

DETECÇÃO DE VAZAMENTOS DE FLUIDOS DE FREIOS A AR EM VAGÕES DO TIPO GÔNDOLA ATRAVÉS DO SINAL ACÚSTICO: Um modelo de classificação de falhas

Air brakes fluids leakage detection in gondola wagons through acoustic signals: A fault classifier model

Jordana Lucia Reis¹, Flávio Miguel Varejão¹

(1) Universidade Federal do Espírito Santo (UFES), Programa de Pós-Graduação em Informática, Av. Fernando Ferrari s/n, 29060-970, Vitória, ES, Brasil, jordana.reis@edu.ufes.br, flavio.varejao@ufes.br

Resumo:

Este artigo apresenta um trabalho em andamento que utiliza um modelo de aprendizado de máquina para detectar sons de vazamento de fluidos de freios a ar em vagões de carga do tipo gôndola. Vagões gôndola transportam carga seca e possuem sistema de freio pneumático, dependendo diretamente de seus componentes de ar comprimido para uma frenagem adequada. Durante a inspeção de vagões, os vazamentos de ar comprimido são identificados a partir do som, reconhecido pelo ouvido humano. O fator de inovação deste trabalho é utilizar aprendizado de máquina para identificar vazamentos de ar comprimido a partir do som gravado. Os dados de entrada para o modelo são sinais acústicos capturados no formato *waveform*, durante acompanhamento da inspeção de vagões. No modelo proposto, o sinal acústico é processado no domínio tempo-frequência, para obtenção do espectrograma da melodia. Após o pré-processamento, os dados de espectrograma servem de entrada para o classificador *Random Forest*. Os resultados iniciais demonstraram que o modelo apresenta boas perspectivas para classificar os sons de vazamento de ar, mas é necessário aumentar o conjunto de dados para melhor avaliação do desempenho da proposta.

Palavras-chave: detecção de falhas; freios de vagões; sinal acústico; falhas de freios.

Abstract:

This article presents a work in progress that applies a machine learning model to detect air brake fluid leak sounds in gondola-type cargo wagons. Gondola wagons carry dry cargo and have a pneumatic brake system, directly depending on their compressed air components for a properly braking. During wagon inspection, compressed air leaks are identified from the sound, recognized by the human ear. The innovation factor of this work is to apply machine learning to identify compressed air leaks from the recorded sound. The input data for the model are acoustic signals captured in waveform format, during monitoring of the inspection of wagons. In the proposed model, the acoustic signal is processed in the time-frequency domain to obtain the melody spectrogram. After pre-processing, the spectrogram data serves as input to the Random Forest Classifier. The initial results showed that the model has good prospects for classifying air leak sounds, but it is necessary to increase the dataset to better evaluate the proposal's performance.

Keywords: fault detection; wagons brakes, acoustic signal; braking fault.

1 Introdução

O uso do transporte ferroviário para escoamento de carga é muito utilizado na indústria, desde a Primeira Revolução Industrial. Este setor vem sofrendo evoluções e modernizações, mas continua suportando a indústria em seu objetivo de transportar grandes volumes de carga, de maneira mais barata e rápida, em comparação com outros meios de transporte disponíveis. Entretanto, ainda são tímidas as iniciativas de modernização e automatização dos processos de inspeção dos componentes ferroviários. Um exemplo disto é o procedimento de inspeção de freios dos vagões de carga. Tal procedimento é realizado por uma dupla de inspetores, que

caminham ao longo de uma linha de vagões escutando atentamente em busca de identificar sons de vazamento de ar comprimido. Uma vez que o vazamento é identificado, é solicitada a retenção dos vagões após a descarga, para devida manutenção. Nem sempre é possível inspecionar todos os lotes de vagões, por exemplo, dependendo das condições climáticas, a inspeção é suspensa, para garantir a segurança do profissional que a executa, outra situação é caso o lote tenha chegado há mais de duas horas, todo o ar comprimido já terá vazado e não há como identificar este tipo de falha. Existem outros fatores limitantes de inspeção de vazamento de fluidos de freios a ar, mas os exemplos

citados são suficientes para demonstrar que o processo seguido atualmente ainda permite que muitos vagões circulem sem a devida verificação dos componentes de freios.

