prognóstico. Os autores enfatizam que a integração de múltiplas fontes de dados e técnicas de pré-processamento pode ampliar a robustez e confiabilidade dos sistemas de monitoramento.

JABER (2024) propôs uma abordagem baseada exclusivamente em sinais no domínio do tempo para a detecção de falhas em mancais. O trabalho explora uma

limitação recorrente na literatura: embora análises nos domínios da frequência e tempo-frequência sejam reconhecidamente eficazes, sua alta complexidade computacional compromete aplicações em tempo real. Jaber aborda este desafio propondo a extração de 14 características estatísticas temporais (como RMS, curtose, assimetria, entre outras) e a aplicação de técnicas de seleção de atributos (Information Gain e Fast Correlation-Based Filter – FCBF), com o objetivo de identificar os melhores preditores para alimentar algoritmos de aprendizado de máquina.

Entre os modelos testados (k-Nearest Neighbors – kNN, Support Vector Machines – SVM e Naïve Bayes), o classificador kNN combinado com FCBF (kNN-FCBF) apresentou desempenho superior, atingindo 99,1% de AUC e 97% de acurácia. O estudo evidencia que, mesmo com a simplicidade da análise no domínio do tempo, é possível obter diagnósticos robustos e eficientes, desde que as características mais relevantes sejam selecionadas de forma adequada.

MAIONE et al. (2025) propõem uma metodologia inovadora de aprendizado profundo para a previsão de séries temporais em motores Diesel marítimos, com o objetivo de antecipar o comportamento dinâmico desses sistemas. O método combina redes neurais recorrentes (RNN) com mecanismos de atenção temporal, permitindo a rede focar seletivamente nos padrões mais relevantes das sequências de entrada ao longo do tempo.

O modelo foi testado utilizando dados operacionais reais provenientes de sensores instalados em motores marítimos, abrangendo variáveis como pressão, temperatura, rotação e vibração. Um dos destaques do estudo é a capacidade de previsão multi-horizonte, ou seja, o modelo não apenas prevê um único passo à frente, mas consegue antecipar diversos instantes futuros, o que é fundamental para o planejamento de ações corretivas em sistemas navais. Os resultados indicaram elevada acurácia preditiva e baixa variância nos erros, mesmo diante de ruídos nos dados e variações operacionais típicas de ambientes marítimos.

### **3. FUNDAMENTAÇÃO TEÓRICA**

O presente capítulo tem como principal objetivo estabelecer as bases conceituais que sustentam o desenvolvimento da dissertação. Para isso, apresenta os fundamentos da análise de vibração nos domínios do tempo e da frequência, destacando como essas abordagens permitem identificar padrões relacionados a falhas de injeção em motores Diesel. Também introduz conceitos estatísticos aplicados ao processamento de sinais, incluindo distribuições probabilísticas, medidas de tendência central e variabilidade, além do impacto de outliers na qualidade dos dados. Outro ponto essencial é a discussão da maldição da dimensionalidade e das técnicas de extração e seleção de características (algoritmo Relief-F), fundamentais para reduzir redundâncias e melhorar a eficiência dos modelos. Por fim, o capítulo aborda os princípios do aprendizado supervisionado, do equilíbrio *bias-variance* e da regularização, fornecendo a fundamentação necessária para a aplicação das Redes Neurais Artificiais na classificação de falhas.

#### **3.1. Análise das Assinaturas de Vibração**

Nesta seção serão apresentados os fundamentos da interpretação dos sinais vibracionais em motores Diesel marítimos. Para isso, descreve a relação entre os domínios do tempo e da frequência, destacando como cada um evidencia diferentes aspectos do comportamento dinâmico do sistema. O texto ressalta a importância da Transformada Rápida de Fourier (FFT) como ferramenta para converter sinais temporais em espectros de frequência, possibilitando identificar componentes harmônicos e padrões de falha. Além disso, enfatiza que a análise combinada dos domínios no tempo e no domínio da frequência oferece diagnósticos mais completos e robustos, essenciais para detectar com precisão falhas de injeção.

##### **3.1.1. Relação entre o Domínio do Tempo e o Domínio da Frequência na Análise de Vibração**

A análise de sinais pode ser realizada em diferentes domínios, sendo os mais relevantes o Domínio do Tempo e o Domínio da Frequência. O Domínio da Frequência é onipresente na natureza e na engenharia, embora nem sempre seja referido explicitamente como tal. Por exemplo, fenômenos como luz, cor e som são manifestações diretas de frequências específicas, mas na linguagem cotidiana nos

referimos a eles por seus efeitos perceptíveis, e não pelo termo técnico "frequência" (TAYLOR, 1994).

A percepção sonora humana está limitada ao intervalo de aproximadamente 20 Hz a 2000 Hz, denominado "faixa audível" (RANDALL, 2011). Sons de baixa frequência, como os emitidos por um cantor barítono, contrastam com sons de alta frequência, exemplificados pelo alcance vocal de um soprano em óperas. Tal distinção evidencia a importância da frequência na caracterização de fenômenos vibracionais.

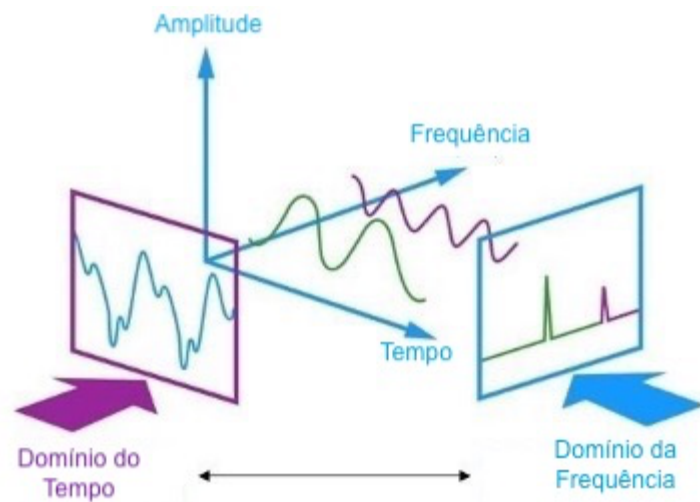
A escolha entre realizar a análise no Domínio do Tempo ou no Domínio da Frequência depende das características do fenômeno e do objetivo do diagnóstico. Informações como a duração de eventos são mais bem descritas no Domínio do Tempo, enquanto a estrutura interna e periódica de sinais, especialmente em sistemas rotativos, revela-se mais nitidamente no Domínio da Frequência (TAYLOR, 1994).

Na engenharia de manutenção preditiva, por exemplo, falhas mecânicas podem não ser visíveis a olho nu, tampouco audíveis, devido a limitações fisiológicas ou à presença de ruídos mascarantes. Ainda que o operador relate que "não vê nada de errado" ou que "o som parece normal", a falha pode estar presente, porém fora do alcance sensorial humano, ou superposta a outros sinais (TAYLOR, 1994).

Análises como o diagnóstico de desbalanceamento podem ser inicialmente realizadas no Domínio do Tempo. Contudo, sinais provenientes de máquinas rotativas são geralmente complexos, exigindo a transformação para o Domínio da Frequência, a fim de facilitar a identificação de componentes harmônicos e padrões de falha (RANDALL, 2011). Realizar a análise exclusivamente no Domínio da Frequência, contudo, pode gerar interpretações equivocadas, sendo recomendada a avaliação conjunta de ambos os domínios para uma interpretação completa e precisa.

A conversão de um sinal do Domínio do Tempo para o Domínio da Frequência é realizada por meio da FFT (FOURIER, 1822). Entretanto, a ampla aplicação desta técnica só foi possível após o advento da computação digital, que permitiu a execução rápida e precisa de cálculos anteriormente impraticáveis.

A Figura 1 representa de forma integrada as duas visões de um mesmo sinal. O Domínio do Tempo em que a amplitude do sinal é plotada em função do tempo, permitindo observar diretamente seus picos, vales e eventuais transientes e o Domínio da Frequência onde é obtido pela aplicação da FFT às oscilações temporais, onde cada pico espectral indica a presença de um componente periódico em determinada frequência.



*Figura 1 - Diagrama da Relação entre o Domínio do Tempo e o Domínio da Frequência*

A compreensão dessa relação é fundamental para o desenvolvimento de diagnósticos robustos em sistemas mecânicos complexos, como motores Diesel marítimos, onde a identificação precisa de falhas de injeção ou de desequilíbrios estruturais depende diretamente da adequada interpretação dos sinais vibracionais em múltiplos domínios.

### **3.1.2. Estatística Aplicada ao Processamento de Sinais**

A modelagem estatística e os métodos de aprendizado supervisionado requerem uma compreensão sólida dos princípios fundamentais da teoria das probabilidades, dado que tais fundamentos são essenciais para a construção e interpretação de modelos preditivos baseados em dados. IVEZIC et al. (2014) oferecem uma abordagem abrangente e didaticamente estruturada sobre as principais distribuições probabilísticas aplicáveis ao contexto do aprendizado de máquina, com destaque para sua aplicação no tratamento de sinais reais, como os oriundos de vibrações em motores Diesel marítimos.

A distribuição de probabilidade  $P(x)$  representa a frequência relativa esperada de ocorrência de um evento aleatório. Em sistemas embarcados sujeitos a ruído, instabilidades térmicas e condições operacionais variáveis, como os motores Diesel marítimos, a modelagem estocástica dos sinais de vibração é indispensável para representar incertezas e fornecer fundamentos para inferências estatísticas e algoritmos de aprendizado.



A referida seção distingue entre distribuições discretas - como a binomial e a de Poisson - e contínuas, dentre as quais se destacam a distribuição normal e a exponencial. Essas últimas são particularmente adequadas para modelar variáveis físicas contínuas, tais como acelerações e amplitudes de vibração.

A distribuição normal (Gaussiana) assume papel central no aprendizado supervisionado ao modelar ruídos e erros de medição, fornecendo base teórica para hipóteses de normalidade em diversos algoritmos. Sua função de densidade de probabilidade (PDF) é dada pela Eq. (3.1):

$$f_X(x) = \left( \frac{1}{\sigma\sqrt{2\pi}} \right) \cdot e^{-\frac{(x-\mu)^2}{2 \cdot \sigma^2}} \quad (3.1)$$

em que  $\mu$  representa a média e  $\sigma^2$  a variância da distribuição (IVEZIC et al., 2014).

A distribuição exponencial, por sua vez, é frequentemente utilizada para modelar o tempo entre eventos sucessivos, como falhas de componentes, e é definida pela Eq. (3.2):

$$f(x|\lambda) = \lambda e^{-\lambda x}, x \geq 0 \quad (3.2)$$

em que  $x$  é a variável aleatória contínua que representa o tempo até a ocorrência de um evento e  $\lambda$  é o parâmetro da taxa da distribuição exponencial, também chamado de taxa de falhas ou intensidade. Ele indica a frequência média com que os eventos ocorrem por unidade de tempo e quanto maior  $\lambda$  mais rápido os eventos tendem a ocorrer

Essas distribuições possibilitam a definição de modelos probabilísticos a priori e a posteriori — conceito fundamental em abordagens bayesianas e aplicado no processo de otimização de hiperparâmetros, como adotado neste trabalho.

Adicionalmente, são introduzidas medidas estatísticas derivadas, tais como média, mediana, variância, desvio padrão, curtose etc., largamente utilizadas neste estudo para extração de características nos Domínios do Tempo e da Frequência. Parte-se da premissa de que distintos estados operacionais do motor, como falhas ou funcionamento normal, manifestam-se por meio de alterações nas propriedades

estatísticas dos sinais. Assim, a análise de distribuições auxilia na redução de ruído e na identificação de padrões informativos relevantes que alimentam as RNAs.

A probabilidade condicional permite o mapeamento  $P(y|x)$ , onde  $x$  representa o vetor de características extraídas dos sinais de vibração e  $y$  refere-se à classe associada à condição do motor (normal ou com falha de injeção). Essa estrutura probabilística fundamenta a escolha da função de custo por entropia cruzada, bem como o uso de validação cruzada como técnica para maximizar a capacidade de generalização do modelo.

### 3.1.3. Análise de Outliers

A presença de outliers - observações que se desviam significativamente do padrão esperado dos dados - constitui uma das principais fontes de degradação do desempenho de algoritmos de aprendizado supervisionado, especialmente em sistemas sensíveis como os modelos baseados em RNAs. De acordo com AGGARWAL (2017), a identificação e o tratamento de outliers são essenciais para garantir a qualidade dos dados e a estabilidade dos modelos preditivos.

A definição estatística clássica de outlier baseia-se na probabilidade de ocorrência de uma amostra sob uma distribuição presumida. Por exemplo, para uma variável contínua normalmente distribuída, um ponto de dado  $x$  pode ser considerado um outlier se obedecer a seguinte condição, conforme Eq. (3.3):

$$|x - \mu| > \lambda - \sigma \quad (3.3)$$

em que  $\mu$  é a média,  $\sigma$  é o desvio padrão e  $\lambda$  é um fator de limiar. Este critério é relacionado diretamente à análise univariada, mas pode ser estendido ao espaço multidimensional por meio da distância de Mahalanobis, apresentada na Eq. (3.4):

$$D_{M(x)} = \sqrt{(x - \mu)^T \Sigma^{-1} (x - \mu)} \quad (3.4)$$

onde  $\Sigma$  representa a matriz de covariância do conjunto de dados (AGGARWAL, 2017).

Neste contexto, que envolve sinais de vibração no Domínio do Tempo e da Frequência, a integridade estatística dos dados é crítica. Os métodos de extração de

características como curtose, skewness, RMS e outros momentos estatísticos são altamente sensíveis a valores extremos. Assim, a presença de outliers pode induzir a um sobreajuste das RNAs, prejudicando a capacidade de generalização do modelo.

AGGARWAL (2017) também classifica os métodos de detecção de outliers em quatro categorias principais: Métodos Estatísticos Paramétricos (baseados na hipótese de distribuição); Métodos Baseados em Distância (como o DBSCAN e a distância de Mahalanobis); Métodos Baseados em Densidade (como o Local Outlier Factor - LOF); e os Métodos Baseados em Modelos (incluindo redes neurais autoencoders e SVMs).

Neste estudo, a utilização de técnicas estatísticas robustas, como o método de quartis com limiares ajustáveis (e.g., método *Clip* no MATLAB), permite a mitigação do efeito de valores extremos antes da alimentação dos dados à rede neural. Essa abordagem também facilita a conformidade dos dados com os pressupostos das técnicas de normalização e validação cruzada aplicadas no processo de treinamento da RNA.

#### 3.1.4. “Maldição da Dimensionalidade”

A “maldição da dimensionalidade” (*curse of dimensionality*) é um dos desafios centrais no aprendizado de máquina e na mineração de dados, com impacto direto na modelagem preditiva e na análise estatística em espaços de alta dimensionalidade. Conceituada inicialmente por BELLMAN (1961) no âmbito do controle dinâmico, essa expressão descreve a degradação exponencial do desempenho de métodos numéricos à medida que aumenta o número de variáveis de entrada (características) (HASTIE et al., 2009; TAN et al. 2018).

No contexto da aprendizagem supervisionada, tal fenômeno decorre do crescimento exponencial do volume do espaço de busca em função da dimensionalidade  $p$ , o que acarreta dispersão amostral e redução drástica da densidade efetiva de dados. Considerando uma unidade cúbica  $[0,1]^p$ , onde  $p$  é o número de dimensões, o volume necessário para cobrir uma fração significativa do espaço aumenta drasticamente com  $p$ . Por exemplo, para cobrir 1% do volume de um espaço de entrada em  $p = 10$  dimensões com uma hiper esfera centrada, seu raio precisa ser de aproximadamente 0,52, o que representa mais da metade da faixa total de cada variável (HASTIE et al., 2009).

Esse efeito é formalmente expresso pela Eq. (3.5):

$$N_{samples} \propto \epsilon^{-p} \quad (3.5)$$

em que  $N_{samples}$  é o número de amostras necessário para manter a resolução,  $\epsilon$  é a resolução desejada e  $p$  é o número de dimensões. Além das implicações estatísticas, a maldição da dimensionalidade compromete algoritmos baseados em distâncias, como k-NN e SVM. Em alta dimensionalidade, a razão entre a menor e a maior distância entre amostras tende a 1, conforme Eq. (3.6):

$$\lim_{p \rightarrow \infty} \frac{\min \|x_i - x_j\|}{\max \|x_i - x_j\|} \rightarrow 1 \quad (3.6)$$

Esse comportamento reduz a capacidade discriminativa dos classificadores, tornando inviável a separação eficiente de classes com base em métricas de proximidade.

No presente estudo, que envolve sinais de vibração com alto número de características extraídas nos Domínios do Tempo, Frequência e Tempo-Frequência, a maldição da dimensionalidade torna-se um desafio comum.

Portanto, a compreensão e o tratamento adequado da maldição da dimensionalidade foram essenciais para garantir a robustez e a eficiência de sistemas preditivos baseados em RNAs, particularmente no contexto deste estudo de detecção de falhas com múltiplas variáveis descritivas.

Para mitigar a maldição da dimensionalidade, foram adotadas estratégias amplamente recomendadas na literatura (GUYON et al., 2003), tais como:

- **Seleção de características** fundamentada em heurísticas estatísticas, visando reduzir o espaço de busca sem perda de informação relevante;
- **Regularização** por meio de hiperparâmetros, como  $\lambda$ , para controle da complexidade do modelo e prevenção de *overfitting*; e
- **Validação cruzada** (cross-validation) para avaliação robusta da capacidade de generalização.

Assim, a compreensão e o tratamento sistemático da maldição da dimensionalidade não apenas viabilizaram a construção de um sistema de detecção de falhas robusto e eficiente, mas também asseguraram alinhamento com as melhores práticas do estado da arte, garantindo maior confiabilidade e reprodutibilidade dos resultados obtidos.

### 3.2. Extração de Características

A extração de características constitui uma etapa fundamental no processo de diagnóstico de falhas em sistemas rotativos, uma vez que transforma sinais brutos em representações informativas e discriminativas para os algoritmos de aprendizado supervisionado. MARTINS et al. (2021) enfatizam esse processo como central na eficácia do método proposto, denominado Hierarchical Decision Architecture (HDA), o qual depende fortemente da qualidade das características para realizar a classificação de falhas combinadas em máquinas rotativas.

No contexto da análise de vibrações, as características são extraídas a partir do sinal no Domínio do Tempo e da Frequência. Essas métricas traduzem aspectos físicos e estatísticos do comportamento dinâmico da máquina e permitem a discriminação entre diferentes condições de falha.

Neste trabalho, adotou-se uma abordagem sistemática para a extração de atributos estatísticos tanto no Domínio do Tempo quanto no Domínio da Frequência, com o intuito de capturar, de forma abrangente, as nuances do comportamento dinâmico do sistema sob diferentes condições operacionais.

No Domínio do tempo, as características foram extraídas diretamente do sinal bruto de aceleração registrado pelos acelerômetros. As Características Descritivas foram relacionadas na Tabela 2. Essas métricas foram aplicadas sobre vetores de amostras segmentados em janelas temporais fixas, o que permite capturar as variações instantâneas no comportamento vibracional do motor.

Complementarmente, no Domínio da Frequência, as mesmas estatísticas foram computadas sobre os espectros de magnitude obtidos pela aplicação da FFT. O objetivo foi evidenciar padrões de frequência associados às falhas de injeção, muitas vezes mascarados no Domínio do Tempo. A Tabela 3 apresenta as expressões matemáticas utilizadas na extração dessas características, aplicadas ao vetor espectral.

As fórmulas utilizadas em ambos os domínios seguem uma abordagem padronizada, garantindo consistência e comparabilidade entre os parâmetros extraídos.

Dessa maneira, as características utilizadas no presente estudo representam uma base sólida para o treinamento, validação e teste dos modelos de RNA, contribuindo significativamente para a acurácia na identificação de falhas de injeção em motores Diesel marítimos.

Tabela 2 - Características Estatísticas Extraídas no Domínio do Tempo

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

17. Energia	$ENERGIA = \sum_{i=1}^L  x_i ^2$
18. Entropia	$ENTROPIA = - \sum_{i=1}^L p(c_i) \log_2 p(c_i)$
19. Moda	$MODA = moda(x_i)$
20. Variação Absoluta	$AV = \sum_{i=1}^{L-1}  x_{i+1} - x_i $
21. Variação Percentual	$PV = \left( \frac{AV}{L} \right) * 100$
22. Valor Absoluto Médio	$MAV = \frac{1}{L} \sum_{i=1}^L  x_i $
23. Valor Absoluto da Soma	$SAV = \sum_{i=1}^L  x_i $
24. Valor Quadrático Médio	$MSV = \frac{1}{L} \sum_{i=1}^L x_i^2$
25. Valor Quadrático da Soma	$SSV = \sum_{i=1}^L x_i^2$
26. Coeficiente de Variação	$CV = \left( \frac{STD}{MEAN} \right) * 100$
27. Erro Padrão da Média	$SEM = \frac{STD}{\sqrt{L}}$

onde  $x_i$  representa o valor correspondente a cada amostra  $i$  do vetor de amostras, no Domínio do Tempo;  $L$  denota o comprimento do vetor de amostras; e  $p(c_i)$  indica a probabilidade de  $x_i$  ser igual aos valores possíveis da sequência  $c_i$  (GUERRA, 2023).

Ao aplicar a fórmula estatística sobre o vetor de amostras, o resultado gerará uma instância, de modo que uma característica será gerada a cada fórmula aplicada. Dessa forma, 27 características serão extraídas para cada vetor de amostra, no Domínio do Tempo.

Tabela 3 - Características Estatísticas Extraídas no Domínio da Frequência

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



17. Energia	$ENERGIA = \sum_{i=1}^L  Y_i ^2$
18. Entropia	$ENTROPIA = - \sum_{i=1}^L p(c_i) \log_2 p(c_i)$
19. Moda	$MODA = moda(Y_i)$
20. Variação Absoluta	$AV = \sum_{i=1}^{L-1}  Y_{i+1} - Y_i $
21. Variação Percentual	$PV = \left( \frac{AV}{L} \right) * 100$
22. Valor Absoluto Médio	$MAV = \frac{1}{L} \sum_{i=1}^L  Y_i $
23. Valor Absoluto da Soma	$SAV = \sum_{i=1}^L  Y_i $
24. Valor Quadrático Médio	$MSV = \frac{1}{L} \sum_{i=1}^L Y_i^2$
25. Valor Quadrático da Soma	$SSV = \sum_{i=1}^L Y_i^2$
26. Coeficiente de Variação	$CV = \left( \frac{STD}{MEAN} \right) * 100$
27. Erro Padrão da Média	$SEM = \frac{STD}{\sqrt{L}}$

A transformação das características de um sinal do Domínio do Tempo para o Domínio da Frequência se deu através da aplicação da FFT. Tal ação foi possível a partir da definição de algumas propriedades do sinal, como a taxa de amostragem ( $f_s$ ), o período de amostragem ( $T$ ), o comprimento ou tamanho do sinal ( $L$ ) e o vetor temporal ( $t$ ) associado ao sinal coletado.

Após o tratamento dos sinais, aplica-se as fórmulas estatísticas sobre os vetores de amostras, o resultado gerará uma instância, de modo que uma característica será gerada a cada fórmula aplicada. Dessa forma, 27 características serão extraídas para cada vetor de amostra, mas agora no Domínio da Frequência.

Os estudos de MARTINS et al. (2021) e GUERRA (2023) fizeram uso de características estatísticas na modelagem para identificação de falhas de operação em equipamentos mecânicos. A seleção criteriosa dessas características permite reduzir a

dimensionalidade do espaço de entrada e aumentar a acurácia dos classificadores utilizados, mitigando o risco de sobreajuste (overfitting) e melhorando a generalização dos modelos.

No estudo de MARTINS et al. (2021) especificamente, a abordagem metodológica também se beneficia da extração de características no Domínio do Tempo e da Frequência e o embasamento fornecido legitima a escolha de diversas características, as quais são sensíveis as variações estruturais e representam padrões indicativos de falhas de operação em equipamentos mecânicos.

### **3.3. Relief-F - Seleção de Variáveis e Redução de Dimensionalidade**

A seleção das melhores características é uma etapa fundamental em sistemas de aprendizado supervisionado, especialmente quando se lida com dados de alta dimensionalidade e redundância, como os obtidos por meio da análise de sinais de vibração em motores Diesel marítimos. O algoritmo Relief-F destaca-se como uma das abordagens mais eficazes e amplamente adotadas nas tarefas de classificação (ROBNIK-ŠIKONJA; KONONENKO, 2003).

Conforme discutido por ROBNIK-ŠIKONJA e KONONENKO (2003), o Relief-F opera com base em uma filosofia de aprendizado baseado em instâncias. Para cada amostra selecionada aleatoriamente no conjunto de dados, o algoritmo identifica os vizinhos mais próximos da mesma classe e de diferentes classes, atualizando iterativamente os pesos atribuídos a cada característica. Essas características contribuem de forma consistente para a separação entre classes recebem aumentos em seus pesos, enquanto aquelas que pouco contribuem para a discriminação entre instâncias tem os seus pesos reduzidos. Esse mecanismo o Relief-F sensível à estrutura local dos dados é altamente eficaz na identificação de atributos relevantes.

URBANOWICZ et al. (2018) ressaltam que um dos principais diferenciais do Relief-F é sua robustez frente a dados ruidosos e com forte correlação entre variáveis, cenário comum em aplicações reais de diagnóstico de falhas. Essa robustez decorre do fato de o algoritmo levar em conta não apenas cada instância de forma isolada, mas também suas interações com vizinhos próximos. Isso possibilita identificar não só atributos que, individualmente, têm poder de discriminação, mas também relações mais complexas entre variáveis — conexões sutis que métodos univariados muitas vezes não conseguem capturar.

Formalmente, dado um conjunto de características  $F = \{f_1, f_2, \dots, f_p\}$ , o problema consiste em identificar um subconjunto ótimo  $F' \subseteq F$  que maximize a relevância preditiva e minimize a redundância, preservando a representatividade do sistema (URBANOWICZ et al., 2018).

