

Monitoramento da Integridade Estrutural de Vias Férreas a Partir de Medições de Vibração a Bordo Utilizando Técnicas de Aprendizado Profundo[☆]

Structural Health Monitoring of Railway Tracks from On-Board Vibration Measurements Using Deep Learning Techniques

Renato da Silva Melo^{1,†}, Marcos Spínola Neto¹, Rafaelle Piazzaroli Finotti¹, Andreia Meixedo², Diogo Rodrigo Ferreira Ribeiro³, Flávio de Souza Barbosa¹, Alexandre Abrahão Cury¹

¹Faculdade de Engenharia, Universidade Federal de Juiz de Fora, Juiz de Fora, Brasil

²Faculdade de Engenharia, Universidade do Porto, Porto, Portugal

³Instituto Superior de Engenharia do Porto, Instituto Politécnico do Porto, Porto, Portugal

[†]**Autor correspondente:** renato.melo@estudante.ufjf.br

Resumo

A manutenção da infraestrutura ferroviária apresenta um constante desafio devido ao desgaste natural e aos danos decorrentes do uso contínuo, que podem comprometer a segurança e eficiência desse meio de transporte. Este estudo propõe o uso de Monitoramento de Integridade Estrutural (SHM, do inglês *Structural Health Monitoring*) através da aplicação de um Autocodificador Variacional (VAE, do inglês *Variational Autoencoder*) para a detecção de irregularidades em vias férreas. O VAE é treinado para aprender a representar o comportamento normal da via e, junto com a Carta de Controle Hotelling T², é capaz de detectar anomalias estruturais. A metodologia proposta inclui a otimização dos hiperparâmetros do VAE utilizando a biblioteca Optuna, buscando maximizar o desempenho do modelo. Os resultados indicam que a combinação do VAE com a Carta de Controle Hotelling T² é eficaz na detecção de defeitos, oferecendo uma solução mais econômica e menos invasiva para a manutenção preventiva das vias. Embora o método ainda não quantifique as anomalias, ele apresenta um grande potencial para aprimorar a confiabilidade operacional.

Palavras-chave

Monitoramento de Integridade Estrutural • Autocodificador Variacional • Carta de Controle Hotelling T² • Manutenção Ferroviária

Abstract

Railway infrastructure maintenance presents a constant challenge due to natural wear and tear and damage resulting from continuous use, which can compromise the safety and efficiency of this means of transport. This study proposes the use of Structural Health Monitoring (SHM) through the application of a Variational Autoencoder (VAE) for the detection of irregularities in railway tracks. The VAE is trained to learn to represent the normal behavior of the track and, together with the Hotelling T² Control Chart, is capable of detecting structural anomalies. The proposed methodology includes the optimization of the VAE hyperparameters using the Optuna library, seeking to maximize the model's performance. The results indicate that the combination of the VAE with the Hotelling T² Control Chart is effective in detecting defects, offering a more economical and less invasive solution for preventive maintenance of tracks. Although the method does not yet quantify anomalies, it has great potential to improve operational reliability.

[☆] Este artigo é uma versão estendida do trabalho apresentado no XXVII ENMC Encontro Nacional de Modelagem Computacional e XV ECTM Encontro de Ciência e Tecnologia de Materiais, ocorridos em Ilhéus – BA, de 1 a 4 de outubro de 2024.

KeywordsStructural Health Monitoring • Variational Autoencoder • Hotelling T^2 Control Chart • Railway Maintenance

1 Introdução

A manutenção de infraestrutura ferroviária é um desafio constante devido ao desgaste natural e aos danos que podem comprometer a segurança e a eficiência do transporte. Inspeções tradicionais, realizadas por equipes de manutenção, são muitas vezes inadequadas para detectar falhas sutis e iniciais, o que pode levar a intervenções tardias e de alto custo. Nesse contexto, o Monitoramento de Integridade Estrutural (SHM, do inglês *Structural Health Monitoring*) surge como uma solução promissora, proporcionando uma forma contínua e automatizada de avaliar a integridade estrutural de diversas construções, como as vias férreas [1].

