

Gabriel Pereira de Calais

**Identificação de Falhas de Dirigibilidade
Durante a Desaceleração Utilizando Adaline e
Transformada Wavelet**

Viçosa, MG

2022

Gabriel Pereira de Calais

Identificação de Falhas de Dirigibilidade Durante a Desaceleração Utilizando Adaline e Transformada Wavelet

Monografia apresentada ao Departamento de Engenharia Elétrica do Centro de Ciências Exatas e Tecnológicas da Universidade Federal de Viçosa, para a obtenção dos créditos da disciplina ELT 402 – Projeto de Engenharia II – e cumprimento do requisito parcial para obtenção do grau de Bacharel em Engenharia Elétrica.

Orientador Rodolpho Neves

Viçosa, MG

2022


GABRIEL PEREIRA DE CALAIS

**IDENTIFICAÇÃO DE FALHAS DE DIRIGIBILIDADE DURANTE
A DESACELERAÇÃO UTILIZANDO ADALINE E
TRANSFORMADA WAVELET**

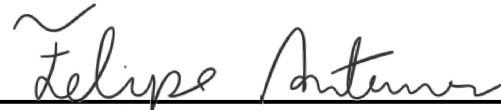
Monografia apresentada ao Departamento de Engenharia Elétrica do Centro de Ciências Exatas e Tecnológicas da Universidade Federal de Viçosa, para a obtenção dos créditos da disciplina ELT 402 – Projeto de Engenharia II e cumprimento do requisito parcial para obtenção do grau de Bacharel em Engenharia Elétrica.

Aprovada em 25 de março de 2022.

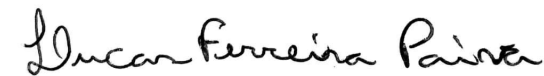
COMISSÃO EXAMINADORA



Prof. Dr. Rodolpho Vilela Alves Neves - Orientador
Universidade Federal de Viçosa



Prof. Me. Felipe Antunes - Membro
Instituto Federal de Minas Gerais



Eng. Lucas Ferreira Paiva - Membro
Universidade Federal de Viçosa

Gabriel Pereira de Calais

Identificação de Falhas de Dirigibilidade Durante a Desaceleração Utilizando Adaline e Transformada Wavelet

Monografia apresentada ao Departamento de Engenharia Elétrica do Centro de Ciências Exatas e Tecnológicas da Universidade Federal de Viçosa, para a obtenção dos créditos da disciplina ELT 402 – Projeto de Engenharia II – e cumprimento do requisito parcial para obtenção do grau de Bacharel em Engenharia Elétrica.

Trabalho aprovado em 25 de Março de 2022.

COMISSÃO EXAMINADORA

Rodolpho Neves
Orientador

Lucas Paiva
Membro Avaliador

Felipe Antunes
Membro Avaliador

Viçosa, MG
2022

*Este trabalho é dedicado à todos que, de várias formas,
me apoiaram, inspiraram e motivaram neste percurso.*

Agradecimentos

Gostaria de agradecer primeiramente a meu orientador Rodolpho Neves que sempre me auxiliou nas minhas diversas empreitadas nessa jornada, ao professor Heverton Pereira que, juntamente com a GESEP, forneceu os meios para que este trabalho pudesse ser realizado e à Universidade Federal de Viçosa por me proporcionar uma grande oportunidade de desenvolvimento pessoal e profissional.

Agradeço, ainda, a meus pais, avós, irmã e todos os familiares que sempre me apoiaram incondicionalmente durante essa caminhada. Agradeço, também, às minhas amizades de longa data de Muriaé e também às que a UFV me proporcionou, em especial Ícaro, Luan, Helena, João Victor, Diuary e Pedro que fizeram de Viçosa um novo lar para mim e meu grande amigo Lucas por todo o companheirismo de sempre, sem eles nada disso seria possível.

“Nascer sabendo é uma limitação porque obriga a apenas repetir e, nunca, a criar, inovar, refazer, modificar. Aprender sempre é o que mais impede que nos tornemos prisioneiros de situações que, por serem inéditas, não saberíamos enfrentar.” (Mario Sérgio Cortella)

Resumo

Anormalidades no sistema de injeção de combustível afetam a dirigibilidade de veículos, prejudicando a realização de manobras do motorista ou a suavidade das respostas destes veículos em diferentes condições de operação. Com os avanços tecnológicos alcançados pela indústria automobilística, métodos objetivos para detecção de anomalias de dirigibilidade veicular têm sido estudados ao longo dos últimos anos, com destaque para metodologias utilizando análise tempo-frequência com transformada Wavelet. Ao realizar uma extração de características através da decomposição dos sinais com o pacote Wavelet visando detectar variações transitórias abruptas, torna-se possível identificar a ocorrência de falhas através da energia do sinal decomposto. Utilizando os conceitos de transformada Wavelet contínua e entropia da informação, este trabalho faz uma análise tempo-frequência do sinal de giro de um motor de combustão interna. As amostras de sinal de giro coletadas do motor foram padronizadas, calculou-se a transformada Wavelet contínua e, finalmente, a entropia do sinal transformado. Com isso, verificou-se a possibilidade de implementação de uma rede *Adaline* a fim de detectar a presença, ou não, de falha nesses sinais e, posteriormente, utilizá-la embarcada em uma unidade de comando eletrônico (ECU).

Palavras-chaves: *Adaline*; análise transiente; ECU; entropia; transformada wavelet.

Abstract

Abnormalities in fuel injection systems affect the drivability of vehicles, blemishing the driver's maneuvering experience or the smoothness of the response of these vehicles under different operating conditions. With the technological advances achieved by the automobile industry, objective methods for detecting anomalies in vehicle drivability have been studied over the last few years, with emphasis on methodologies using time-frequency analysis with Wavelet transform. When performing a feature extraction through Wavelet decomposition aiming to detect abrupt transient variations, it becomes possible to improve the drivability of a vehicle identifying the occurrence of failures by using the energy of the decomposed signal. Therefore, using the concepts of continuous Wavelet transform and entropy of information, this work makes a time-frequency analysis of the rotation signal of an internal combustion engine. The samples collected from the motor were standardized, the continuous Wavelet transform was calculated and, finally, the entropy of the transformed signal was measured. Thus, the possibility of implementing an Adaline capable of detecting the presence, or not, of abrupt changes in these signals was verified, and eventually, it could be embedded in an electronic control unit (ECU).

Key-words: Adaline; ECU; entropy; transient analysis; wavelet transform.