Seja um conjunto de dados de treinamento definido pela Eq. (3.10):

$$S = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}, \quad (3.10)$$

em que cada instância  $x_i \in \mathbb{R}^p$  é um vetor de características e  $y_i \in \{1, \dots, C\}$  representa a classe associada. O algoritmo estima um vetor de pesos  $W = \{w_1, w_2, \dots, w_p\}$  no qual cada peso  $w_j$  expressa a relevância da  $j$  – ésima característica.

A atualização dos pesos é realizada iterativamente, comparando instâncias aleatórias  $R$  com seu vizinho mais próximo da mesma classe (near-hit,  $H$ ) e com os seus vizinhos mais próximos de classes distintas (near-miss,  $M^C$ ). A regra de atualização é dada pela Eq. (3.11):

$$w_j := w_j - \frac{1}{m} \cdot \text{diff}(f_j, R, H) + \frac{1}{m} \sum_{c \in C, c \neq y_R} P(c) \cdot \text{diff}(f_j, R, M^{(c)}), \quad (3.11)$$

onde  $\text{diff}(f_j, I_1, I_2)$  quantifica a diferença entre os valores da características  $f_j$  em duas instâncias  $I_1, I_2$  normalizada em  $[0,1]$  e  $m$  é o número de iterações. Para atributos numéricos, tem-se a seguir a Eq. (3.12):

$$\text{diff}(f_j, I_1, I_2) = \frac{|\text{valor}(f_j, I_1) - \text{valor}(f_j, I_2)|}{\max(f_j) - \min(f_j)} \quad (3.12)$$

Essa formulação assegura que características discriminativas apresentem pesos positivos — uma vez que  $R$  e  $H$  tendem a ser semelhantes, enquanto  $R$  e  $M^C$  tendem a divergir. Já atributos irrelevantes, para os quais não há diferença estatisticamente significativa entre instâncias de mesma ou diferentes classes, convergem para pesos próximos de zero (URBANOWICZ et al., 2018).

Do ponto de vista estatístico, a expectativa da atualização para a  $i$ -ésima característica pode ser expressa pela Eq.(3.13):

$$\mathbb{E}[\delta_i] = -\mathbb{E}[(x^j - H^j)^2] + \mathbb{E}[(x^j - M^j)^2] \quad (3.13)$$

De modo que  $\mathbb{E}[\delta_i] > 0$  para atributos relevantes e  $\mathbb{E}[\delta_i] \approx 0$  para atributos irrelevantes (KONONENKO, 1994). Essa propriedade garante consistência estatística ao algoritmo, uma vez que, para  $m \rightarrow \infty$ , onde os pesos convergem para valores teóricos de relevância (KIRA; RENDELL, 1992).

Adicionalmente, a abordagem Relief-F é compatível com problemas com múltiplas classes e múltiplos rótulos, como demonstrado por CAI et al. (2015), sendo assim particularmente apropriada para o presente estudo, que envolve a classificação de condição de falha de injeção. O algoritmo é computacionalmente eficiente, operando em tempo linear em relação ao número de instâncias avaliadas, o que o torna viável mesmo para conjuntos de dados extensos e de alta dimensionalidade.

O uso do Relief-F justifica-se pela necessidade de mitigar os efeitos adversos da maldição da dimensionalidade, selecionando um subconjunto informativo de variáveis capazes de maximizar a capacidade discriminativa do modelo preditivo. Ao reduzir o espaço de entrada a atributos estatisticamente significativos — extraídos dos domínios de tempo, frequência e tempo-frequência —, o algoritmo contribui diretamente para o aumento da performance das RNAs, melhorando sua capacidade de generalizando e promovendo maior interpretabilidade dos resultados.

Segundo EVUKOFF (2001), a escolha de atributos relevantes permite redução do tempo de treinamento, da economia de recursos computacionais e a remoção de ruído e dados redundantes, melhorando a interpretação do modelo e sua capacidade de generalização. Isso é especialmente relevante no contexto do uso de RNAs, cujo desempenho é sensivelmente afetado pela dimensionalidade da entrada e pela distribuição estatística dos dados.

Além disso, a literatura ressalta a importância da análise exploratória e do uso de métodos estatísticos para a escolha dos atributos mais relevantes. Técnicas como análise de variância, correlação, análise de componentes principais e filtros baseados em entropia são utilizadas com frequência nesse processo. Em nosso estudo, as métricas também foram avaliadas quanto à sua contribuição individual para os modelos de classificação, visando maximizar a divisão (separabilidade) entre as classes.

Assim, a modelagem com RNAs *feedforward* fornece uma base sólida e cientificamente validada para a identificação de falhas de injeção em motores Diesel, permitindo a construção de classificadores precisos e eficientes mesmo diante da complexidade dos sinais envolvidos em equipamentos alternativos como é o caso do motor Diesel marítimo.

### 3.4. Fundamentos de Aprendizado de Máquina

#### 3.4.1. Aprendizado Supervisionado e Generalização de Modelos

O aprendizado supervisionado é um dos pilares da modelagem preditiva em problemas de inferência estatística e mineração de dados. No contexto deste estudo, este paradigma é adotado para modelar a relação entre sinais de vibração adquiridos de um motor Diesel marítimo e as respectivas classes de falhas de injeção simuladas, com base em dados rotulados. Conforme estabelecido por HASTIE, TIBSHIRANI e FRIEDMAN (2009), a principal tarefa do aprendizado supervisionado é estimar uma função preditiva  $f: X \rightarrow Y$ , onde  $X$  representa o espaço de entrada (neste estudo, as características extraídas dos sinais) e  $Y$  representa o espaço de saída (as classes de falha).

A modelagem supervisionada baseia-se em um conjunto de treinamento  $\{(x_i, y_i)\}_{i=1}^N$ , onde  $x_i \in \mathbb{R}^p$  representa um vetor de atributos descritivos e  $y_i$  a respectiva resposta categórica. A função  $f$  é aprendida de forma a minimizar a expectativa do erro preditivo, representada pela Eq. (3.14):

$$f^*(x) = \arg \min_f \mathbb{E}_{(X,Y)} [L(Y, f(X))] \quad (3.14)$$

em que  $L(Y, f(X))$  é uma função de perda adequada ao problema de classificação múltiplas classes, como a entropia cruzada (utilizada no presente estudo). Essa formulação estabelece uma base rigorosa para justificar a adoção de modelos como RNAs, capazes de aprender funções complexas e não lineares.

Para assegurar a generalização do modelo, os dados foram estratificados nos subconjuntos de treinamento (70%), validação (15%) e teste (15%), conforme recomendado na literatura para controle de sobreajuste (overfitting). A validação cruzada foi utilizada para realizar os ajustes dos hiperparâmetros, mitigando o viés e a variância do estimador final (HASTIE et al., 2009).

O impacto da qualidade dos dados rotulados é amplamente enfatizado na obra, uma vez que erros sistemáticos nesse processo afetam diretamente a curva de aprendizado e os limites de desempenho. Isso reforça a importância de um protocolo rigoroso de aquisição e rotulagem, como implementado experimentalmente nesta dissertação.

Por fim, a estrutura teórica proposta por HASTIE et al. (2009) fornece um embasamento matemático sólido para todas as decisões metodológicas adotadas na modelagem supervisionada, desde a definição da função de perda até os mecanismos de validação e ajuste do modelo.

### 3.4.2. O Dilema *Bias-Variance* no Contexto do Aprendizado Supervisionado

Ao treinar modelos de aprendizado de máquina, busca-se o equilíbrio entre a fidelidade do modelo aos dados de treinamento e sua capacidade de generalizar para novos dados e nunca vistos. Esse equilíbrio é formalizado pelo *bias-variance trade-off*, que descreve a decomposição do erro preditivo em três componentes: viés (bias), variância e ruído irreduzível (ALPAYDIN, 2010; HASTIE et al., 2009).

A decomposição formal do erro esperado é dada pela na Eq. (3.15):

$$E \left[ (y - f(x))^2 \right] \quad (3.15)$$

A decomposição formal do erro esperado é expressa como na Eq. (3.16):

$$E \left[ (y - f(x))^2 \right] = Bias^2 \left( \hat{f}(x) \right) + Var \left( \hat{f}(x) \right) + \sigma^2 \quad (3.16)$$

onde  $\sigma^2$  representa o ruído irreduzível.

O viés representa a tendência do modelo em realizar suposições simplificadas sobre o problema, o que pode levar a ocorrências de erros sistemáticos. Por outro lado, a variância reflete a sensibilidade do modelo a pequenas flutuações nos dados de treinamento. Modelos com alto viés tendem a subajustar (underfitting) os dados, enquanto aqueles com alta variância tendem a sofrer de sobreajuste (overfitting) (ALPAYDIN, 2010).

No contexto deste estudo, o qual envolve a identificação de falhas de injeção em motores Diesel por meio de RNAs, o risco de sobreajuste é significativo, considerando

a alta dimensionalidade das características extraídas dos sinais de vibração coletados. Para mitigar esse risco, foram adotadas práticas rigorosas, como a divisão dos dados em conjuntos de treino, validação e teste. Adicionalmente, foi utilizado a validação cruzada durante o ajuste dos hiperparâmetros como o número de neurônios, taxa de aprendizado, número de épocas e no uso das técnicas de regularização. Uma adequada calibração desses elementos, por meio de abordagens como a otimização bayesiana, permite uma maximização da capacidade preditiva sem comprometimento da capacidade de generalização do modelo.

### 3.4.3. Divisão dos Dados em Conjuntos de Treinamento, Validação e Teste

Uma adequada divisão dos dados em conjuntos de treinamento e teste é um pilar fundamental para a construção de modelos preditivos robustos e com alta capacidade de generalização do modelo. Empiricamente, a utilização de proporções como 70/30 ou 80/20 tem se mostrado satisfatória em diversas aplicações de aprendizado de máquina supervisionada, sendo amplamente adotada em problemas de classificação. GHOLAMY et al. (2018) forneceram uma explicação pedagógica e estatística para essa prática, a qual é amplamente difundida.

O ponto central da justificativa se baseia na necessidade de evitar o overfitting, fenômeno no qual um modelo se ajusta excessivamente aos dados de treinamento, perdendo sua capacidade de generalização para dados novos ou dados nunca vistos. Para mitigar esse risco, os dados observados devem ser divididos em um subconjunto usado para ajustar os parâmetros do modelo na fase de treinamento e outro para avaliar seu desempenho preditivo na fase de teste.

Os autores demonstram que a divisão ótima está relacionada à minimização da variância total da estimativa de erro do modelo, levando em consideração o Teorema Central do Limite. A variância total do erro preditivo, quando o conjunto de dados é dividido em proporções  $p$  e  $1 - p$ , é dada pela Equação (3.17):

$$\sigma_{total}^2 \propto \frac{1}{pN} + \frac{1}{(1-p)N} = \frac{1}{p(1-p)N} \quad (3.17)$$

onde  $N$  é o número total de amostras e  $p$  representa a fração alocada ao conjunto de treinamento. O produto  $p(1-p)$  atinge seu valor máximo quando  $p = 0,5$ , mas nesse

caso a variância da estimativa de erro tende a subestimar o erro real devido à incerteza maior sobre os parâmetros aprendidos com menos dados (GHOLAMY et al., 2018).

A análise probabilística do artigo mostra que, para garantir que a variância da previsão no conjunto de teste seja maior que a incerteza associada ao modelo treinado, a proporção ideal do conjunto de treinamento deve satisfazer a desigualdade da Equação (3.18):

$$\frac{2}{\sqrt{p}} \leq \frac{1}{\sqrt{1-p}} \quad (3.18)$$

A resolução desta inequação conduz à conclusão de que valores de  $p \geq 0,8$  são mais seguros para garantir estimativas de erro válidas e confiáveis. Assim, a escolha de proporções como 80/20 ou 70/30 para treinamento/teste é justificada não apenas pela prática empírica, mas também por princípios estatísticos sólidos, que equilibram a capacidade de ajuste do modelo e a confiança nas métricas de validação.

No presente trabalho, essa abordagem é estendida com a adição de um conjunto de validação (15%), usado especificamente para ajustar hiperparâmetros e evitar o viés da seleção sobre os dados de teste, em conformidade com as boas práticas recomendadas na literatura [GHOLAMY et al., 2018].

O gráfico apresentado na Figura 2 ilustra o comportamento da função  $\frac{1}{p(1-p)}$ , que é comumente usada para representar a variância relativa na divisão entre dados de treinamento e teste, conforme discutido no artigo de GHOLAMY Et al. (2018). Essa função atinge seu valor mínimo quando  $p = 0,5$ , ou seja, quando os conjuntos de treinamento e teste possuem tamanhos iguais. No entanto, na prática, valores como 70% e 80% de dados para treino (representados pelas linhas verticais) são preferidos para garantir que o modelo disponha de dados suficientes para aprender, reduzindo o erro de generalização.



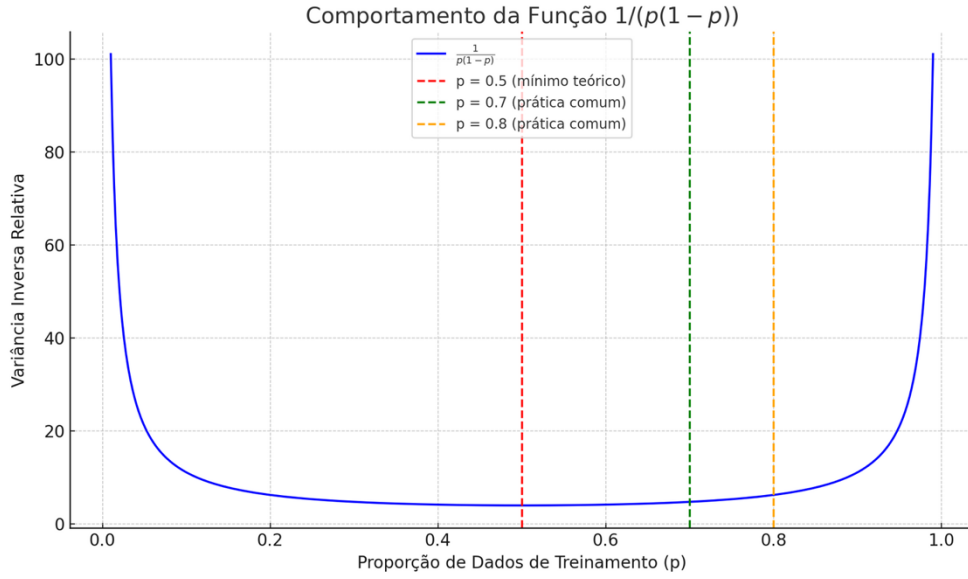


Figura 2 - Comportamento da Função  $1/(p(1-p))$

#### 3.4.4. Regularização - L2 (Ridge) e L1 (Lasso)

A regularização é uma técnica fundamental no treinamento de redes neurais, pois visa mitigar o problema do overfitting — situação em que o modelo se ajusta excessivamente aos dados de treinamento, perdendo capacidade de generalização para novos dados. De acordo com HAYKIN (2009), a regularização atua adicionando um termo de penalidade à função de custo, desestimulando soluções com pesos excessivamente grandes, que geralmente estão associados a modelos de alta complexidade e variância.

A função de custo regularizada  $E_{total}$  é expressa como na Equação (3.19):

$$E_{total} = E_{emp} + \lambda \cdot \Omega(\omega) \quad (3.19)$$

onde:

- $E_{emp}$  é o erro empírico (por exemplo, o erro de entropia cruzada);
- $\Omega(\omega)$  é o termo de regularização; e
- $\lambda$  é o parâmetro de regularização que controla o peso do termo de penalidade.

O autor explica que diferentes formas de regularização, como L2 (Ridge) e L1 (Lasso), influenciam diretamente a estrutura dos pesos da rede. A L2 tende a distribuir os pesos de forma mais homogênea, reduzindo todos eles proporcionalmente, enquanto

a L1 promove a esparsidade, ou seja, força alguns pesos a se tornarem exatamente zero, o que é útil para seleção automática de características (HAYKIN, 2009).

As formas mais comuns de regularização são conhecidas como L1 (Least Absolute Shrinkage and Selection Operator – Lasso) e L2 (Ridge Regression). Ambas inserem termos penalizadores à função de custo durante o treinamento, o que desencoraja a complexidade excessiva dos modelos por meio do controle dos pesos dos parâmetros.

Na regularização L2, o termo penalizador é proporcional ao quadrado da magnitude dos coeficientes, conforme Equação (3.20):

$$\mathcal{L}_{L2} = \mathcal{L}_0 + \lambda \sum_{j=1}^d w_j^2 \quad (3.20)$$

onde:

- $\mathcal{L}_0$  representa a função de custo original (por exemplo, entropia cruzada),
- $w$  são os pesos da rede neural,
- $\lambda$  é o parâmetro de regularização que controla o grau de penalização.

Já na regularização L1, a penalidade é dada pela soma dos valores absolutos dos pesos, conforme Equação (3.21):

:

$$\mathcal{L}_{L1} = \mathcal{L}_0 + \lambda \sum_{j=1}^d [w_j] \quad (3.21)$$

A regularização L1 promove esparsidade nos parâmetros do modelo, favorecendo a seleção automática de características ao forçar alguns pesos a zero, o que a torna adequada para problemas com grande número de atributos irrelevantes. Em contraste, a L2 distribui suavemente os pesos, resultando em soluções mais estáveis e amplamente adotadas em redes neurais profundas.

No contexto desta dissertação, o termo  $\lambda$  foi tratado como hiperparâmetro a ser otimizado por meio de uma abordagem de otimização bayesiana, utilizando a função bayesopt do MATLAB. A seleção cuidadosa de  $\lambda$  foi essencial para garantir o equilíbrio entre ajuste e generalização da rede neural, sobretudo considerando o alto grau de não

linearidade e dimensionalidade dos dados provenientes dos sinais de vibração do motor (ALPAYDIN, 2010). Garantir a generalização do modelo é fundamental e tal capacidade está diretamente relacionada à escolha apropriada dos algoritmos de treinamento, regularização e divisão dos dados em subconjuntos de treino, validação e teste. Esta divisão permite ajustar hiperparâmetros de maneira robusta e evitar o overfitting, um fenômeno na qual o modelo se ajusta aos dados de treino, perdendo a capacidade de generalização (ALPAYDIN, 2010).

### 3.5. Redes Neurais Artificiais (RNAs)

#### 3.5.1. Estrutura e Fundamentos Matemáticos: Teorema da Aproximação Universal

A modelagem de fenômenos complexos e altamente não lineares, como os sinais de vibração gerados por motores Diesel submetidos a falhas de injeção, requer o uso de métodos preditivos capazes de representar funções complexas entre variáveis de entrada e saída. Segundo HASIE, TIBSHIRANI e FRIEDMAN (2009), a escolha de uma função preditiva apropriada é central para o sucesso em tarefas de aprendizado supervisionado, sendo que a função preditiva ideal é aquela que minimiza o risco esperado de erro, representado matematicamente pela Eq. (3.22):

$$f(x) = \arg \min_f \mathbb{E}_{(x,y)} [L(y, f(x))] \quad (3.22)$$

onde  $L(y, f(x))$  é a função de perda, e a expectativa é tomada em relação à distribuição conjunta dos dados  $(x, y)$ .

Neste contexto, as (RNAs) se destacam por sua capacidade de atuar como aproximadores universais. Essa propriedade é sustentada por teoremas formais que afirmam que uma rede neural do tipo *feedforward* com ao menos uma camada oculta e funções de ativação não lineares (como ReLU ou base radial) pode aproximar qualquer função mensurável contínua com erro arbitrariamente pequeno (HASTIE et al., 2009). Isso torna as RNAs particularmente adequadas para problemas com padrões não lineares complexos, como a classificação de falhas mecânicas com base em sinais de vibração multivariados.

Um marco teórico fundamental para a justificativa do uso de RNAs em tarefas de classificação não linear é o Teorema da Aproximação Universal, proposto por George Cybenko em seu artigo seminal “Approximation by superpositions of a sigmoidal

function” (CYBENKO, 1989). Nesse trabalho, o autor demonstra que uma rede neural *feedforward* de camada única com função de ativação sigmoideal é capaz de aproximar qualquer função contínua em um conjunto compacto de  $\mathbb{R}^n$ , com uma precisão arbitrária, desde que possua número suficiente de neurônios na camada oculta.

Formalmente, seja  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  uma função contínua e  $\sigma$  uma função de ativação sigmoideal (ou seja, uma função contínua e não linear que satisfaz  $\lim_{x \rightarrow \infty} \sigma(x) = 0$  e  $\lim_{x \rightarrow -\infty} \sigma(x) = 1$ ). Cybenko prova que para todo  $\epsilon > 0$ , existe uma função, conforme Eq. (3.23):

$$G(x) = \sum_{j=1}^N \alpha_j \sigma(y_j^T x + \theta_j) \quad (3.23)$$

onde:

$x \in \mathbb{R}^n$  é o vetor de entrada;

$\sigma: \mathbb{R} \rightarrow \mathbb{R}$  é uma função de ativação sigmoideal contínua, tal que:

- se  $t \rightarrow +\infty$ , então  $\sigma(t) \rightarrow 1$ ; e

- se  $t \rightarrow -\infty$ , então  $\sigma(t) \rightarrow 0$ .

$y_j \in \mathbb{R}^n$  é o vetor de pesos da camada oculta;

$\theta_j \in \mathbb{R}$  é o viés associado ao neurônio da camada oculta;

$\alpha_j \in \mathbb{R}$  ..... representa o peso da saída daquele neurônio.

A principal contribuição de Cybenko reside na demonstração de que tais redes são densas no espaço  $C(I^n)$  – o espaço das funções contínuas sobre  $I^n$  – o que significa que, para qualquer função contínua  $f$  e qualquer  $\epsilon > 0$ , existe uma combinação de forma acima, conforme Eq. (3.24):

$$|G(x) - f(x)| < \epsilon \quad \forall x \in I^n \quad (3.24)$$

A chave teórica está na propriedade de distinção da função  $\sigma$ , definida pela Eq. (3.25):

$$\int_{I^n} \sigma(y^T x + \theta) d\mu(x) = 0 \quad \forall y \in \mathbb{R}^n, \quad (3.25)$$

$$\theta \in \mathbb{R} \Rightarrow \mu = 0$$

ou seja, se a integral de  $\sigma$  sobre todos os funcionais afins for nula para uma medida  $\mu$ , então essa medida deve necessariamente ser a nula — condição satisfeita por funções sigmoidais comuns (como logística e tangente hiperbólica).

Este teorema fundamenta o uso de RNAs em problemas de classificação e regressão com não linearidades elevadas, como no presente estudo de identificação de falhas de injeção em motores Diesel marítimos, onde os sinais de vibração apresentam características complexas e multivariadas. A capacidade da RNA de capturar essas relações não lineares por meio de uma única camada oculta com funções de ativação apropriadas permite sua aplicação robusta e eficaz.

Além disso, o artigo destaca que embora o modelo garanta a existência de aproximações arbitrárias, não se compromete com a eficiência computacional da construção — ou seja, a quantidade  $N$  de neurônios pode ser muito grande para funções altamente complexas, levando à chamada maldição da dimensionalidade. Ainda assim, a demonstração de Cybenko (1989) é um dos fundamentos teóricos mais poderosos para a confiança na arquitetura de redes *feedforward* na modelagem de sistemas reais.

### 3.5.2. Estrutura e Funcionamento de Redes Neurais *Feedforward*

As RNAs do tipo *feedforward* constituem uma das arquiteturas mais fundamentais e amplamente empregadas em tarefas de classificação, regressão e reconhecimento de padrões. Segundo AGGARWAL (2018) e HAYKIN (2009), essas redes são compostas por uma sequência de camadas de neurônios organizadas linearmente, onde os dados fluem unidirecionalmente da camada de entrada para a(s) camada(s) oculta(s), e, finalmente, para a camada de saída — sem loops ou ciclos, caracterizando o termo “*feedforward*”.

Cada neurônio na rede realiza uma operação de soma ponderada das entradas, seguida da aplicação de uma função de ativação não linear. Essa função é crucial para permitir que a rede modele relações complexas e não lineares entre as variáveis de entrada e saída. Esta operação pode ser formalizada da seguinte maneira, conforme Eq. (3.26):

$$a_j = \phi \left( \sum_{i=1}^n w_{ji} x_i + b_j \right) \quad (3.26)$$

onde:

- $a_j$  é a ativação do neurônio  $j$ ;
- $w_{ji}$  representa o peso associado à conexão entre o neurônio  $i$  da camada anterior e o neurônio  $j$ ;
- $x_i$  é a entrada correspondente;
- $b_j$  é o viés (bias); e
- $\emptyset$  é a função de ativação.

AGGARWAL (2018) enfatiza que a capacidade de aprendizado de uma RNA está diretamente relacionada ao número de neurônios e camadas ocultas. Redes com apenas uma camada oculta são teoricamente capazes de aproximar qualquer função contínua, conforme demonstrado pelo Teorema da Aproximação Universal. No entanto, a complexidade do problema pode demandar a utilização de múltiplas camadas ocultas e mecanismos de regularização para evitar o sobreajuste (overfitting) e melhorar a generalização.

A atualização dos pesos sinápticos — parâmetros que determinam a influência de cada entrada sobre o neurônio — é realizada por meio de algoritmos de aprendizado supervisionado, como o Gradiente Descendente ou, como neste estudo, o Gradiente Conjugado Escalonado. Esses algoritmos visam minimizar uma função de custo (como a entropia cruzada) que quantifica o erro entre as predições da rede e os rótulos reais.

Além disso, a arquitetura *feedforward* é particularmente apropriada para tarefas em que as entradas e saídas não têm dependência temporal, o que a diferencia das RNNs, mais indicadas para séries temporais. Na presente dissertação, a escolha da arquitetura *feedforward* se justifica pela natureza estática dos vetores de características extraídos dos sinais de vibração, processados em janelas de tempo fixas e independentes.

Assim, a modelagem com RNAs *feedforward* fornece uma base sólida e cientificamente validada para a identificação de falhas de injeção em motores Diesel, permitindo a construção de classificadores precisos e eficientes mesmo diante da complexidade dos sinais envolvidos.

