


# Identification of Drivability Failures Using Adaline in an ECU

Gabriel P. Calais, Ronaldo Q. Marinho, Rodolpho V. A. Neves  and Heverton A. Pereira , *Member, IEEE*

**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 an extraction of characteristics 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 are standardized, the continuous wavelet transform is calculated and, finally, the entropy of the transformed signal is measured. Thus, the possibility of implementing an Adaline model capable of detecting the presence, or not, of abrupt changes in these signals is verified, and later, it can be embedded in an electronic control unit (ECU). The results show that the use of the Log Energy entropy as an input of the Adaline model is promising, granting 100% of accuracy on the dataset studied.

**Index Terms**—Adaline, entropy, multiresolution, transient analysis, wavelet transform.

## I. 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 [1]. 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 [2]. 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 [3]. 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 [4].

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 [5].

Em [6], 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 [7] 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 [8] 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 [6] 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 [7], 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 [8], 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 [8], além da utilização de um modelo Adaline para classificar

Gabriel P. Calais, Rodolpho V. A. Neves and Heverton A. Pereira are with the Department of Electrical Engineering, Federal University of Viçosa e-mail: {gabriel.calais, rodolpho.neves, heverton.pereira}@ufv.br.

Ronaldo Q. Marinho is with Stellanis S/A e-mail: ronaldoqm@gmail.com.

as amostras. O objetivo é, portanto, detectar anomalias de dirigibilidade relacionadas à desaceleração, utilizando somente uma escala de decomposição *wavelet* e um modelo Adaline. As amostras de sinal de giro coletadas no motor são padronizadas, calcula-se a transformada *wavelet* contínua e, finalmente, a entropia do sinal transformado. Faz-se uma comparação entre as entropias do pacote *wavelet* abordadas (*Shannon* e *Log Energy*) a fim de definir a mais adequada ao problema abordado. Assim, a entropia *Log Energy* é usada como entrada do modelo Adaline, juntamente com o valor máximo do sinal de giro e, então, é feita a detecção da presença, ou não, de falha nos sinais de maneira simples e objetiva, utilizando os 2 atributos mencionados, possibilitando, eventualmente, a implementação do algoritmo em unidades de controle eletrônico (ECUs).

## II. 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 (ECU, do inglês *Electronic Control Unit*), 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 [8].

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 [9].

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 [2]. 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. A Fig. 1 apresenta o processo de identificação de falhas abordado nesse trabalho.

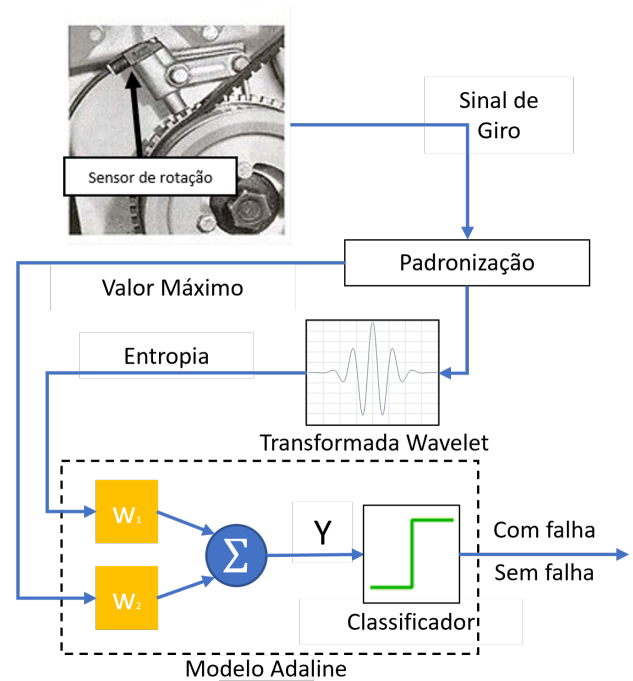


Fig. 1. Representação do processo realizado para a técnica desenvolvida

Para isso, o processamento da medição de velocidade pode ser feito por diferentes técnicas, como a transformada de Fourier de curta duração (STFT, ou *Short Time Fourier Transform*), a distribuição de *Wigner-Ville* (WVD) ou a transformada *wavelet* [6], [8], [10], [11]. Dentre estas abordagens, [10] 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, [10] 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 [11].

