

Manutenção Preditiva Veicular: Aplicação de Técnicas de Aprendizado de Máquina para Análise Sonora de Falhas

Valéria Silva Santos¹ , Breno Santana Santos² , Marianne Silva¹ *

¹ Universidade Federal de Alagoas, Penedo, Brasil

Email: valeria.silva@arapiraca.ufal.br; marianne.silva@penedo.ufal.br

² Universidade Federal do Rio Grande do Norte, Natal, Brasil

Email: breno1005@hotmail.com

*corresponding author

RESEARCH ARTICLE

Annals of Data Analysis

<https://periodicos.ufpe.br/revistas/ADA/>

Submitted on: 12.12.2025.

Accepted on: 01.08.2026.

Published on: 01.08.2026.

Copyright © 2026 by author(s).

This work is licensed under the Creative

Commons Attribution International

License CC BY-NC-ND 4.0

<http://creativecommons.org/licenses/by-nc-nd/4.0/deed.en>




Resumo

A Indústria 4.0 tem proporcionado mudanças no setor automotivo, em especial na manutenção veicular, permitindo a transição de métodos reativos para a manutenção preditiva e personalizada. Deste modo, este trabalho investiga a aplicação da análise de áudio para o diagnóstico de anomalias em motores de combustão interna. A abordagem proposta utilizou um conjunto de dados de 537 áudios, dos quais foram extraídas características como Coeficientes Cepstrais na Frequência de Mel (MFCCs), Taxa de Cruzamento por Zero (ZCR) e Centróide Espectral, para classificar os sons de motores com o algoritmo Random Forest. O modelo demonstrou alta eficácia, alcançando uma acurácia de 99% ao diferenciar motores saudáveis de motores com falhas de ignição. Assim, conclui-se que a análise de áudio, combinada com o aprendizado de máquina, é uma estratégia promissora para o diagnóstico automotivo.

Palavras-chave

Manutenção preditiva veicular. Indústria 4.0, Aprendizado de Máquina, Análise sonora.



1 Introdução

A Indústria 4.0, ou Quarta Revolução Industrial, é um paradigma tecnológico que tem redefinido o cenário industrial, impulsionando a integração de sistemas ciberfísicos e a digitalização de processos produtivos Soori et al. (2024). Essa nova fase da manufatura é caracterizada pela convergência de tecnologias, como a Internet das Coisas (IoT), a inteligência artificial (IA) Kamalapuram and Choudhury (2024). Essas inovações visam aprimorar a eficiência, a flexibilidade e a personalização da produção, ao mesmo tempo que promovem a interconexão e a otimização de toda a cadeia de valor Soori et al. (2024); Hossain et al. (2024).


Deste modo, no universo da mobilidade e do transporte, essa transformação tecnológica tem um impacto direto na forma como a manutenção de veículos é realizada Mahale et al. (2025). Tradicionalmente baseada em cronogramas fixos e inspeções manuais, a manutenção automotiva agora pode evoluir para um modelo mais inteligente e preditivo, capaz de antecipar problemas e agir antes que eles causem danos maiores, alinhando-se com a visão de uma manutenção personalizada para cada ativo Nalla (2025).

Apesar da evolução tecnológica, a detecção de falhas mecânicas em estágios iniciais ainda é um desafio Hossain et al. (2024). A manutenção preventiva tradicional, muitas vezes, não é capaz de prever com precisão o momento em que um componente irá falhar, levando a quebras inesperadas, paradas não programadas e custos de reparo elevados Mahale et al. (2025). Nesse contexto, a análise de ruídos gerados por peças em movimento, como rolamentos e motores, é uma técnica para identificar anomalias Fenga and Biazzo (2025). No entanto, a inspeção auditiva humana é subjetiva e ineficiente em grande escala, tornando a identificação de defeitos um gargalo para a eficiência operacional Nagy and Lakatos (2025); Fenga and Biazzo (2025).