Lista de figuras

Figura 1 – Modelo de Wavelet Morlet.	20
Figura 2 – Sequência de manobras de aceleração e posterior desaceleração.	23
Figura 3 – Exemplo de amostra antes e após padronização.	23
Figura 4 – Representação do processo realizado para a técnica desenvolvida	24
Figura 5 – Transformadas Wavelet de sinais com e sem falha.	26
Figura 6 – Distribuição dos dados com entropia de <i>Shannon</i>	27
Figura 7 – Distribuição dos dados com entropia <i>Log Energy</i>	27
Figura 8 – Matrizes de confusão do treinamento da <i>Adaline</i>	28
Figura 9 – Gráficos de dispersão dos dados de treino e de teste.	29
Figura 10 – Matriz de Confusão para os dados de teste.	30
Figura 11 – Histograma de erro - classificação das amostras de teste.	30

Lista de tabelas

Tabela 1 – Arquitetura e Parâmetros da <i>Adaline</i>	25
---	----

Lista de abreviaturas e siglas

Adaline	Neurônio Linear Adaptável
CWT	Transformada Wavelet Contínua
ECU	Unidade de Controle Eletrônico
MCI	Motor de Combustão
RPM	Rotações Por Minuto
STFT	Transformada de Fourier de Curta Duração
WVD	Distribuição de Wigner-Ville

Lista de símbolos

β	Letra grega beta
π	Letra grega pi
ψ	Letra grega psi
ω	Letra grega ômega
τ	Letra grega tau

Sumário

1	INTRODUÇÃO	14
1.1	Objetivos	15
2	REVISÃO BIBLIOGRÁFICA	17
2.1	Descrição do Sistema	17
2.2	Ferramentas Matemáticas e Computacionais	18
2.2.1	Análises Tempo-Frequência	18
2.2.2	Distribuição de Wigner-Ville	18
2.2.3	Definições Gerais da Transformada Wavelet	19
2.2.4	Análise de Entropia dos Sinais	20
2.2.5	Redes Neurais Artificiais e <i>Adaline</i>	21
3	MATERIAIS E MÉTODOS	22
3.1	Conjunto de Dados	22
3.2	Processamento dos Dados	22
3.3	Construção e validação do modelo	24
4	RESULTADOS E DISCUSSÃO	26
5	CONSIDERAÇÕES FINAIS	31
	REFERÊNCIAS	32

1 Introdução

Os avanços tecnológicos alcançados pela indústria automobilística têm propiciado significativas melhorias no conforto do usuário de um veículo. Uma importante característica no desenvolvimento de um veículo automotor é a dirigibilidade veicular. A dirigibilidade veicular se refere à resposta do mesmo às manobras do motorista e à suavidade dessa resposta em diferentes condições de operação (JAUCH et al., 2015). Esse quesito é fundamental para que, na interação com o veículo, as manobras solicitadas pelo condutor sejam atendidas de maneira confortável e precisa.

Porém, as respostas a algumas dessas manobras podem ser influenciadas direta ou indiretamente por fenômenos associados ao processo de combustão interna do motor, como alguma anormalidade no sistema de injeção de combustível ou aspiração de ar (PULKRABEK, 2004). O processo de avaliação da dirigibilidade veicular é particular de cada fabricante e, geralmente, um avaliador realiza testes e considera suas impressões ao fazê-los, interpretando de maneira subjetiva (DOREY; HOLMES, 1999). Essa subjetividade pode dificultar a determinação das devidas ações a serem implementadas no sistema de controle, possivelmente gerando esforços de calibração desnecessários para a correção das anomalias (CACCIATORI, 2006).

Em consequência disso, métodos objetivos para detecção de anomalias de dirigibilidade veicular têm sido estudados ao longo dos últimos anos, com destaque para metodologias utilizando análise tempo-frequência com transformada *Wavelet*. Nestas metodologias, a análise e o processamento de sinais por *Wavelets* possibilitam a obtenção imediata de informações em relação a outras técnicas de análise em tempo-frequência (SANTIAGO; PEDERIVA, 2003).

Em (ZHANG; LI, 2016), é apresentado um método para diagnosticar falhas abruptas de sensores utilizando o pacote *Wavelet* do software MATLAB juntamente com redes neurais artificiais. Ao realizar uma extração de características através da decomposição dos sinais com o pacote *Wavelet* visando detectar variações transitórias abruptas, torna-se possível identificar a ocorrência de falhas através da energia do sinal decomposto.

Em (ZABIHI-HESARI et al., 2019) foi desenvolvido um sistema de detecção de falhas para um motor a diesel de 12 cilindros de alta potência, sendo implementado para identificar falhas de combustão causadas por injeções anormais de combustível. A abordagem se baseia na análise do espectro de potência de sinais de vibração através da transformada *wavelet* discreta, utilizando redes neurais para uma classificação automática.

Já em (MARINHO, 2017) é proposta uma metodologia para detecção de falhas de desaceleração em um motor de combustão interna. O autor utiliza os conceitos de

transformada *Wavelet* contínua e entropia da informação, fazendo uma análise tempo-frequência do sinal de giro do motor para extração de características. Contudo, os métodos mencionados apresentam algumas limitações, as quais este trabalho pretende contornar. A abordagem de (ZHANG; LI, 2016) se mostra eficaz para detectar 5 tipos de falhas de sensor, porém requer uma decomposição *wavelet* em 8 escalas, além de utilizar 32 neurônios na camada escondida da rede neural. De forma semelhante, o algoritmo de (ZABIHI-HESARI et al., 2019), apesar de possibilitar a determinação do local de ocorrência das falhas, também se mostra complexo em termos de requisitos de processamento computacional e arquitetura da rede neural, utilizando duas camadas escondidas.

Devido ao número limitado de pesquisas sobre o assunto, este trabalho almeja contribuir com o acervo existente até o momento. Sendo assim, propõe-se uma adaptação da abordagem sugerida por (MARINHO, 2017), visando aperfeiçoar o método de processamento de sinais de giro coletados de um motor de combustão interna, utilizando um banco de dados maior e propondo uma análise de entropia diferente da aplicada em (MARINHO, 2017), além da utilização de uma Rede *Adaline* para classificar as amostras. As amostras de sinal de giro coletadas no motor são padronizadas, calcula-se a transformada *Wavelet* contínua e, finalmente, a entropia do sinal transformado. As entropias do pacote *Wavelet* abordadas (*Shannon* e *Log Energy*) são usadas como entradas da *Adaline*, juntamente com o valor máximo do sinal de giro e, então, a detecção da presença, ou não, de falha nos sinais é feita de maneira simples e objetiva, utilizando os 2 atributos mencionados, possibilitando, eventualmente, a implementação do algoritmo em unidades de controle eletrônico (ECUs, do inglês *Electronic Control Unit*).

1.1 Objetivos

O objetivo geral deste trabalho é detectar anomalias de dirigibilidade relacionadas à desaceleração, utilizando somente uma escala de decomposição *wavelet* e uma Rede *Adaline*.