### 3.5.3. Funções de Ativação e Custo

As funções de ativação desempenham papel central na capacidade de uma Rede Neural Artificial (RNA) aprender e representar relações não lineares complexas. A escolha da função de ativação influencia diretamente a expressividade da rede, sua eficiência computacional e sua capacidade de generalização. Conforme discutido por AGGARWAL (2018), funções clássicas como a sigmoide, a tangente hiperbólica (tanh) e a ReLU (Rectified Linear Unit) possuem vantagens e limitações específicas, e sua adoção deve considerar a natureza do problema e a estrutura da rede.

A função sigmoide, conforme Eq. (3.27):

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3.27)$$

é contínua e diferenciável, transformando entradas em um intervalo entre 0 e 1. Embora útil em problemas probabilísticos e classificações binárias, ela sofre com o problema do gradiente desvanecido em regiões saturadas, o que pode comprometer o aprendizado em redes profundas. A função tangente hiperbólica, conforme Eq. (3.28):

$$\tanh x = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.28)$$

resolve parcialmente esse problema ao centralizar a saída em torno de zero, mas ainda é vulnerável à saturação para entradas extremas.

Por sua vez, a função ReLU tornou-se popular devido à sua simplicidade computacional e à mitigação do gradiente desvanecido. No entanto, apresenta limitações como a “morte do neurônio” quando valores negativos se acumulam, além de não ser ideal para modelagens com domínios altamente não lineares ou que requeiram decisões com fronteiras suaves.

Neste trabalho, optou-se pela função base radial (Radial Basis Function – RBF), expressa como na Eq.(3.29):

$$\phi(x) = \exp\left(-\frac{\|x - c\|^2}{2\sigma^2}\right) \quad (3.29)$$

onde  $c$  representa o centro do neurônio e  $\sigma$  é o parâmetro que controla a largura da base. A principal vantagem da RBF reside na sua natureza local e na capacidade de modelar funções altamente não lineares com elevada precisão. Conforme destacado por AGGARWAL (2018), a RBF é particularmente eficaz quando as fronteiras de decisão são complexas, o que a torna ideal para problemas de classificação multiclasse, como a detecção de falhas de injeção em motores Diesel com base em sinais de vibração.

Além disso, a função RBF se destaca por possibilitar uma interpretação geométrica clara: neurônios são ativados com maior intensidade quando a entrada está próxima ao centro  $c$ , permitindo uma discriminação mais refinada dos padrões. Essa característica é fundamental neste estudo, que envolve a distinção entre múltiplas classes associadas a diferentes falhas de injeção simuladas cilindro a cilindro.

Dessa forma, a escolha da RBF neste trabalho é justificada tanto do ponto de vista teórico quanto empírico, sendo suportada por estudos consolidados na literatura, como os de HASSOUN (1995) e AGGARWAL (2018), e validada experimentalmente pelos elevados desempenhos obtidos nas fases de teste e validação do modelo.

Para problemas de classificação, a função de custo adotada foi a entropia cruzada, por oferecer vantagens superiores à função erro quadrático médio em contextos em que as saídas são probabilísticas. A função de custo da entropia cruzada penaliza previsões com alta confiança quando incorretas, promovendo modelos mais cautelosos e calibrados (HASSOUN, 1995). Segundo AGGARWAL (2018), a entropia cruzada é particularmente eficaz porque penaliza severamente previsões com alta confiança que estão incorretas. Sua formulação matemática, para uma instância com  $C$  classes, pode ser expressa como na Eq. (3.30):

$$L(y, \hat{y}) = - \sum_{i=1}^c y_i \log(\hat{y}_i) \quad (3.30)$$

onde:

- $y_i$  representa a classe real;
- $\hat{y}_i$  é a probabilidade prevista para a classe  $i$  pela rede neural.

Essa função é derivada do conceito de entropia em teoria da informação, sendo apropriada quando a saída do modelo representa uma distribuição de probabilidade. Vantagens destacadas por AGGARWAL (2018) incluem alta sensibilidade a classificações erradas com alta confiabilidade, estabilidade numérica quando combinada



com o algoritmo softmax, e melhora da convergência do modelo em tarefas de classificação multiclasse.

Em virtude dessas características, a função de entropia cruzada foi adotada nesta dissertação como função de custo principal para o treinamento dos modelos baseados em redes neurais, alinhando-se às boas práticas relatadas na literatura de aprendizado de máquina e redes neurais profundas.

#### 3.5.4. Redes Neurais de Função de Base Radial (RBF)

As Redes Neurais de Função de Base Radial (RBF) representam uma classe distinta de modelos computacionais inspirados em unidades biológicas com respostas localizadas, ou seja, que são sensíveis apenas a determinadas regiões do espaço de entrada. Essa característica confere às RBFs propriedades excepcionais de interpolação e aproximação de funções, tornando-as especialmente úteis em aplicações que exigem classificações multiclasse ou aproximações de funções complexas, como a identificação de falhas de injeção de combustível em motores Diesel marítimos (HASSOUN, 1995).

##### - Estrutura e Arquitetura

A arquitetura padrão de uma RBF é composta por três camadas:

- A camada de entrada, que transmite o vetor de entrada diretamente para a camada oculta;
- A camada oculta, formada por unidades com funções de ativação radialmente simétricas — tipicamente funções Gaussianas; e
- A camada de saída, usualmente composta por neurônios lineares que realizam combinações ponderadas das saídas da camada oculta.

Cada unidade da camada oculta avalia a "proximidade" entre o vetor de entrada  $x$  e um centro  $c_j$  associado, produzindo uma resposta significativa apenas se a entrada estiver próxima ao centro, segundo a métrica Euclidiana, conforme Eq. (3.31):

$$z_j = \exp\left(-\frac{\|x - c_j\|^2}{2\sigma_j^2}\right) \quad (3.31)$$

onde  $\sigma_j$  representa a largura (ou desvio padrão) da função de ativação associada ao neurônio  $j$  (HASSOUN, 1995).

- Propriedades Fundamentais:

Uma das principais vantagens das RBFs sobre outras arquiteturas de redes neurais, como as redes *feedforward* com unidades sigmóides, reside em sua capacidade de realizar aproximações locais, ou seja, somente um subconjunto de neurônios é ativado para uma determinada entrada, conferindo maior eficiência computacional no treinamento e melhor desempenho nas tarefas de classificação.

HASSOUN (1995) destaca que, virtude a essa natureza localizada, as RBFs são capazes de realizar aproximação universal de funções contínuas com precisão arbitrária, desde que sejam utilizados um número suficiente de neurônios e realize a escolha adequada de centros e larguras (POGGIO; GIROSI, 1989).

- Treinamento e Ajuste de Parâmetros

O processo de treinamento de uma RBF é geralmente dividido em duas etapas principais:

a) Determinação dos centros e larguras das funções radiais:

Tradicionalmente realizada via algoritmos de clustering, como o k-means, que identificam regiões densamente povoadas no espaço de entrada e posicionam os centros de forma a cobrir adequadamente os dados. A escolha das larguras é realizada com base na distância média entre os centros ou através de heurísticas que fazem o balanceamento da capacidade de generalização e a precisão local (MOODY; DARKEN, 1989).

b) Ajuste dos pesos da camada de saída:

Geralmente implementado por métodos lineares, como a pseudoinversa generalizada, ou via regra delta, visando minimizar o erro quadrático médio (SSE), conforme Eq. (3.32):

$$E = \frac{1}{2} \sum_{i=1}^m \| y_i - d_i \|^2 \quad (3.32)$$

onde  $y_i$  é a saída da rede para a entrada  $x_i$  e  $d_i$  é a saída desejada (HASSOUN, 1995).

Esse treinamento eficiente, em comparação com as redes de retropropagação tradicionais, resulta em tempos de aprendizado mais enxutos, sendo altamente desejável em sistemas de diagnóstico em tempo real, como na possibilidade de monitoramento de falhas em motores Diesel.

#### - Aplicação das RBFs na Classificação e Diagnóstico

As RBFs são particularmente adequadas para tarefas de classificação, dado que suas funções de ativação localizadas promovem uma segmentação natural do espaço de entrada em regiões associadas a diferentes classes. Isso reduz as taxas de falsos positivos e melhora a robustez do classificador, como demonstrado em diversas aplicações de diagnóstico de falhas mecânicas (WETTSCHERECK; DIETTERICH, 1992).

No contexto específico deste estudo, as RBFs foram utilizadas para a classificação multiclasse de 13 classes distintas de um motor Diesel marítimo, obtendo notável desempenho na detecção de falhas de injeção.

#### - Limitações e Considerações

Apesar de sua eficácia, as RBFs possuem certas limitações, especialmente na sua reduzida capacidade de extrapolação, uma vez que suas camadas ocultas não respondem significativamente a entradas situadas fora da região onde foram treinadas (HASSOUN, 1995). Adicionalmente, em espaços de entrada de alta dimensionalidade, a necessidade de um número elevado de neurônios pode resultar em sobreajuste, demandando técnicas adequadas de regularização, além de um aumento considerável no tempo de processamento.

### **3.5.5. Algoritmos de Otimização para Treinamento de Redes Neurais**

A etapa de otimização em RNAs consiste em ajustar os pesos sinápticos da rede de modo a minimizar uma função de custo, representando o erro entre a predição do modelo e os rótulos verdadeiros. Diversos algoritmos de otimização têm sido propostos na literatura, cada qual com características distintas quanto à sua eficiência, robustez e complexidade computacional. Dentre os mais tradicionais, destacam-se o Gradiente

Descendente, o Gradiente Descendente Estocástico, o Gradiente Conjugado e sua variante escalonada, o Gradiente Conjugado Escalado — adotado na presente pesquisa.

O Gradiente Descendente é o algoritmo base que ajusta os pesos da rede segundo a direção oposta ao gradiente da função de custo, sendo definido pela atualização iterativa, conforme Equação (3.33):

$$W_{t+1} = W_t - \eta \nabla J(W_t) \quad (3.33)$$

onde  $W$  representa o vetor de pesos,  $\eta$  a taxa de aprendizado e  $J(W)$  a função de custo. Embora simples, o Gradiente Descendente apresenta limitações como lenta convergência e sensibilidade à escolha de  $\eta$  (ALPAYDIN, 2010).

O Gradiente Descendente Estocástico melhora a eficiência ao atualizar os pesos com base em amostras individuais ou pequenos lotes (mini-batches), o que acelera o treinamento em grandes bases de dados. Contudo, esse método é mais ruidoso e pode sofrer com oscilações na direção do gradiente (AGGARWAL, 2018).

O Gradiente Conjugado foi desenvolvido para acelerar a convergência em problemas quadráticos, evitando as limitações do Gradiente Descendente ao considerar direções de busca conjugadas ao invés do gradiente puro. Em redes neurais, adaptações do Gradiente Conjugado têm mostrado ganhos de eficiência, especialmente em modelos de média escala (HASSOUN, 1995).

Neste contexto, o Gradiente Conjugado Escalado surge como uma alternativa robusta, combinando os benefícios do Gradiente Conjugado com técnicas de escalonamento que eliminam a necessidade de linha de busca explícita. Proposto por MØLLER (1993), o Gradiente Conjugado Escalado ajusta dinamicamente o passo de atualização com base em aproximações de segunda ordem, conferindo maior estabilidade e rápida convergência do modelo.

A análise comparativa revela que o Gradiente Conjugado Escalado atinge mínimos locais de forma mais eficiente do que métodos convencionais, tornando-se especialmente indicado em problemas com múltiplas variáveis e alta não linearidade — como a classificação de padrões vibracionais em motores Diesel. Por essa razão, o Gradiente Conjugado Escalado foi selecionado como o algoritmo de otimização principal neste estudo, contribuindo para a estabilidade do treinamento e melhor desempenho global da RNA.

### 3.6. Métricas de Avaliação de Desempenho

Para proceder à avaliação do desempenho dos algoritmos de classificação aplicados ao diagnóstico de falhas, torna-se fundamental estabelecer as métricas que serão utilizadas para mensurar sua eficácia. A definição criteriosa dessas métricas é essencial, pois permite quantificar a capacidade dos modelos em identificar corretamente as diferentes classes de falha, bem como avaliar sua robustez, sensibilidade e confiabilidade. As principais métricas adotadas neste estudo estão descritas nos subitens a seguir:

#### 3.6.1. Precisão (Precision)

A precisão é uma métrica que quantifica a proporção de classificações corretas dentro das instâncias que o modelo previu como positivas. Em outras palavras, ela avalia a exatidão das predições positivas realizadas pelo algoritmo, indicando com que frequência as falhas identificadas pelo modelo correspondem, de fato, a falhas reais. A precisão é definida pela Eq. (3.34):

$$Precisão = \frac{VP}{VP + FP} \quad (3.34)$$

onde:

- **VP (Verdadeiros Positivos)** representa a quantidade de instâncias corretamente classificadas como falhas;
- **FP (Falsos Positivos)** representa a quantidade de instâncias incorretamente classificadas como falhas, quando na verdade são condições normais.

Um valor elevado de precisão indica que o modelo comete poucos erros ao classificar uma condição como falha, o que é particularmente relevante em sistemas de diagnóstico, onde falsos alarmes podem levar a manutenções desnecessárias, aumento de custos operacionais e indisponibilidade do motor Diesel (POWERS, 2011; TAN et al., 2018; GOODFELLOW et al., 2016).

### 3.6.2. Sensibilidade (Recall)

A Sensibilidade, também conhecida como Recall ou taxa de verdadeiros positivos, é uma métrica essencial na avaliação de modelos de classificação, especialmente em contextos em que a detecção de eventos positivos (como falhas) é crítica. Esta métrica indica a proporção de instâncias positivas corretamente identificadas pelo modelo em relação ao total de instâncias verdadeiramente positivas no conjunto de dados. Sua formulação matemática é expressa pela Eq. (3.35):

$$Recall = \frac{VP}{VP + FN} \quad (3.35)$$

Onde:

- **FN (Falsos Negativos)** são as instâncias que o modelo classificou incorretamente como normais, apesar de representarem falhas reais.

Um valor elevado de Sensibilidade reflete a capacidade do modelo de minimizar a ocorrência de falsos negativos, o que é particularmente importante em aplicações como manutenção preditiva. Para sistemas de diagnóstico de falhas em motores, por exemplo, uma sensibilidade alta assegura que um baixo número de falhas passe despercebidas, aumentando a confiabilidade do sistema de monitoração.

Essa métrica é amplamente utilizada na literatura de aprendizado de máquina e é considerada indispensável na análise de classificadores binários e multiclasse (POWERS, 2011; TAN et al., 2018; GOODFELLOW et al., 2016).

### 3.6.3. Acurácia (Accuracy)

A acurácia é uma métrica amplamente utilizada na avaliação de modelos de classificação, sendo definida como a proporção de predições corretas em relação ao total de instâncias avaliadas. Ela oferece uma visão geral do desempenho do classificador ao considerar tanto as predições corretas de instâncias positivas quanto de instâncias negativas. A acurácia é definida pela Eq. (3.36):

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN} \quad (3.36)$$

Onde:

- **VN (Verdadeiros Negativos)** são as instâncias normais corretamente classificadas; e

Embora seja uma métrica de fácil compreensão e interpretação, a acurácia pode se tornar traiçoeira em bases de dados desbalanceadas, nas quais uma das classes domina. Nestes casos, um classificador pode atingir alta acurácia apenas por prever a classe majoritária, negligenciando completamente a detecção da classe minoritária, o que pode ser insatisfatório em sistemas de diagnóstico de falhas (GOODFELLOW; BENGIO; COURVILLE, 2016).

Por isso, é recomendada a utilização da acurácia em conjunto com outras métricas, como Precisão, Sensibilidade e F1-Score, para uma avaliação mais robusta do desempenho da RNA.

#### 3.6.4. F1-Score

O F1-Score é uma métrica que combina, de forma harmônica, as duas principais medidas de desempenho de um classificador: a precisão e a sensibilidade. Trata-se de uma medida especialmente útil em cenários nos quais existe um desequilíbrio entre as classes, como nos sistemas de diagnóstico de falhas, onde a ocorrência de falhas é significativamente menor em comparação com condições normais. Matematicamente, o F1-Score é definido pela Equação (3.37):

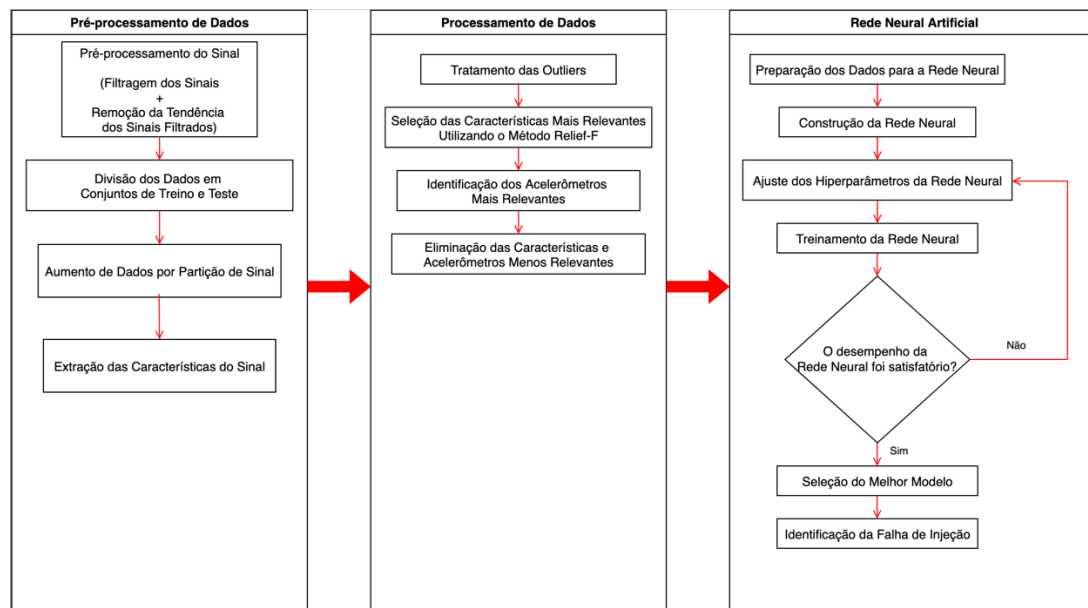
$$F1 - Score = 2 * \frac{Precisão * Recall}{Precisão + Recall} \quad (3.37)$$

Essa equação expressa a média harmônica entre a precisão e a sensibilidade, penalizando severamente valores discrepantes entre essas duas métricas. Devido esse motivo, o F1-Score é particularmente recomendado quando se busca um equilíbrio entre a capacidade do modelo de detectar falhas (sensibilidade) e a de evitar alarmes falsos (precisão).

Um valor elevado de F1-Score ( $F1-Score \geq 95\%$ ) indica que o modelo é capaz de identificar corretamente a maioria das falhas com uma baixa taxa de falsos positivos, o que o torna um parâmetro decisivo na escolha do modelo mais adequado em aplicações de manutenção preditiva baseadas em aprendizado de máquina (POWERS, 2011; TAN et al., 2018; GOODFELLOW et al., 2016).

## 4. METODOLOGIA

Este capítulo descreve detalhadamente o procedimento metodológico adotado para a identificação de falhas de injeção em um motor Diesel marítimo, com base em sinais de vibração e utilizando modelos de RNAs. A metodologia foi estruturada em três grandes blocos: (i) pré-processamento dos dados, (ii) seleção das características e acelerômetros mais relevantes, e (iii) modelagem com RNA, conforme ilustrado no fluxograma a seguir (Figura 3).



*Figura 3 - Fluxograma Geral da Metodologia para Classificação de Falhas de Injeção em Motor Diesel utilizando Sinais de Vibração e Redes Neurais Artificiais*

### 4.1. Pré-processamento de Dados

A primeira etapa consistiu no carregamento dos sinais brutos de vibração adquiridos durante os ensaios realizados em bancada de teste instrumentada, tendo como unidade sob análise o motor Diesel marítimo MTU 12V4000C11. Os dados foram obtidos por meio de 15 acelerômetros uniaxiais do tipo ICP®, estrategicamente posicionados sobre os cabeçotes dos cilindros (pontos 1V a 12V) e próximos às janelas de inspeção do bloco (pontos 13T, 14T e 15T), conforme mostrado na Figura 4.






Figura 4 - Pontos de instalação dos acelerômetros

A aquisição foi executada com frequência de amostragem de 10.240 Hz, utilizando placas de aquisição NI 9234 e o ambiente LabVIEW™ para monitoramento e registro contínuo.

O processamento inicial dos sinais incluiu duas etapas essenciais: filtragem digital e remoção de tendência (*detrending*). A filtragem foi aplicada com o objetivo de atenuar componentes de ruído de alta frequência e preservar as faixas espectrais de interesse associadas ao comportamento vibracional do motor. A etapa de *detrending* visou eliminar variações de baixa frequência e deslocamentos do sinal, garantindo que as componentes dinâmicas relevantes para a detecção de falhas de injeção fossem adequadamente realçadas.

Com os sinais limpos, foi realizada uma técnica fundamental tanto para aumentar o volume amostral quanto para capturar variações estatísticas locais ao longo do tempo. Esta etapa configura-se como um processo de *data augmentation* estruturado, em que múltiplos segmentos extraídos de um mesmo sinal contribuem para enriquecer a diversidade da base de dados sem induzir viés artificial. Como resultado, a generalização dos modelos de aprendizado de máquina foi significativamente favorecida.

Para cada janela segmentada, procedeu-se à extração de um conjunto abrangente de características estatísticas, abrangendo os Domínios do Tempo, da Frequência (via FFT) e do Tempo-Frequência (utilizando também a FFT). As características extraídas, presentes nas Tabelas 2 e 3, incluem métricas clássicas como média, variância, valor

RMS, fator de crista, curtose, entropia espectral, entre outras, previamente validadas na literatura para problemas de detecção de falhas mecânicas.

Em seguida, os dados extraídos foram organizados e etiquetados conforme suas respectivas classes, abrangendo uma condição normal de operação e 12 condições de falha. Estas falhas corresponderam à simulação de falhas de injeção total em cada um dos 12 cilindros do motor, realizadas sempre de forma individualizada, ou seja, sem ocorrência simultânea em mais de um cilindro. Esses dados foram divididos em subconjuntos de treinamento (70%), validação (15%) e teste (15%). Essa divisão estratificada assegurou o equilíbrio entre as classes e permitiu avaliação objetiva do desempenho dos modelos preditivos. Os conjuntos resultantes foram salvos em estrutura compatível com os algoritmos de aprendizagem subsequentes.

#### **4.2. Processamento de Dados**

Após a etapa de pré-processamento e extração de características, iniciou-se o processo de refinamento e organização dos dados com o objetivo de otimizar sua entrada nas RNAs. Esta fase foi essencial para garantir que os dados apresentados aos modelos de aprendizado mantivessem alta integridade, representatividade estatística e relevância discriminativa.

Durante o processamento dos sinais de vibração adquiridos dos acelerômetros, foi implementada uma etapa dedicada ao tratamento de outliers, com o propósito de mitigar a influência de valores extremos que poderiam comprometer a acurácia e a robustez dos modelos. A identificação dos outliers foi realizada com base no critério estatístico dos quartis, também conhecido como método do Intervalo Interquartil (IQR), o qual se baseia na distribuição dos dados e detecta valores que se encontram significativamente distantes da mediana.

Uma vez identificados os valores anômalos, adotou-se a técnica de correção por *clipping*, que consiste em ajustar os valores excedentes aos limites inferiores e superiores aceitáveis, definidos com base no IQR. Essa abordagem foi preferida à simples exclusão das amostras, pois preserva a integridade da base de dados e evita a redução do volume amostral, o que poderia prejudicar a capacidade de generalização do modelo.

Essa estratégia assegurou que os sinais mantivessem sua estrutura estatística e dinamicidade, sendo protegidos contra distorções ocasionadas por ruídos extremos, falhas instrumentais pontuais ou interferências esporádicas durante a aquisição. Dessa forma, o conjunto final de dados alimentado as RNAs apresentou maior consistência e

representatividade em relação às condições reais de operação do motor, favorecendo o desempenho dos modelos preditivos de falhas de injeção.

Na sequência, foi conduzida a seleção das características mais relevantes por meio do método Relief-F, uma técnica amplamente reconhecida na literatura por sua eficácia na identificação de atributos discriminativos em problemas de classificação. O algoritmo Relief-F avaliou a importância relativa de cada uma das características extraídas, considerando sua capacidade de distinguir entre as diferentes classes de falha de injeção. Esta seleção visou reduzir a dimensionalidade do vetor de características, eliminar redundâncias e evitar o fenômeno conhecido como *curse of dimensionality*, que tende a comprometer o desempenho de modelos em bases com grande número de atributos.

Além da redução de atributos, também foi realizada a identificação dos acelerômetros mais relevantes. A partir da análise dos pesos atribuídos às características extraídas de cada sensor, foram priorizados os acelerômetros cuja contribuição era mais expressiva para a detecção das falhas simuladas. Esta abordagem permitiu reduzir a complexidade do sistema de instrumentação sem perda significativa de desempenho.

As características e sensores com menor contribuição diagnóstica foram eliminados da base de dados, consolidando um conjunto otimizado de entradas para as etapas de modelagem preditiva. O resultado desse processamento foi um banco de dados altamente representativo, com atributos informativos e livres de ruído, pronto para ser utilizado no treinamento, validação e teste das RNAs.

#### **4.3. Redes Neurais Artificiais**

A etapa final da metodologia consistiu na implementação, treinamento e validação de modelos baseados em RNAs, com o objetivo de classificar as diferentes condições operacionais do motor Diesel e identificar falhas de injeção de combustível a partir dos sinais de vibração previamente processados. A escolha dessa abordagem se justifica por sua reconhecida robustez na modelagem de sistemas dinâmicos, complexos e não lineares — características inerentes aos fenômenos associados à mecânica de combustão e falhas de injeção em motores alternativos.

Inicialmente, realizou-se a preparação dos dados de entrada, o que incluiu a normalização das características selecionadas e a organização dos vetores de entrada e saída, assegurando compatibilidade com os requisitos topológicos da rede. Essa etapa foi essencial para garantir que todas as variáveis apresentassem escalas compatíveis e que a distribuição das amostras fosse balanceada entre as 13 classes definidas (1 condição

normal e 12 condições com falhas de injeção simuladas individualmente para cada cilindro do motor).