Com isso, o objetivo deste trabalho é explorar a aplicação da análise de áudios com inteligência artificial para a manutenção preditiva personalizada em veículos. Para isso, desenvolveu uma abordagem capaz de processar ruídos de componentes específicos e, por meio de modelos de aprendizado de máquina, identificar padrões que sinalizam o início de uma falha. Ao automatizar essa análise, busca-se não apenas aprimorar a precisão e a velocidade da detecção de defeitos, mas também permitir que as intervenções de manutenção sejam feitas no momento exato em que são necessárias.

Ao utilizar inteligência artificial, por meio do aprendizado de máquina para interpretar dados acústicos, é possível transformar ruídos em *insights*, na qual pode permitir uma transição da manutenção corretiva para uma abordagem proativa e personalizada Rashed et al. (2025). A implementação de uma abordagem como essa oferece benefícios, incluindo a redução de custos operacionais, o aumento da disponibilidade dos veículos e a melhora da segurança geral, ao prever falhas que poderiam comprometer a operação Fenga and Biazzo (2025); Mahale et al. (2025).

Por fim, o restante deste artigo encontra-se organizado da seguinte forma: a Seção 2 apresenta trabalhos relacionados; a Seção 3 detalha a abordagem proposta; a Seção 4 descreve o estudo de caso realizado para validar a metodologia; a Seção 5 discute os principais resultados obtidos; e, finalmente, a Seção 6 apresenta as considerações finais e sugere caminhos para trabalhos futuros.



2 Trabalhos Relacionados


A detecção de falhas em veículos utilizando a análise de áudio e aprendizado de máquina é uma área de pesquisa que tem se expandido rapidamente, especialmente com os avanços da Indústria 4.0 Akbalık et al. (2024); Shabbir et al. (2024). Enquanto a inspeção manual por mecânicos especialistas é uma abordagem tradicional e eficaz, ela é inerentemente custosa, demorada e propensa a erros humanos Nasim et al. (2024). A automação desse processo por meio de análise de dados se apresenta como uma alternativa para otimizar a manutenção veicular Fedorishin et al. (2022).

Assim, um dos principais desafios na área é a falta de generalização dos modelos, já que muitos estudos se baseiam em dados coletados em ambientes controlados e com um número limitado de modelos de veículos ou tipos de falhas. Para superar isso, o trabalho de Akbalık et al. (2024) propõem uma estrutura de diagnóstico de falhas que utiliza um conjunto de dados diversificado de veículos e condições do mundo real. Os autores empregam os Coeficientes de Frequência Mel Cepstral (MFCCs) e a Máquina de Aprendizagem Extrema (ELM) para classificação, alcançando alta precisão, recall e acurácia. O estudo também realiza uma análise de frequência detalhada para associar falhas específicas a faixas de frequência de áudio, como, por exemplo, problemas de motor e turbo a frequências entre 0.7 e 0.8 kHz.

Em uma abordagem diferente e com um foco na aplicação em larga escala, Fedorishin et al. (2022) introduziram a AMPNet, uma rede neural que funde dados de áudio, vibração (de um acelerômetro) e metadados tabulares do veículo para detectar falhas de motor de forma automatizada. Eles criaram um grande conjunto de dados multimodais com a colaboração de mais de 1.000 inspetores e demonstraram que a fusão de dados de áudio, vibração e metadados tabulares superou individualmente a performance de cada modalidade, atingindo um mROC de 0.844 e mAP de 0.454. Além disso, a implementação da AMPNet na plataforma de leilões da ACV resultou em uma redução de 20.85% nas reclamações de arbitragem relacionadas a problemas de motor, mostrando a eficácia do sistema em um ambiente real.

Complementar, Shabbir et al. (2024), focaram na detecção de sirenes de veículos de emergência em gerenciamento de tráfego, o que, embora não se aplique diretamente à manutenção veicular, compartilha uma problemática similar de classificação de áudio em ambientes ruidosos. O trabalho propõe um modelo de *deep learning* em conjunto (*stacking ensemble*) que combina MLP e DNN como modelos base e um LSTM como meta-aprendiz. Ao extrair uma variedade de *features* de áudio, incluindo MFCCs, e utilizar uma abordagem de fusão, eles alcançaram uma acurácia impressionante de 99.12% na classificação de sirenes, superando a performance de estudos anteriores no mesmo *dataset*.