A partir disso, os objetivos específicos são os que seguem:

- Selecionar, separar e padronizar os sinais de giro coletados;
- Tratar os dados e realizar uma análise tempo-frequência utilizando transformada *Wavelet*;
- Empregar decomposição *wavelet* com o cálculo de entropia das transformadas;
- Implementar uma rede neural artificial capaz de detectar as falhas desejadas nos sinais estudados através de variações abruptas e da amplitude dos mesmos;

- Avaliar os requisitos computacionais exigidos para o método, a fim de verificar a possibilidade de implementá-lo em ECUs.

2 Revisão Bibliográfica

Neste capítulo são apresentados os conceitos envolvidos com as falhas de dirigibilidade automotiva estudada, além da relevância de um método objetivo para detecção das mesmas. Ainda, definições e conceitos matemáticos e computacionais são apresentados visando possibilitar um entendimento do trabalho, bem como da abordagem adotada.

2.1 Descrição do Sistema

A dirigibilidade em veículos com motores de combustão interna (MCI) está relacionada diretamente aos fenômenos que ocorrem durante o processo de combustão, como a queima e a injeção de combustível, abertura de válvula de aspiração do motor, entre outros. O controle e monitoramento de variáveis como a velocidade de rotação do motor são executados por uma unidade de controle eletrônico, que possui capacidade de processar sinais obtidos pelas medições dessas variáveis, além de algoritmos complexos, a fim de garantir que sejam realizadas todas as tarefas de funcionamento e segurança necessárias a um bom desempenho do motor de combustão, bem como as solicitações do usuário (MARINHO, 2017).

A investigação da ocorrência de vários tipos de falhas em controle de motores de combustão e dirigibilidade veicular é associada, de forma significativa, à melhora do desempenho do veículo, ao aumento da eficiência do consumo de combustível, à redução das emissões veiculares e à melhora do padrão de segurança. Uma vez identificadas as falhas ou oscilações, estas devem ser devidamente tratadas por meio de ajustes realizados nos sistemas de parametrização e softwares das centrais eletrônicas de controle presentes nos veículos, processo este também conhecido no ambiente de engenharia automobilística como calibração (SCHOEGGL; RAMSCHAK, 2000).

Quando o usuário aciona um pedal de aceleração, a ECU processa o deslocamento do pedal e envia um sinal ao atuador do motor a combustão. Este atuador, geralmente uma válvula de admissão de combustível, permite que seja fornecido mais combustível ao motor, que pode fornecer mais torque ao eixo e mais força às rodas do veículo. Ao liberar o pedal de aceleração, a quantidade de combustível fornecida ao motor é reduzida, diminuindo a força que o motor fornece ao eixo das rodas, que podem provocar oscilações na velocidade de rotação do motor e, conseqüentemente, falhas de dirigibilidade.

A ocorrência desse tipo de oscilação se dá devido a uma queima irregular do combustível, injeção inadequada do mesmo ou, ainda, por uma abertura desproporcional da válvula de aspiração de ar (PULKRABEK, 2004). As oscilações podem ser identificadas

na velocidade de rotação do motor, que é monitorada por sensores de relutância que medem a velocidade de rotação do eixo do motor. Com a detecção das oscilações, um processo de calibração pode ser realizado.

2.2 Ferramentas Matemáticas e Computacionais

Nesta seção serão descritas de forma sucinta, as ferramentas matemáticas utilizadas para o desenvolvimento do trabalho.

2.2.1 Análises Tempo-Frequência

Como descrito por (WEI et al., 2010), análise de sinais é um estudo abrangente principalmente no que se refere ao transporte de informações. Um sinal pode transportar quantidades enormes de dados em que a informação relevante é muitas vezes mais difícil de ser encontrada. Assim é necessário um processamento dos dados através de representações, decompondo o sinal principal em formas de onda ou elementos complementares.

Engenheiros ou especialistas em análise de sinais possuem a sua disposição uma significativa quantidade de ferramentas para tal. Uma das ferramentas provavelmente mais conhecida e citada é a análise de Fourier, que divide um sinal em senoides constituintes de diferentes frequências. Em outras palavras, a análise de Fourier traz uma abordagem matemática para representar um sinal do domínio do tempo no domínio da frequência (LATHI, 2006).

Assim, o processamento do sinal de velocidade aqui estudado pode ser feito por diferentes técnicas, como a transformada de Fourier de curta duração (STFT, do inglês *Short Time Fourier Transform*, a distribuição de *Wigner-Ville* (WVD) ou a transformada *Wavelet* (ZHANG; LI, 2016), (MARINHO, 2017), (XIANG; HU, 2012), (RALSTON et al., 2007). Como o conceito da transformada de Fourier é algo amplamente difundido e utilizado, são apresentadas a seguir a distribuição de *Wigner-Ville* e a transformada *Wavelet*.

2.2.2 Distribuição de Wigner-Ville

Como descrito por (RALSTON et al., 2007), matematicamente, a WVD de um sinal $x(t)$ é a transformada de Fourier da função de autocorrelação tempo-dependente do sinal em relação à variável de atraso τ :

$$W(t, \omega) = -\frac{1}{2\pi} \int x(t + \tau/2)x^*(t - \tau/2)e^{-j\tau\omega} d\tau \quad (2.1)$$

onde

$$R(\tau) = x(t + \tau/2)x^*(t - \tau/2) \quad (2.2)$$

é a função de autocorrelação tempo-dependente do sinal e x^* é o conjugado complexo do sinal. Em termos de algoritmos, isso significa que para cada amostra temporal de $x(t)$, $R(\tau)$ é calculado através do produto de valores anteriores e futuros deste sinal. Aplica-se então a transformada de Fourier ao resultado para produzir a WVD.

2.2.3 Definições Gerais da Transformada Wavelet

O pré-processamento dos dados utilizados neste trabalho é feito a partir da aplicação do conceito de transformada *Wavelet* contínua (CWT - *Continuous Wavelet Transform*) utilizando a *wavelet* tipo Morlet. A *Wavelet* Morlet é apresentada em (MERRY; STEINBUCH, 2005) como uma onda plana modulada por uma função Gaussiana, expressa por

$$\psi(t) = \pi^{-\frac{1}{4}} [e^{i\beta t} - e^{-\frac{\beta^2}{2}}] e^{-\frac{t^2}{2}}. \quad (2.3)$$

na qual β , geralmente, assume valor igual a 5. Sarkar et al. (SARKAR; DAS; PURKAIT, 2013) descreve que o emprego da *Wavelet* Morlet apresenta uma melhor performance se comparadas a outras famílias *Wavelet*, sob a ótica de resolução e detecção de falhas em transitórios. A Fig. 1 apresenta um exemplo de uma *Wavelet* Morlet.