Em termos financeiros, o impacto do setor ferroviário, em geral, é significativo na estratégia logística da economia do Brasil, segundo dados da [ANTF 2021], apenas no ano de 2021, foram movimentadas 506,8 milhões de toneladas de cargas nas ferrovias brasileiras. Já em relação ao investimento em manutenção e reparos, a indústria ferroviária de forma global, investe um grande montante de recursos financeiros em manutenções e projetos de renovação de ferrovias e veículos ferroviários todos os anos, segundo estudo de [Xie et al. 2020].

Por outro lado, a média anual de acidentes ferroviários no Brasil, segundo apuração realizada por [Miguel 2020], estava em torno de 850 registros, até o ano de 2020. Neste contexto, obviamente, o sistema de frenagem de quaisquer veículos deve ser considerado uma parte crítica e importante para o bom funcionamento da máquina.

De acordo com [Jin et al. 2021], identificar falhas no sistema de frenagem dos trens é necessário para garantir a confiabilidade e saúde da composição ferroviária. Uma possível solução para detecção de falhas é aplicar a tecnologia para implementar o conceito de manutenção preditiva, isto é, monitorar um ativo para prever quando este poderá apresentar falhas, substituindo-o antes do evento ocorrer. Além de garantir um sistema ferroviário mais confiável, a manutenção preditiva também reduz o custo de manutenções e renovações preventivas ou reativas, pois minimiza a indisponibilidade dos ativos através de planejamento e otimização da vida útil dos componentes.

O objetivo deste trabalho é propor um modelo de classificação de áudio capaz de detectar vazamento de ar comprimido. Os dados classificados devem permitir identificar se há falhas no sistema de freios a ar em vagões gôndola, de forma similar ao executado atualmente pelo profissional de inspeção de freios em campo.

O restante deste trabalho está organizado da seguinte forma: na seção 2, serão abordados os trabalhos relacionados

ao assunto de aplicação de aprendizado de máquina para detecção de falhas em componentes de freios de vagões. Na seção 3, são descritos os procedimentos adotados para construção do modelo. Na seção 4, são apresentados os resultados alcançados neste trabalho até o momento. Finalmente, a seção 5 trata das conclusões parciais deste estudo.

2 Trabalhos Relacionados

Evitar os acidentes ferroviários, em específico os causados por falhas no sistema de freios, foi uma das motivações apresentadas para o desenvolvimento do trabalho de [Zhang et al. 2019], que implementou fusão e seleção de características multidimensionais, redução de dimensionalidade, e por fim, *Gradient Boosting Decision Tree* (GBDT) para diagnóstico das falhas. Segundo os autores, os resultados demonstraram excelente desempenho no reconhecimento de falhas em componentes de freios de vagões.

Já [Ye et al. 2020], desenvolveu uma pesquisa onde os sons produzidos pela frenagem dos vagões ferroviários serviram de entrada para um modelo de detecção de freios aplicados. Um dispositivo instalado ao lado da linha férrea, a princípio isolada para o estudo, gravava em formato *waveform* o som emitido pelas pás de freio em contato com as rodas dos trens no momento da aplicação e liberação dos freios. Assim mapeou-se as amostras de som com freios aplicados e freios liberados. Aos dados sonoros, aplicou-se a Transformada Rápida de Fourier (FFT), seguida de representação de espectrograma e extração de características. Como o trabalho considerou 12 tipos diferentes de vagões, uma etapa de correspondência de padrão foi necessária, uma vez que os dados foram rotulados, aplicou-se o algoritmo Máquina de Vetores de Suporte (SVM) para classificação, alcançando 98% de acurácia. O estudo coletou dados em campo, compondo um conjunto de 66 amostras.

Em 2022, [Ji 2022] publicou um estudo focado no sistema de freios a ar para trens de alta-velocidade. A proposta do trabalho foi isolar a falha identificada e diagnosticar o componente defeituoso, utilizando dados criados em uma plataforma para testes de

freios de trens de alta-velocidade. A coleta de dados foi realizada através do uso de sensores para medir a pressão dos componentes do sistema de freios, especificamente válvula e cilindro. O conjunto de dados analisado era composto apenas de eventos de falha, contendo 70 amostras.

É importante ressaltar que a revisão de literatura realizada é não-exaustiva, mas até o momento, não foram encontradas pesquisas que utilizem dados de sinais acústico para detectar falhas de vazamentos de fluidos de freios de vagões gôndola, objeto de estudo neste trabalho.

3 Procedimentos Metodológicos

A metodologia aplicada neste trabalho obedece a seguinte ordem: coleta de dados sonoros em campo; pré-processamento dos dados; desenvolvimento e treinamento de classificador; e teste e avaliação de desempenho do classificador.