Nos últimos anos, os avanços em aprendizado de máquina e inteligência artificial têm revolucionado o campo do SHM, permitindo a análise precisa de grandes volumes de dados coletados por sensores. Esses dados são fundamentais para a detecção precoce de falhas, minimizando riscos e otimizando a manutenção preventiva. Nos estudos de Finotti et al. [2], foram utilizados autocodificadores esparsos (SAEs, do inglês *Sparse Autoencoders*) para a identificação de alterações estruturais em sistemas dinâmicos a partir de respostas de vibração, demonstrando sua eficácia em distinguir diferentes estados de danos e condições operacionais. Um outro estudo, de Spínola Neto et al. [3], compara o uso de quatro metodologias baseadas na combinação de diferentes autocodificadores com a Carta de Controle T^2 , destacando a capacidade dos autocodificadores variacionais (VAEs, do inglês *Variational Autoencoders*) de modelar a distribuição probabilística das respostas estruturais e identificar padrões complexos em dados não rotulados. Com isso, os sistemas de SHM oferecem uma abordagem mais confiável e menos custosa do que as inspeções tradicionais para a manutenção estrutural, permitindo a detecção de sinais de deterioração com base em limiares definidos previamente [4].

O presente estudo destaca o uso do VAE, um tipo de autocodificador que consiste em uma rede neural profunda de natureza não supervisionada, capaz de introduzir uma abordagem probabilística na modelagem dos dados. O VAE aprende a representar os dados através de uma distribuição latente, o que permite uma reconstrução eficiente das entradas [5]. Além disso, ele melhora a extração de características relevantes dos dados ao gerar uma representação mais estruturada e interpretável. Este trabalho se alinha com diversos estudos recentes que também exploram o uso de técnicas de aprendizado profundo para detecção de anomalias estruturais, como o de Finotti et al. [6], que destacou o uso de autocodificadores esparsos e da Carta de Controle T^2 aplicados a respostas dinâmicas, demonstrando a eficácia dessas metodologias em diferentes cenários de monitoramento estrutural.

Desta maneira, o objetivo deste trabalho é investigar o uso do VAE para a detecção de defeitos em vias férreas simuladas, utilizando as representações latentes geradas pelo VAE como parâmetros para a Carta de Controle T^2 . Ao combinar essas duas técnicas, busca-se uma solução mais precisa e econômica para a manutenção preventiva de vias férreas, além de contribuir para a segurança operacional.

2 Fundamentação Teórica

A metodologia empregada para identificar alterações estruturais é composta por duas etapas principais:

1. **Autocodificador Variacional (VAE):** Neste artigo, utiliza-se o VAE para extrair características dos sinais dinâmicos monitorados, funcionando como um redutor de parâmetros.
2. **Carta de Controle T de Shewhart (T^2):** Esta ferramenta gráfica, baseada na métrica estatística T^2 , é utilizada para indicar objetivamente a ocorrência de mudanças estruturais, calculada a partir dos parâmetros da camada latente do VAE.

Uma breve discussão dessas duas etapas é apresentada nas seções a seguir. Mais detalhes podem ser encontrados em Goodfellow et al. [5] e Montgomery [7].

2.1 Autocodificador Variacional (VAE)

O VAE consiste em uma variação do autocodificador tradicional que, além de aprender uma representação eficiente dos dados, modela a distribuição das características latentes. Isso é feito introduzindo uma regularização que aproxima a distribuição das variáveis latentes a uma distribuição normal, promovendo uma geração mais robusta e contínua dos dados.

Durante o treinamento, o VAE é otimizado para minimizar a diferença, ou divergência, entre os dados de entrada originais ($\mathbf{x}$) e os dados reconstruídos ($\mathbf{x}'$), combinando o erro de reconstrução e um termo de regularização baseado na divergência de Kullback-Leibler (KL) entre a distribuição das variáveis latentes e uma distribuição normal padrão.

Para gerar uma amostra dos dados de entrada, o VAE primeiro extrai uma amostra $\mathbf{z}$ da distribuição dos dados $p(\mathbf{z})$. Em seguida, a amostra passa por uma rede geradora diferenciável $g(\mathbf{z})$. Finalmente, $\mathbf{x}$ é extraída de uma distribuição $p(\mathbf{x}; g(\mathbf{z})) = p(\mathbf{x}|\mathbf{z})$. Durante o treinamento, a rede codificadora $q(\mathbf{z}|\mathbf{x})$ é usada para obter $\mathbf{z}$, e $p(\mathbf{z})$ é então uma rede decodificadora [5].