Com isso, a CWT de um sinal $x(t)$ é definida como:

$$CWT(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \psi_{a,b} dt \quad (2.4)$$

na qual, neste trabalho, ψ é a *wavelet* Morlet apresentada em 2.3 e os termos a e b são, respectivamente, os parâmetros de escala e de deslocamento.

Dessa forma, dentre as abordagens apresentadas, Xiang (XIANG; HU, 2012) aponta que a STFT possui uma limitação entre as resoluções de tempo e de frequência, isto é, para obter informações precisas sobre frequência, informações de tempo são perdidas.

Além disso, Xiang (XIANG; HU, 2012) destaca que a WVD possui uma desvantagem conhecida como interferência de termo cruzado. Termos cruzados são elementos que aparecem na representação WVD entre autotermos, que correspondem a componentes de sinal fisicamente existentes. Esses termos cruzados indicam falsamente a existência de componentes de sinal entre os autotermos (RALSTON et al., 2007).

Por fim, a transformada *Wavelet* se mostra vantajosa para análises tempo-frequência, possibilitando uma detecção de variações abruptas nos sinais (ZHANG; LI, 2016). Existem diferentes tipos de famílias *wavelets* e, dentre elas, as mais amplamente utilizadas são: *Morlet*, *Haar*, *Daubechies*, *Coiflets* e *Symlets*. A escolha de uma *Wavelet* é realizada pelas características do sinal e natureza da aplicação.




Figura 1 – Modelo de Wavelet Morlet.

2.2.4 Análise de Entropia dos Sinais

A decomposição *wavelet* baseada em entropia, apresentada por *Coifman* e *Wickerhauser* (COIFMAN; WICKERHAUSER, 1992), é usada para calcular as entropias de *Shannon* e *Log Energy*, ambas disponíveis no pacote *Wavelet* do *software* MATLAB.

Conceitualmente, a entropia está relacionada a quanta informação é transportada por um sinal. Em outras palavras, a entropia permite analisar quanta aleatoriedade existe no sinal (AYDIN; SARAOĞLU; KARA, 2009). A entropia de *Shannon* provém da Teoria da Informação, sendo entendida como uma medida do grau de incerteza do sistema e é definida por

$$E_{ShanEn} = -\sum_i s_i^2 \log(s_i^2) \quad (2.5)$$

e a entropia *Log Energy* é dada por

$$E_{LogEn} = \sum_i \log(s_i^2), \quad (2.6)$$

sendo s_i os coeficientes de um sinal s em uma base ortonormal (MATHWORKS, 2005).

2.2.5 Redes Neurais Artificiais e *Adaline*

A extração de características descrita possibilita o uso de vetores característicos como entradas de uma rede neural. Uma rede neural artificial é um modelo computacional inspirado no sistema nervoso de seres vivos e, assim, possuem a capacidade de aquisição e manutenção do conhecimento (baseado em informações). Os neurônios artificiais são modelos bem simplificados dos neurônios biológicos (SILVA; SPATTI; FLAUZINO, 2010).

O modelo de neurônio mais simples (*perceptron*) engloba as principais características de uma rede neural biológica, ou seja, paralelismo e alta conectividade. Assim, a saída é determinada pela soma ponderada de cada uma das entradas do neurônio. Portanto, as redes neurais podem ser definidas como um conjunto de unidades de processamento, caracterizadas por neurônios artificiais, que são interligados por um grande número de interconexões (sinapses artificiais), representadas por vetores ou matrizes de pesos sinápticos (SILVA; SPATTI; FLAUZINO, 2010).

Nesse contexto, existem os seguintes paradigmas de aprendizado: supervisionado, no qual há uma rotulação dos dados de entrada, indicando à rede qual deve ser a saída para aquele caso; não supervisionado, no qual não há indicação da resposta desejada para os padrões de entrada; e reforço, quando um sistema de recompensa é aplicado à rede. Neste trabalho, o tipo de aprendizado adotado é o aprendizado supervisionado, resultante do modelo de rede neural escolhido.

Similarmente à configuração estrutural do *perceptron*, a *Adaline* é também constituída de apenas uma camada neural, sendo composta ainda por somente um único neurônio artificial. Uma das propriedades mais importantes de uma *Adaline* é a capacidade de aprender por intermédio de exemplos e fazer inferências sobre o que aprendeu, melhorando gradativamente o seu desempenho. A *Adaline* utiliza um algoritmo de aprendizagem cuja tarefa é ajustar os pesos de suas conexões (FERNEDA, 2006). O aprendizado ocorre quando a rede atinge uma solução generalizada para uma classe de problemas.

3 Materiais e Métodos

Este trabalho utiliza um conjunto de dados semelhante ao obtido em (MARINHO, 2017), cujos pontos principais serão destacados para melhor entendimento. O número de sinais aqui analisados é maior, contando, também, com amostras de menor tamanho.

3.1 Conjunto de Dados

Para a obtenção dos dados, realizada por (MARINHO, 2017), um veículo Fiat Toro 2.4 Flex foi disponibilizado pela empresa *Stellantis* e foram realizados testes de desaceleração em suas instalações, localizadas no Centro Técnico de Engenharia em Betim, Minas Gerais. O veículo foi abastecido com Gasolina Padrão Nacional (E27%) e os testes foram feitos como descrito a seguir.

Com o veículo em movimento, em segunda marcha e com baixa aceleração (aproximadamente 1500 RPM), iniciou-se uma rampa de aceleração entre 2500 e 3000 RPM e retirou-se a ação de aceleração. Neste momento, ocorre a manobra de desaceleração desejável, em uma condição comum de tráfego urbano. Após o giro do motor retornar a aproximadamente 1500 RPM reinicia-se um novo ciclo.

O procedimento descrito foi repetido até que fosse possível (limite de distância da pista de provas) e os ciclos de aquisições foram armazenados. A Fig. 2 apresenta uma rodada de medição da velocidade do motor para uma das voltas na pista de provas.

3.2 Processamento dos Dados

O ciclo de aquisição da velocidade exemplificado na Fig. 2 foi realizado em duas etapas: com e sem degradação do sistema de controle provocada via *software*, para a análise comparativa da classificação das manobras com e sem falha. Os dados foram separados em 250 amostras de 301 pontos cada, com o intuito de analisar somente a região onde a falha pode estar presente, sendo 125 amostras contendo falha e 125 sem falhas. Além disso, foi feita uma padronização dessas amostras, de forma que todas tenham início no valor zero de amplitude, como ilustrado na Fig. 3.

Posteriormente, calcula-se a Transformada *Wavelet* de Morlet das amostras e, então, a entropia dos sinais obtidos, de modo a se obter um indicador objetivo da presença ou não de falhas nos sinais analisados.




Figura 2 – Sequência de manobras de aceleração e posterior desaceleração.




Figura 3 – Exemplo de amostra antes e após padronização.