Deste modo, percebe-se que a literatura recente valida a aplicação de aprendizado de máquina e análise de áudios para a detecção de problemas em veículos, superando abordagens tradicionais. Os estudos de Akbalık et al. (2024); Fedorishin et al. (2022) demonstram o potencial de sistemas que não se limitam a laboratórios, mas sim a ambientes e dados do mundo real. Enquanto Shabbir et al. (2024) foca na exploração de MFCCs e análises de frequência, Fedorishin et al. (2022) demonstra o valor da fusão de múltiplas



modalidades de dados (áudio, vibração e metadados) para detecção de falhas. O trabalho de Shabbir et al. (2024), por sua vez, destaca o como as abordagens de *ensemble* alcançam alta precisão na classificação de sons em ambientes complexos. Assim, este trabalho busca mitigar essas lacunas aplicando uma abordagem para diagnosticar falhas automotivas, com foco na personalização da manutenção e na aplicação prática da Indústria 4.0.

3 Abordagem Proposta

A abordagem proposta para este trabalho segue um fluxo modular e adaptável, desenhado para permitir a aplicação a diversos tipos de dados e problemáticas de classificação. A abordagem é dividida em três etapas: (1) Pré-processamento e Preparação de Dados, (2) Engenharia de Atributos e Extração de Características e (3) Modelagem e Classificação, conforme observa-se na Figura 1. Cada fase foi concebida para ser independente e flexível, facilitando a substituição ou o ajuste de componentes conforme a necessidade do conjunto de dados.




Figura 1: Pipeline da Abordagem Proposta.

Na primeira fase, o foco é a preparação dos dados brutos. Independente da natureza dos dados (sejam eles áudios, imagens, dados tabulares, etc.), esta etapa envolve a coleta, limpeza e organização do conjunto de dados. O objetivo é garantir que todas as amostras estejam em um formato consistente e que ruídos ou inconsistências sejam tratados adequadamente, preparando para a análise subsequente.

Em seguida, a fase de engenharia de atributos e extração de características é implementada. Nesta etapa, aplicam-se técnicas de processamento de sinais e de dados para converter as amostras brutas em representações numéricas que sejam relevantes e informativas para os modelos de aprendizado de máquina. A escolha das características a serem extraídas será detalhada no estudo de caso, mas o processo é importante para capturar os padrões subjacentes aos dados.

Por fim, a fase de modelagem e classificação utiliza os atributos extraídos para treinar, validar e testar um modelo de aprendizado de máquina. A seleção do algoritmo de classificação e a definição de suas configurações, bem como as métricas de avaliação, serão apresentadas no estudo de caso. Este passo visa construir um sistema capaz de realizar previsões precisas e confiáveis, cuja performance será avaliada para demonstrar a eficácia da abordagem.



4 Estudo de Caso

Esta seção apresenta o estudo de caso para validar a abordagem proposta, com o intuito de investigar o diagnóstico de falhas em motores de combustão interna, utilizando a análise acústica. Para alcançar esse objetivo, as subseções a seguir detalham as questões de pesquisa, preparação e as métricas utilizadas para a avaliação da abordagem.

4.1 Questões de Pesquisa

Esta subseção destaca as Questões de Pesquisa (QP) que o estudo de caso irá responder, guiando a investigação e a análise dos resultados.

QP1: Um modelo de aprendizado de máquina, treinado com sons de motores, é capaz de diferenciar com precisão um motor saudável de um motor com falhas de ignição ou mecânicas?

QP2: Quais características acústicas (*features*) são mais relevantes para a classificação de falhas específicas, como a ausência de combustão em cilindros?

QP3: A acurácia do modelo é impactada pelo tipo e quantidade de falhas presentes no conjunto de dados?

4.2 Conjunto de Dados


O estudo utiliza o conjunto de dados *Acoustic Fault Dataset of Internal Combustion Engine Under Controlled Conditions for Ignition and Mechanical Anomalies*, disponibilizado em Filho et al. (2025). Este conjunto de dados foi escolhido por suas características controladas, que garantem a qualidade e a relevância dos áudios para a pesquisa. O *dataset* contém amostras de áudio de motores em duas condições: (1) Motores saudáveis – Áudios de um motor operando em condições perfeitas; (2) Motores com falhas – Áudios de um motor com falhas simples, a ausência de combustão em cilindros, simulada pela desconexão dos cabos das velas.