Na Tabela 4 é mostrado os principais componentes adotados na arquitetura da RNA.

*Tabela 4 - Principais componentes da arquitetura da Rede Neural Artificial adotada*

<b>Componente</b>	<b>Descrição</b>
<b>Arquitetura</b>	Rede Neural Artificial (RNA) do tipo <i>feedforward</i> .
<b>Camada oculta</b>	Uma camada, com número variável de neurônios.
<b>Função de ativação</b>	<i>Radial Basis Function</i> (RBF) – elevada capacidade de modelagem em regiões não lineares do espaço de decisão, eficaz em classificação multiclasse e de alta dimensionalidade.
<b>Algoritmo de treinamento</b>	Gradiente Conjugado Escalonado de Retropropagação ( <i>trainscg</i> ) – eficiente em redes de porte intermediário e estável no processo iterativo de minimização.
<b>Função de desempenho</b>	Entropia cruzada ( <i>crossentropy</i> ) – apropriada para classificação com saídas probabilísticas, penalizando com maior rigor classificações incorretas de alta confiança.

A etapa de ajuste dos hiperparâmetros envolveu tanto a calibração empírica inicial de parâmetros como a aplicação de um processo sistemático de otimização. Nesse contexto, foi empregada a otimização bayesiana, utilizando a função *bayesopt* do ambiente MATLAB. Esse método busca encontrar automaticamente a combinação ótima de parâmetros da RNA, reduzindo a necessidade de ajustes manuais e aumentando a capacidade de generalização do modelo.

O espaço de busca dos hiperparâmetros foi definido por um vetor de variáveis otimizáveis, conforme relação abaixo:

- Número de neurônios na camada oculta;
- Taxa de aprendizado;
- Número máximo de épocas de treinamento;
- Objetivo de erro mínimo (goal) para critério de parada;

- Gradiente mínimo (min\_grad) para critério de convergência;
- Máximo de falhas de validação consecutivas (max\_fail);
- Parâmetro sigma da função RBF; e
- Fator de regularização lambda para controle de sobre ajuste.

Esse processo de otimização automatizada possibilitou a seleção sistemática das melhores combinações de hiperparâmetros para cada cenário (número de características e acelerômetros utilizados), resultando em modelos altamente performáticos e consistentes nos conjuntos de teste, conforme evidenciado no capítulo Resultados e Discussões.

Com a rede devidamente configurada, deu-se início ao treinamento supervisionado, no qual o modelo foi exposto aos exemplos rotulados oriundos do conjunto de dados de treinamento, correspondentes a 70% da base total. Os 30% restantes foram divididos igualmente entre os conjuntos de validação (15%) e teste (15%). A divisão estratificada teve como objetivo garantir o equilíbrio entre as classes e prevenir o *overfitting*, assegurando que o modelo fosse avaliado em dados independentes daqueles usados no treinamento.

Durante o treinamento, a rede neural ajustava iterativamente seus pesos com base nos erros cometidos, enquanto o conjunto de validação era utilizado para monitorar a evolução do desempenho e ativar mecanismos de parada antecipada, como o *early stopping*, em caso de degradação da generalização.

Após o treinamento, a performance da RNA foi avaliada com base em métricas estatísticas aplicadas exclusivamente ao conjunto de teste, incluindo precisão, sensibilidade, acurácia, especificidade e F1-Score. Caso os resultados não atingissem os critérios mínimos de desempenho estipulados, novos cenários de hiperparâmetros eram definidos e o processo de treinamento era repetido.

Uma vez identificado um modelo com F1-Score superior a 95%, este era considerado apto a compor o conjunto final de modelos aprovados para identificação de falhas de injeção de combustível em motores Diesel com base na análise dos sinais de vibração.

## 5. ESTUDO DE CASO

Este capítulo tem como objetivo apresentar o estudo de caso aplicado, detalhando o motor Diesel marítimo analisado (Figura 5), os procedimentos de aquisição dos sinais de vibração e a metodologia experimental empregada para a simulação e identificação de falhas de injeção.



*Figura 5 - Vista Geral do Motor MTU 12V4000 e do Dinamômetro Prüftechnik BFBg 2h*

### 5.1 Caracterização do Conjunto Motor Diesel e Dinamômetro

As características construtivas e operacionais do motor diesel MTU 12V4000C11

encontram-se sintetizadas na Tabela 5, abrangendo informações como número de cilindros, sistema de injeção, dimensões geométricas, potência nominal e torque máximo. Complementarmente, a Tabela 6 apresenta as dimensões globais e o peso aproximado do motor, enquanto a Tabela 7 descreve a posição do centro de gravidade em condição seca, aspecto relevante para análises de instalação e balanceamento estrutural. Os dados de desempenho em diferentes rotações de operação, incluindo potência, torque e consumo específico, são apresentados na Tabela 8, fornecendo subsídios para a avaliação da eficiência energética do motor. Por fim, a Tabela 9 apresenta as especificações técnicas do dinamômetro Hofmann BFBg 2h, empregado nos ensaios experimentais, destacando sua capacidade de torque, potência e requisitos de refrigeração.

*Tabela 5 - Especificações Técnicas – Motor Diesel MTU 12V4000C11*

<b>Especificações Técnicas – Motor Diesel MTU 12V4000C11</b>	
<b>Fabricante / Modelo</b>	MTU / 12V4000C11
<b>Número de Cilindros / Ciclo</b>	12 cilindros em V / 4 tempos
<b>Ângulo entre bancadas em V</b>	90°
<b>Sistema de Injeção</b>	Injeção direta
<b>Sistema de Combustível</b>	Common Rail com controle eletrônico DDEC IV
<b>Controle de Injeção</b>	Controle individual por cilindro, com controle total do tempo de injeção
<b>Resfriamento</b>	Por água
<b>Turboalimentação</b>	Estágio único - Um turbocompressor por bancada
<b>Diâmetro do Cilindro (Bore)</b>	165 mm
<b>Curso (Stroke)</b>	190 mm
<b>Deslocamento por Cilindro</b>	4,1 litros
<b>Deslocamento Total</b>	48,8 litros
<b>Razão de Compressão</b>	14:1
<b>Potência Nominal</b>	1.193 kW
<b>Rotação Nominal</b>	1.900 RPM
<b>Torque Máximo</b>	7.595 N·m
<b>Velocidade do Torque Máximo</b>	1.500 rpm
<b>Ordem de Ignição (Firing Order)</b>	A1-B2-A5-B4-A3-B1-A6-B5-A2-B3-A4-B6

Tabela 6 - Dimensões / Peso Aproximado

Dimensões / Peso Aproximado	
<b>Comprimento Total</b>	2.537,7 mm
<b>Largura Total</b>	1.587,8 mm
<b>Altura Total</b>	1.736,3 mm
<b>Seco (Dry)</b>	6.044 kg
<b>Molhado (Wet)</b>	6.428 kg

Tabela 7 - Centro de Gravidade (Motor Seco)

Centro de Gravidade (Motor Seco)	
<b>Referência Do bloco traseiro ao longo do eixo X</b>	899,2 mm
<b>Acima do virabrequim (eixo Y)</b>	238,8 mm
<b>À direita do virabrequim (eixo Z)</b>	0,0 mm

Tabela 8 - Dados de Desempenho do MTU 12V4000C11

Dados de Desempenho do MTU 12V4000C11			
Rotação (rpm)	Potência (kW)	Torque (N·m)	Consumo (g/kWh)
1200	633	5038	211
1350	905	6398	194
1500	1193	7595	190
1650	1193	6905	193
1800	1193	6330	194
1900	1193	5996	-

Tabela 9 - Dados Técnicos do Dinamômetro

Dados Técnicos do Dinamômetro		
Modelo	BFBg 2h	—
Binário de rotação máximo	22.920	N.m
Potência máxima	5.000	kW
Potência máxima do dinamômetro	24.000	N
Rotação máxima	3.000	min <sup>-1</sup> (rpm)
Necessidade de água refrigerante (capacidade máxima)	135.000	L/h
Temperatura máxima da água refrigerante (entrada)	45	°C
Temperatura máxima da água refrigerante (saída)	70	°C



Uma das principais inovações tecnológicas do motor MTU Série 4000, como o modelo 12V4000C11 (Figura 6) utilizado neste estudo, é a incorporação do sistema de injeção de combustível do tipo *Common Rail*, que representa um marco em termos de controle preciso, eficiência energética e redução de emissões em aplicações marítimas de alto desempenho.

Diferentemente dos sistemas convencionais que utilizam injetores comandados por came ou bombas de injeção com êmbolos individuais para gerar pressão pontualmente, o sistema *Common Rail* da Série 4000 opera com uma única bomba de alta pressão, que fornece combustível continuamente pressurizado para todos os injetores, independentemente do regime de operação. Com isso, elimina-se a dependência mecânica da posição do virabrequim, permitindo um controle independente do momento da injeção.




Figura 6 - Esquema de um Sistema Common Rail. Fonte: BASSHUYSEN; SCHÄFER (2004).

O gerenciamento integral do ciclo de injeção é realizado por meio do sistema eletrônico *Detroit Diesel Electronic Control* (DDEC IV), que atua diretamente sobre as solenóides das unidades injetoras. Esse sistema eletrônico é responsável por controlar com precisão o início da injeção (BOI), a duração do pulso (PW), a quantidade de combustível injetado e a atomização do jato, em função dos parâmetros operacionais do motor e das condições ambientais.

Esse controle dinâmico é viabilizado por meio de microprocessadores presentes no módulo DDEC IV, que recebem sinais de diversos sensores (temperatura, pressão, rotação, entre outros), permitindo decisões em tempo real sobre o ciclo de injeção ideal para cada cilindro.

### 5.1.1. Injeção Eletrônica Piloto e Otimização da Combustão

Uma importante funcionalidade habilitada pelo DDEC IV é a Injeção Eletrônica Piloto. Nos sistemas de injeção convencionais, o atraso de ignição entre a injeção e o início da combustão tende a provocar acúmulo de combustível não queimado na câmara, o que resulta em picos elevados de pressão (*rate of pressure rise*), emissão de fumaça branca, ruído de combustão intenso (*knocking*) e maiores níveis de consumo específico.

Com a Injeção Eletrônica Piloto (Figura 7), o sistema injeta uma pequena quantidade inicial de combustível antes da injeção principal, o que proporciona o início da combustão de forma mais suave e controlada. A imagem mostra as curvas de voltagem, corrente elétrica, estado da válvula de controle e taxa de injeção ao longo do tempo. O gráfico ilustra a ocorrência de múltiplos pulsos de injeção, evidenciando o controle dinâmico realizado pela ECU. Essa estratégia permite a implementação de injeção piloto e principal, otimizando a combustão e reduzindo emissões.




Figura 7 - Ciclo de Injeção Multipulso do Sistema Common Rail Controlado por DDEC IV. Fonte: Rolls-Royce.

### 5.1.2. Injetores Eletrônicos Unitários

Outro diferencial do sistema é a utilização de Injetores Eletrônicos Unitários, os quais recebem combustível já pressurizado pelos trilhos do Common Rail e não

necessitam gerar pressão internamente. Esse conceito elimina a necessidade de ajustes mecânicos associados ao came e permite que toda a atuação seja feita eletronicamente. O DDEC IV é responsável por comandar a quantidade de combustível injetado, a precisão do tempo de abertura e o fechamento do injetor.

Essa arquitetura favorece a padronização da injeção entre os cilindros, maior repetibilidade e confiabilidade, além de viabilizar estratégias de diagnóstico eletrônico baseadas em parâmetros como tempo de resposta, corrente de acionamento e pressão nos trilhos.

## **5.2 Detroit Diesel Diagnostic Link (DDDL)**

No presente estudo, o software *Detroit Diesel Diagnostic Link* (DDDL) foi utilizado como ferramenta técnica essencial para a indução experimental de falhas de injeção no motor MTU 12V4000C11, viabilizando a coleta de sinais de vibração associados a diferentes condições de operação, incluindo falhas simuladas de forma precisa e não invasiva.

O DDDL, desenvolvido pela *Detroit Diesel Corporation* (DDC), é um ambiente diagnóstico avançado que permite a comunicação direta com a ECU DDEC IV do motor. Dentre suas múltiplas funcionalidades, destaca-se a capacidade de interromper seletivamente a injeção de combustível em cada um dos cilindros, de forma totalmente controlada, rápida e segura (Figura 8). Ressalta-se que, virtude limitação do software DDDL, somente é possível realizar cortes de injeção em um cilindro por vez. O software também não permite atrasar ou adiantar a injeção do combustível e alterar a quantidade de combustível injetado.

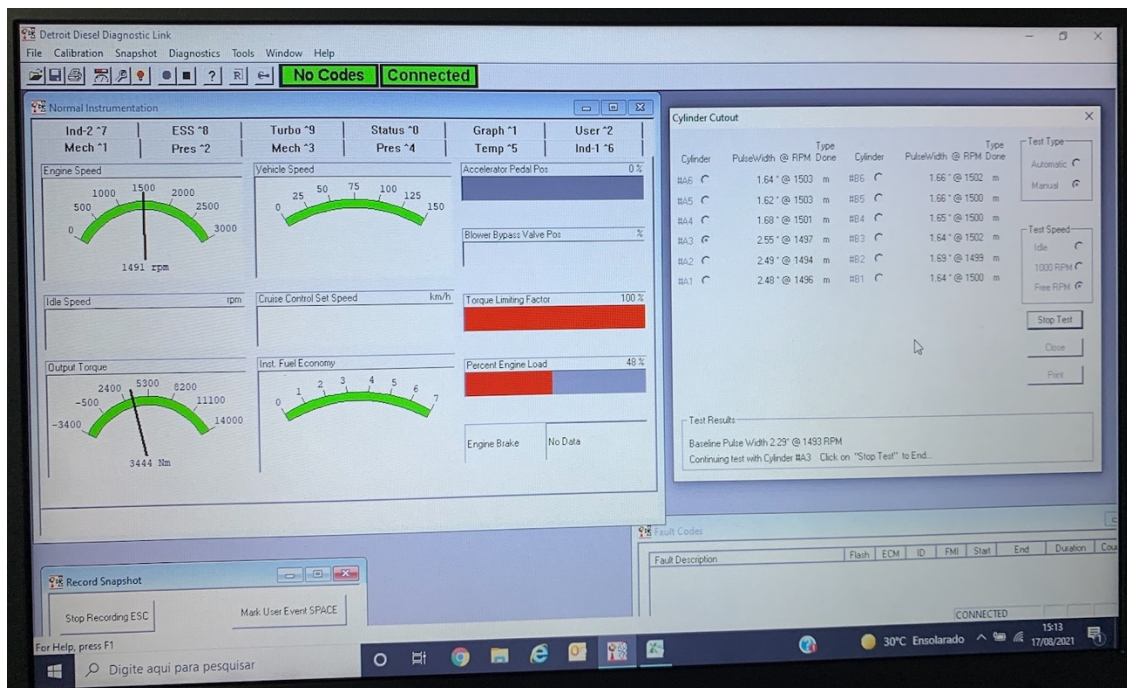
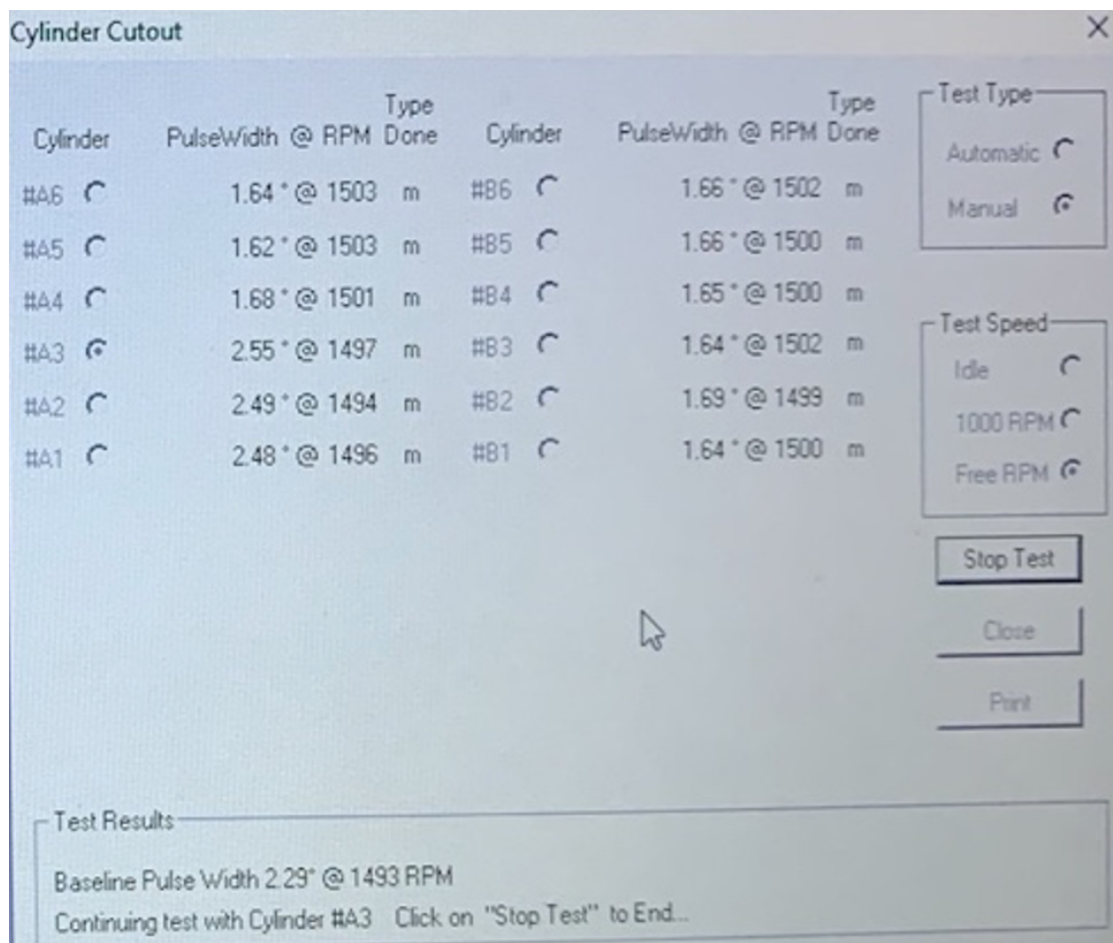


Figura 8 - Interface gráfica do software Detroit Diesel Diagnostic Link

Durante os testes experimentais, o DDDL foi empregado para realizar **cortes individuais de combustível nas unidades injetoras eletrônicas**, simulando falhas reais de injeção, sem a necessidade de intervenções mecânicas ou físicas no motor. Esse processo foi fundamental para isolar os efeitos vibracionais de cada cilindro, permitindo a construção de um banco de dados com assinaturas distintas para condições normais e falhas de injeção de combustível; reproduzir, com elevada fidelidade, falhas típicas como ausência de injeção ou interrupção abrupta da queima e avaliar a sensibilidade dos acelerômetros posicionados em diferentes regiões do motor (cilindros e bloco) frente às variações dinâmicas induzidas. A Figura 9 mostra a janela do *software* DDL onde é possível selecionar o cilindro que sofrerá corte de injeção de combustível.



*Figura 9 - Tela da Janela de Corte de Injeção de Combustível, do DDDL, no Cabeçote A3 ou 3V*

A indução sistemática de falhas com o suporte do DDDL permitiu garantir a qualidade e a rotulagem precisa dos dados utilizados para o treinamento dos modelos de RNAs. Essa abordagem assegurou a consistência nos cenários de coleta, com replicabilidade controlada para cada condição testada, o sincronismo entre a falha induzida e o início da aquisição dos sinais de vibração, evitando ambiguidade nos dados, a geração de um conjunto de dados confiável e tecnicamente robusto, com separação clara entre as classes de operação normal e com falha de injeção.

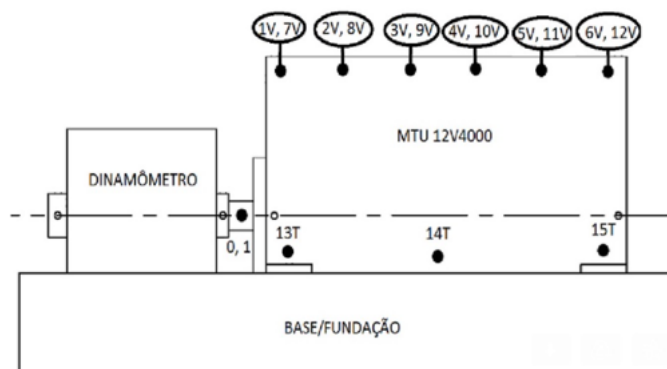
O uso do DDDL foi, portanto, não apenas um recurso de apoio diagnóstico, mas um elemento central da metodologia experimental, viabilizando uma análise fundamentada dos efeitos das falhas de injeção sobre o comportamento vibracional do motor e servindo como base de referência para validação dos modelos de classificação desenvolvidos nesta dissertação.

### 5.3 Sistema de Aquisição de Dados

Para a coleta dos sinais de vibração utilizados neste estudo, foi desenvolvido um



sistema de aquisição de dados robusto, configurado para atender aos requisitos de alta resolução temporal, múltiplos canais simultâneos e confiabilidade em ambientes industriais severos. O sistema foi responsável por captar, registrar e armazenar os sinais provenientes dos acelerômetros instalados no motor Diesel MTU 12V4000C11, bem como de outros sensores auxiliares de monitoramento. Na Figura 10 é possível visualizar os pontos de coleta das assinaturas de vibração.



*Figura 10 - Vista do Conjunto Motor-Dinamômetro*

### 5.3.1. Arquitetura do Sistema de Aquisição

O sistema foi composto por cinco placas de aquisição do tipo NI 9234, pertencentes à série C da *National Instruments*. Cada placa dispõe de quatro canais de entrada analógica para aquisição de sinais dinâmicos com alto desempenho, totalizando 20 canais disponíveis, dos quais 15 foram utilizados simultaneamente para a aquisição de sinais de vibração e referência.

Os dados foram adquiridos a uma taxa de amostragem de 10.240 Hz, valor selecionado com base na faixa de frequência de interesse para identificação de falhas mecânicas no regime de operação do motor analisado, garantindo conformidade com o critério de Nyquist para as componentes espectrais de até 5.120 Hz.

A infraestrutura experimental contou com a presença de um Tacômetro e de um Sistema Torque Track (Figura 11), instalado no eixo do Dinamômetro, utilizado para o monitoramento do torque dinâmico transmitido pelo eixo de manivelas do motor. Esse sistema foi configurado para registrar variações de torque ao longo do tempo, com potencial para revelar oscilações associadas a irregularidades na combustão e falhas de injeção. Esses sensores, permitem a medição das deformações torcionais diretamente associadas às cargas mecânicas transmitidas durante a operação do motor.





Figura 11 - Instalação do Tacômetro e do Sistema Torque Track

Entretanto, cabe destacar que, embora esses sistemas estivessem plenamente operacionais durante os ensaios experimentais, os dados por eles obtidos não foram utilizados nas análises realizadas neste estudo. A decisão visou manter o foco exclusivo na análise de sinais de vibração para diagnóstico de falhas por meio de RNAs. Os dados coletados por esses sensores foram devidamente armazenados e serão objeto de investigações futuras, voltadas à integração de múltiplas fontes de sinal para diagnósticos mais abrangentes e robustos.

### 5.3.2. Transdutores Instalados

O aparato experimental incluiu um total de 15 acelerômetros uniaxiais, sendo que 12 acelerômetros foram fixados diretamente sobre os cabeçotes dos cilindros, permitindo análise individualizada por unidade injetora e 3 acelerômetros adicionais foram posicionados estrategicamente próximos às janelas de inspeção do bloco (Figura 12), visando à avaliação comparativa entre medições em regiões estruturais distintas do motor.



*Figura 12 - Disposição dos acelerômetros nos cabeçotes e no bloco do motor MTU 12V4000C11*

Essa distribuição permitiu capturar padrões vibracionais tanto localizados quanto globais, fundamentais para o diagnóstico baseado em aprendizado de máquina.

Para a aquisição dos sinais de vibração no motor Diesel MTU 12V4000C11, foram utilizados acelerômetros uniaxiais piezoelétricos do tipo ICP® (*Integrated Circuit Piezoelectric*) fabricados pela *PCB Piezotronics*, reconhecida mundialmente pela precisão e confiabilidade de seus sensores em aplicações de engenharia mecânica e monitoramento de máquinas rotativas.

Os acelerômetros empregados nas medições possuem as seguintes características técnicas:

- **Tipo de sensor:** Piezoelétrico ICP® uniaxial
- **Sensibilidade nominal:** ~100 mV/g
- **Faixa de frequência útil:** 0,5 Hz a 10.000 Hz
- **Amplitude máxima de medição:** até  $\pm 50$  g
- **Montagem recomendada:** base roscada, magnética ou colada
- **Conector:** BNC padrão para compatibilidade com sistemas da National Instruments

#### 5.4 Software de Aquisição

O software utilizado para controle, aquisição e armazenamento dos dados foi o



LabVIEW™ (*Laboratory Virtual Instrument Engineering Workbench*), também da National Instruments, conforme Figura 13. Esta plataforma viabilizou a criação de rotinas personalizadas para o gerenciamento simultâneo dos canais de entrada, a visualização em tempo real dos sinais coletados e o armazenamento estruturado dos dados em arquivos compatíveis com processamento posterior em MATLAB®.



Figura 13 - Interface gráfica do software LabVIEW™ utilizada para aquisição de sinais de vibração do motor MTU 12V4000C11

Os sinais captados pelos acelerômetros foram transmitidos aos módulos NI 9234 através de conexões blindadas e compatíveis com o padrão ICP®, garantindo condicionamento interno de sinal, proteção contra ruídos eletromagnéticos e alta linearidade entre aceleração e saída em tensão.

A correta integração dos acelerômetros com o sistema de aquisição por meio do software LabVIEW™ contribuiu diretamente para a alta resolução dos dados utilizados nas análises nos Domínios do Tempo, Frequência e Tempo-Frequência, consolidando a base experimental do presente estudo.