3.3 Construção e validação do modelo

A seguir, utilizando a função *patternnet* disponível no *Deep Learning Toolbox* do MATLAB, uma *Adaline* para reconhecimento de padrões é implementada. Os dois atributos utilizados como variáveis de entrada da *Adaline* são, portanto, os valores de entropia obtidos através da decomposição *wavelet* e os valores máximos dos sinais de giro padronizados. O processo completo é ilustrado na Fig. 4.

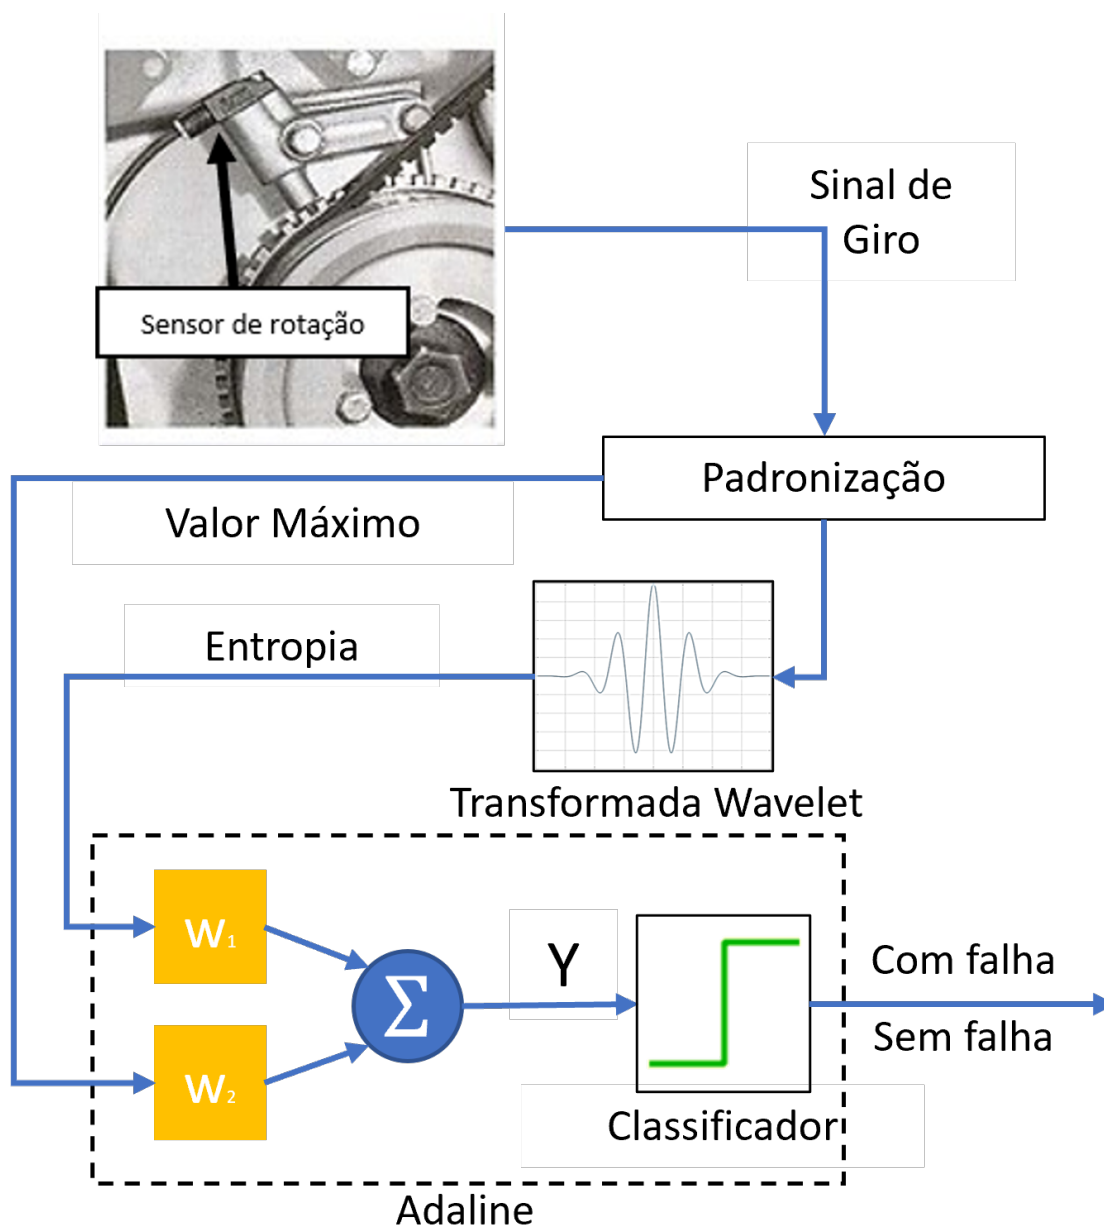


Figura 4 – Representação do processo realizado para a técnica desenvolvida

O treinamento da *Adaline* é feito com 80% dos dados, com amostras escolhidas balanceada, isto é, a quantidade de amostras com falha é igual à de amostras sem falha. Ademais, os parâmetros de treinamento são indicados na Tabela 1.

Tabela 1 – Arquitetura e Parâmetros da *Adaline*

Parâmetro	Descrição
Tipo da RNA	Adaline
Número de Camadas	1
Número de Neurônios	1
Funções de ativação	<i>Tan-Sigmoid</i> e <i>Log-Sigmoid</i>
Método de aprendizagem	Gradiente descendente e taxa de aprendizado variável
Taxa de adaptação	Inicial: 0,01; Incremento: 1,05; Decremento: 0,7
Método de validação	<i>Cross Entropy</i>

Finalmente, os dados de teste são usados e, a partir dos resultados, utilizou-se de gráficos de dispersão, matrizes de confusão e erros amostrais para avaliar o desempenho do método.

4 Resultados e Discussão

Os resultados deste trabalho foram divididos em duas partes. Inicialmente foi realizada uma comparação da performance da rede *Adaline* quanto à utilização das entropias pelos métodos de *Shannon* e *Log Energy*. Na observação dos resultados obtidos com os dados selecionados para treino, determinou-se o melhor método de entropia, com relação à acurácia da rede. Já na segunda parte, utilizando a abordagem escolhida, analisam-se os resultados obtidos com os dados de teste e, por fim, discute-se a validação do método.

As Transformadas *Wavelet* foram calculadas com uma escala de decomposição, sendo suficiente para a extração da característica desejada, de acordo com (MARINHO, 2017). A Fig. 5 apresenta uma comparação das transformadas para um sinal com falha e um sinal sem falha, respectivamente.