A natureza controlada do *dataset* permite uma avaliação precisa do modelo, minimizando o ruído e a variabilidade de ambientes reais, o que é ideal para a prova de conceito inicial.

4.3 Instrumentação

A abordagem proposta foi conduzida em um ambiente de programação, utilizando a linguagem Python¹. A pesquisa se apoiou em um conjunto de bibliotecas reconhecidas na comunidade de ciência de dados e aprendizado de máquina. Para a manipulação e

¹<https://docs.python.org/3/>



organização dos dados, foram utilizadas as bibliotecas NumPy² e Pandas³, para a realização de cálculos numéricos e a estruturação dos dados em matrizes e DataFrames.

O processamento e análise de áudio foram realizados por meio da biblioteca Librosa⁴. Ela foi importante para carregar os arquivos de som e extrair as características acústicas. Para a implementação da pipeline de aprendizado de máquina, incluindo a divisão dos dados, a construção do modelo e a avaliação, a biblioteca Scikit-learn⁵ foi a ferramenta principal. O algoritmo Random Forest foi selecionado para a tarefa de classificação, e métricas como a acurácia e o relatório de classificação foram utilizadas para validar o desempenho do modelo. Por fim, a biblioteca Matplotlib⁶ foi empregada para gerar a visualização gráfica dos dados.

4.4 Preparação de Dados e Treinamento do Modelo

O processo de pré-processamento e preparação dos dados começou com o carregamento de 537 áudios do conjunto de dados. Deste total, 179 arquivos correspondiam a um motor em perfeitas condições, enquanto 358 continham falhas simples, que eram especificamente a ausência de combustão nos cilindros P1 e P4, simulada pela desconexão dos cabos das velas. Para facilitar a organização e a rotulação das classes, os arquivos foram separados em duas pastas ("normal" e "falha").

Em seguida, um loop de processamento percorreu os arquivos de cada pasta, aplicando uma função de extração de características. As informações resultantes foram organizadas em uma matriz X, enquanto os rótulos das classes (0 para "normal" e 1 para "falha") foram armazenados em um vetor Y, conforme observa-se na Figura 2. Essa etapa finalizou a preparação dos dados.




Figura 2: Fluxo de trabalho para o pré-processamento de áudio e a construção dos vetores de dados para o modelo de aprendizado de máquina.


²<https://numpy.org/>

³<https://pandas.pydata.org/>

⁴<https://librosa.org/>

⁵<https://scikit-learn.org/>

⁶<https://matplotlib.org/>



Para assegurar uma avaliação do modelo, o conjunto de dados foi dividido em uma proporção de 80% para treino e 20% para teste. Esta divisão garante que o modelo seja validado com dados que não foram utilizados durante o processo de aprendizagem.

Por fim, na fase de extração de características, foram utilizadas as seguintes *features* para cada arquivo de áudio:

- MFCCs: uma característica padrão para a classificação de áudio, que captura as propriedades espectrais do som.
- Taxa de Cruzamento por Zero (ZCR): indicador para a identificação de ruídos percussivos e padrões rítmicos.
- Centróide Espectral: uma medida que reflete o "centro de massa" da frequência, fornecendo diagnósticos sobre o tom do som.

A média de cada uma dessas características foi calculada e concatenada em um único vetor, servindo como a entrada final para o modelo. A fase de treinamento foi conduzida com o algoritmo de aprendizado supervisionado Random Forest, selecionado por conveniência. Com o modelo treinado, a etapa de avaliação foi iniciada.

4.5 Métricas de Avaliação

Nesta subseção, descreve-se as métricas utilizadas para avaliar o desempenho do modelo, para isso selecionou-se as seguintes métricas:


1. Acurácia - medida primária para determinar a porcentagem de previsões corretas do modelo.
2. Matriz de Confusão - fornece um detalhamento das previsões, mostrando o número de verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos.
3. Relatório de Classificação - oferece métricas como Precisão, *Recall* e F1-Score para cada classe, dando uma visão mais completa do desempenho do modelo.