Nesse estudo, foi utilizado o Erro Quadrático Médio (MSE) como função de perda para o VAE, como definido na Eq. (1). O MSE desempenha um papel crítico na minimização das diferenças quadráticas entre os valores previstos e reais, melhorando assim a precisão da reconstrução e facilitando a extração de características significativas dos dados.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - x_i)^2. \quad (1)$$

2.2 Carta de Controle T de Shewhart (T^2)

A Carta de Controle T^2 é uma ferramenta gráfica estatística usada para avaliar a influência de vários parâmetros ao longo do tempo. Ela exibe múltiplos pontos de dados, cada um representando uma métrica estatística específica, com linhas horizontais separando diferentes classes de cenários estruturais. Pontos fora dos intervalos esperados indicam mudanças na estrutura, sugerindo a ocorrência de situações indesejadas.

Neste estudo, o T^2 foi calculado com base nos parâmetros extraídos das camadas latentes do VAE, permitindo a identificação de mudanças ou danos nos sinais analisados ao comparar os valores observados com limites estatisticamente estabelecidos. A estatística T^2 representa a distância entre uma nova observação de dados e o vetor média amostral correspondente. Ou seja, quanto maior o valor de T^2 , maior é a distância dos novos dados em relação à média. Essa métrica é baseada na relação entre variáveis e na dispersão dos dados (matriz de covariância).

Dada uma matriz $\mathbf{H}_{N \times M}$ representando um conjunto de dados ao longo de um certo período (que, neste artigo, são as características extraídas das camadas latentes do VAE), o T^2 pode ser calculado conforme a Eq. (2):

$$T^2 = R(\mathbf{h} - \bar{\mathbf{h}})^T \mathbf{S}^{-1} (\mathbf{h} - \bar{\mathbf{h}}). \quad (2)$$

Referente à Eq. (2), $\bar{\mathbf{h}}$ é o vetor médio das M características disponíveis, obtido por meio de uma submatriz de $\mathbf{H}$ com R observações ($\mathbf{H}_{R \times M}$, $R < N$); $\bar{\mathbf{h}}$ e $\mathbf{S}$ são, respectivamente, o vetor médio de referência e a matriz de covariância de referência. Nos estudos realizados, o Limite Superior de Controle (UCL) foi definido como o valor que excede 95% dos valores de T^2 dos dados de treinamento. Valores de T^2 superiores ao UCL indicam possíveis alterações nos dados, sugerindo a presença de danos estruturais ou outras anomalias. Assim, 5% dos valores de T^2 dos dados de treinamento estarão acima do UCL, o que não representa um problema se estiverem próximos a ele.

3 Metodologia

A metodologia proposta tem como objetivo avaliar a eficiência do VAE combinado com a carta de controle T^2 na classificação não supervisionada de sinais de vibração que refletem diferentes condições de irregularidades para uma via de linha de trem. O modelo é treinado exclusivamente com dados da via em estado intacto, sem nenhuma irregularidade, e posteriormente testado com dados de diversas condições. Este processo permite comparar cada sinal com um estado de referência, identificando variações significativas entre diferentes estados enquanto mantém a consistência dentro de cada estado.

Os dados foram divididos em três conjuntos: treinamento, validação e monitoramento. Na fase de treinamento, um conjunto de dados extraído do estado intacto da estrutura é usado para treinar o modelo VAE. Esse conjunto é denominado conjunto de treinamento. Na fase de validação, outro conjunto de dados (dados de validação), também extraído do mesmo estado estrutural da fase de treinamento, é aplicado ao modelo treinado na etapa anterior, com o objetivo de verificar a capacidade do modelo de classificar novos dados. Espera-se que sejam produzidos valores de T^2 estatisticamente semelhantes para os conjuntos de treinamento e validação, já que pertencem ao mesmo estado estrutural. Na fase de monitoramento, conjuntos de dados extraídos de outros casos estruturais, diferentes daqueles usados nas fases de treinamento e validação, são apresentados ao modelo, e é esperado que sejam produzidos valores de T^2 maiores do que os obtidos nas fases anteriores, pois pertencem a um estado estrutural diferente daquele usado para treinamento.