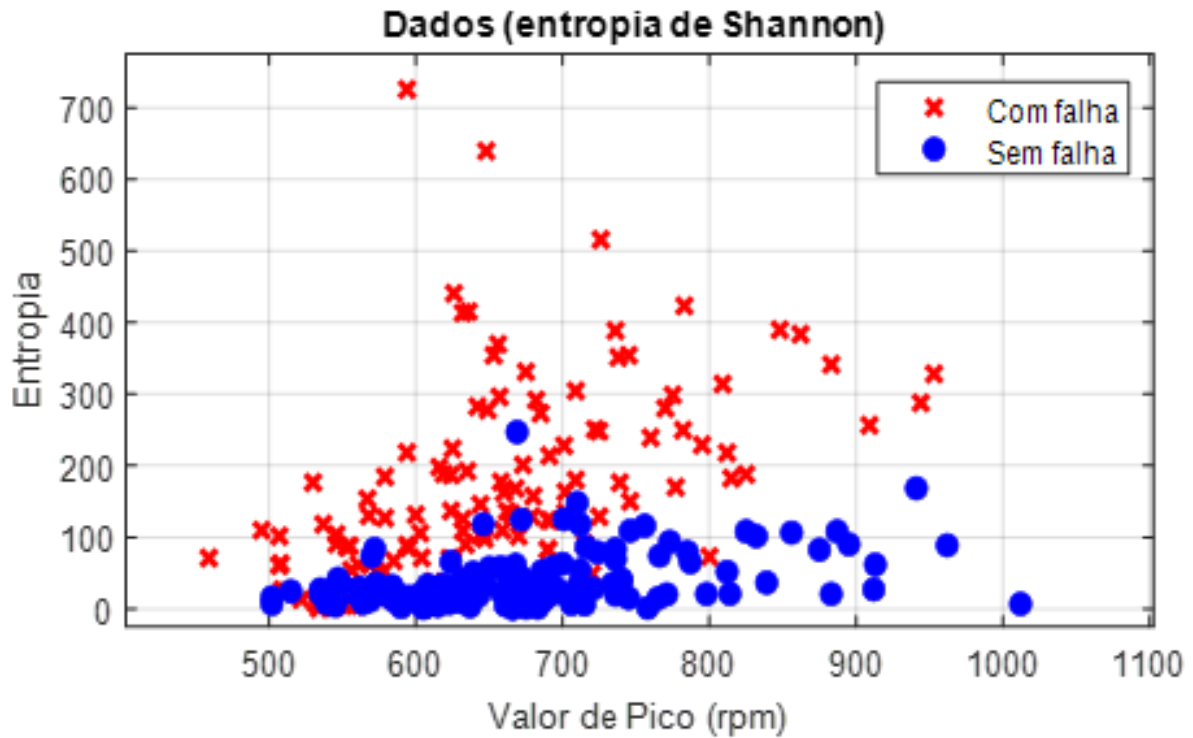
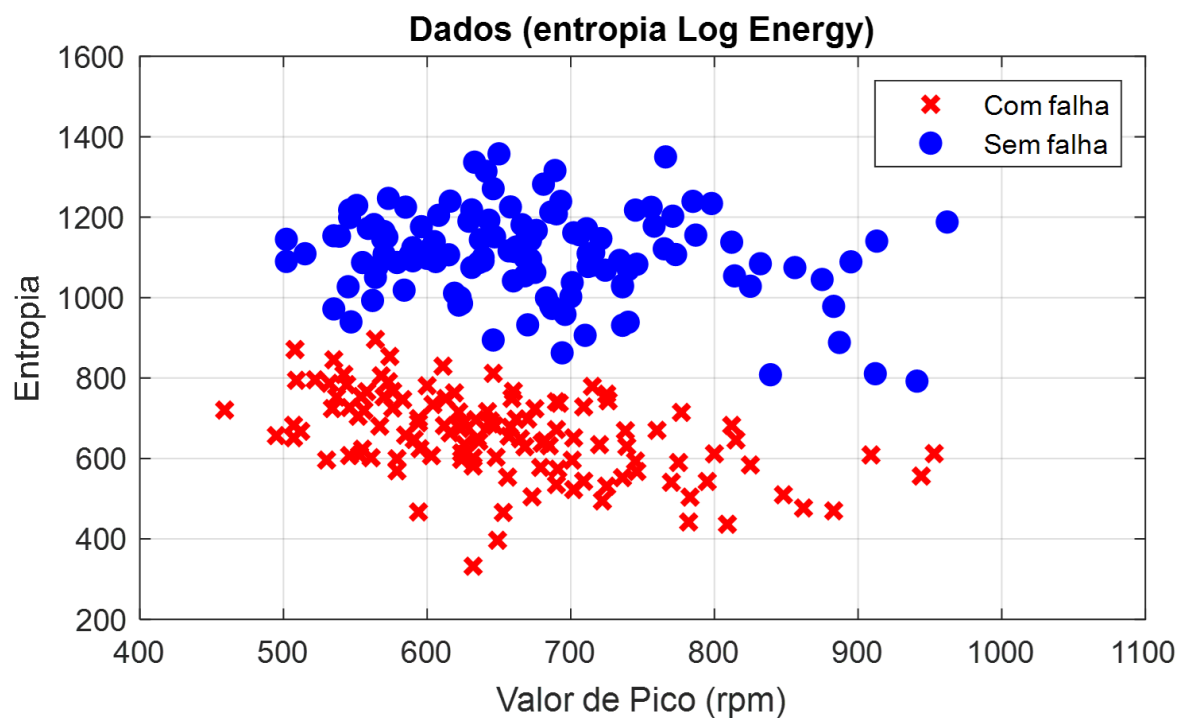


Figura 5 – Transformadas Wavelet de sinais com e sem falha.

Após a determinação das transformadas, foram calculadas as entropias das amostras e, juntamente com os valores máximos de cada amostra, utilizou-se gráficos de dispersão para uma observação analítica dos dados.

Como é possível verificar na Fig. 6, com a entropia de *Shannon* não há uma separação clara entre as amostras com e sem falha, representadas em vermelho e azul, respectivamente. Já na Fig. 7, é visível que existe uma divisão entre as amostras das duas classes.

Com isso, pode-se perceber que a utilização da entropia *Log Energy* se mostra mais vantajosa em comparação com a entropia de *Shannon*, para este banco de dados. Ainda, é possível notar que as classes de amostras na Fig. 7 são linearmente separáveis. Esse fato

Figura 6 – Distribuição dos dados com entropia de *Shannon*.Figura 7 – Distribuição dos dados com entropia *Log Energy*.

permite a implementação de uma *Adaline* contendo somente um neurônio, o que simplifica o processamento computacional pela ECU.

Dessa forma, optando pelo uso da entropia *Log Energy*, a *Adaline* é implementada

usando o valor máximo do sinal de giro e o valor de entropia como entradas.