3.1 Coleta de Dados

O procedimento de coleta do conjunto de dados foi realizado em campo, durante acompanhamento de rotina de inspeção de freios de vagões, na companhia Vale S.A. A captura do som foi feita através da utilização de *smartphone*, utilizando um aplicativo gratuito para gravação de áudio em waveform, chamado waveEditor, disponível nas lojas dos sistemas operacionais destes dispositivos. A exemplo da inspeção realizada por humanos, a distância do dispositivo de gravação ao vagão, foi estabelecida em aproximadamente 1 metro, salvo algumas exceções devido a irregularidades do terreno.

Os componentes do sistema de freios avaliados são: cilindros, válvulas e mangotes. Estes são os componentes nos quais os vazamentos de ar comprimido podem ser identificados.

Foram inspecionados três lotes de vagões, contendo em média, 84 vagões cada lote. Até o momento da escrita deste artigo, foram realizadas coletas sobre 13 eventos de vazamento de ar comprimido, fluido do sistema de freios dos vagões gôndola. De maneira análoga, foram gravadas 13 situações de situação normal onde não há som de vazamento de ar. Cada gravação dura aproximadamente 5 segundos.

Após a captura do som, cada amostra foi rotulada em condição de falha e condição normal, especificada a linha de inspeção e o lado do vagão onde foi realizada a gravação. Cada amostra foi nomeada de acordo com estas informações. Por exemplo, o arquivo de áudio fe13_2022_07_15_163536544.wav, refere-se à captura de áudio de uma situação de falha (f), identificada ao percorrer o lado esquerdo (e) do vagão, cujo lote foi inspecionado na linha de inspeção de número 13, seguido de data e hora da coleta.

A Figura 2 é uma imagem capturada durante a inspeção de freios de vagões, onde é possível observar dois vagões gôndola, carregados de minério de ferro no pátio de inspeção, pelo lado direito dos vagões, destacados pelo retângulo de cor branca, os componentes analisados nesta pesquisa, onde é possível identificar vazamentos de ar comprimido.



Figura 1 - Visualização de componentes de freios inspecionados na pesquisa. (Dados da Pesquisa, 2022)

3.2 Pré-processamento

Um sinal acústico pode ser representado como uma forma de onda em função do tempo, representando a intensidade do som em cada instante do tempo.

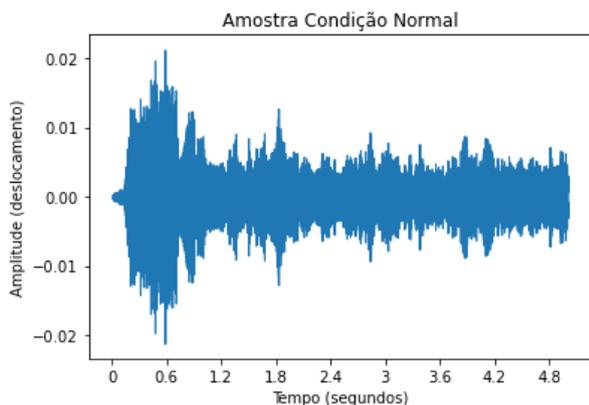


Figura 2 - Representação gráfica de amostra de som de condição normal em amplitude x tempo (Dados da Pesquisa, 2022)

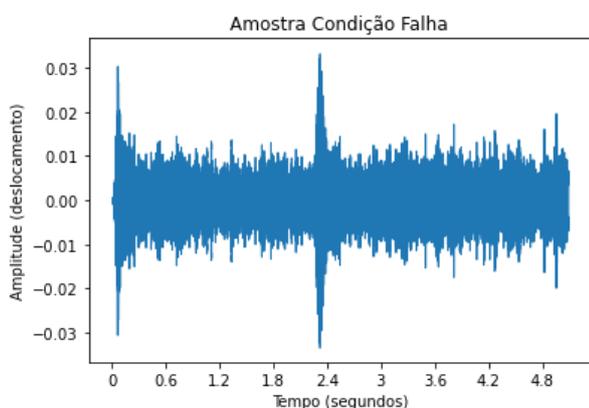


Figura 3 - Representação gráfica de amostra de som de condição de falha em amplitude x tempo (Dados da Pesquisa, 2022)