Por fim, a transformada *wavelet* se mostra vantajosa para análises tempo-frequência, possibilitando uma detecção de variações abruptas nos sinais [6]. 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. Assim, é importante entender as propriedades da análise e síntese *wavelet* [8], a fim de determinar a melhor estratégia de tratamento dos sinais estudados. Porém, não existe uma receita única para a escolha da *wavelet*. Para séries temporais com variações bruscas no sinal, a *wavelet* de Haar pode ser mais indicada. Já para análises de séries temporais com variações mais suaves as

*wavelet* de Morlet seriam mais indicadas [12]. Neste trabalho, o problema estudado se encaixa no segundo cenário, logo, a *wavelet* Morlet foi escolhida.

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 [13] como uma onda plana modulada por uma função Gaussiana, expressa por

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

na qual  $\beta$ , geralmente, assume valor igual a 5. Em [14] é descrito 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. 2 apresenta um exemplo do módulo de uma *wavelet* Morlet.

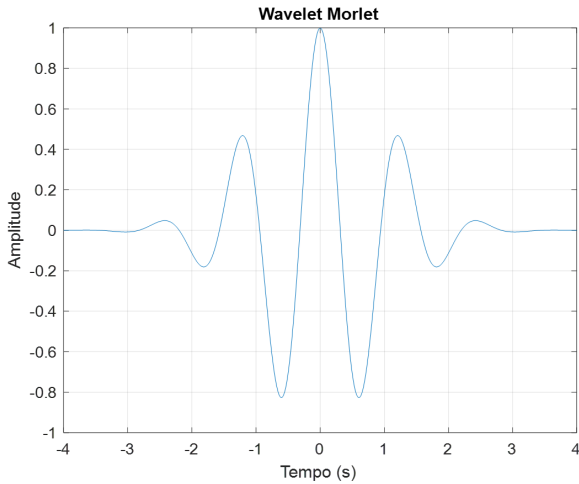


Fig. 2. Modelo de *wavelet* Morlet (módulo).

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

$$CWT(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \psi_{a,b} dt \quad (2)$$

na qual, neste trabalho,  $\psi$  é a *wavelet* Morlet apresentada em (1) e os termos  $a$  e  $b$  são, respectivamente, os parâmetros de escala e de deslocamento.

A seguir, em função da necessidade de obter um parâmetro objetivo para a classificação das falhas após a decomposição do sinal via transformada *wavelet* de Morlet, é feita a análise da entropia deste sinal. A decomposição *wavelet* baseada em entropia, apresentada em [15], é usada para calcular as entropias de *Shannon* e *Log Energy*, ambas disponíveis no pacote *wavelet* do *software* MATLAB. A escolha das entropias se deu baseada em precedentes da literatura. A entropia de *Shannon* é usada em [8] para detecção de falhas semelhantes às estudadas neste trabalho, enquanto [16] utiliza da entropia *Log Energy* para classificar padrões em eletroencefalogramas.

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 [17]. A entropia de *Shannon* provém da Teoria da Informação,

sendo entendida como uma medida do grau de incerteza do sistema e é definida por

$$E_{ShanEn} = - \sum_i s_i^2 \log(s_i^2) \quad (3)$$

e a entropia *Log Energy* é dada por

$$E_{LogEn} = \sum_i \log(s_i^2), \quad (4)$$

sendo  $s_i$  os coeficientes de um sinal  $s$  em uma base ortonormal [18].