Por fim, destaca que todos os dados, códigos-fonte e resultados do trabalho foram disponibilizados no GitHub⁷ para garantir a reprodutibilidade da pesquisa.

5 Resultados

Esta seção tem como objetivo discutir os resultados obtidos na aplicação do estudo de caso, conforme apresentado na Seção 4.

⁷<https://github.com/ValeriaSilvaSantos1/classificacao-sons-motores-automotivos>



Para à QP1, os resultados confirmam que um modelo de aprendizado de máquina, neste caso o Random Forest, é capaz de diferenciar com precisão um motor saudável de um com falhas. O processamento dos 537 áudios resultou em uma acurácia de 99%, indicando que o modelo conseguiu classificar corretamente a grande maioria das amostras. A análise detalhada da performance (Tabela 1), reforça esse resultado ao demonstrar métricas de precisão, *recall* e F1-score altas para ambas as classes, "normal" (Classe 0) e "falha" (Classe 1).

Tabela 1: Relatório de Classificação

Classe	Precision	Recall	F1-score	Support
0	0.98	1.00	0.99	64
1	1.00	0.98	0.99	44
accuracy			0.99	108
macro avg		0.99	0.99	108
weighted avg		0.99	0.99	108

A precisão de 100% na detecção de falhas e o recall de 98% para esta mesma classe demonstram a qualidade do classificador em identificar as anomalias de forma precisa, sem favorecer uma classe em detrimento da outra.

A performance obtida também permite responder à QP2, indicando que as características acústicas selecionadas, a média de MFCCs, a Taxa de Cruzamento por Zero e o Centróide Espectral, foram relevantes para a tarefa de classificação. O aprendizado do modelo Random Forest em distinguir os padrões de som entre as classes normal e com falha de combustão evidencia a capacidade dessas *features* de capturar as assinaturas sonoras únicas associadas a cada condição. A combinação dessas características, que abrangem aspectos de timbre, ritmo e distribuição de energia sonora, foi importante para o modelo conseguir identificar as diferenças sutis entre os ruídos de um motor em perfeitas condições e aqueles com anomalias.

Em relação à QP3, os resultados demonstram que a acurácia do modelo não foi impactada negativamente pela diferença na quantidade de amostras entre as classes. Embora o conjunto de dados tenha uma proporção desequilibrada (179 áudios normais contra 358 com falhas), o modelo manteve um desempenho para ambas as classes, com um F1-score de 0.99. Isso sugere que o algoritmo Random Forest lidou bem com a assimetria dos dados, reforçando a validade de sua escolha. Além disso, a visualização dos dados por meio da Análise de Componentes Principais corroborou os resultados numéricos, como pode ser demonstrado na Figura 3. Deste modo, observa-se uma separação clara entre as amostras de motor normal e com falhas, o que permite evidenciar que o classificador foi capaz de aprender as diferenças relevantes entre os grupos.

Por fim, destaca que a combinação de métricas de avaliação com a análise visual reforça a validade do processo adotado. Os resultados demonstram que a abordagem proposta é viável para a detecção de falhas em motores por meio da análise de áudios, abrindo caminho para a aplicação prática em sistemas de manutenção preditiva veicular.





Figura 3: Amostras de áudio após a redução de dimensionalidade por Análise de Componentes Principais.

6 Conclusão

O trabalho teve como objetivo aplicar técnicas de aprendizado de máquina para a detecção de falhas em motores automotivos a partir da análise de áudio. A abordagem proposta, que empregou a extração de características acústicas com a biblioteca Librosa e a classificação por meio do algoritmo Random Forest, demonstrou ser uma estratégia para o diagnóstico de anomalias em motores.