Para cada gravação, aplicou-se o seccionamento em arquivos de 1 segundo, resultando em 153 arquivos, e posterior aquisição dos dados no domínio tempo-frequência, utilizando a Transformada de Fourier de Tempo Curto (STFT), gerando matrizes para treinamento e teste do modelo de classificação. A biblioteca librosa foi utilizada como suporte no processo de aplicação do método STFT, sendo que os parâmetros utilizados foram estabelecidos como: 1) n_fft igual a 2048, para o tamanho da FFT. 2) hop_length , igual a 1024, para o tamanho do salto. 3) $window$, foi a lista resultante da execução função Blackman-Harris que recebeu o parâmetro número de pontos de saída igual a 1024. Os demais parâmetros foram mantidos exatamente como o padrão da biblioteca.

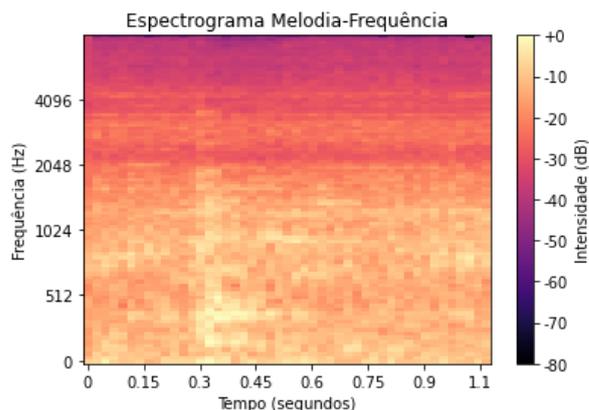


Figura 4 - Exemplo de espectrograma de melodia de uma amostra de falha (Dados da Pesquisa, 2022)

Como seleção de características, aplicou-se o espectrograma de melodia com taxa de amostragem igual a 44.100, dividido em 100 bandas, compostas de 47 valores de espectrograma de melodia. Em seguida, os dados dos arquivos foram normalizados em valores entre 0 (zero) e 1 (um).

Como os áudios originais foram gravados com aproximadamente 5 segundos, alguns arquivos continham alguns milissegundos a mais e alguns continham alguns milissegundos a menos. Desta forma, quando aplicado o seccionamento em 1 segundo de duração, algumas seções ficaram menores do que 1 segundo. Para garantir a padronização, os arquivos menores que 1 segundo, no total 26, foram desconsiderados. Portanto, o conjunto contou com 127 arquivos, de 47 colunas e 100 linhas, linhas tais geradas a partir das 100 bandas do espectrograma. Destes arquivos, 65 são referentes a amostras de áudio em condições normais e 62 referem-se a amostras de áudio capturado em condição de falha. Assim, foi formada uma base para alimentar o modelo com 12.700 amostras, rotuladas em duas classes, condição normal e condição de falha, de acordo com a nomenclatura do arquivo original.

3.3 Modelo

O modelo escolhido para os testes foi o *Random forest classifier* (RFC), pois apresentou melhor resultado em validação cruzada repetida 10 vezes, quando comparado com os modelos K-vizinhos mais próximos, Árvore de decisão e Máquina de vetores de suporte.

Os dados foram separados em conjuntos de treino e teste, sendo que 20% do conjunto foi utilizado para teste, isto é, 2.540 entradas, e o restante para treino. O conjunto foi separado em treino e teste de forma randômica, utilizando a semente igual a sete (7). O número de estimadores utilizado como parâmetro para a execução do modelo foi igual a um mil (1000). Os resultados apresentados na próxima seção são parciais e foram obtidos com um conjunto reduzido de amostras, apresenta informações considerando o conjunto de testes, que não foi utilizado no processo de treinamento do modelo.

4 Resultados

A acurácia alcançada pelo modelo foi de 0,73% e F1-score acima de 70% para ambas classes. Entretanto, algumas condições de falha foram incorretamente rotuladas como condição normal pelo modelo, o que pode ser prejudicial para o propósito de auxiliar o processo de inspeção dos freios de vagão.

É importante ressaltar que este trabalho está em andamento e uma evolução já identificada é avaliar outras formas seleção de características para fornecer como entrada ao modelo, as características que ofereçam informações de qualidade para melhorar o desempenho do modelo proposto, assim como utilizar a Transformada Rápida de Fourier (FFT) diretamente. Além disso, o conjunto de dados está em processo de formação, sendo incrementado a cada acompanhamento de inspeção em campo, processo pelo qual são capturadas as amostras de áudio.