A extração de características descrita possibilita o uso de vetores característicos como entradas de um modelo Adaline. Similarmente à configuração estrutural do Perceptron, o modelo Adaline é também constituído de apenas uma camada escondida, sendo composto ainda por somente um único neurônio artificial. O modelo Adaline, devido ainda à sua simplicidade estrutural, tem sido mais utilizada em problemas de classificação de padrões envolvendo apenas duas classes distintas. Além disso, possui uma arquitetura *feedforward*, pois o fluxo de informações é realizado sempre adiante, isto é, partindo das entradas em direção à saída da rede [19].

A equação que define um modelo *Adaline* é dada como a seguir:

$$\hat{y} = b + \sum_i w_i x_i, \quad (5)$$

onde  $b$  representa a *bias*,  $w_i$  os pesos e  $x_i$  o valor de cada *input* do modelo.

### III. TREINAMENTO E AVALIAÇÃO DO MODELO

Este trabalho utiliza um banco de dados semelhante ao obtido em [8], cujos pontos principais serão destacados para melhor entendimento. Para a obtenção dos dados, realizada em [8], 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), inicia-se uma rampa de aceleração e, entre 2500 e 3000 RPM, retira-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. 3 apresenta uma rodada de medição da velocidade do motor para uma das voltas na pista de provas.

O ciclo de aquisição da velocidade exemplificado na Fig. 3 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. Para gerar ou simular a falha em estudo, foi realizado um procedimento de degradação do sistema de controle,




Fig. 3. Sequência de manobras de aceleração e posterior desaceleração.

retirando os filtros digitais do comando de fechamento da válvula de aspiração fazendo com que, durante o processo de desaceleração, esta válvula feche de forma mais rápida ou irregular, causando, assim, oscilações típicas nas manobras que geram desconforto ao usuário, caracterizadas como falhas na dirigibilidade [8].

Após a aquisição, 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. 4.

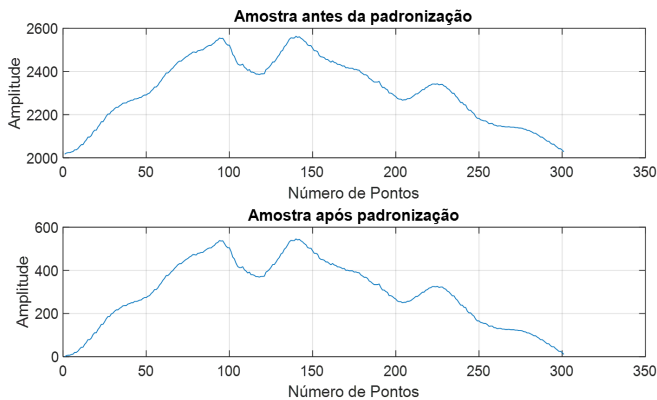


Fig. 4. Exemplo de amostra antes e após padronização.

Posteriormente, calcula-se a Transformada *wavelet* de Morlet das amostras e, então, a entropia dos sinais obtidos. Assim, utilizando a função *patternnet* disponível no *Deep Learning Toolbox* do MATLAB, um modelo Adaline para reconhecimento de padrões é implementada. Os dois atributos utilizados como variáveis de entrada do modelo 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. 1.

O treinamento do modelo Adaline é feito com 80% dos dados, com amostras escolhidas de maneira 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 I.

TABELA I  
ARQUITETURA E PARÂMETROS DO MODELO 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 aprendizagem 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, utiliza-se de gráficos de dispersão, matrizes de confusão e erros amostrais para avaliar o desempenho do método.

#### IV. RESULTADOS

Os resultados deste trabalho foram divididos em duas partes. Inicialmente foi realizada uma comparação da performance do modelo 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, analisa-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 [8]. A Fig. 5 apresenta uma comparação das transformadas para um sinal com falha e um sinal sem falha, respectivamente.




Fig. 5. Transformadas *wavelet* de sinais com e sem falha.