Ao analisar os resultados, foi possível responder às questões de pesquisa propostas. Em relação à QP1, os resultados confirmam que o modelo de aprendizado de máquina foi capaz de diferenciar com precisão um motor saudável de um motor com falhas de combustão nos cilindros P1 e P4. A acurácia de 99% e as métricas detalhadas do relatório de classificação demonstraram a alta eficácia do modelo em distinguir as duas classes. A QP2 foi respondida ao mostrar que características como MFCCs, Taxa de Cruzamento por Zero e Centróide Espectral são relevantes para a tarefa de classificação, pois permitiram ao modelo identificar os padrões sonoros distintos de cada tipo de motor. Por fim, a QP3 foi respondida pela análise do desempenho do modelo, que não foi impactado pela quantidade de amostras em cada classe, mantendo métricas de desempenho elevadas e equilibradas, mesmo com a base de dados desproporcional. A visualização por PCA reforçou essa conclusão, evidenciando uma separação clara entre as amostras.

Conclui-se, portanto, que a combinação de sons de motores e aprendizado de máquina é uma estratégia para auxiliar na detecção precoce de falhas. A abordagem adotada estabelece uma base para futuras aplicações em diagnósticos automotivos. Como perspectivas para trabalhos futuros, sugere-se a expansão da base de dados para incluir uma maior diversidade de falhas e condições de gravação, a fim de testar a generalização do modelo. Além disso, a comparação com outros algoritmos de classificação e a exploração de diferentes conjuntos de características acústicas.



Referências

- Akbalık, F., Yıldız, A., Ertuğrul, F., and Zan, H. (2024). Engine fault detection by sound analysis and machine learning. *Applied Sciences*, 14(15):6532.
- Fedorishin, D., Forte III, L., Birgiolas, J., Schneider, P., and Govindaraju, V. (2022). Large-scale acoustic automobile fault detection: Diagnosing engines through sound. In *Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining (KDD '22)*, New York, NY, USA. ACM.
- Fenga, L. and Biazzo, L. (2025). Stochastic modeling and time-frequency analysis for predictive maintenance of automotive suspension systems. *Applied Stochastic Models in Business and Industry*, 41(3):e70013.
- Filho, A. C. L., de Vasconcelos Lima, T. L., Torres, N. N. S., Maciel, J. N., and Junior, O. H. A. (2025). Acoustic fault dataset of internal combustion engine under controlled conditions for ignition and mechanical anomalies (dataset).
- Hossain, M., Rahman, M., and Ramasamy, D. (2024). Artificial intelligence-driven vehicle fault diagnosis to revolutionize automotive maintenance: A review. *Computer Modeling in Engineering & Sciences*, 141(2):951.
- Kamalapuram, S. K. and Choudhury, D. (2024). Industry 4.0 technologies for cultivated meat manufacturing. *Food Bioengineering*, 3(1):14–28.
- Mahale, Y., Kolhar, S., and More, A. S. (2025). A comprehensive review on artificial intelligence driven predictive maintenance in vehicles: technologies, challenges and future research directions. *Discover Applied Sciences*, 7(4):243.
- Nagy, J. and Lakatos, I. (2025). Acoustic fingerprint in vehicle manufacturing as a basis for future applications. *Pollack Periodica*.
- Nalla, N. R. (2025). Predictive maintenance in fleet management: Analyzing audio data for hazard detection. *Journal of Electrical Systems*, 21.
- Nasim, M. F., Hamad, A. A., Jaffar, A., Khalaf, O. I., Ouahada, K., Hamam, H., Akram, S., and Siddique, A. (2024). Cognitive inspired sound-based automobile problem detection: A step toward xai. *SSRN*.
- Rashed, A., Abdulazeem, Y., Farrag, T. A., Bamaqa, A., Almaliki, M., Badawy, M., and Elhosseini, M. A. (2025). Toward inclusive smart cities: Sound-based vehicle diagnostics, emergency signal recognition, and beyond. *Machines*, 13(4):258.
- Shabbir, A., Cheema, A. N., Ullah, I., Almanjahie, I. M., and Alshahrani, F. (2024). Smart city traffic management: Acoustic-based vehicle detection using stacking-based ensemble deep learning approach. *IEEE Access*, 12:35947–35956.
- Soori, M., Arezoo, B., and Dastres, R. (2024). Virtual manufacturing in industry 4.0: A review. *Data Science and Management*, 7(1):47–63.