Os sinais dinâmicos estruturais no domínio do tempo foram utilizados como entrada para o VAE. Todos os dados foram padronizados utilizando a padronização $\mathbf{z}$ -score, conforme a Eq. (3):

$$\mathbf{z} = \frac{\mathbf{x} - \mu}{\sigma}. \quad (3)$$

Na Eq. (3), $\mathbf{z}$ refere-se ao vetor do sinal padronizado, $\mathbf{x}$ é o vetor do sinal original, e μ e σ são o valor médio e o desvio padrão do sinal, respectivamente.

4 Aplicação

Os dados utilizados neste estudo foram obtidos por meio de simulações numéricas que simulam as respostas dinâmicas obtidas por sistemas de medição a bordo durante a passagem de veículos ferroviários em diferentes condições de irregularidades da via e variações de velocidade. Esses dados representam um subconjunto das simulações originalmente desenvolvidas e utilizadas por Magalhães et al. [8] que, na ocasião, aplicaram estratégias de Monitoramento da Integridade Estrutural (SHM) usando autocodificadores esparsos para a identificação de danos em rodas ferroviárias. Desta maneira, ressalta-se que o conjunto de dados utilizado para o desenvolvimento deste estudo foi cedido por Magalhães et al. [8] para a avaliação da presença de irregularidades anormais em vias férreas. As simulações da interação dinâmica entre o veículo e a via foram realizadas utilizando um software interno denominado Vehicle-Structure Interaction Analysis (VSI), desenvolvido em linguagem MATLAB [9] e implementado nos estudos de Magalhães et al. [8]. A abordagem em relação à interação veículo-via adotada no VSI é detalhadamente descrita nos estudos de Montenegro et al. [10] [11] e têm sido aplicada de maneira recorrente em outros estudos, como Guedes et al. [12], Silva et al. [13] e Mosleh et al. [14].

A análise realizada pelo VSI considera um modelo tridimensional de contato roda-trilho que integra o veículo e a via através da teoria Hertziana [15]. O software também utiliza a uma rotina denominada USETAB de Kalker [16], que considera o cálculo de contato via-veículo totalmente não linear, de modo a representar a complexidade do problema de maneira mais fidedigna possível, considerando inclusive o cálculo das forças normais e tangenciais resultantes da fluência por atrito do rolamento. Embora os modelos de subsistemas tenham sido inicialmente desenvolvidos de formas independentes, o VSI os integra por meio de uma abordagem de acoplamento abrangente [8]. A Fig. 1 representa, de maneira resumida, os processos de modelagem e simulação realizados para a obtenção dos dados de vibração utilizados neste estudo.




Figura 1: Esquema do modelo de interação veículo-via. Adaptado de Magalhães et al. [8].

Os dados obtidos através do VSI, utilizando a metodologia descrita anteriormente e empregados na pesquisa realizada por Magalhães et al. [8], foram utilizados neste estudo com o propósito de detectar irregularidades na via férrea. Tais irregularidades de via representam pequenas variações na cota do trilho em função de imperfeições superficiais, consequentes do processo de desgaste dos mesmos. Essas imperfeições podem ser medidas através de veículos de inspeção de via dedicados, conforme evidenciado pelas administrações ferroviárias de Portugal. Nesta aplicação, os registros de aceleração vertical simulados foram realizados por sete acelerômetros dispostos em distintas posições de um vagão. As características das séries temporais e demais parâmetros dos dados analisados estão detalhados na Tabela 1.

Todos os registros foram realizados a partir da simulação de técnicas de medição a bordo dos veículos, sendo quatro destes nas quatro caixas de eixos e três em posições da estrutura do vagão. Foram consideradas ainda dez velocidades distintas, variando de 40 a 120 km/h, dez cenários de irregularidades na via e uma única condição de carregamento do veículo, conforme também apresentado na Tabela 1.

A Fig. 2 apresenta os sinais dinâmicos típicos de registros realizados na caixa de eixo traseira esquerda para níveis de irregularidades 1, 2, 3 e 4 a uma velocidade de 60 km/h.