Calculando-se a raiz do valor quadrático médio (RMS, *root mean square*) das transformadas, verifica-se que as amostras com falha possuem, em média um valor RMS de 0,822, enquanto as amostras sem falha apresentam uma média de 0,601. Assim, pode-se concluir que as transformadas dos sinais com falha apresentam, em média, variações mais bruscas de amplitude se comparadas às de sinais 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.




Fig. 6. Distribuição dos dados com entropia de *Shannon*.

Já na Fig. 7, é possível notar que as duas classes são linearmente separáveis. Esse fato permite a implementação de um modelo Adaline, o que simplifica o processamento computacional pela ECU. 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.




Fig. 7. Distribuição dos dados com entropia *Log Energy*.

A diferença entre os resultados das duas entropias é estritamente matemática, já que o termo  $-s_i^2$  presente na entropia *Shannon* inverte e atenua a lógica do conceito da entropia na separação das classes, em comparação com a *Log Energy*. Dessa forma, optando pelo uso da entropia *Log Energy*, o modelo Adaline é implementado usando o valor máximo do sinal de giro e o valor de entropia como entradas (*inputs*).

Durante a fase de treinamento, 200 das 250 amostras foram utilizadas para treinar o modelo Adaline, sendo 100 de cada classe, com falha e sem falha. Entre as 200 amostras, fez-se uma divisão aleatória dos dados em 170 amostras para treino e 30 para validação, usadas como critério de parada do treinamento.

As amostras de validação são usadas no algoritmo de cross-validation (validação cruzada), que consiste em uma técnica para avaliar a capacidade de generalização do modelo, buscando estimar a acurácia 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 acurácia do treinamento pode ser verificada na Fig. 8, sendo possível perceber que o aprendizado ocorreu de forma correta.

Dados de Treino			Dados de Validação		
Classe Estimada	0	86 50.6%	0 0.0%	100% 0.0%	Classe Verdadeira
	1	0 0.0%	84 49.4%	100% 0.0%	
		100% 0.0%	100% 0.0%	100% 0.0%	

Dados de Treino			Dados de Validação		
Classe Estimada	0	14 46.7%	0 0.0%	100% 0.0%	Classe Verdadeira
	1	0 0.0%	16 53.3%	100% 0.0%	
		100% 0.0%	100% 0.0%	100% 0.0%	

(a) Amostras de treino

(b) Amostras de validação

Fig. 8. Matrizes de confusão de treinamento do modelo 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 do modelo Adaline, plotada juntamente aos dados de treino.




Fig. 9. Gráficos de dispersão dos dados de treino e de teste.

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  $10^{-4}$  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  $10^{-4}$ , o algoritmo conseguiu classificar as amostras de maneira correta. Além disso, esse resultado indica que o modelo Adaline não sofreu com *overfitting*, ou seja, o aprendizado ocorreu sem que houvesse “memorização” dos dados de treino, mas sim uma generalização da situação apresentada.

Dados de Treino		
Classe Estimada	Classe Verdadeira	
	0	1
0	25 50.0%	0 0.0%
1	0 0.0%	25 50.0%
	100% 0.0%	100% 0.0%

Fig. 10. Matriz de Confusão para os dados de teste.

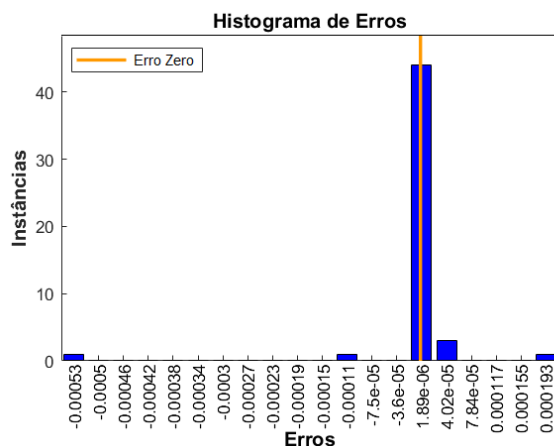


Fig. 11. Histograma de erro referente à saída  $Y$  do modelo Adaline.