## 5.5 Procedimento Experimental

O experimento foi realizado em uma bancada de teste instrumentada, especialmente preparada para o diagnóstico de falhas de injeção de combustível em motores Diesel. O motor avaliado foi o MTU 12V4000C11, operando sob diferentes condições de carga e com simulação de falhas em suas unidades de injetoras, utilizando

recursos do sistema de controle eletrônico DDEC IV.

Nesta pesquisa foram utilizados ao todo 39 cenários experimentais, dos quais 36 envolviam condições de falha e 3 correspondiam à condição normal de operação (sem falha), conforme descrito na Tabela 10. Embora, à primeira vista, pudesse parecer que o conjunto de dados apresentaria um desbalanceamento entre as classes, em função da existência de uma única condição normal de operação e de 12 condições distintas de falha de injeção (uma por cilindro), tal situação não se verifica nesta pesquisa. Isso porque o balanceamento entre classes foi garantido pelo processo de *data augmentation* aplicado aos sinais brutos, o que resultou em um número equivalente de instâncias para cada classe. Dessa forma, ainda que a condição normal esteja representada por um único arquivo experimental, o volume de amostras extraídas deste cenário foi proporcional ao das demais classes de falha, assegurando distribuição equilibrada de dados. Assim, a classe normal permanece única, sem necessidade de subdivisões artificiais, enquanto as 12 classes de falha representam falhas totais de injeção simuladas individualmente em cada cilindro, sem ocorrência simultânea. Este procedimento metodológico eliminou o risco de enviesamento do modelo, permitindo que a Rede Neural Artificial fosse treinada com uma base de dados estratificada e estatisticamente balanceada, condição essencial para a robustez e a generalização dos resultados obtidos.

*Tabela 10 - Cenários Simulados e Utilizados*

<b>Rotação (RPM)</b>	<b>Torque (N·m)</b>	<b>Potência (kW)</b>	<b>Falhas Simuladas (Cilindros)</b>
1500	850	127,5	Sem falha
1500	850	127,5	Nº 1 a 12
1500	2040	306	Sem falha
1500	2040	306	Nº 1 a 12
1500	3272	490	Sem falha
1500	3272	490	Nº 1 a 12

As falhas foram simuladas por meio do corte eletrônico de combustível em apenas um cilindro por vez, utilizando o sistema DDDL, uma vez que a arquitetura do DDEC IV não permite a realização de falhas simultâneas. Assim, cada cenário de falha representa a interrupção da injeção de combustível em um único cilindro específico, com o motor em funcionamento contínuo.

A Tabela 10 apresenta um resumo consolidado dos cenários simulados e

efetivamente utilizados na composição do banco de dados experimental empregado neste estudo. Todos os testes foram realizados com rotação constante de 1500 RPM, distribuídos em três faixas de carga: 127,5 kW, 306 kW e 490 kW, representando diferentes regimes operacionais do motor Diesel marítimo MTU 12V4000C11.

Para cada faixa de carga, foram considerados dois tipos de condição operacional: condição normal (sem falhas) e condições com falhas simuladas de injeção de combustível, totalizando 13 classes distintas. As falhas foram induzidas de forma individual em cada um dos 12 cilindros. Vale destacar que, devido à arquitetura eletrônica do sistema de gerenciamento DDEC IV, não foi possível realizar falhas simultâneas, assegurando que cada classe de falha representasse exclusivamente a ausência de injeção em um único cilindro.

A organização dessas combinações foi fundamental para garantir a diversidade e a representatividade das classes, bem como para viabilizar a aplicação de técnicas de aprendizado supervisionado robustas. Além disso, a padronização dos parâmetros operacionais de rotação e carga em cada cenário contribuiu para a confiabilidade da análise comparativa entre os Domínios do Tempo, Frequência e Tempo-Frequência, objetivo central desta pesquisa.

Para cada cenário, os sinais de vibração foram adquiridos por meio de um sistema multicanal com 15 acelerômetros uniaxiais (12 alocados nos cabeçotes e 3 no bloco do motor, conforme Figura 10. A aquisição foi feita com frequência de amostragem de 10.240 Hz, assegurando resolução espectral adequada para análise nos Domínios do Tempo, Frequência e Tempo-Frequência.

O tempo de coleta de dados por cenário foi de 60 segundos, permitindo a geração de amostras estatisticamente representativas para cada classe. Considerando todas as classes e cargas, foram coletadas 620.000 amostras/cenários, totalizando aproximadamente 24 milhões de amostras.

Embora cenários adicionais com rotação de 1800 RPM tenham sido testados em três faixas de carga (122 kW, 306 kW e 490 kW), conforme Tabela 11, os mesmos não foram utilizados neste estudo e serão utilizados em estudos futuros.

Tabela 11 - Cenários Simulados e Não Utilizados

<b>Cenário</b>	<b>Rotação (RPM)</b>	<b>Torque (N·m)</b>	<b>Potência (kW)</b>	<b>Falhas Simuladas (Cilindros)</b>
Nº 1	1800	670	122	Sem falha

Nº 2	1800	670	122	Cilindro Nº 5
Nº 3	1800	670	122	Cilindro Nº 12
Nº 4	1800	1700	306	Sem falha
Nº 5	1800	1700	306	Cilindro Nº 1
Nº 6	1800	1700	306	Cilindro Nº 9
Nº 7	1800	2722	490	Sem falha
Nº 8	1800	2722	490	Cilindro Nº 3
Nº 9	1800	2722	490	Cilindro Nº 11

## 5.6 Utilização Futura dos Dados Coletados em 1800 RPM

Embora o presente estudo tenha se concentrado exclusivamente em cenários com rotação constante de 1500 RPM, visando garantir homogeneidade e padronização das análises nos três domínios de estudo (Tempo, Frequência e Tempo-Frequência), cenários adicionais foram conduzidos a 1800 RPM, abrangendo três faixas de carga (122 kW, 306 kW e 490 kW), e incluindo tanto condições normais quanto falhas simuladas em diferentes cilindros.

A disponibilização desses dados abre uma avenida promissora para estudos futuros, principalmente nas seguintes direções:

- **Análise de Robustez e Generalização dos Modelos:** Ao se testar os modelos treinados com dados a 1500 RPM em cenários de 1800 RPM, será possível avaliar sua capacidade de generalização frente a regimes dinâmicos distintos, característica essencial para aplicações reais em sistemas embarcados.
- **Transferência de Aprendizado (*Transfer Learning*):** Técnicas modernas de aprendizado podem ser aplicadas utilizando os dados de 1500 RPM como base e adaptando os modelos para 1800 RPM com menor quantidade de dados rotulados, explorando a similaridade estrutural entre os regimes.
- **Estudos sobre o Impacto da Rotação na Assinatura Vibracional:** A comparação direta entre as assinaturas vibracionais das mesmas falhas em diferentes rotações permitirá compreender como a velocidade angular influencia na propagação de vibrações, favorecendo o refinamento de atributos e filtros adaptativos.
- **Deteção de Regime Operacional:** Incorporando dados de 1800 RPM, será possível desenvolver modelos híbridos que, além de diagnosticar falhas,

identifiquem automaticamente o regime de rotação do motor, o que amplia significativamente a aplicabilidade dos algoritmos.

Dessa forma, os dados de 1800 RPM representam um ativo experimental de elevado valor, que poderá ser explorado em trabalhos futuros voltados à validação cruzada de modelos, desenvolvimento de algoritmos e análises comparativas entre regimes dinâmicos típicos da operação marítima.

## 6. RESULTADOS E DISCUSSÕES

### 6.1 Apresentação Geral dos Dados

Nesta seção, apresentam-se os parâmetros gerais empregados para a modelagem com RNAs e os principais resultados obtidos a partir dos testes realizados com sinais de vibração nos Domínios do Tempo, Frequência e Tempo-Frequência.

A configuração geral dos hiperparâmetros seguiu uma faixa predefinida, ajustada por meio de experimentação e validação cruzada, conforme detalhado na Tabela 12. O modelo foi treinado, validado e testado utilizando a partição dos dados em 70%, 15% e 15%, respectivamente.

*Tabela 12 - Intervalos de Hiperparâmetros Utilizados na Modelagem com RNA*

Hiperparâmetros	Intervalo	
	Mínimo	Máximo
Número de Neurônios (n)	20	40
Taxa de Aprendizado (lr)	$1 \times 10^{-3}$	$1 \times 10^{-1}$
Número de Épocas (epochs)	200	1500
Meta (Goal)	$1 \times 10^{-7}$	$1 \times 10^{-5}$
Mínimo Gradiente (min_grad)	$1 \times 10^{-7}$	$1 \times 10^{-5}$
Máximo de Falhas de Validação (max_fail)	10	30
Sigma (sigma)	$1 \times 10^{-10}$	$1 \times 10^{-8}$
Lambda (lambda)	$1 \times 10^{-12}$	$1 \times 10^{-10}$

### 6.2 Resultados no Domínio do Tempo

#### 6.2.1. Desempenho com Diferentes Quantidades de Características e Acelerômetros

Com o objetivo de avaliar a eficiência dos modelos de RNAs na identificação de falhas de injeção em motores Diesel marítimos, realizou-se uma análise comparativa aprofundada utilizando diferentes quantidades de características estatísticas extraídas do sinal de vibração no Domínio do Tempo (1, 2, 5, 9, 18 e 27) e diferentes configurações de acelerômetros (1, 3, 5, 10 e 15). Esta análise buscou identificar o equilíbrio ideal entre desempenho, diagnóstico e custo computacional, considerando a redução de sensores e o número de atributos utilizados na entrada da rede.

Os resultados evidenciam que o desempenho do modelo está diretamente relacionado ao número e à qualidade das características extraídas, bem como à quantidade e posicionamento dos acelerômetros, conforme Figura 14. De forma geral, o

modelo apresentou excelente robustez diagnóstica mesmo com configurações enxutas.

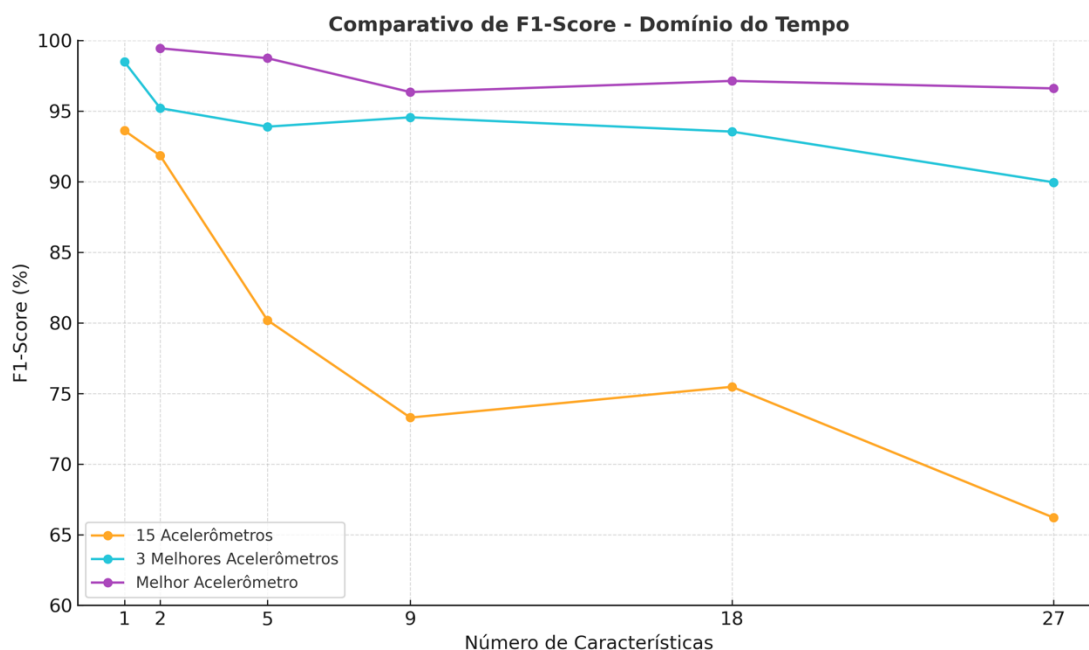


Figura 14 - Comparativo de F1-Score - Domínio do Tempo


No cenário com **15 acelerômetros**, observou-se que o maior valor de F1-Score (93,61%) foi alcançado com apenas uma característica estatística. À medida que mais características foram adicionadas (até 27), o desempenho caiu gradualmente, atingindo um F1-Score de 66,21%. Esse comportamento indica que, apesar do aumento de informação, a adição de variáveis irrelevantes ou redundantes pode comprometer a capacidade de generalização do modelo, possivelmente devido ao fenômeno conhecido como *curse of dimensionality* (TAN; STEINBACH; KUMAR, 2018).

O cenário intermediário, com **3 melhores acelerômetros** (seleção dos melhores realizadas pelo Relief-F), apresentou desempenho altamente competitivo. Com duas características estatísticas, foi obtido um F1-Score de 98,48%, praticamente equiparado ao modelo com apenas um acelerômetro. Além disso, esse cenário ofereceu uma redução no tempo de processamento, variando entre 127 e 269 segundos, comparado ao intervalo de 143 a 295 segundos observado com um único acelerômetro, evidenciando uma melhor eficiência computacional.

Por outro lado, ao utilizar somente o **melhor acelerômetro**, a rede alcançou valores extremamente elevados de desempenho: o F1-score máximo foi de 98,74% utilizando duas características, superando inclusive o modelo com 15 acelerômetros. Isso demonstra a relevância de um processo criterioso de seleção de sensores e reforça a

hipótese de que um acelerômetro bem posicionado pode capturar assinaturas vibracionais representativas o suficiente para um diagnóstico preciso, especialmente quando combinado com um conjunto de características estatísticas relevantes.


Ao fixar **27 características** e variar a quantidade de acelerômetros de 1 a 15, verificou-se que o melhor desempenho foi obtido com 1 acelerômetro, atingindo um F1-Score de 96,60%, decaindo gradativamente até atingir 66,21% com 15 acelerômetros, conforme Figura 15. Essa tendência corrobora a ideia de que o excesso de acelerômetros, sem um critério adequado de seleção, pode adicionar ruído e complexidade ao modelo, sem necessariamente melhorar sua capacidade de predição.



*Figura 15 - F1-Score e Tempo de Processamento (Domínio do Tempo - 27 Características)*

A Figura 16 apresenta a relação entre o desempenho do modelo, medido pelo F1-Score, e o tempo de processamento para diferentes cenários de combinação de acelerômetros e características extraídas no Domínio do Tempo. Observa-se que todos os cenários analisados mantêm valores elevados de F1-Score, variando de aproximadamente 93% a 99,43%, evidenciando a robustez do modelo na detecção de falhas. O melhor desempenho é alcançado no cenário que utiliza o acelerômetro individual mais representativo com duas características, atingindo 99,43%.





*Figura 16 - Melhores F1-Score e Tempo de Processamento por Cenário no Domínio do Tempo*

Esse resultado sugere que a seleção criteriosa de um único sensor aliado a um número reduzido, porém discriminante, de características pode ser suficiente para garantir elevado desempenho na tarefa de classificação. Por outro lado, nota-se uma tendência de redução no F1-Score quando há incremento no número de acelerômetros, como observado no cenário com 15 sensores, cujo desempenho cai para cerca de 93%. Esse comportamento indica que o aumento indiscriminado do número de sensores não resulta em ganhos proporcionais, podendo inclusive introduzir redundâncias ou ruídos que prejudicam a capacidade de generalização do modelo.

Em relação ao tempo de processamento, há um comportamento não linear: inicialmente elevado no cenário com 1 e 3 acelerômetros (aproximadamente 300 segundos), o tempo reduz significativamente para cerca de 140 segundos com 15 acelerômetros, aumentando novamente para cerca de 200/250 segundos no cenário com 27 características. Essa variação reflete o impacto combinado do número de características e do processo de seleção de sensores sobre a complexidade computacional do modelo. Tais resultados reforçam que, para aplicações embarcadas em sistemas de monitoramento de motores marítimos, a estratégia de utilizar um conjunto reduzido e otimizado de sensores e características representa a solução mais eficiente, equilibrando precisão diagnóstica e viabilidade computacional.

Essas observações reforçam a importância de abordagens sistemáticas para seleção de características e acelerômetros, especialmente quando se busca maximizar o desempenho diagnóstico com o mínimo de recursos físicos e computacionais.

### 6.2.2. Frequência e Contribuição dos Acelerômetros Mais Relevantes


A avaliação da contribuição dos acelerômetros para o diagnóstico de falhas de injeção, no contexto da análise no Domínio do Tempo, revelou padrões claros quanto à localização dos sensores mais eficazes. A Tabela 13 apresenta os resultados dos principais cenários analisados, destacando o número de acelerômetros, a quantidade de características estatísticas, o acelerômetro de melhor desempenho em cada configuração e os respectivos F1-Score, Acurácia, Precisão, Sensibilidade e Especificidade.

*Tabela 13 - Resultados com melhores acelerômetros nos cenários avaliados no Domínio do Tempo*

DOMÍNIO DO TEMPO							
Cenários		Resultados					
Nº Acel.	Nº Caract	Melhor Acel.	F1-Score (%)	Acurácia (%)	Precisão (%)	Sensibilidade (%)	Especificidade (%)
1	2	7	99,44	99,43	99,43	99,48	99,95
1	5	15	98,74	99,67	98,73	98,77	99,89
1	9	13	96,34	96,20	96,37	96,38	99,68
1	18	9	97,13	97,15	97,24	97,11	99,76
1	27	2	96,60	96,77	96,69	96,67	99,73
3	1	7	98,48	98,48	98,40	98,62	99,87
3	2	7	95,20	95,26	95,24	95,26	99,61


A análise desses dados foi aprofundada com o auxílio do croqui do motor Diesel marítimo (Figura 12), o qual representa a localização física dos acelerômetros nos cabeçotes dos cilindros e no bloco do motor. Esse esquema foi essencial para compreender a relação entre desempenho diagnóstico e posição do sensor.

Observou-se que os acelerômetros localizados nos cabeçotes foram os mais frequentemente selecionados como os melhores pontos de medição (Figura 17). O que, de certa forma, era o resultado mais esperado uma vez que são os pontos mais próximos da origem da sinal de falha de injeção. Em especial, o acelerômetro 7 (cilindro 7, bancada B) destacou-se com 44,4% das ocorrências, seguido pelo acelerômetro 2 (cilindro 2, bancada A) com 22,2%. Os acelerômetros 9, 13 e 15 completaram a lista dos sensores mais representativos, todos também posicionados sobre os cilindros. Nenhum dos acelerômetros instalados no bloco ou regiões mais afastadas foi selecionado entre os melhores.



*Figura 17 - Localização dos Acelerômetros Mais Relevantes (Domínio do Tempo)*

A distribuição da frequência de ocorrência dos melhores acelerômetros é sintetizada na Figura 18.



*Figura 18 - Frequência de seleção dos melhores acelerômetros (Domínio do Tempo)*

Esse padrão de ocorrência revela que os acelerômetros montados diretamente sobre os cabeçotes dos cilindros — áreas críticas do sistema de injeção — são mais sensíveis às alterações dinâmicas provocadas por falhas de injeção. Essa sensibilidade se deve à proximidade direta com os eventos mecânicos e combustão, o que permite a captura de assinaturas de vibração com maior sensibilidade.

Do ponto de vista técnico e prático, esses resultados sustentam duas importantes conclusões:

A seleção do ponto de medição é mais determinante do que a quantidade de sensores. É possível alcançar alto desempenho diagnóstico com apenas um acelerômetro

bem posicionado, como demonstrado pelos elevados F1-Scores (>98%) em configurações com sensor único.

A concentração dos melhores resultados nos cilindros confirma a superioridade dessas posições para fins diagnósticos. Sensores instalados em regiões mais distantes, como o bloco do motor, não apresentaram desempenho competitivo neste estudo.

A Tabela 14, que reúne as métricas de precisão de treinamento, validação e teste nos diferentes cenários do Domínio do Tempo, possui papel central na interpretação dos resultados desta dissertação. Ela não é apenas um registro numérico, mas evidencia aspectos fundamentais da metodologia e das conclusões do estudo.

*Tabela 14 - Precisões de Treinamento, Validação e Testes obtidas no Domínio do Tempo em diferentes configurações de número de acelerômetros e características estatísticas*

DOMÍNIO DO TEMPO					
Cenários		Resultados			
Nº Acel.	Nº Caract	Melhor Acel.	Precisão Treinamento (%)	Precisão Validação (%)	Precisão Teste (%)
1	2	7	99,35	98,29	99,43
1	5	15	99,80	98,48	98,67
1	9	13	99,02	97,53	96,21
1	18	9	99,47	97,15	97,15
1	27	2	99,10	96,02	96,77
3	1	7	99,19	96,77	98,48
3	2	7	98,25	95,83	95,26

Primeiro, a Tabela 14 demonstra a consistência e robustez do modelo de RNA desenvolvido. Ao comparar os valores de treinamento, validação e teste, percebe-se que não há discrepâncias relevantes que caracterizem *overfitting* (quando o modelo memoriza o conjunto de treinamento, mas falha em generalizar para dados novos) nem *underfitting* (quando o modelo não aprende adequadamente os padrões). A proximidade entre as três métricas indica que o sistema foi bem calibrado, reforçando a eficácia das estratégias metodológicas adotadas, como a seleção de características via Relief-F e a divisão estratificada dos conjuntos de dados.

Em segundo lugar, ela evidencia a importância da otimização do número de acelerômetros e de características estatísticas. Resultados como o do cenário com 1 acelerômetro e 2 características (Precisão de Teste = 99,43%) demonstram que é possível

alcançar desempenho superior com configurações enxutas, ao invés de aumentar indiscriminadamente sensores e atributos. Este achado confirma a hipótese de que qualidade e posicionamento dos sensores são mais relevantes que a quantidade, além de mitigar a chamada maldição da dimensionalidade, já identificada na fundamentação teórica como um desafio para problemas de alta dimensionalidade

A Figura 19 mostra a Matriz de Confusão para o melhor resultado obtido no Domínio do Tempo (1 acelerômetro e 2 características). Aqui ela mostra quais classes foram corretamente identificadas (verdadeiros positivos) e quais foram confundidas entre si (falsos positivos e falsos negativos). Isso é essencial em problemas multiclasse, como neste estudo de falhas de injeção em motores Diesel, no qual há 13 classes (1 condição normal + 12 falhas de injeção simuladas).

A Matriz de Confusão de Validação evidencia que o modelo apresentou desempenho global extremamente elevado, com precisão média em torno de 98,3%, o que valida sua robustez e capacidade de generalização. Observa-se que a maioria das classes, como as classes 2, 4, 6, 7, 9, 10 e 13, alcançou 100% de acerto, indicando que o modelo foi capaz de aprender padrões bem definidos e consistentes para esses cenários específicos, reforçando sua eficácia no diagnóstico de falhas de injeção.

A predominância de valores na diagonal e pouquíssimos registros fora dela indica uma alta generalização do modelo.

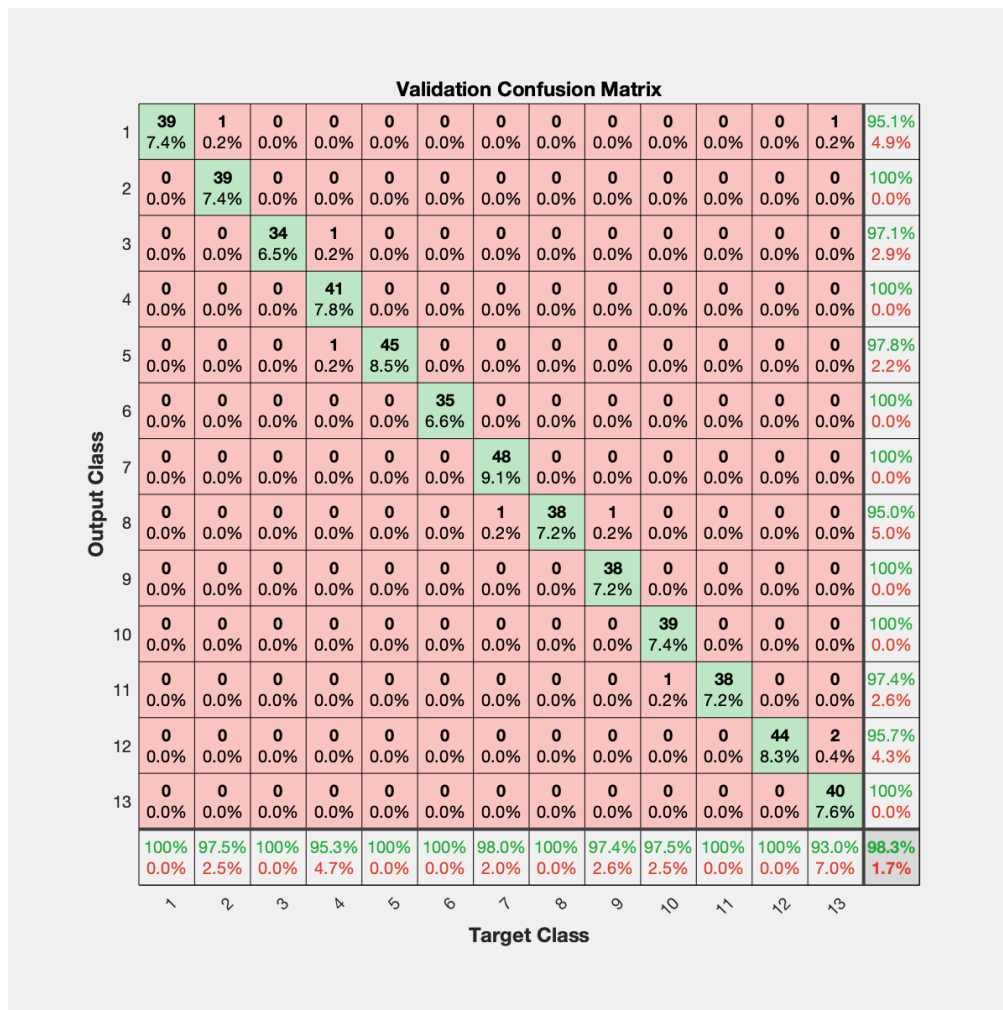



Figura 19 - Matriz de Confusão do melhor resultado obtido no Domínio do Tempo

A Figura 20 representa a função de custo por entropia cruzada durante o processo de treinamento da RNA onde mede a distância entre as distribuições de probabilidade previstas pela rede (saídas do modelo) e as distribuições reais (rótulos corretos, codificados em *one-hot*). Em termos práticos, ela penaliza classificações incorretas com alta confiança e recompensa previsões corretas.