As análises foram conduzidas considerando a irregularidade da via em diferentes velocidades, garantindo que, para cada velocidade, fossem realizadas as etapas de treinamento, validação e monitoramento utilizando os dados de

Tabela 1: Parâmetros dos dados dinâmicos analisados.

Parâmetro	Características
Frequência de Amostragem	10 kHz
Ruído Artificial	5%
Frequência de Corte	1500 Hz
Posições dos Acelerômetros	Quatro nas caixas de eixos (traseiro esquerdo, dianteiro esquerdo, traseiro direito, dianteiro direito) e três na estrutura do vagão (centro do eixo traseiro, centro do eixo dianteiro, centro da estrutura do vagão)
Velocidades Consideradas	40, 50, 60, 70, 75, 80, 90, 100, 110, 120 (km/h)




Figura 2: Sinais dinâmicos de aceleração no domínio do tempo coletados no eixo traseiro esquerdo, à velocidade de 60 km/h. a) Irregularidade 1; b) Irregularidade 2; c) Irregularidade 3; d) Irregularidade 4.

aceleração obtidos em dez cenários distintos de irregularidades, sendo um cenário referente a uma via íntegra, sem a presença de irregularidades anômalas e nove cenários correspondendo aos padrões de irregularidades anômalas considerados na simulação. Para cada velocidade, as fases de treinamento e validação foram executadas com base no cenário de irregularidade 1, aquele que considera a condição de uma via intacta, sem a presença de imperfeições que afetem a integridade estrutural da via.

Ressalta-se que havia um único sinal disponível para cada nível de irregularidade e velocidade. Portanto, foi necessário segmentar esses sinais em partes menores para aumentar a quantidade de dados disponíveis para treinamento, validação e testes, aprimorando assim a capacidade de aprendizado do modelo. Dessa maneira, cada um dos sinais originais, que apresentavam dimensões distintas para cada velocidade, foram segmentados em dez partes, conforme apresentado pela Tabela 2.

Para otimizar o desempenho do VAE, utilizou-se o otimizador de parâmetros *Optuna* Akiba et al. [17] para a busca de hiperparâmetros. Essa abordagem permitiu testar diversas combinações de taxa de aprendizado, tamanhos da camada intermediária e da camada latente, além de números de batches e épocas de treinamento. O objetivo foi aprimorar a capacidade de distinção entre as classes de irregularidades de via para cada acelerômetro em diferentes velocidades.

5 Resultados

Em todas as situações avaliadas, observou-se que a maior parte dos valores de T^2 dos dados de treinamento e validação permaneceram abaixo da UCL, indicando um bom comportamento do modelo na classificação de novos dados, embora ainda ocorra uma considerável dispersão dos dados de validação em relação aos dados de treinamento. Como os conjuntos de treinamento e validação pertencem à mesma classe de irregularidade, era esperado que os valores

Tabela 2: Resumo dos dados originais e segmentados.

Velocidade (km/h)	Sinal Original (Nº de Pontos)	Sinal Segmentado (Nº de Pontos)
40	60459	6045
50	46167	4616
60	36639	3663
70	29833	2983
75	27111	2711
80	24729	2472
90	20759	2075
100	17583	1758
110	14984	1498
120	12819	1281

de T^2 fossem semelhantes. Além disso, os hiperparâmetros selecionados em todas as análises permitiram a correta identificação de alteração nas irregularidades da via, uma vez que todos os níveis de irregularidades anômalas monitoradas excederam a UCL, conforme ilustrado na Fig. 3, que representa quatro gráficos dos resultados da Carta de Controle Hotelling T^2 , a partir das camadas latentes dos autocodificadores, no qual cada cor representa um cenário distinto de irregularidade da via.