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.

Com relação à implementação do método em ECUs, alguns pontos precisam ser levados em conta. O cálculo da transformada wavelet pode ser feito utilizando um processo de discretização análogo ao descrito em [20], realizando a decomposição em somente uma camada escondida, gerando, assim, um único valor escalar após o cálculo da entropia. Já o modelo Adaline pode ser implementado de acordo com a equação (5), tendo os seguintes parâmetros:  $b = -11, 17$ ;  $w_1 = 32, 995$ ;  $w_2 = 109, 0075$ .

## V. CONCLUSÕES

Este trabalho propôs um método de avaliação do sinal de velocidade do eixo de um motor a combustão em condição de

desaceleração utilizando um modelo 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. Entretanto, pode ser necessário realizar testes para a utilização deste método na detecção de outros tipos de falha.

Ainda, devido à simplicidade do modelo implementado, verifica-se que não são necessários grandes esforços computacionais para realizar o processamento proposto. Portanto, a detecção da presença, ou não, de falha nos sinais é feita de maneira simples e objetiva utilizando a entropia *Log Energy* e o valor de pico dos sinais como atributos de entrada para o modelo Adaline. 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.

## REFERENCES

- [1] C. Jauch, K. Bovee, S. Tamilarasan, L. Güvenc, and G. Rizzoni, “Modeling of the osu ecocar 2 vehicle for drivability analysis,” *IFAC-PapersOnLine*, vol. 48, no. 15, pp. 300–305, 2015.
- [2] W. W. Pulkrabek, “Engineering fundamentals of the internal combustion engine,” 2004.
- [3] R. Dorey and C. Holmes, “Vehicle driveability-its characterisation and measurement,” SAE Technical Paper, Tech. Rep., 1999.
- [4] E. Cacciatori, “Evaluating the impact of driveability requirements on the performance of an energy management control architecture for a hybrid electric vehicle,” 2006.
- [5] D. F. de Arruda Santiago and R. Pederiva, “Influência da resolução tempo-frequência da wavelet de morlet no diagnóstico de falhas de máquinas rotativas,” *Mecânica Computacional*, pp. 2538–2550, 2003.
- [6] H. Zhang and W. Li, “A new method of sensor fault diagnosis based on a wavelet packet neural network for hybrid electric vehicles,” in *2016 9th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI)*. IEEE, 2016, pp. 1143–1147.
- [7] A. Zabihi-Hesari, S. Ansari-Rad, F. A. Shirazi, and M. Ayati, “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*, vol. 233, no. 6, pp. 1910–1923, 2019.
- [8] R. Q. Marinho, H. A. Pereira, L. B. Felix, and G. A. Rodrigues, *Detecção de Falhas de Dirigibilidade Veicular Através da Análise de Tempo-Frequência de Oscilações do Sinal de Giro de um Motor a Combustão Interna*. XIII SBAI - Simpósio Brasileiro de Automação Inteligente, 2017.
- [9] P. Schoeegl and E. Ramschak, “Vehicle driveability assessment using neural networks for development, calibration and quality tests,” SAE Technical Paper, Tech. Rep., 2000.
- [10] L. Xiang and A. Hu, “Comparison of methods for different time-frequency analysis of vibration signal,” *J. Softw.*, vol. 7, no. 1, pp. 68–74, 2012.
- [11] M. Ralston, M. Rauch-Davies, K. Li-Chun, X. Hui-Ping, and Y. Di-Sheng, “General method to reduce cross-term interference in the wigner-ville decomposition,” in *2007 SEG Annual Meeting*. OnePetro, 2007.
- [12] J. E. Castilho, M. Domingues, O. Mendes, and A. Pagamisse, “Introdução ao mundo das wavelets,” *Sociedade Brasileira de matemática Aplicada e Computacional, Sao Carlos*, 2012.
- [13] R. Merry and M. Steinbuch, *Wavelet theory and applications: literature study*. Eindhoven University of Technology, 2005.