Pela Figura 20, observa-se que:

- As três curvas (treinamento em azul, validação em verde e teste em vermelho) seguem trajetórias bastante próximas, o que demonstra que a RNA manteve consistência entre aprender e generalizar;
- Houve uma queda acentuada da entropia cruzada nas primeiras épocas (até ~220), seguida de uma redução mais suave até estabilizar-se por volta da época 600. Esse comportamento é esperado, já que o modelo aprende rapidamente no início e depois realiza ajustes finos nos pesos;

- O melhor desempenho de validação ocorreu na época 590, com valor de entropia cruzada  $\approx 0,0030559$ , o que é um resultado consideravelmente baixo, indicando uma relação muito alta entre as previsões e os rótulos reais; e
- A sobreposição das curvas confirma que não houve overfitting significativo, pois o desempenho de validação e teste acompanhou o de treinamento até a convergência.



*Figura 20 - Função de custo por entropia cruzada durante o processo de treinamento da RNA no Domínio do Tempo*

Face ao exposto, o gráfico que representa a função de custo por entropia cruzada durante o processo de treinamento da RNA comprova que o modelo atingiu ótima capacidade de classificação, com baixo erro e elevada generalização, validando a eficácia da configuração de hiperparâmetros e da estratégia de seleção de características adotada, uma vez que o desempenho consistente no treino, validação e teste evita o risco de resultados artificiais.

A Figura 21 (gráfico Gradiente vs Épocas) permite acompanhar a intensidade das atualizações dos pesos ao longo do processo de treinamento da RNA. O gradiente reflete diretamente a magnitude desses ajustes em que valores elevados indicam alterações bruscas nos parâmetros, enquanto valores mais baixos correspondem a ajustes mais sutis e refinados. Dessa forma, a análise do gradiente é essencial para verificar se o algoritmo

de otimização está de fato convergindo para um mínimo da função de custo. Quando se observa uma queda progressiva seguida de estabilização, tem-se um forte indicativo de que a RNA está se ajustando corretamente e se aproximando de uma configuração de pesos estável e otimizada.




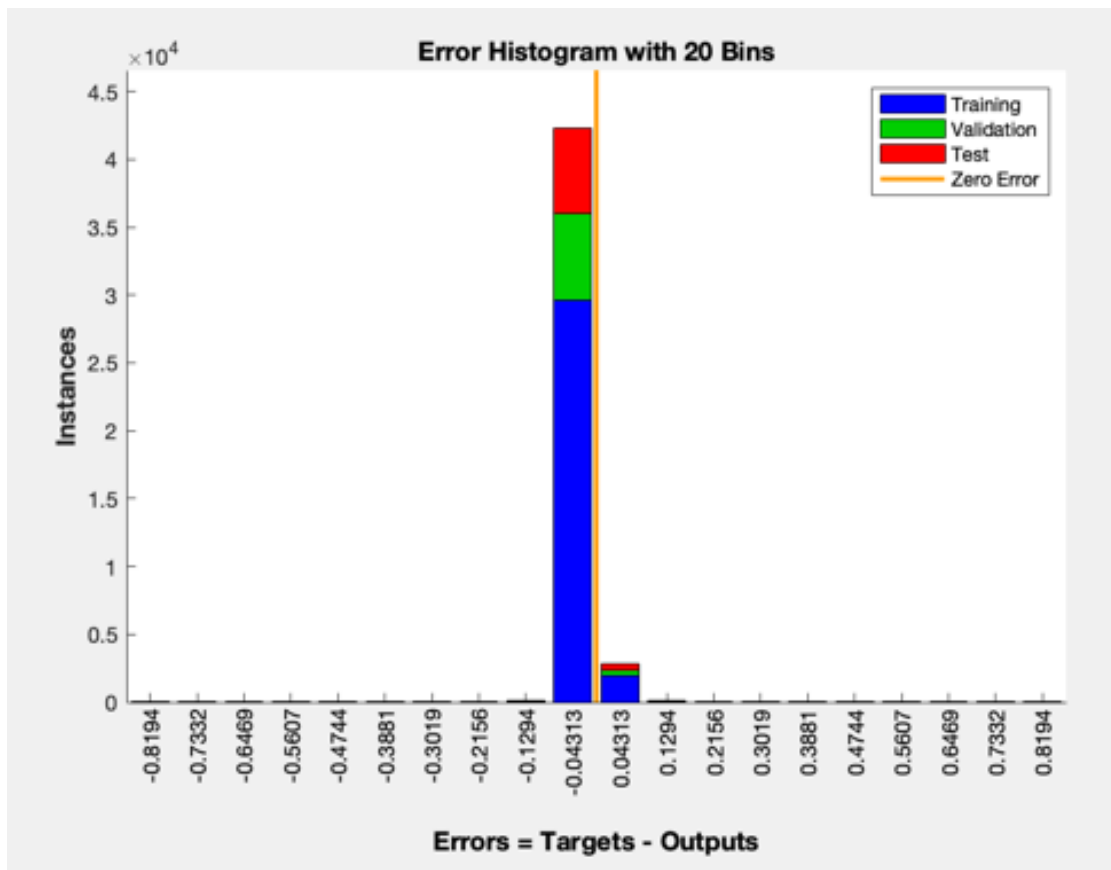
Figura 21 - Gradiente  $\times$  Épocas no Domínio do Tempo

Observa-se que o gradiente tem início em torno de  $10^{-1}$  e decresce gradualmente até a ordem de  $10^{-4}$  na última época de treinamento (época 620). Esse comportamento confirma que o processo de aprendizagem ocorreu de forma estável, com ajustes cada vez menores nos pesos da rede à medida que o modelo se aproximava do ponto ótimo de convergência. O valor final do gradiente, aproximadamente  $2,8 \times 10^{-4}$ , é considerado baixo, o que indica que os pesos da RNA atingiram uma configuração próxima ao mínimo local da função de custo, evidenciando a consolidação do processo de otimização.

Os resultados apresentados indicam que o treinamento da RNA ocorreu de maneira eficiente e convergente, com o gradiente reduzido progressivamente. Isso garante que o modelo não apenas se ajustou bem aos dados de treinamento, mas também manteve capacidade de generalização, evitando *overfitting*.

A Figura 22 mostra o Histograma de Erros, para o melhor resultado obtido no Domínio do Tempo. Ele mostra a distribuição das diferenças entre os valores reais (*targets*) e os valores previstos (*outputs*) pela RNA. Esse tipo de representação é bastante útil porque permite avaliar a qualidade do ajuste do modelo de forma mais detalhada do que métricas globais, mostrando não apenas o valor médio do erro, mas também sua dispersão e simetria.





*Figura 22 - Histograma de Erros no Domínio do Tempo*

No histograma apresentado na Figura 22, observa-se que a grande maioria dos erros está altamente concentrada em torno de zero, com barras azuis (treinamento), verdes (validação) e vermelhas (teste) sobrepostas, formando um pico estreito. Isso indica que a RNA apresentou excelente desempenho de predição, com erros residuais muito baixos em todos os conjuntos.

As barras em torno do zero sugerem que não há viés sistemático relevante, já que os erros se distribuem de forma simétrica em torno do valor ideal. Além disso, o fato de os três conjuntos (treinamento, validação e teste) apresentarem distribuições semelhantes comprova que o modelo manteve consistência e capacidade de generalização, sem evidências significativas de sobreajuste.

Esses resultados confirmam a eficácia das estratégias de seleção de características e acelerômetros adotadas no Domínio do Tempo, demonstrando que o modelo foi capaz de reproduzir com precisão o comportamento dinâmico do motor, mesmo em cenários complexos de diagnóstico de falhas de injeção.

### 6.2.3. Ranqueamento das 27 Características Estatísticas no Domínio do Tempo

A seleção de características desempenha um papel decisivo na construção de modelos preditivos robustos, sobretudo em sistemas complexos como motores Diesel marítimos, nos quais os sinais de vibração são ricos em informações, mas também em redundâncias. A análise realizada por meio do algoritmo Relief-F revelou comportamentos distintos quanto à relevância das métricas estatísticas a depender do domínio de investigação, permitindo compreender não apenas quais atributos se destacam, mas também como a variância da sua importância se manifesta em cada caso.

No domínio do tempo (Figura 23), observou-se uma clara dispersão entre as características avaliadas. Algumas métricas, como Fator de Impulso e Fator de Crista, surgem como fortemente discriminativas, enquanto outras, como Média e Soma, apresentam pesos negativos, sugerindo baixa ou até mesmo efeito adverso na classificação. Esse cenário evidencia que os atributos temporais não são uniformemente relevantes: há um contraste acentuado entre aqueles capazes de capturar assinaturas sutis do processo de combustão e outros que apenas acrescentam ruído ao modelo. Em outras palavras, a variância entre as relevâncias é elevada, o que reforça a necessidade de uma etapa criteriosa de seleção para evitar sobrecarga dimensional e perda de desempenho.

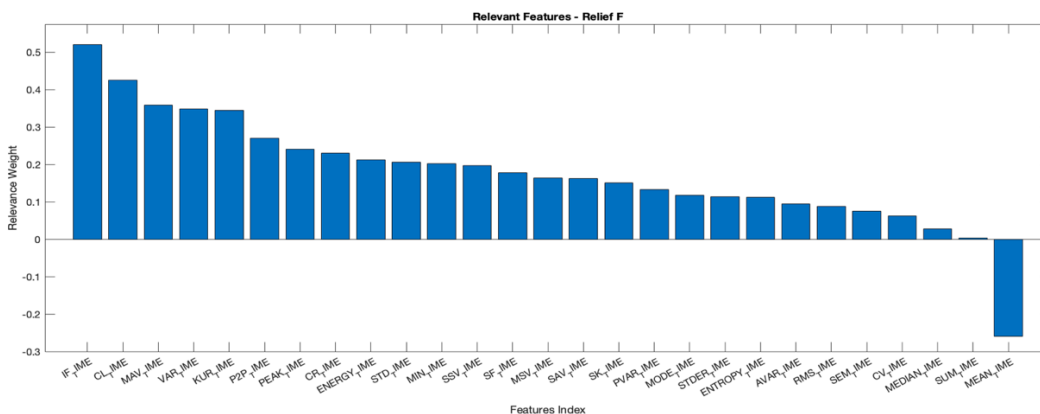


Figura 23 - Ranqueamento das 27 Características no Domínio do Tempo

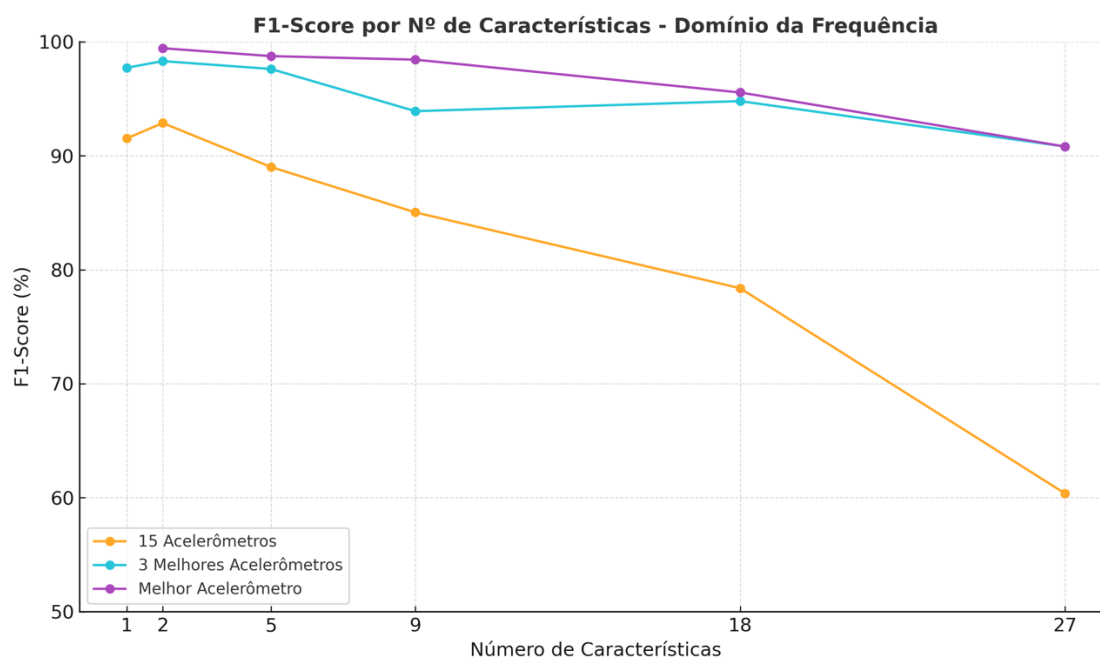
## 6.3 Resultados no Domínio da Frequência

### 6.3.1. Análise Comparativa de Desempenho com Diferentes Quantidades de Características e Acelerômetros

A análise dos resultados no Domínio da Frequência buscou avaliar a capacidade das RNAs em identificar falhas de injeção em motores Diesel marítimos a partir de sinais

de vibração, considerando diferentes configurações de entrada: variação no número de características estatísticas extraídas (1, 2, 5, 9, 18 e 27) e na quantidade de acelerômetros utilizados (1, 3, 5, 10 e 15).

Assim como observado no Domínio do Tempo, os resultados mostram que o desempenho dos modelos é altamente sensível tanto à seleção de características quanto à escolha dos sensores empregados, reforçando a importância do pré-processamento criterioso e da otimização dos hiperparâmetros de modelagem, conforme pode ser visualizado na Figura 24.



*Figura 24 - F1-Score por Nº de Características - Domínio da Frequência*

No cenário com os **15 acelerômetros ativos**, observou-se que o melhor desempenho foi alcançado utilizando 2 características estatísticas, com um F1-Score de 92,87%. Entretanto, houve uma queda progressiva de desempenho com o aumento do número de características: ao utilizar 27 características, o F1-Score reduziu drasticamente para 60,38%. Essa degradação evidencia novamente o impacto da maldição da dimensionalidade (TAN; STEINBACH; KUMAR, 2018), em que a adição indiscriminada de variáveis irrelevantes ou ruidosas compromete a capacidade discriminativa do modelo.

Além disso, o tempo de processamento apresentou uma variação moderada, entre 145 segundos (com 1 característica) e 274 segundos (com 18 características), sendo mais influenciado pelo aumento do número de características do que pelo número de

acelerômetros.

Ao reduzir a quantidade de sensores para os **3 melhores acelerômetros**, os resultados demonstraram uma melhoria substancial em todas as métricas. O melhor desempenho foi obtido com 2 características, atingindo um F1-Score de 98,30%, evidenciando o benefício da seleção estratégica de acelerômetros. Além disso, o tempo de processamento foi mantido em níveis bastante competitivos, variando de 154 a 257 segundos.

A comparação entre as combinações mostra que, mesmo com poucos acelerômetros e características selecionadas, é possível atingir desempenho de classificação superior, indicando que a qualidade das informações capturadas é mais relevante que a quantidade bruta de dados.

Na configuração utilizando apenas **o melhor acelerômetro**, foram obtidos os melhores resultados absolutos no Domínio da Frequência: um F1-Score de 99,43% ao se utilizar 2 características estatísticas.

Entretanto, o tempo de processamento em alguns casos foi elevado, atingindo 696 segundos para o cenário de 2 características, devido à configuração da rede neural empregada para esse cenário específico (número de neurônios, taxa de aprendizado e número de épocas) além da necessidade de realizar FFT.

Ao fixar **27 características** e variar o número de acelerômetros de 1 a 15 (Figura 25), verificou-se uma tendência clara de queda no desempenho com o aumento da quantidade de sensores: o F1-Score caiu de 98,10% (1 acelerômetro) para 60,38% (15 acelerômetros). Esse comportamento reforça o entendimento de que o excesso de acelerômetros não necessariamente traduz-se em ganho de desempenho e pode, de fato, adicionar ruído ao sistema, impactando negativamente os resultados.

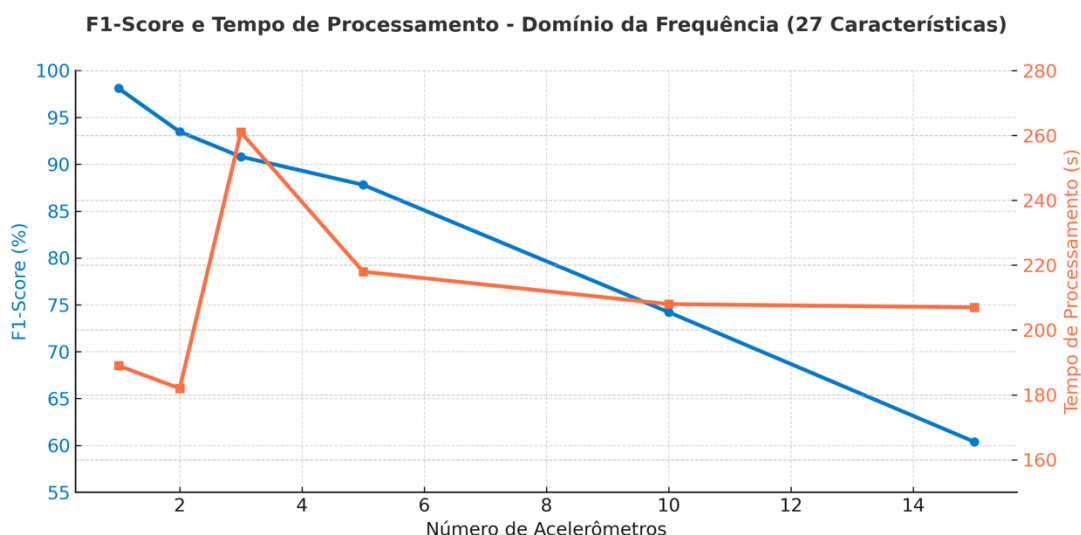


Figura 25 - F1-Score x Tempo de Processamento (Domínio da Frequência - 27 Características)

Na Figura 26, a qual compara os **melhores resultados consolidados no Domínio da Frequência** destaca que utilizar apenas 1 acelerômetro e 2 características proporcionou o melhor F1-Score de 99,43%.

A configuração com 3 melhores acelerômetros e 2 características também se mostrou altamente eficaz, com F1-Score de 98,30%, apresentando um compromisso interessante entre desempenho e um tempo de processamento reduzido de apenas 229 segundos, tempo de processamento três vezes menor do que o obtido no cenário com um acelerômetro e 2 características.

A configuração com todos os 15 acelerômetros resultou em desempenho inferior à meta mínima de 95% de F1-Score.




Figura 26 - F1-Score e Tempo de Processamento por Cenário no Domínio da Frequência

Os resultados no Domínio da Frequência reforçam a eficácia da metodologia proposta de diagnóstico de falhas de injeção via RNA, mesmo em cenários restritos em termos de número de acelerômetros e características. De maneira geral, observou-se que poucas características estatísticas selecionadas estrategicamente são suficientes para representar suficientemente bem o comportamento do sistema, a escolha criteriosa dos acelerômetros é fundamental para maximizar o desempenho do diagnóstico e o excesso de variáveis e acelerômetros sem critérios robustos de seleção, compromete a eficiência e a eficácia dos modelos, aumentando o custo computacional e reduzindo a capacidade de generalização da RNA.

### 6.3.2. Frequência e Contribuição dos Acelerômetros Mais Relevantes


A identificação dos acelerômetros mais relevantes no Domínio da Frequência revelou um padrão técnico significativo, alinhado com o comportamento mecânico do sistema de injeção de combustível do motor Diesel. A Tabela 15 apresenta os cenários com melhores resultados, discriminando o número de acelerômetros utilizados, a quantidade de características extraídas, o acelerômetro que apresentou o melhor desempenho e os respectivos F1-Score, Acurácia, Precisão, Sensibilidade e Especificidade.

*Tabela 15 - Resultados com melhores acelerômetros nos cenários avaliados no Domínio da Frequência*

DOMÍNIO DA FREQUÊNCIA							
Cenários		Resultados					
Nº Acel.	Nº Caract	Melhor Acel.	F1-Score (%)	Acurácia (%)	Precisão (%)	Sensibilidade (%)	Especificidade (%)
1	2	2	99,43	99,43	99,50	99,39	99,95
1	5	2	98,74	98,67	98,80	98,73	99,89
1	9	1	98,43	98,48	98,39	98,52	99,87
1	18	2	95,55	95,45	95,65	95,56	99,62
1	27	4	98,10	98,10	98,17	98,05	99,84
3	1	4	97,72	97,72	97,73	97,80	99,81
3	2	2	98,30	98,29	98,39	98,25	99,86
3	5	2	97,61	97,53	97,68	97,64	99,79

A análise espacial desses sensores, conforme representado no croqui do motor Diesel (Figura 27), mostra que os acelerômetros 1, 2 e 4 estão localizados sobre os

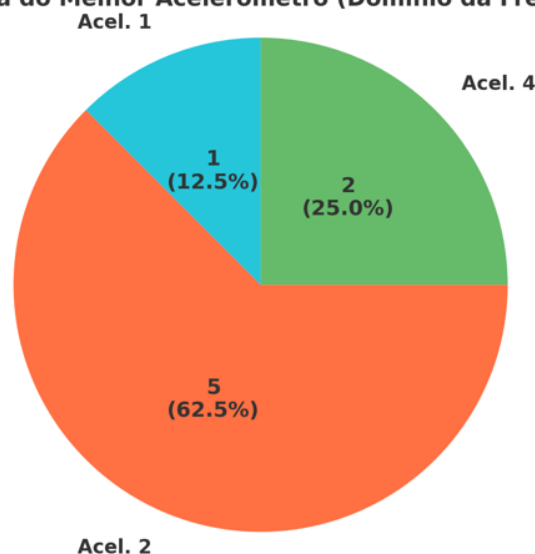
cabeçotes dos cilindros 1, 2 e 4, todos pertencentes à bancada A. Esta informação é de extrema relevância, pois destaca que os sensores de maior contribuição diagnóstica não estão posicionados no bloco do motor ou em regiões periféricas, mas sim diretamente sobre os cilindros, onde os efeitos vibracionais das falhas de injeção se manifestam com maior intensidade e especificidade.



*Figura 27 - Localização dos acelerômetros no motor Diesel (bancada A em destaque)*

O gráfico apresentado na Figura 28 resume a frequência de ocorrência dos acelerômetros que obtiveram o melhor desempenho nos diferentes cenários modelados. O acelerômetro 2 se destaca de forma marcante, sendo o mais eficaz em 66,7% dos casos que alcançaram F1-Score acima de 95%. Em seguida, o acelerômetro 4 foi selecionado em 22,2% dos cenários, e o acelerômetro 1, em 11,1%.

**Frequência do Melhor Acelerômetro (Domínio da Frequência)**



*Figura 28 - Frequência de seleção dos melhores acelerômetros no Domínio da Frequência*

A predominância do acelerômetro 2, posicionado sobre o cilindro 2, é tecnicamente justificável pela sua proximidade direta com a zona de combustão e atuação do sistema de injeção, o que permite captar com maior nitidez os efeitos vibracionais gerados por anomalias como falhas de atomização, atraso de ignição ou variações de pressão no bico injetor.

Esses resultados confirmam que os melhores desempenhos de classificação, com F1-Scores superiores a 95%, foram obtidos a partir de sinais capturados por sensores localizados diretamente sobre os cilindros. Nenhum dos sensores situados no bloco do motor apresentou desempenho competitivo nos cenários analisados.

Em termos práticos, essa evidência empírica reforça que a instrumentação otimizada pode ser concentrada em poucos pontos de medição estrategicamente posicionados sobre os cilindros. Essa abordagem reduz significativamente o número de sensores e a complexidade do sistema de aquisição, sem sacrificar a acurácia diagnóstica, o que é extremamente vantajoso para aplicações embarcadas e sistemas de manutenção preditiva em ambientes navais.

Assim como no Domínio do Tempo, no Domínio da Frequência a concentração dos melhores resultados nos cilindros/cabeçotes confirma a superioridade dessas posições para fins diagnósticos. Os acelerômetros instalados nos cilindros da bancada A — especialmente o acelerômetro 2 — são os mais eficazes para identificação de falhas de injeção em motores Diesel, combinando precisão diagnóstica elevada e viabilidade prática de implementação.

Analisando os valores de precisões de Treinamento, Validação e Teste mostrados na Tabela 16 é verificado que o valor de Precisão de Teste variou entre 95,45% e 99,43%, o que confirma a consistência dos resultados e a aplicabilidade prática da metodologia. Além disso, observa-se que cenários com configurações enxutas, como 1 acelerômetro e 2 características, já foram capazes de atingir desempenho próximo ao máximo registrado (99,43%), reforçando que a qualidade da informação captada pelo sensor e a seleção criteriosa de atributos são mais determinantes do que a quantidade bruta de dados.



*Tabela 16 - Precisões de Treinamento, Validação e Testes obtidas no Domínio da Frequência em diferentes configurações de número de Acelerômetros e Características Estatísticas*

DOMÍNIO DA FREQUÊNCIA					
Cenários		Resultados			
Nº Acel.	Nº Caract	Melhor Acel.	Precisão Treinamento (%)	Precisão Validação (%)	Precisão Teste (%)
1	2	2	99,59	98,86	99,43
1	5	2	99,76	98,48	98,67
1	9	1	99,43	99,05	98,48
1	18	2	97,96	96,77	95,45
1	27	4	99,55	97,72	98,10
3	1	4	99,67	97,72	97,72
3	2	2	99,72	98,29	98,29
3	5	2	99,22	96,02	97,53

Outro aspecto evidenciado é a presença de pequenas variações entre as precisões de treinamento, validação e teste, sempre em patamares próximos, o que indica boa generalização e ausência de *overfitting*. Esse comportamento comprova que a RNA conseguiu aprender padrões relevantes de vibração sem memorizar o conjunto de treinamento, o que a torna adequada para cenários reais de operação.