Figura 3: Cartas de Controle T^2 para as irregularidades da via, a partir de sinais dinâmicos coletados no eixo traseiro esquerdo. (a) 90 km/h; (b) 100 km/h; (c) 110 km/h; (d) 120 km/h

Para aprofundar a análise realizada, foram elaborados box-plots específicos para cada um dos resultados da Carta de Controle Hotelling T^2 , levando em consideração os dados de cada acelerômetro e os distintos níveis de irregularidades de via analisados. A introdução destas representações gráficas visa facilitar a interpretação estatística dos resultados, permitindo identificar possíveis tendências e valores atípicos, representados pelos outliers. Embora o VAE tenha identificado com precisão as alterações nos níveis de irregularidades distintos do nível 1, os valores de T^2 das demais classes mostraram-se estatisticamente semelhantes entre si, conforme pode ser visualizado através dos box-plots representativos dos dados, indicados na Fig. 4. Nessa figura, percebe-se a superposição dos *whiskers*

(bigodes) dos box-plots para cada nível de irregularidade. A mediana correspondente a cada nível de irregularidade também não demonstrou a presença de padrões entre as distintas análises realizadas e relação com o aumento do grau de irregularidade da via. Tais observações sugerem que o modelo enfrentou dificuldades em distinguir claramente os diferentes níveis de irregularidades. Essas dificuldades podem ser atribuídas à natureza dos sinais dinâmicos que, apesar de apresentarem variações em amplitude e frequência, exibem padrões semelhantes, indicando que o modelo de VAE ainda não atingiu o refinamento necessário. Apesar dessas limitações, o VAE demonstrou sua eficácia na identificação de sinais dinâmicos distintos dos considerados saudáveis para a segurança estrutural da via, embora a quantificação das irregularidades ainda não tenha sido alcançada.




Figura 4: Box-plots referentes aos valores de T^2 para as irregularidades da via, a partir de sinais dinâmicos coletados no eixo traseiro esquerdo. (a) 90 km/h; (b) 100 km/h; (c) 110 km/h; (d) 120 km/h

6 Conclusões

Neste estudo, foi investigada a eficácia do uso de um Autocodificador Variacional e da ferramenta estatística Carta de Controle Hotelling T^2 , no processo de detecção e quantificação de irregularidades que representam alterações estruturais em vias férreas. A abordagem mostrou-se eficaz na identificação de anomalias estruturais com base em dados de aceleração obtidos por sistemas de medição embarcados, proporcionando uma solução econômica e menos invasiva em comparação com as inspeções tradicionais.

Embora a metodologia tenha sido eficiente na detecção de mudanças significativas no comportamento estrutural, a dificuldade em distinguir diferentes níveis de irregularidade foi uma limitação, sugerindo que o modelo de VAE adotado ainda precisa ser refinado para melhorar a separação entre diferentes tipos e níveis de danos.

Para superar essas limitações, futuras pesquisas devem explorar a adoção de autocodificadores convolucionais ou esparsos, que podem fornecer uma modelagem mais detalhada dos padrões de irregularidades. Além disso, melhorias no ajuste de hiperparâmetros e a incorporação de dados adicionais de diferentes cenários operacionais podem contribuir para uma maior robustez do modelo, possibilitando uma classificação precisa das anomalias estruturais.

Agradecimentos

Este trabalho foi financiado pela CAPES (Código Financeiro 0001), Conselho Nacional de Desenvolvimento Científico e Tecnológico — CNPq (Brasil) — Projetos CNPq/FNDCT/MCTI 407256/2022-9, 402533/2023-2, 303982/2022-5 e 308008/2021-9 e Fundação de Amparo à Pesquisa do Estado de Minas Gerais — FAPEMIG — Processo BPD-00080-22.