- [14] S. Sarkar, S. Das, and P. Purkait, "Wavelet and SFAM based classification of induction motor stator winding short circuit faults and incipient insulation failures," in *2013 IEEE 1st International Conference on Condition Assessment Techniques in Electrical Systems (CATCON)*. IEEE, 2013, pp. 237–242.
- [15] R. R. Coifman and M. V. Wickerhauser, "Entropy-based algorithms for best basis selection," *IEEE Transactions on information theory*, vol. 38, no. 2, pp. 713–718, 1992.
- [16] S. Raghu, N. Sriraam, and G. P. Kumar, "Effect of wavelet packet log energy entropy on electroencephalogram (eeg) signals," *International Journal of Biomedical and Clinical Engineering (IJBCE)*, vol. 4, no. 1, pp. 32–43, 2015.
- [17] S. Aydin, H. M. Saraoğlu, and S. Kara, "Log energy entropy-based eeg classification with multilayer neural networks in seizure," *Annals of biomedical engineering*, vol. 37, no. 12, p. 2626, 2009.
- [18] MathWorks. (2005) Wentropy, entropy (wavelet packet). [Online]. Available: <https://www.mathworks.com/help/wavelet/ref/wentropy.html>
- [19] I. N. Da Silva, D. H. Spatti, and R. A. Flauzino, "Redes neurais artificiais para engenharia e ciências aplicadas-curso prático," *São Paulo: Artliber*, 2010.
- [20] L. Arts, E. van den Broek *et al.*, "The fast continuous wavelet transformation (fcwt) for real-time, high-quality, noise-resistant time–frequency analysis," *Nature Computational Science*, vol. 2, no. 1, pp. 47–58, 2022.



**Gabriel Pereira de Calais** é estudante de Engenharia Elétrica na Universidade Federal de Viçosa (UFV), seus interesses de pesquisa são Modelagem de Sistemas Dinâmicos e Inteligência Artificial.



**Ronaldo Quintão Marinho** recebeu o título de mestre em engenharia pelo Centro Federal de Educação Tecnológica de Minas Gerais - CEFET MG, Especialista em sistemas Eletro-Eletrônicos pelo CEFET-MG e Engenheiro Eletricista pela PUC-MG. Atua como Engenheiro de Desenvolvimento de Produto na Indústria Automobilística desde 2006 (Grupo Stellantis S/A) com experiência em Proteção de Sistemas elétricos em indústrias em geral (GE).



**Rodolpho Vilela Alves Neves** recebeu o grau de Bacharel em Engenharia Elétrica pela Universidade Federal de Viçosa (UFV), Viçosa, Brasil, em 2011, e os graus M.Sc. e D.Sc. em Engenharia Elétrica pela Universidade de São Paulo (EESC/USP), São Carlos, Brasil, em 2013 e 2018, respectivamente. De 2015 a 2016, ele esteve como Pesquisador Visitante na Aalborg University, Dinamarca. Atualmente, é Professor Adjunto no Departamento de Engenharia Elétrica na UFV. Seus interesses de pesquisa incluem controle inteligente de sistemas dinâmicos

e gerenciamento de microrredes de energia.



**Heverton Augusto Pereira** possui graduação em Engenharia Elétrica (2007) pela Universidade Federal de Viçosa (UFV), mestrado em Engenharia Elétrica (2009) pela Universidade de Campinas (UNICAMP) e doutorado em Engenharia Elétrica (2015) pela Universidade Federal de Minas Gerais (UFMG). Realizou doutorado sanduíche (2014) na Aalborg University, Dinamarca. Desde 2009 é professor na Universidade Federal de Viçosa. Seus principais interesses de pesquisa incluem conversores conectados à rede para sistemas de

energia fotovoltaica e eólica e sistemas de transmissão de alta tensão baseados em MMC.