Também merece destaque a influência do número de características: enquanto cenários com poucas variáveis mantêm índices próximos a 99%, a inclusão de conjuntos maiores (como 18 características) leva a uma redução de desempenho (95,45% no teste), evidenciando os efeitos da maldição da dimensionalidade, já discutida em diferentes partes da dissertação. Assim, a tabela reforça a importância de técnicas de seleção como o Relief-F, que auxiliam na identificação dos atributos mais relevantes e evitam redundâncias prejudiciais.

A Matriz de Confusão de Validação obtida no Domínio da Frequência (Figura 29) demonstra o elevado desempenho da RNA na classificação das 13 classes. De forma geral, observa-se que os valores estão concentrados na diagonal principal, evidenciando que a maioria absoluta das amostras foi corretamente classificada. As taxas de acerto por classe variaram entre 97,5% e 100%, resultando em uma acurácia global próxima de 98,9%, o que confirma a robustez e a confiabilidade do modelo desenvolvido.

Algumas classes, como 1, 2, 6, 7, 8, 9 e 10, apresentaram desempenho perfeito, com 100% de acerto e nenhuma instância incorretamente classificada. Já outras classes,

como 3, 4, 5, 11, 12 e 13, mostraram pequenas taxas de erro, em torno de 2,2 a 2,6%, geralmente decorrentes de confusões com classes vizinhas. Esse comportamento é tecnicamente esperado, pois acelerômetros instalados em cilindros próximos captam assinaturas vibracionais semelhantes, o que pode levar a sobreposições sutis entre padrões de falha.

Apesar dessas pequenas imprecisões, o desempenho obtido é altamente satisfatório, com erros limitados e estruturados em pares de classes adjacentes, sem comprometer a capacidade diagnóstica do modelo. A matriz, portanto, confirma que o Domínio da Frequência é uma abordagem eficaz para a identificação de falhas de injeção em motores Diesel, apresentando resultados homogêneos entre as classes e demonstrando tanto a sensibilidade da metodologia quanto a importância de uma seleção criteriosa de características e do posicionamento adequado dos acelerômetros para minimizar possíveis sobreposições de assinaturas.

Validation Confusion Matrix													
Output Class	1	2	3	4	5	6	7	8	9	10	11	12	13
	47 8.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100 0.0%
	0 0.0%	37 7.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100 0.0%
	0 0.0%	0 0.0%	38 7.2%	1 0.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	97.4 2.6%
	0 0.0%	0 0.0%	0 0.0%	37 7.0%	1 0.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	97.4 2.6%
	1 0.2%	0 0.0%	0 0.0%	0 0.0%	39 7.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	97.5 2.5%
	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	38 7.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100 0.0%
	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	41 7.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100 0.0%
	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	30 5.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100 0.0%
	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	37 7.0%	0 0.0%	0 0.0%	0 0.0%	100 0.0%
	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	50 9.5%	0 0.0%	0 0.0%	100 0.0%
	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.2%	43 8.2%	97.7 2.3%
	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	45 8.5%	1 0.2%
	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.2%	39 7.4%
	97.9 2.1%	100 0.0%	100 0.0%	97.4 2.6%	97.5 2.5%	100 0.0%	100 0.0%	100 0.0%	100 0.0%	98.0 2.0%	100 0.0%	97.8 2.2%	97.5 2.5%
Target Class													

Figura 29 - Matriz de Confusão do melhor resultado obtido no Domínio da Frequência

O gráfico de Entropia Cruzada no Domínio da Frequência (Figura 30) ilustra o comportamento da função de custo durante o treinamento, validação e teste da RNA ao longo de 512 épocas. A entropia cruzada mede a discrepância entre as probabilidades previstas pela rede e as classes reais codificadas em *one-hot*, sendo, portanto, um indicador direto da qualidade da classificação.

Observa-se que, nas primeiras 25 épocas, há uma queda acentuada da função de custo, reflexo do rápido aprendizado inicial da rede. A partir desse ponto, a redução torna-se mais gradual até estabilizar-se próximo da época 467, onde foi registrada a melhor performance de validação, com valor de entropia cruzada de aproximadamente 0,0031. Esse resultado é extremamente baixo, indicando que as previsões do modelo estão fortemente alinhadas às classes reais.





Figura 30 - Função de custo por entropia cruzada durante o processo de treinamento da RNA no Domínio da Frequência

Outro aspecto relevante é a proximidade entre as curvas de treinamento (azul), validação (verde) e teste (vermelho). A ausência de grandes divergências entre elas confirma que o modelo alcançou boa capacidade de generalização, evitando tanto o

*underfitting* quanto o *overfitting*. Em outras palavras, a RNA aprendeu os padrões relevantes do conjunto de dados sem memorizar os exemplos de treinamento, mantendo desempenho consistente também nos dados não vistos.

A convergência estável das curvas, somada ao baixo valor final da entropia cruzada, comprova a eficácia da configuração de hiperparâmetros e da estratégia de seleção de características adotadas. Esse comportamento valida a robustez do modelo no Domínio da Frequência e reforça sua aplicabilidade em cenários reais de diagnóstico de falhas de injeção, nos quais a confiabilidade e a consistência são fatores essenciais.

A Figura 31 representa o gráfico Gradiente vs Épocas apresenta a evolução da magnitude do gradiente durante o processo de treinamento da RNA ao longo de 512 épocas. O gradiente representa a intensidade das atualizações realizadas nos pesos da rede em cada iteração, estando diretamente ligado à eficiência do algoritmo de otimização em encontrar o mínimo da função de custo.



*Figura 31 - Gradiente x Épocas no Domínio da Frequência*

Observa-se que, nas primeiras épocas, o gradiente apresenta valores mais elevados, na ordem de  $10^{-2}$ , o que indica ajustes mais intensos nos parâmetros da RNA, característicos da fase inicial de aprendizado, quando o modelo ainda está distante da solução ótima. Com o avanço do treinamento, ocorre uma redução gradual da magnitude do gradiente, que se estabiliza na faixa de  $10^{-3}$ , mostrando que as atualizações nos pesos se tornam progressivamente menores, em razão da aproximação do ponto ótimo de convergência.

Ao final do processo, na época 512, o gradiente atinge o valor de aproximadamente 0,00119, considerado baixo e adequado para indicar convergência estável. Esse comportamento demonstra que a RNA não apenas reduziu a função de

custo, mas também atingiu um ponto de equilíbrio, evitando oscilações que poderiam sugerir instabilidade ou dificuldade de convergência.

O Histograma de Erros apresentado para o Domínio da Frequência (Figura 32) mostra a distribuição das diferenças entre os valores-alvo (*targets*) e as saídas produzidas pela RNA durante o treinamento, validação e teste. Esse tipo de gráfico é especialmente útil para avaliar a qualidade do ajuste do modelo, permitindo identificar a concentração, a dispersão e possíveis vieses nos erros.

Na Figura 32, observa-se que a grande maioria das instâncias — representadas pelas barras em azul (treinamento), verde (validação) e vermelho (teste) — está concentrada em torno de zero, com pequenas variações residuais. Essa concentração indica que a RNA foi capaz de aprender os padrões do sinal de vibração com elevado grau de precisão, minimizando discrepâncias entre as previsões e os valores reais. A linha laranja, que representa o erro zero ideal, coincide com o centro da distribuição, reforçando que os erros médios estão praticamente nulos.

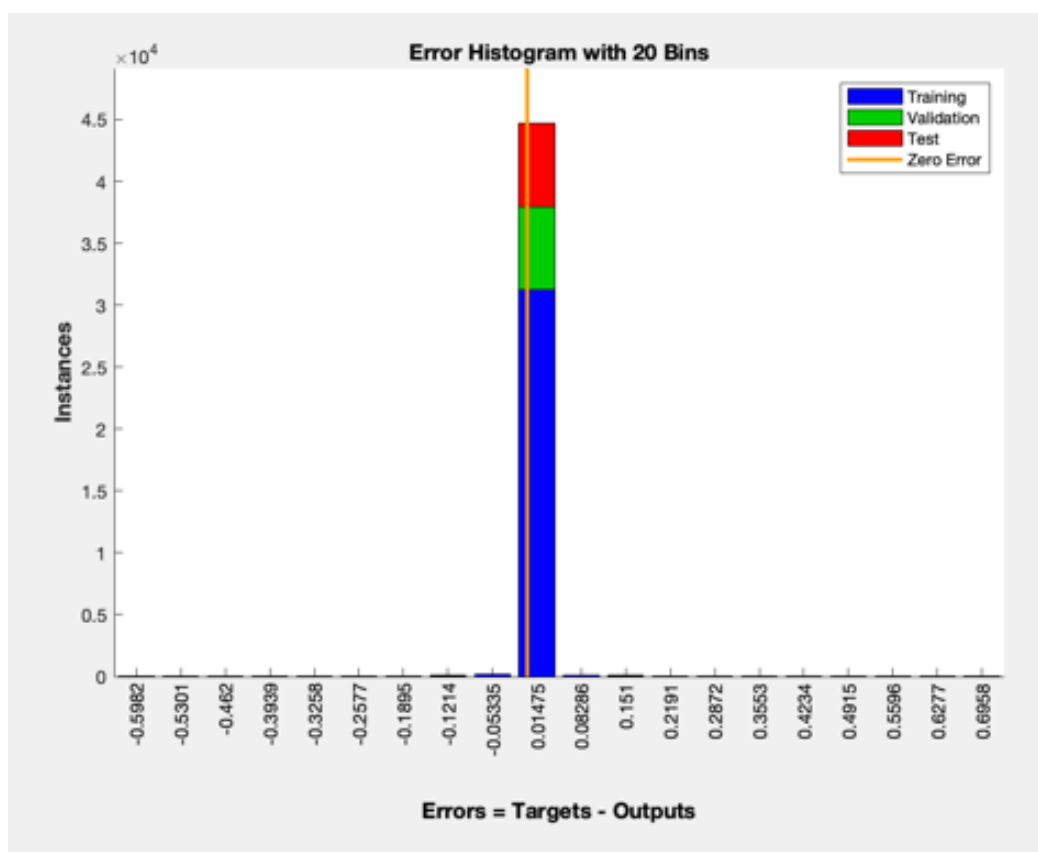


Figura 32 - Histograma de Erros no Domínio da Frequência


Outro aspecto relevante é a semelhança entre as distribuições dos conjuntos de treinamento, validação e teste. Essa consistência demonstra que o modelo não sofreu de

*overfitting*, pois apresentou comportamento homogêneo mesmo em dados não utilizados no aprendizado direto. Além disso, não há evidências de vieses sistemáticos: os erros não se deslocam significativamente para valores positivos ou negativos, o que mostra que a rede não tende a superestimar nem a subestimar os resultados.

Por fim, a forma estreita e concentrada da distribuição reforça a robustez da modelagem no Domínio da Frequência, confirmando que a RNA alcançou previsões altamente confiáveis e generalizáveis. Esses resultados validam as estratégias de seleção de características e acelerômetros adotada, evidenciando que o modelo conseguiu representar com fidelidade o comportamento dinâmico do motor, mesmo em cenários complexos de diagnóstico de falhas de injeção.

### **6.3.3. Ranqueamento das 27 Características Estatísticas no Domínio da Frequência**

No domínio da frequência (Figura 33), o comportamento é mais homogêneo. A maior parte das métricas estatísticas apresenta pesos positivos e relativamente próximos, com pequena amplitude de variação. Esse padrão sugere que, ao serem projetados no espectro, os sinais de vibração distribuem melhor a informação entre os diferentes atributos, resultando em menor contraste de relevância. Assim, a variância é reduzida, e praticamente todas as variáveis oferecem contribuição útil, ainda que em diferentes magnitudes. Esse equilíbrio faz do domínio da frequência um campo promissor para a construção de modelos estáveis, reduzindo o risco de sobreajuste associado a variáveis irrelevantes.




*Figura 33 - Ranqueamento das 27 Características no Domínio da Frequência*

## 6.4 Resultados no Domínio Tempo-Frequência

### 6.4.1. Desempenho com Diferentes Quantidades de Características e Acelerômetros

O estudo realizado no Domínio Tempo-Frequência visou aprofundar a avaliação da capacidade dos modelos de RNAs de diagnosticar falhas de injeção de combustível em motores Diesel marítimos a partir dos sinais de vibração. Para tanto, foram analisados diferentes cenários, variando-se tanto o número de características extraídas (1, 2, 5, 9, 18, 27 e 54) quanto o número de acelerômetros utilizados (1, 3, 5, 10 e 15).

Esta análise exploratória demonstrou o impacto significativo da seleção criteriosa de atributos e sensores sobre o desempenho do sistema de diagnóstico, reafirmando tendências observadas nos Domínios do Tempo e da Frequência e revelando características específicas do comportamento no Domínio Tempo-Frequência, conforme pode ser verificado na Figura 34.



*Figura 34 - F1-Score por Número de Características no Domínio Tempo-Frequência*

Quando utilizados 15 acelerômetros, observou-se que o melhor desempenho foi alcançado com apenas 1 característica estatística, obtendo-se um F1-Score de 92,95%. À medida que o número de características aumentava, houve uma clara tendência de degradação de desempenho: com 54 características, o F1-Score reduziu para 61,62%.

Essa queda é um forte indicativo do fenômeno da maldição da dimensionalidade (TAN; STEINBACH; KUMAR, 2018), em que a adição excessiva de características irrelevantes ou redundantes gera sobrecarga no modelo, reduzindo sua capacidade de generalização.

O tempo de processamento, por outro lado, variou de forma moderada, entre 162 segundos (2 características) e 286 segundos (54 características), sendo proporcional ao aumento da dimensionalidade dos dados.

Com a utilização dos 3 melhores acelerômetros, os resultados foram significativamente superiores. O melhor desempenho foi alcançado com apenas 1 característica, resultando em um F1-Score de 98,08%.

Além disso, o tempo de processamento foi otimizado, situando-se entre 135 e 511 segundos. Destaca-se que, mesmo com o acréscimo de características, o impacto negativo sobre o desempenho foi muito mais suave do que no cenário com 15 acelerômetros, demonstrando a importância estratégica da seleção de acelerômetros para reduzir a complexidade sem comprometer a qualidade do diagnóstico.

No cenário com apenas um acelerômetro, foram observados os melhores




resultados absolutos no Domínio Tempo-Frequência. Utilizando 2 características estatísticas, o modelo atingiu um F1-Score de 99,27%, Acurácia de 99,24%, Precisão de 99,32% e um Recall de 99,23%.

Tais métricas evidenciam uma extraordinária capacidade de diagnóstico, mesmo com configuração mínima de acelerômetros e características, o que é extremamente relevante para aplicações de manutenção preditiva em ambientes operacionais restritos.

O tempo de processamento nesse cenário variou entre 152 segundos (27 características) e 318 segundos (2 características), considerado plenamente aceitável diante dos elevados índices de performance obtidos.

Ao fixar o número de características em 54 e variar o número de acelerômetros (Figura 35), observou-se novamente que a performance diminui com o aumento da quantidade de sensores: o F1-Score caiu de 93,99% (1 acelerômetro) para 61,62% (15 acelerômetros).



*Figura 35 - F1-Score e Tempo de Processamento no Domínio Tempo-Frequência (54 Características)*


Este resultado confirma a tendência previamente detectada nos Domínios de Tempo e da Frequência, onde a combinação de excesso de variáveis e muitos sensores sem seleção adequada prejudica a capacidade discriminativa dos modelos de RNA, indicando a necessidade imperativa de métodos eficientes de seleção de características e otimização da disposição dos acelerômetros.

A análise final dos cenários no Domínio Tempo-Frequência (Figura 36) evidenciou que a utilização de 1 acelerômetro e 2 características resultou nos melhores desempenhos globais de F1-Score de 99,27%.

No cenário com os 3 melhores acelerômetros, também com 1 e 2 características,

proporcionaram resultados consistentes e elevados, com F1-Scores superiores a 96%.

As configurações com 15 acelerômetros apresentaram desempenho mais baixo (F1-Score máximo de 92,95%), mesmo realizando a seleção das características.



*Figura 36 - F1-Score e Tempo de Processamento por Cenário no Domínio Tempo-Frequência*

Esses achados reforçam a conclusão de que a qualidade das informações é muito mais relevante que a quantidade de dados brutos no contexto de diagnóstico baseado em vibração.

Dessa maneira, os resultados obtidos no Domínio Tempo-Frequência reafirmam que uma seleção criteriosa do número de características e acelerômetros pode maximizar o desempenho do diagnóstico. Características bem selecionadas capturam de forma eficiente os fenômenos físicos relacionados às falhas de injeção.

RNAs são ferramentas poderosas para o reconhecimento de padrões em sinais complexos, especialmente quando alimentadas com dados adequadamente tratados.

#### **6.4.2. Frequência e Contribuição dos Acelerômetros Mais Relevantes**

No Domínio Tempo-Frequência, a análise dos acelerômetros mais relevantes para o diagnóstico de falhas de injeção em motores Diesel evidenciou, de forma consistente, a superioridade dos sensores localizados sobre os cilindros, quando comparados aos instalados no bloco do motor.


A Tabela 17 apresenta os melhores resultados obtidos em diferentes cenários de

modelagem, detalhando o número de acelerômetros utilizados, o número de características extraídas, o acelerômetro com melhor desempenho em cada caso e os respectivos F1-Score, Acurácia, Precisão, Sensibilidade e Especificidade.

*Tabela 17 - Resultados com melhores acelerômetros nos cenários avaliados no Domínio Tempo-Frequência*


DOMÍNIO TEMPO-FREQUÊNCIA							
Cenários		Resultados					
Nº Acel.	Nº Caract	Melhor Acel.	F1-Score (%)	Acurácia (%)	Precisão (%)	Sensibilidade (%)	Especificidade (%)
1	2	8	99,27	99,24	99,32	99,23	99,94
1	5	15	97,27	97,34	97,33	97,26	99,78
1	9	2	95,27	95,45	95,48	95,21	99,62
1	18	3	95,36	95,45	5,32	95,45	99,62
1	27	3	96,37	96,39	96,54	96,31	99,70
3	1	8	98,08	98,10	98,17	98,04	99,84
3	2	8	96,84	96,77	96,84	96,90	99,73

Para compreender a relevância espacial dos sensores, a Figura 37 ilustra a disposição física dos acelerômetros sobre o motor Diesel marítimo. Os acelerômetros 2, 3, 8 e 15 foram os que apresentaram melhor desempenho nos testes. Importante notar que os acelerômetros 2, 3 e 8 estão posicionados diretamente sobre os cabeçotes dos cilindros, ao passo que o acelerômetro 15 está situado no bloco do motor.



*Figura 37 - Localização dos Acelerômetros com melhores desempenhos*

A distribuição da frequência de seleção dos melhores acelerômetros é sintetizada na Figura 38. O acelerômetro 8, montado sobre o cilindro 8, obteve o melhor desempenho em 42,9% dos cenários com F1-Score acima de 95%. Em seguida, o acelerômetro 3 (cilindro 3) foi o mais eficaz em 28,6% dos casos. Já os acelerômetros 2 e 15 foram selecionados em apenas 14,3% dos cenários cada.



*Figura 38 - Frequência de seleção dos melhores acelerômetros no Domínio Tempo-Frequência*

Esses dados confirmam a tendência observada nos demais domínios analisados, onde os sensores localizados nos cilindros capturam com maior fidelidade os eventos vibracionais relacionados às falhas de injeção, como variações na pressão de injeção, desequilíbrios de combustão e anomalias no acionamento da válvula injetora. Essa superioridade é resultado da proximidade direta com as fontes primárias de excitação mecânica, o que assegura a integridade dos sinais e amplia sua capacidade discriminativa nos modelos de RNA.

Adicionalmente, mesmo nos cenários com múltiplos sensores e maior número de características, os acelerômetros dos cilindros se mantiveram como os mais eficazes. Isso reforça a tese de que a seleção espacial correta do ponto de medição é mais determinante que a quantidade de sensores, contribuindo diretamente para a viabilidade prática de sistemas de monitoramento embarcado com baixa complexidade.

A Tabela 18 destaca a consistência entre as métricas de treinamento, validação e teste. Par os cenários apresentados, as diferenças entre elas são pequenas, o que confirma a boa capacidade de generalização do modelo e a ausência de sobreajuste (*overfitting*).

Mesmo em cenários com maior número de características (18 ou 27), onde há ligeira redução nas taxas de precisão, os valores se mantêm acima de 95%, demonstrando que a rede neural conseguiu aprender padrões discriminativos robustos, ainda que o excesso de variáveis tenha introduzido algum nível de redundância, associado ao fenômeno da maldição da dimensionalidade.

A tabela também evidencia que, quando utilizados três acelerômetros, os resultados permanecem altamente satisfatórios, atingindo até 98,10% de precisão em teste, o que reforça o equilíbrio entre desempenho e custo computacional alcançado pela estratégia de seleção dos melhores sensores.

*Tabela 18 - Precisões de Treinamento, Validação e Testes obtidas no Domínio Tempo-Frequência em diferentes configurações de número de Acelerômetros e Características Estatísticas*

<b>DOMÍNIO TEMPO-FREQUÊNCIA</b>					
<b>Cenários</b>		<b>Resultados</b>			
<b>Nº</b>	<b>Nº</b>	<b>Melhor</b>	<b>Precisão</b>	<b>Precisão</b>	<b>Precisão</b>
<b>Acel.</b>	<b>Caract</b>	<b>Acel.</b>	<b>Treinamento (%)</b>	<b>Validação (%)</b>	<b>Teste (%)</b>
1	2	8	99,72	98,86	99,24
1	5	15	99,72	98,48	97,34
1	9	2	99,06	96,02	95,45
1	18	3	99,72	97,15	95,45
1	27	3	99,59	96,02	96,40
3	1	8	99,67	98,10	98,10
3	2	8	99,51	97,53	96,77

A Matriz de Confusão de Validação no Domínio Tempo-Frequência (Figura 39) mostra que os resultados obtidos são altamente satisfatórios, com taxas de precisão por classe majoritariamente superiores a 95% e acertos perfeitos em diversas categorias. O desempenho médio manteve-se elevado, em 98,9%, o que confirma a robustez do modelo também no Domínio Tempo-Frequência.

Algumas classes, como 1, 2, 3, 5, 6, 7, 8, 9 e 10, atingiram 100% de acerto, sem qualquer registro de falsos positivos ou falsos negativos, demonstrando que a rede foi capaz de aprender padrões muito bem definidos e consistentes nesses cenários. Os erros apresentados são residuais e estruturados, ocorrendo predominantemente entre classes vizinhas, como 12 ↔ 13. Tal padrão é tecnicamente esperado, uma vez que sensores posicionados em cilindros adjacentes captam assinaturas de vibração semelhantes, o que pode gerar sobreposições sutis entre os padrões de falha.



classificação.





Figura 40 - Função de custo por entropia cruzada durante o processo de treinamento da RNA no Domínio Tempo-Frequência

Outro ponto relevante é a proximidade entre as curvas de treinamento (azul), validação (verde) e teste (vermelho). Essa sobreposição indica que o modelo não sofreu com *overfitting*, já que o erro não divergiu entre os conjuntos e não apresenta sinais de *underfitting*, pois as três curvas convergem para valores bastante reduzidos. Isso confirma a boa capacidade de generalização da rede.

O gráfico “Gradiente vs Épocas” (Figura 41), referente ao Domínio Tempo-Frequência, mostra a evolução da magnitude do gradiente durante o processo de treinamento da RNA ao longo de 501 épocas. O gradiente representa a intensidade das atualizações realizadas nos pesos da rede em cada iteração, sendo um parâmetro-chave para avaliar a eficiência do processo de otimização.

Nas primeiras épocas, o gradiente apresenta valores mais elevados, na ordem de  $10^{-2}$ , indicando ajustes intensos nos pesos da rede, característicos da fase inicial de aprendizado, quando o modelo ainda está distante do ponto ótimo. À medida que o treinamento avança, há uma redução gradual e consistente da magnitude do gradiente, que se estabiliza na faixa de  $10^{-3}$ . Esse comportamento mostra que os ajustes se tornam

progressivamente mais sutis, refletindo a aproximação da rede a um mínimo local da função de custo.



*Figura 41 - Gradiente x Épocas no Domínio Tempo-Frequência*

Ao final do treinamento, na época 501, o gradiente atinge o valor de aproximadamente 0,00107, considerado baixo e indicativo de convergência estável. Além disso, a trajetória descendente, mesmo com pequenas oscilações naturais ao longo do processo, confirma que a rede neural manteve um comportamento consistente e controlado durante a otimização.






Figura 42 - Histograma de Erros no Domínio Tempo-Frequência

O Histograma de Erros referente ao Domínio Tempo-Frequência (Figura 42) mostra a distribuição das diferenças entre os valores reais (*targets*) e as saídas previstas pela RNA nos conjuntos de treinamento, validação e teste. Esse gráfico é uma ferramenta importante porque permite avaliar não apenas a magnitude média dos erros, mas também sua dispersão e consistência entre os diferentes conjuntos de dados.

Observa-se que a imensa maioria das instâncias, representadas pelas barras em azul (treinamento), verde (validação) e vermelho (teste), está concentrada muito próxima de zero, exatamente em torno da linha laranja que indica o erro nulo ideal. Essa forte concentração revela que a RNA foi capaz de reproduzir as saídas com altíssima fidelidade, reduzindo os erros residuais a valores praticamente desprezíveis.

Outro aspecto relevante é a semelhança entre as distribuições dos três conjuntos. A presença equilibrada de erros próximos de zero em treinamento, validação e teste demonstra que o modelo não sofreu com *overfitting*, uma vez que manteve desempenho consistente também em dados não utilizados no processo de aprendizado. Além disso, não se verificam deslocamentos sistemáticos dos erros para valores positivos ou negativos, o que indica ausência de vieses de superestimação ou subestimação das saídas.

Conclui-se, portanto, que no Domínio Tempo-Frequência — assim como nos Domínios do Tempo e da Frequência — a adoção de acelerômetros posicionados nos cilindros é uma estratégia técnica eficaz para o diagnóstico preciso de falhas de injeção em motores Diesel marítimos, representando uma solução de alto desempenho e elevada aplicabilidade industrial.