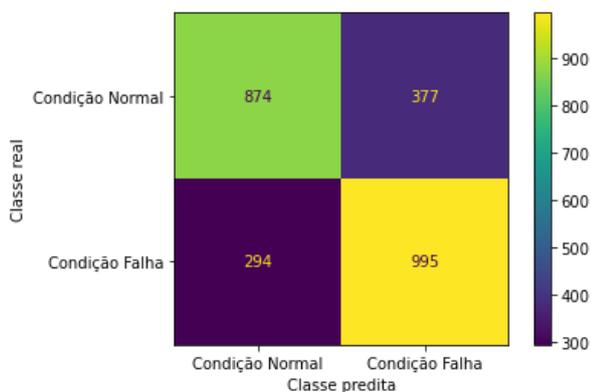


Figura 5- Matriz de confusão (Dados da Pesquisa, 2022)

5 Conclusão ou Considerações Finais

Este trabalho apresentou uma abordagem para utilizar dados de sinal acústico para identificar vazamentos de fluidos de freios de vagão, e consequente detecção de falhas no sistema de frenagem de vagões de transporte de carga. Os resultados iniciais indicam que é possível utilizar o som gravado em aplicativo gratuito de telefone móvel para alimentar um modelo de classificação inteligente, capaz de auxiliar o processo de inspeção de freios de vagões gôndola.

Na evolução do desenvolvimento deste trabalho, pretende-se avaliar outros tipos de espectrogramas para representar o sinal acústico, comparando ao desempenho alcançado neste estudo. Além disso, há espaço para trabalhar mais detalhes do áudio de entrada, eventualmente capturando o sinal com outros tipos de equipamentos, que embora possam restringir a utilização da proposta, possam trazer mais informações sobre o dado pela qualidade da gravação. Assim também, evoluir na exploração e mapeamento de frequências, amplitudes, e demais atributos que contribuam para direcionar a criação de um modelo mais assertivo.

Referências

ANTF. *Informações gerais: o setor ferroviário de carga brasileiro*. Associação Nacional dos Transportadores Ferroviários, 2021. Disponível em: <https://www.antf.org.br/informacoes-gerais/>. Acesso em: 13 nov. 2022.

Ji, Hongquan. *Optimization-based incipient fault isolation for the high-speed train air brake system*. IEEE Transactions on Instrumentation and Measurement, 71, 2022. Disponível em: <https://ieeexplore.ieee.org/document/9666849>. Acesso em: 13 nov. 2022.

JIN, Yongze *et al.* *Fault diagnosis of brake train based on multi-sensor data fusion*. Sensors, 21, 2021. Disponível em: <https://www.mdpi.com/1424-8220/21/13/4370>. Acesso em: 13 nov.2022.

MIGUEL, Daniel. *Acidentes ferroviários no Brasil: análise comparativa com a união europeia*. In: Congresso ANPET, 34, 2020. Disponível em: [https://www.anpet.org.br/anais34/documentos/2020/Aspectos Econômicos Sociais Políticos e Ambientais do Transporte/Gestão do Transporte Ferroviário e Hidroviário/4_220_AC.pdf](https://www.anpet.org.br/anais34/documentos/2020/Aspectos%20Econômicos%20Sociais%20Políticos%20e%20Ambientais%20do%20Transporte/Gestão%20do%20Transporte%20Ferroviário%20e%20Hidroviário/4_220_AC.pdf). Acesso em 13 nov. 2022.

XIE, Jiawei *et al.* *Systematic literature review on data-driven models for predictive maintenance of railway track: implications in geotechnical engineering*. *Geosciences* (Switzerland), 10:1–24, 2020. Disponível em: <https://www.mdpi.com/2076-3263/10/11/425>. Acesso em: 13 nov. 2022.

ZHANG, Meng; LIU, Zhen; Dang, Xinyue. *Fault diagnosis on train brake system based on multi-dimensional feature fusion and gbdt enhanced classification*. 2018 International Conference on Intelligent Rail Transportation (ICIRT), Singapura, 2019. Disponível em: <https://ieeexplore.ieee.org/document/8641607>. Acesso em: 13 nov. 2022.

YE, Yuling; ZHANG, Jun; LIANG, Hengda. *An acoustic-based recognition algorithm for the unreleased braking of railway wagons in marshalling yards*. *IEEE Access*, 8:120295–120308, 2020. Disponível em: <https://ieeexplore.ieee.org/document/9129748>. Acesso em: 13 nov. 2022.