Durante a fase de treinamento, 200 das 250 amostras foram utilizadas para treinar a *Adaline*, sendo 100 de cada classe, com falha e sem falha. Entre as 200 amostras, fez-se uma divisão aleatória dos dados em 140 amostras para treino e 60 para validação. Vale ressaltar que 30 das 60 amostras de validação foram usadas como critério de parada do treinamento, ou seja, o desempenho do algoritmo é verificado durante o treinamento utilizando 30 amostras.

As amostras de validação são usadas no algoritmo de validação cruzada, que consiste em uma técnica para avaliar a capacidade de generalização do modelo, buscando estimar a precisão do mesmo em um novo conjunto de dados. Assim, a validação cruzada tem o intuito de ajustar o desempenho do algoritmo, possibilitando a comparação objetiva de diferentes métodos em termos de suas respectivas classificações.

A precisão do treinamento pode ser verificada na Fig. 8, sendo possível perceber que a classificação ocorreu de forma correta.

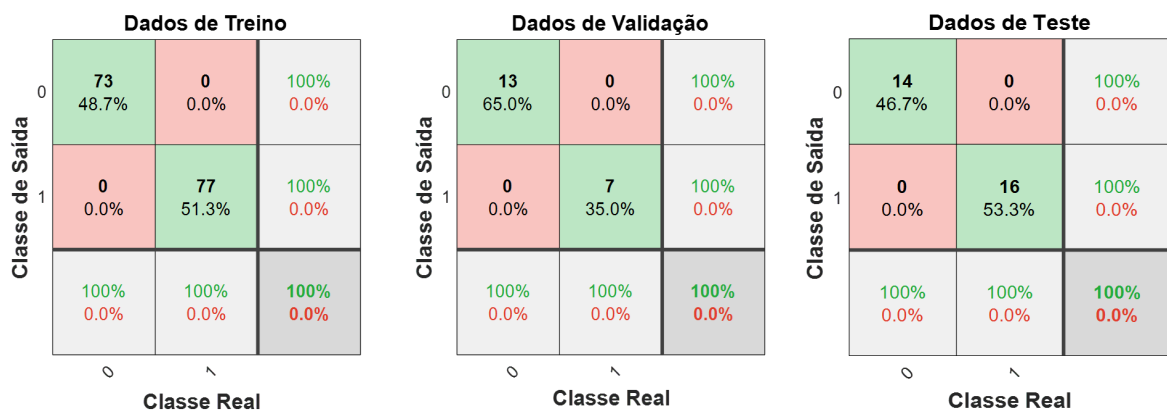


Figura 8 – Matrizes de confusão do treinamento da *Adaline*.

Em seguida, foram utilizadas as 50 amostras restantes para testar o desempenho do modelo. A Fig. 9 mostra a distribuição dos dados de treinamento e de teste. A fim de facilitar o entendimento das classificações realizadas, foi aproximada uma reta, simbolizando o limite de decisão da *Adaline*, plotada juntamente aos dados de treino.

Apresentando os dados de teste ao modelo, todas as amostras foram classificadas corretamente, alcançando 100% de acurácia para este banco de dados, como é possível verificar na Fig. 10. Ainda, por meio do histograma apresentado na Fig. 11, pode-se perceber que os erros residuais, isto é, diferenças entre a saída Y da rede e a classificação final, estão na ordem de 10^{-6} e, portanto, o resultado obtido é próximo e fiel ao esperado.

Dessa forma, como o modelo atingiu 100% de acurácia ao classificar os dados de teste com um erro de ordem 10^{-6} , o algoritmo mostra-se capaz de classificar as amostras de maneira correta. Além disso, esse resultado indica que a *Adaline* não sofreu com *overfitting*,

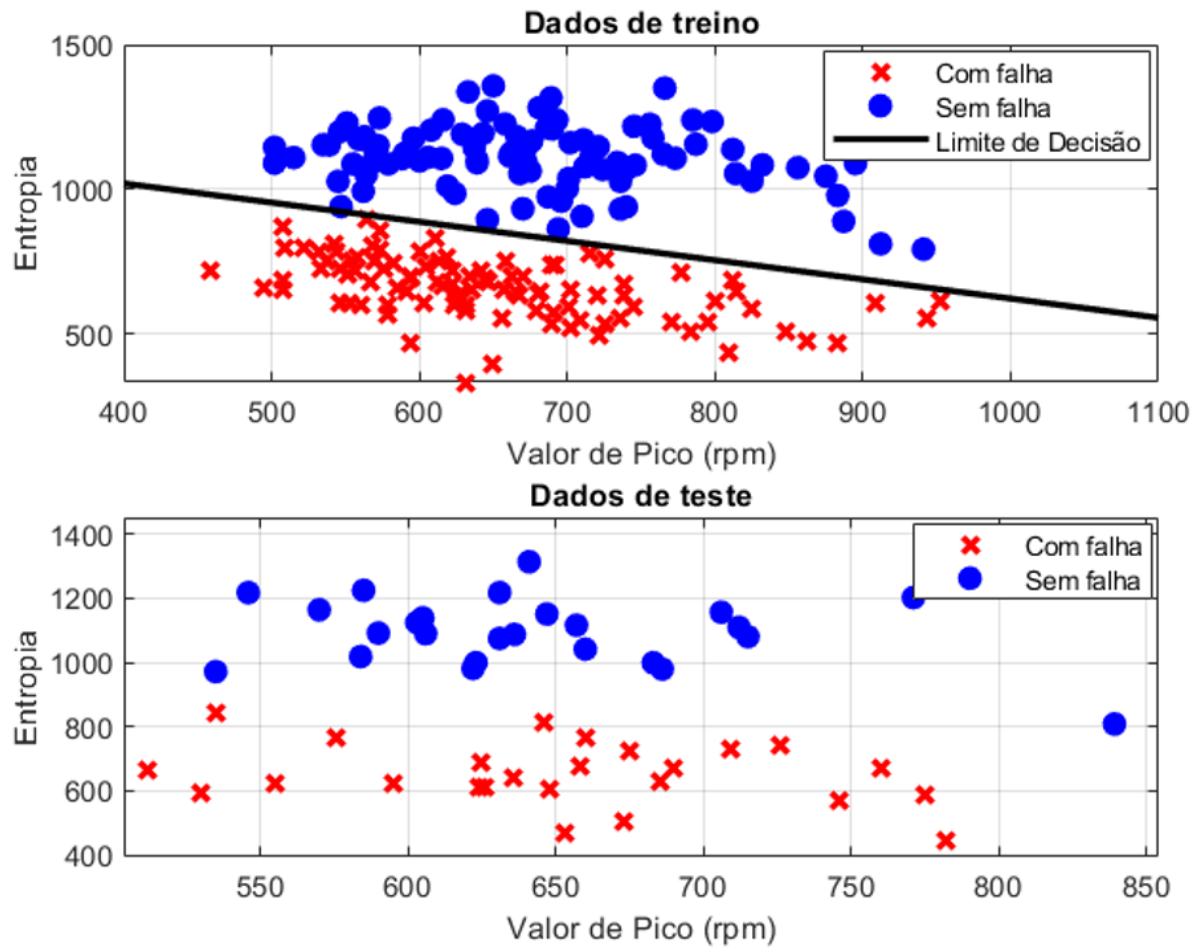


Figura 9 – Gráficos de dispersão dos dados de treino e de teste.

ou seja, o aprendizado ocorreu sem que houvesse “memorização” dos dados de treino, mas sim uma generalização da situação apresentada.