Referências

- [1] H. Souza e W. Courage, “Value of information of a pro-active shm-based tool supported by advanced fe models and bayesian statistics towards efficiency in bridge management,” *Structure and Infrastructure Engineering*, vol. 18, no. 4, pp. 554–572, 2021. Disponível em: <https://doi.org/10.1080/15732479.2021.1978507>
- [2] R. P. Finotti, F. Barbosa, A. A. Cury, e R. L. Pimentel, “Numerical and experimental evaluation of structural changes using sparse auto-encoders and svm applied to dynamic responses,” *Applied Sciences*, vol. 11, no. 24, 2021. Disponível em: <https://doi.org/10.3390/app112411965>
- [3] M. Spínola Neto, R. Finotti, F. Barbosa, e A. Cury, “Structural damage identification using autoencoders: A comparative study,” *Buildings*, vol. 14, no. 7, 2024. Disponível em: <https://doi.org/10.3390/buildings14072014>
- [4] F. J. Carrión, J. A. Quintana, e S. E. Crespo, “Techno-economical and practical considerations for SHM systems,” *Journal of Civil Structural Health Monitoring*, vol. 7, no. 2, pp. 207–215, 2017. Disponível em: <https://doi.org/10.1007/s13349-017-0215-x>
- [5] I. Goodfellow, Y. Bengio, e A. Courville, *Deep Learning*. Cambridge, Massachusetts, EUA: MIT Press, 2016. Disponível em: <http://www.deeplearningbook.org>
- [6] R. P. Finotti, C. F. da Silva, P. H. E. Oliveira, F. Barbosa, A. A. Cury, e R. C. Silva, “Novelty detection on a laboratory benchmark slender structure using an unsupervised deep learning algorithm,” *Latin American Journal of Solids and Structures*, vol. 20, no. 9, 2023. Disponível em: <https://doi.org/10.1590/1679-78257591>
- [7] D. C. Montgomery, *Introduction to Statistical Quality Control*. Nova York, EUA: John Wiley & Sons, 2009. Disponível em: <chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://www.uaar.edu.pk/fs/books/12.pdf>
- [8] J. Magalhães, T. Jorge, R. Silva, A. Guedes, D. Ribeiro, A. Meixedo, M. Araliya, C. Vale, P. Montenegro, e A. A. Cury, “A strategy for out-of-roundness damage wheels identification in railway vehicles based on sparse autoencoders,” *Railway Engineering Science*, vol. 32, pp. 421–443, 2024. Disponível em: <https://doi.org/10.1007/s40534-024-00338-4>
- [9] The, MathWorks, e Inc., “Matlab version: (r2018a),” Natick, Massachusetts, United States, 2018. Disponível em: <https://www.mathworks.com>
- [10] P. A. Montenegro, S. G. M. Neves, R. Calçada, M. Tanabe, e M. Sogabe, “Wheel–rail contact formulation for analyzing the lateral train–structure dynamic interaction,” *Computers & Structures*, vol. 152, pp. 200–214, 2015. Disponível em: <https://doi.org/10.1016/j.compstruc.2015.01.004>
- [11] P. A. Montenegro e R. Calçada, “Wheel–rail contact model for railway vehicle–structure interaction applications: development and validation,” *Railway Engineering Science*, vol. 31, no. 3, pp. 181–206, 2023. Disponível em: <https://doi.org/10.1007/s40534-023-00306-4>
- [12] A. Guedes, R. Silva, D. Ribeiro, C. Vale, M. Araliya, P. Montenegro, e A. Meixedo, “Detection of wheel polygonization based on wayside monitoring and artificial intelligence,” *Sensors*, vol. 23, no. 4, 2023. Disponível em: <https://doi.org/10.3390/s23042188>
- [13] R. Silva, A. Guedes, D. Ribeiro, C. Vale, A. Meixedo, A. Mosleh, e P. Montenegro, “Early identification of unbalanced freight traffic loads based on wayside monitoring and artificial intelligence,” *Sensors*, vol. 23, no. 3, 2023. Disponível em: <https://doi.org/10.3390/s23031544>
- [14] A. Mosleh, A. Meixedo, D. Ribeiro, P. Montenegro, e R. Calçada, “Early wheel flat detection: an automatic data-driven wavelet-based approach for railways,” *Vehicle System Dynamics*, vol. 61, no. 6, pp. 1664–1673, 2022. Disponível em: <https://doi.org/10.1080/00423114.2022.2103436>
- [15] H. Hertz, *Ueber die Berührung fester elastischer Körper*. Germany: Journal für die reine und angewandte Mathematik, 1882. Disponível em: <http://eudml.org/doc/148490>
- [16] J. J. Kalker, *Book of Tables for the Hertzian Creep-force Law*. Netherlands: Faculty of Technical Mathematics and Informatics, Delft University of Technology, 1996. Disponível em: <https://books.google.com.br/books?id=Yrf5GgAACAAJ>
- [17] T. Akiba, S. Sano, T. Yanase, T. Ohta, e M. Koyama, “Optuna: A next-generation hyperparameter optimization framework,” em *KDD '19: Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, A. for Computing Machinery, Ed., Ankur Teredesai and Vipin Kumar. Anchorage, EUA: 25 July 2019, 2019, pp. 2623 – 2631. Disponível em: <https://doi.org/10.1145/3292500.3330701>