### 6.4.3. Ranqueamento das 54 Características Estatísticas no Domínio da Tempo-Frequência

Quando se avança para o domínio tempo-frequência (Figura 43), a análise volta a revelar um quadro de heterogeneidade. O aumento no número de características — decorrente da combinação das representações no domínio do tempo e da frequência — intensifica a dispersão de relevâncias. Características como Valor Mínimo, Pico e Curtose destacam-se como fortemente positivas, ao passo que outras, como Fator de Crista e Moda, apresentam pesos negativos expressivos. Esse resultado reflete um paradoxo: o enriquecimento da base de características amplia o potencial de discriminação do modelo, mas, ao mesmo tempo, gera um conjunto mais heterogêneo, no qual muitos elementos tornam-se redundantes ou prejudiciais. A variância, nesse caso, cresce de forma significativa, reforçando a importância da seleção criteriosa para que apenas os atributos mais informativos sejam mantidos.





Figura 43 - Ranqueamento das 54 Características no Domínio da Tempo-Frequência

## 6.5. Comparação Entre os Domínios

Os resultados obtidos com a aplicação das RNAs demonstram um desempenho

bastante satisfatório na tarefa de diagnóstico de falhas de injeção em motores Diesel marítimos, utilizando sinais de vibração. Independentemente do domínio de análise empregado — Tempo, Frequência ou Tempo-Frequência — os modelos foram capazes de identificar padrões representativos das diferentes condições operacionais com elevados índices de desempenho, em especial quando configurados com as melhores combinações de características estatísticas e parâmetros de treinamento.

Os melhores resultados obtidos nos três domínios de análise evidenciam a elevada capacidade discriminativa dos modelos propostos, conforme apresentado na Figura 44. No **Domínio do Tempo**, destacou-se o **F1-Score de 99,44%**, utilizando apenas **duas características estatísticas**. Já no **Domínio da Frequência**, o melhor desempenho foi registrado com um **F1-Score de 99,43%**, ao se empregar **duas características estatísticas**. No **Domínio Tempo-Frequência**, o melhor desempenho foi obtido com um **F1-Score de 99,27%**, também com **duas características estatísticas**.



*Figura 44 - Melhores F1-Scores por Domínio de Análise*


A Tabela 19 foi utilizada para construir os gráficos Radar Plot para comparar simultaneamente o desempenho dos três domínios de análise em múltiplas métricas de classificação e eficiência computacional. Essa visualização possibilita uma interpretação intuitiva do equilíbrio entre acurácia, sensibilidade, precisão, especificidade, F1-Score e tempo de processamento normalizado, facilitando a identificação de pontos fortes e

limitações de cada abordagem, e subsidiando a escolha do método mais adequado aos objetivos propostos.

*Tabela 19 - Métricas de Desempenho por Domínio*

Métrica	Domínio do Tempo (%)	Domínio da Frequência (%)	Domínio do Tempo-Frequência (%)
Precisão	99,43	99,50	99,32
Sensibilidade	99,48	99,39	99,23
Acurácia	99,43	99,43	99,24
Especificidade	99,95	99,95	99,94
F1-Score	99,44	99,43	99,27
Tempo de Processamento Normalizado	86,11	65,86	84,95
Tempo	294 s	696 s	318 s

Para a análise comparativa do desempenho entre os três domínios de processamento — Domínio do Tempo, Domínio da Frequência e Domínio Tempo-Frequência — foi utilizado um gráfico do tipo Radar Plot (Figura 45). Essa representação gráfica permite a visualização simultânea de múltiplas métricas de avaliação, englobando Precisão, Sensibilidade, Acurácia, Especificidade, F1-Score e Tempo de Processamento Normalizado.



*Figura 45 - Gráfico Radar Plot comparando os 3 Domínios Estudados*

A escolha desse tipo de gráfico justifica-se pelo seu potencial em oferecer uma visão integrada e intuitiva do desempenho de cada abordagem, possibilitando a identificação de padrões, pontos fortes e eventuais deficiências de forma mais clara do

que seria possível por meio de tabelas numéricas isoladas. Além disso, o Radar Plot facilita a interpretação dos resultados no contexto multidimensional, permitindo evidenciar possíveis *trade-offs* entre desempenho e custo computacional.

A análise visual do gráfico evidencia que o **Domínio do Tempo** (azul) apresenta a maior área total, indicando um equilíbrio consistente entre alto F1-Score e rapidez de processamento. O **Domínio da Frequência** (laranja) destaca-se por apresentar o maior valor de Precisão, porém, apresenta desempenho inferior no eixo de velocidade de processamento. Já o **Domínio Tempo-Frequência** (verde) mostra-se competitivo em termos de velocidade, mas com métricas de classificação ligeiramente inferiores às das demais abordagens. Dessa forma, a visualização proporcionada pelo Radar Plot contribui para embasar, de maneira objetiva e fundamentada, a escolha do método no Domínio Tempo como o mais eficaz e adequado aos objetivos da pesquisa, considerando não apenas métricas isoladas, mas o desempenho global de cada domínio.

#### 6.5.1. Custo Computacional no Pré-processamento dos Sinais de Vibração

Durante a etapa de pré-processamento dos sinais de vibração, observou-se uma diferença significativa no custo computacional entre os domínios de análise empregados. Em particular, o Domínio do Tempo apresentou tempo de processamento substancialmente inferior quando comparado aos Domínios da Frequência e Tempo-Frequência. Essa diferença é atribuída à ausência da necessidade de aplicar a FFT no Domínio do Tempo.

A análise no Domínio do Tempo utiliza diretamente os sinais de vibração brutos, extraindo características estatísticas básicas — como média, desvio padrão, fator de crista, entre outras — sem a necessidade de transformação dos dados para outro domínio. Isso implica que o processamento ocorre de forma linear e direta sobre os dados temporais.

Por outro lado, nos Domínios da Frequência e Tempo-Frequência, a aplicação da FFT torna-se etapa obrigatória. A FFT é um algoritmo que converte o sinal do Domínio do Tempo para o Domínio da Frequência, permitindo analisar a distribuição espectral da energia do sinal. Embora a FFT seja computacionalmente eficiente, sua aplicação a cada segmento de dados gera um aumento significativo do custo de processamento, principalmente em bases de dados volumosas e em aplicações que exigem análise contínua ou em tempo real.

Além disso, no Domínio Tempo-Frequência, a necessidade de calcular múltiplas

transformadas em janelas temporais sobrepostas ou sucessivas acentua ainda mais o custo computacional, uma vez que cada janela demanda uma nova execução da FFT.

Portanto, a superioridade em termos de tempo de processamento observada no Domínio do Tempo é uma consequência direta da simplicidade do pré-processamento necessário. Essa característica faz com que o Domínio do Tempo seja particularmente vantajoso para aplicações embarcadas e sistemas de monitoramento em tempo real, onde tempo de resposta rápido e baixo consumo computacional são fatores críticos.

Esta diferença operacional entre os domínios justifica, em parte, o excelente equilíbrio observado no Domínio do Tempo entre a alta acurácia diagnóstica e a eficiência computacional, sendo um dos fatores que contribuíram para a escolha desta abordagem como a mais adequada no contexto do presente estudo.

### **6.5.2. Considerações Sobre Custo Computacional da RNA**

O **Domínio do Tempo** ofereceu o menor tempo de processamento (143 segundos) aliado ao melhor desempenho diagnóstico.

O **Domínio da Frequência**, embora competitivo em desempenho, exigiu quase o dobro do tempo (257 segundos).

O **Domínio Tempo-Frequência** teve um tempo intermediário (152 segundos), mas com desempenho ligeiramente inferior aos demais domínios.

Esses dados mostram que menores tempos de processamento, sem perda de desempenho, são críticos para aplicações marítimas práticas, onde a resposta rápida é fundamental. A otimização do número de características e acelerômetros mostrou ser decisiva para atingir um alto desempenho no diagnóstico de falhas.

### **6.5.3. Desempenho da RNA com Base nas Melhores Características**

Independentemente do domínio escolhido, os melhores desempenhos foram obtidos quando o cenários tinham apenas 1 ou 2 características estatísticas. No Domínio do Tempo, uma única característica proporcionou resultados extraordinários com F1-Score de 99,44%. Nos Domínios da Frequência e Tempo-Frequência, duas características adequadamente escolhidas bastaram para obter desempenhos também superiores a 99%.

Esses resultados evidenciam que seleções adequadas das melhores características capturam informações suficientes para o diagnóstico de falha de injeção de combustível. Tal fato ressalta que modelos simples são mais rápidos e robustos, enquanto o uso

excessivo de atributos compromete o desempenho devido à maldição da dimensionalidade.

A escolha das melhores características é, portanto, uma etapa crítica para maximizar o desempenho e minimizar os custos computacionais.

#### 6.5.4. Frequência e Contribuição dos Acelerômetros Mais Relevantes

A análise da incidência dos acelerômetros mais relevantes mostrou que os **acelerômetros localizados nos cabeçotes** foram frequentemente selecionados nos cenários de melhor desempenho.

Em todos os domínios, o uso de 1 ou 3 melhores acelerômetros foi suficiente para atingir F1-Score superiores a 98%, comprovando que a posição estratégica dos acelerômetro é mais importante do que a quantidade;

É possível reduzir drasticamente o número de acelerômetros sem prejuízo no desempenho, o que é vital para sistemas de monitoramento embarcados onde espaço e custo são limitados.

### 6.6. Comparação Entre Este Estudo e a Dissertação de Guerra (2023)

#### 6.6.1. Desempenho Diagnóstico Utilizando os Três Melhores Acelerômetros

Com o objetivo de contextualizar os resultados obtidos neste trabalho, realizou-se uma comparação direta com os dados apresentados por GUERRA (2023), cujo trabalho abordou o diagnóstico de falhas de injeção em motores Diesel utilizando algoritmos de aprendizado de máquina, especificamente K-NN, SVM e RF. A comparação foi realizada com base no desempenho diagnóstico obtido a partir dos três melhores acelerômetros no Domínio do Tempo, para diferentes quantidades de características estatísticas extraídas dos sinais de vibração.

A Tabela 20 sintetiza os principais resultados comparativos, considerando os valores de F1-score obtidos para 5, 9 e 18 características estatísticas.

*Tabela 20 - Comparação de desempenho entre GUERRA (2023) e o presente estudo utilizando 3 acelerômetros no Domínio do Tempo*

Nº de Características	Algoritmo (Guerra)	F1-Score (%)	Algoritmo (Bodanese )	F1-Score (%)
5	K-NN	88,4	RNA	93,89
5	SVM	91,74	RNA	93,89
9	K-NN	96,15	RNA	94,55
9	SVM	95,34	RNA	94,55
18	K-NN	93,39	RNA	93,54
18	SVM	97,36	RNA	93,54

Observa-se que os modelos baseados em RNAs utilizados neste estudo apresentaram desempenho robusto e estável em todos os cenários, com F1-Scores consistentemente superiores a 93%. Ainda que Guerra (2023) tenha alcançado seu melhor resultado com o algoritmo SVM (F1-score de 97,36% com 18 características), a RNA demonstrou um desempenho ainda melhor com menos características (F1-Score de 98,48% com 1 característica), fator decisivo para aplicações em tempo real e com restrições computacionais. Este resultado evidencia a capacidade da RNA em extrair padrões relevantes mesmo em condições de baixa dimensionalidade, aspecto altamente desejável em sistemas de monitoramento embarcados.

Além disso, destaca-se que o algoritmo Random Forest, testado por Guerra, apresentou desempenho significativamente inferior em dois cenários (F1-Score de apenas 46,98% com 9 e 18 características), enquanto a RNA mostrou-se estável e confiável, sem quedas abruptas de performance.

#### **6.6.2. Considerações Finais da Comparação**

Em síntese, os resultados obtidos neste estudo demonstram que as RNAs apresentam desempenho competitivo ou superior frente aos algoritmos tradicionais de aprendizado supervisionado; a estabilidade do modelo com variação do número de características foi maior na abordagem com RNA; a eficiência com menor número de entradas (acelerômetros e características descritivas) posiciona a RNA como alternativa preferencial para aplicações embarcadas e a simplicidade na configuração e a robustez frente a ruídos ou variações tornam as RNAs uma solução tecnicamente viável e operacionalmente eficiente.

Por fim, a metodologia proposta contribui com o avanço técnico para o diagnóstico inteligente de falhas de injeção em motores Diesel marítimos.



## 7. CONCLUSÕES

Este trabalho apresentou o desenvolvimento e avaliação de um sistema inteligente para o diagnóstico de falhas de injeção em motores Diesel marítimos, baseado na análise de sinais de vibração e no uso de RNAs. A investigação concentrou-se na aplicação de técnicas de extração e seleção de características nos Domínios do Tempo, Frequência e Tempo-Frequência, associadas a diferentes configurações de acelerômetros, com o objetivo de identificar cenários otimizados que maximizassem o desempenho diagnóstico com o menor custo computacional.

Os resultados experimentais comprovaram que a abordagem com RNAs, alimentadas por um conjunto reduzido e estrategicamente selecionado de características estatísticas e acelerômetros, é altamente eficaz na identificação precisa de falhas de injeção. Em particular, foi possível alcançar F1-scores superiores a 99% nos três domínios analisados, sendo o Domínio do Tempo o mais eficaz e eficiente em termos de custo computacional. A ausência da necessidade de transformações espectrais (como a FFT) nesse domínio contribuiu significativamente para a redução do tempo de processamento, tornando-o particularmente adequado para aplicações embarcadas e em tempo real.

Adicionalmente, observou-se que o desempenho da RNA se manteve elevado mesmo em cenários de baixa dimensionalidade, com 1 ou 2 características e apenas um acelerômetro. Essa constatação reforça a viabilidade de se implementar soluções compactas e de alta precisão em ambientes com restrições físicas e operacionais, como navios e plataformas offshore. A consistência dos resultados também confirmou a influência direta da posição dos acelerômetros sobre os cabeçotes dos cilindros, em detrimento daqueles instalados no bloco do motor.

Em termos comparativos, a metodologia proposta demonstrou desempenho competitivo ou superior em relação a algoritmos clássicos como SVM, K-NN e Random Forest, conforme análise comparativa com o trabalho de Guerra (2023). A RNA se destacou não apenas pelo desempenho, mas pela robustez frente a variações nas entradas e pela simplicidade de configuração.

Dessa forma, a dissertação contribui tecnicamente ao propor uma solução otimizada, precisa e de baixo custo computacional para diagnóstico de falhas em sistemas críticos. Além disso, os resultados obtidos abrem caminho para futuras pesquisas com foco na implantação em tempo real, desenvolvimento de sistemas embarcados autônomos e expansão para outros tipos de falhas mecânicas além da injeção de combustível.

## 8. SUGESTÕES PARA TRABALHOS FUTUROS

Durante a etapa de pesquisa de campo descrita no Estudo de Caso, foram obtidos diversos registros e parâmetros adicionais que, embora não tenham sido incorporados à análise principal desta dissertação, apresentam grande potencial para estudos complementares. Entre eles, destacam-se as variações de vibração em regimes transitórios, os dados de funcionamento em diferentes níveis de carga e rotação, bem como registros provenientes de diferentes pontos de medição no motor e na estrutura da embarcação. Adicionalmente, foram coletados dados por meio de *strain gages* instalados no sistema, com o objetivo de registrar deformações associadas ao comportamento torsional do eixo. Esses dados, ainda não explorados nesta pesquisa, representam uma oportunidade relevante para investigações voltadas ao estudo das vibrações torcionais do motor.

O aproveitamento dessas informações em trabalhos futuros pode ampliar significativamente a compreensão sobre o comportamento dinâmico do sistema, especialmente em condições não estacionárias. Isso possibilitaria o desenvolvimento de modelos preditivos mais robustos e sensíveis a alterações sutis no desempenho, bem como a avaliação da relação entre vibrações torcionais e falhas de injeção, complementando as análises já realizadas com base nos sinais de acelerômetros. A aplicação de técnicas de análise no domínio tempo-frequência, associadas a métodos avançados de machine learning e deep learning, poderia revelar padrões complexos ainda não identificados nos sinais coletados, aumentando a capacidade diagnóstica e permitindo detecção mais precisa, inclusive em regimes transitórios.

## 9. REFERÊNCIAS BIBLIOGRÁFICAS

- AGGARWAL, C. C. Outlier Analysis. 2. ed. Cham: Springer, 2017.
- AGGARWAL, C. C. Neural Networks and Deep Learning: A Textbook. Cham: Springer, 2018.
- ALPAYDIN, E. Introduction to Machine Learning. 2. ed. Cambridge: MIT Press, 2010.
- AYANKOSO, S.; DUTTA, A.; HE, Y.; GU, F.; BALL, A.; PAL, S. K. Performance of vibration and current signals in the fault diagnosis of induction motors using deep learning and machine learning techniques. *Structural Health Monitoring*, v. 1, p. 1-17, 2024. DOI: 10.1177/14759217241289874.
- BUSINARO, A. et al. Accelerometer based methodology for combustion parameters estimation. 2015.
- CAI, Y.; YANG, M.; GAO, Y.; YIN, H. Relief-F-based Multi-label Feature Selection. *International Journal of Database Theory and Application*, v. 8, n. 4, p. 307-318, 2015. DOI: 10.14257/ijdta.2015.8.4.31.
- CHARLES. Detecting the crankshaft torsional vibration of Diesel engines for combustion related diagnosis. 2009.
- CHEN, et al. Improved automated diagnosis of misfire in internal combustion engines based on simulation models. 2015.
- COOLEY, J. W.; TUKEY, J. W. An Algorithm for the Machine Calculation of Complex Fourier Series. *Mathematics of Computation*, v. 19, n. 90, p. 297-301, 1965.
- CYBENKO, G. (1989). "Approximation by Superpositions of a Sigmoidal Function," *Math. Control Signals Systems*, **2**, 303-314.
- DEJONG. Engine Monitoring Using Vibration Signals. 1986.
- DIAZDELAO, F. A. et al. Stochastic structural dynamic analysis using Bayesian emulators. *Computers & Structures*, v. 120, p. 24-32, 2013.
- DINIZ, P. S. R.; SILVA, E. A. B.; NETTO, S. L. Processamento Digital de Sinais: Projeto e Análise de Sistemas. 2. ed. Porto Alegre: Bookman, 2014.
- DRAKE, S. Galileo at Work: His Scientific Biography. Chicago: University of Chicago Press, 1978.
- EVSKOFF, Alexandre G. *Inteligência Computacional: Fundamentos e Aplicações*. Rio de Janeiro: E-papers, 2020. ISBN: 978-65-87065-02-1.
- EWINS, D. J. Modal Testing: Theory, Practice, and Application. 2. ed. Baldock: Research Studies Press, 2000.

- FOURIER, J. B. J. *Théorie analytique de la chaleur*. Paris: Chez Firmin Didot, père et fils, 1822.
- MAIONE, F.; LINO, P.; GIANNINO, G.; MAIONE, G. A new deep learning strategy to predict time-series of marine diesel engines. *Preprint – TechRxiv*, 2025.
- GAWANDE. Fault Detection of Inline Reciprocating Diesel Engine: A Mass and Gas-Torque Approach. 2012.
- GHOLAMY, A.; KREINOVICH, V.; KOSHELEVA, O. Why 70/30 or 80/20 Relation Between Training and Testing Sets: A Pedagogical Explanation. El Paso: University of Texas at El Paso, 2018.
- GIROSI, F.; POGGIO, T. Networks and the Best Approximation Property. *Biological Cybernetics*, v. 63, n. 3, p. 169–176, 1990.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. Cambridge: MIT Press, 2016.
- GU, M. et al. Research of fault diagnosis and prediction based on Bayesian networks and time series model. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 2025.
- GUYON, I.; ELISSEEFF, A. An introduction to variable and feature selection. *Journal of Machine Learning Research*, v. 3, p. 1157–1182, 2003.
- GUERRA, V. N. Diagnóstico de falhas de ignição em motor Diesel marítimo utilizando sinais de vibração e aprendizado de máquinas. 2023. 78 f. Dissertação (Mestrado em Engenharia Oceânica) – Instituto Alberto Luiz Coimbra de Pós-graduação e Pesquisa de Engenharia (COPPE), Universidade Federal do Rio de Janeiro (UFRJ), Rio de Janeiro, 2023.
- HARRIS, F. J. On the use of windows for harmonic analysis with the discrete Fourier transform. *Proceedings of the IEEE*, v. 66, n. 1, p. 51-83, 1978.
- HASSOUN, M. H. *Fundamentals of Artificial Neural Networks*. Cambridge: MIT Press, 1995.
- HAYKIN, Simon. *Neural Networks and Learning Machines*. 3rd ed. Upper Saddle River: Pearson Education, 2009. ISBN: 978-0-13-147139-9.
- HU. Burnt Fraction Sensitivity Analysis and 0-D Modelling of Common Rail Diesel Engine Using Wiebe Function. 2017.
- HUU, H. D. et al. Improved convolutional neural network-based bearing fault diagnosis using multi-phase motor current signals. *International Journal of Power Electronics and Drive Systems (IJPEDS)*, 2025.

- IVEZIC, Ž.; CONNOLLY, A.; VANDERPLAS, J.; GRAY, A. Statistics, Data Mining and Machine Learning in Astronomy: A Practical Python Guide for the Analysis of Survey Data. Princeton: Princeton University Press, 2014.
- JABER, A.A. Diagnosis of Bearing Faults Using Temporal Vibration Signals: A Comparative Study of Machine Learning Models with Feature Selection Techniques. *J Fail. Anal. and Preven.* 24, 752–768 (2024). <https://doi.org/10.1007/s11668-024-01883-0>
- JARDINE, A. K. S.; LIN, D.; BANJEVIC, D. A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, v. 20, n. 7, p. 1483-1510, 2006.
- JIA, F. et al. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data. *Mechanical Systems and Signal Processing*, v. 72, p. 303-315, 2020.
- JUNG. Development of misfire detection algorithm using quantitative FDI performance analysis. 2015.
- KIRA, K.; RENDELL, L. A practical approach to feature selection. *Proceedings of the Ninth International Workshop on Machine Learning*, 1992.
- KLINCHAEAM. Condition Monitoring of a Small Four-stroke Petrol Engine using Vibration Signals. 2009.
- KONONENKO, I. Estimating attributes: analysis and extensions of Relief. *European Conference on Machine Learning*, 1994.
- LEI, Y. et al. Machinery health prognostics: A systematic review from data acquisition to RUL prediction. *Mechanical Systems and Signal Processing*, v. 104, p. 799-834, 2018.
- LYON. Recovery of Fault Signatures in Diesel Engines. 1988.
- MACIÁN. Detection and correction of injection failures in Diesel engines on the basis of turbocharger instantaneous speed frequency analysis. 2005.
- 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.
- MEDEIROS. Fault detection in Diesel Engine Injectors using a vibration and sound pressure level technique. 2018.
- MOODY, J.; DARKEN, C. Fast Learning in Networks of Locally Tuned Processing Units. *Neural Computation*, v. 1, n. 2, p. 281–294, 1989.

- MORAES, Gabriel Hasmann Freire; RIBEIRO JUNIOR, Ronny Francis; GOMES, Guilherme Ferreira. Fault Classification in Diesel Engines Based on Time-Domain Responses through Signal Processing and Convolutional Neural Network. *Vibration*, v. 7, p. 863–893, 2024. DOI: <https://doi.org/10.3390/vibration7040046>.
- MØLLER, M. F. A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning. *Neural Networks*, v. 6, n. 4, p. 525-533, 1993.
- NEUPANE, Dhiraj; BOUADJENEK, Mohamed Reda; DAZELEY, Richard; ARYAL, Sunil. Data-driven machinery fault diagnosis: A comprehensive review. *Neurocomputing*, v. 627, p. 129588, 2025. DOI: <https://doi.org/10.1016/j.neucom.2025.129588>.
- NYQUIST, H. Certain topics in telegraph transmission theory. *Transactions of the American Institute of Electrical Engineers*, v. 47, n. 2, p. 617-644, 1928.
- POWERS, David M. W. Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. *Journal of Machine Learning Technologies*, v. 2, n. 1, p. 37-63, 2011.
- PRAWIN, J. Deep learning neural networks with input processing for vibration-based bearing fault diagnosis. *Structural Health Monitoring Journal*, 2024.
- RANDALL, R. B. *Vibration-based Condition Monitoring: Industrial, Aerospace and Automotive Applications*. Chichester: John Wiley & Sons, 2011.
- TAGHIZADEH-ALISARAEI. *Fault Detection of Injectors in Diesel Engines Using Vibration Time-Frequency Analysis*. 2018.
- TAN, P.-N.; STEINBACH, M.; KUMAR, V. *Introduction to Data Mining*. 2. ed. Boston: Pearson, 2018.
- TAGLIALATELA-SCAFATI, F.; LAVORGNA, M. *Vibration Signal Analysis for Condition Monitoring of Diesel Engines*.
- TAYLOR, J. *The Vibration Analysis Handbook*. 1. ed., 2. impressão. Tampa: Vibration Consultants, 1994.
- THARANGA, K. L. P.; LIU, Shuyong; ZHANG, Shuai; WANG, Yuan. Diesel Engine Fault Diagnosis with Vibration Signal. *Journal of Applied Mathematics and Physics*, v. 8, p. 2031-2042, 2020. DOI: [10.4236/jamp.2020.89151](https://doi.org/10.4236/jamp.2020.89151).
- URBANOWICZ, R. J.; MEEKER, M.; LA CAVA, W.; OLSON, R. S.; MOORE, J. H. Relief-Based Feature Selection: Introduction and Review. *Journal of Biomedical Informatics*, v. 85, p. 189-203, 2018. DOI: [10.1016/j.jbi.2018.07.014](https://doi.org/10.1016/j.jbi.2018.07.014).ZHU.

- Detection of Cylinder Pressure in Diesel Engines Using Cylinder Head Vibration and Time Series Methods. 2007.
- WETTSCHERECK, D.; DIETTERICH, T. Improving the Performance of Radial Basis Function Networks by Learning Center Locations. *NeurIPS*, p. 1133–1140, 1992.