Para a aplicação da técnica em modelos de veículos diferentes do utilizado neste trabalho é necessário, entretanto, que seja feito um novo treinamento da rede para melhor ajuste dos parâmetros e pesos, devido a possíveis diferenças no modelo e nas condições de operação dos motores à combustão.




Figura 10 – Matriz de Confusão para os dados de teste.




Figura 11 – Histograma de erro - classificação das amostras de teste.

5 Considerações Finais

Este trabalho propôs um método de avaliação do sinal de velocidade do eixo de um motor a combustão em condição de desaceleração utilizando uma rede *Adaline* para detecção de falhas de dirigibilidade.

Após a seleção e tratamento dos dados utilizando transformada *Wavelet* e o cálculo de entropia das transformadas, o método desenvolvido pode ser usado como um classificador elementar capaz de identificar a presença ou ausência de falha de dirigibilidade durante a desaceleração do veículo, pois se mostrou eficaz na análise da manobra relacionada à velocidade de rotação do eixo do motor.

Ainda, devido à simplicidade do modelo implementado, verifica-se que não são necessários grandes esforços computacionais para realizar o processamento proposto. Assim, possibilita-se uma eventual implementação do algoritmo em ECUs de modo a ser utilizado de forma embarcada, eliminando, eventualmente, a necessidade de uma análise humana subjetiva e esforços adicionais de calibração nos testes relacionados.

Referências

- AYDIN, S.; SARAOĞLU, H. M.; KARA, S. Log energy entropy-based eeg classification with multilayer neural networks in seizure. *Annals of biomedical engineering*, Springer, v. 37, n. 12, p. 2626, 2009. Citado na página 20.
- CACCIATORI, E. Evaluating the impact of driveability requirements on the performance of an energy management control architecture for a hybrid electric vehicle. IET, 2006. Citado na página 14.
- COIFMAN, R. R.; WICKERHAUSER, M. V. Entropy-based algorithms for best basis selection. *IEEE Transactions on information theory*, IEEE, v. 38, n. 2, p. 713–718, 1992. Citado na página 20.
- DOREY, R.; HOLMES, C. *Vehicle driveability-its characterisation and measurement*. [S.l.], 1999. Citado na página 14.
- FERNEDA, E. Redes neurais e sua aplicação em sistemas de recuperação de informação. *Ciência da Informação*, SciELO Brasil, v. 35, p. 25–30, 2006. Citado na página 21.
- JAUCH, C. et al. Modeling of the osu ecocar 2 vehicle for drivability analysis. *IFAC-PapersOnLine*, Elsevier, v. 48, n. 15, p. 300–305, 2015. Citado na página 14.
- LATHI, B. P. *Sinais e Sistemas Lineares*. [S.l.]: Bookman, 2006. Citado na página 18.
- MARINHO, R. Q. *Detecção de Falhas de Dirigibilidade Veicular Através da Análise de Tempo-Frequência de Oscilações do Sinal de Giro de um Motor a Combustão Interna*. Dissertação (Mestrado) — Universidade Federal de Sao Joao del-Rei, 2017. Citado 6 vezes nas páginas 14, 15, 17, 18, 22 e 26.
- MATHWORKS. *Wentropy, Entropy (wavelet packet)*. 2005. Disponível em: <<https://www.mathworks.com/help/wavelet/ref/wentropy.html>>. Citado na página 20.
- MERRY, R.; STEINBUCH, M. Wavelet theory and applications. *literature study, Eindhoven university of technology, Department of mechanical engineering, Control systems technology group*, 2005. Citado na página 19.
- PULKRABEK, W. W. *Engineering fundamentals of the internal combustion engine*. 2004. Citado 2 vezes nas páginas 14 e 17.
- RALSTON, M. et al. General method to reduce cross-term interference in the wigner-ville decomposition. In: ONEPETRO. *2007 SEG Annual Meeting*. [S.l.], 2007. Citado 2 vezes nas páginas 18 e 19.
- SANTIAGO, D. F. de A.; PEDERIVA, R. Influência da resolução tempo-frequência da wavelet de morlet no diagnóstico de falhas de máquinas rotativas. *Mecânica Computacional*, p. 2538–2550, 2003. Citado na página 14.
- SARKAR, S.; DAS, S.; PURKAIT, P. Wavelet and sfam based classification of induction motor stator winding short circuit faults and incipient insulation failures. In: IEEE. *2013 IEEE 1st International Conference on Condition Assessment Techniques in Electrical Systems (CATCON)*. [S.l.], 2013. p. 237–242. Citado na página 19.

SCHOEGGL, P.; RAMSCHAK, E. *Vehicle driveability assessment using neural networks for development, calibration and quality tests*. [S.l.], 2000. Citado na página 17.

SILVA, I. N. D.; SPATTI, D. H.; FLAUZINO, R. A. *Redes neurais artificiais para engenharia e ciências aplicadas-curso prático*. São Paulo: Artliber, 2010. Citado na página 21.

WEI, J.-j. et al. Experimental comparison research on active vibration control for flexible piezoelectric manipulator using fuzzy controller. *Journal of Intelligent and Robotic Systems*, Springer, v. 59, n. 1, p. 31–56, 2010. Citado na página 18.

XIANG, L.; HU, A. Comparison of methods for different time-frequency analysis of vibration signal. *J. Softw.*, Citeseer, v. 7, n. 1, p. 68–74, 2012. Citado 2 vezes nas páginas 18 e 19.

ZABIHI-HESARI, A. et al. Fault detection and diagnosis of a 12-cylinder trainset diesel engine based on vibration signature analysis and neural network. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, SAGE Publications Sage UK: London, England, v. 233, n. 6, p. 1910–1923, 2019. Citado 2 vezes nas páginas 14 e 15.

ZHANG, H.; LI, W. A new method of sensor fault diagnosis based on a wavelet packet neural network for hybrid electric vehicles. In: IEEE. *2016 9th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI)*. [S.l.], 2016. p. 1143–1147. Citado 4 vezes nas páginas 14, 15, 18 e 19.