



ANÁLISE DA CORRELAÇÃO ENTRE SINAIS DE SENSORES EM TRUQUES FERROVIÁRIOS E O DESGASTE DE RODAS POR MEIO DE SIMULAÇÃO MULTICORPOS.

Theo Trainotti Freire¹; Philipe Augusto de Paula Pacheco²; Matheus Valente Lopes¹,
Auteliano Antunes dos Santos¹

¹Laboratório Ferroviário (Lafer), Universidade Estadual de Campinas (UNICAMP) – Brasil

²Instituto Federal do Sudeste de Minas Gerais (IF Sudeste MG) – Brasil

RESUMO

Este trabalho apresenta uma metodologia para a detecção e classificação do desgaste de rodas ferroviárias (cava) utilizando simulação multicorpos e técnicas de processamento de sinal. O objetivo central consistiu em identificar combinações mínimas de sensores e descritores, dentro de um amplo espaço amostral, capazes de distinguir diferentes níveis de desgaste com elevada precisão. A metodologia baseou-se na extração de descritores de sinais provenientes de sensores triaxiais e na aplicação de Modelos de Misturas Gaussianas (GMM) para a separação das classes de dados. A estratégia de aproximação inicial do GMM foi otimizada através do uso de uma pequena parcela de dados rotulados, o que contribuiu para o sucesso da classificação. Os resultados demonstram que o emprego de sensores triaxiais é fundamental para capturar a dinâmica do contacto roda-trilho, permitindo obter uma *F1-score* médio por classe de 0,98 com um único sensor, e 1,0 com dois. Verificou-se que a sensibilidade do sistema é superior quando os sensores estão posicionados em componentes próximos ao defeito, como o rodeiro ou a travessa lateral, em contraste com a instrumentação na caixa do vagão, que sofre maior atenuação pelos sistemas de amortecimento. A análise dos descritores permitiu a validação física dos achados em conformidade com a teoria de dinâmica ferroviária, evidenciando o potencial da metodologia para aplicações de manutenção baseada na condição.

Palavras-chave: Dinâmica ferroviária; Desgaste de rodas; Simulação multicorpos; Veículo ferroviário instrumentado; Monitoramento baseado em condição; Sensibilidade de sensores.

1. INTRODUÇÃO

A transição das estratégias de manutenção reativa e periódica para a Manutenção Baseada em Condição (CBM) é uma tendência em diversos setores industriais, entre eles, o setor ferroviário (Ahmad, 2012). Ao monitorar continuamente o estado dos componentes, a CBM permite antecipar falhas críticas e otimizar a manutenção de ativos. No contexto do material rodante, essa prática é viabilizada pelos Vagões Instrumentados (*Instrumented Railway Vehicles* – IRVs), que utilizam sensores embarcados para a coleta de dados dinâmicos em tempo real durante a operação comercial (Stow, 2019).

Embora o monitoramento de trens de passageiros seja amplamente documentado, as operações de carga pesada (*heavy haul*) — fundamentais para a economia brasileira (PEREIRA, 2024)— exigem estudos dedicados. As cargas por eixo elevadas e a dinâmica da via aceleram o desgaste de componentes críticos (Yenealem, Redda, & Mohammedseid, 2023; Zhai, Stichel, & Ling, 2025), criando um cenário onde as metodologias de diagnóstico devem ser adaptadas às diversas condições de operação.

Dentre as falhas de superfície de roda, o desgaste do tipo cava é particularmente crítico (Wang Z, 2025), pois altera a geometria da interface roda-trilho e pode comprometer a estabilidade do veículo. Diferentemente do desgaste uniforme, a cava faz com que os pontos de contato se dispersem de forma irregular pela superfície da roda. Esta condição pode levar à formação de um "falso flange", que intensifica a interação roda-trilho e excita vibrações laterais de alta energia, comprometendo a estabilidade lateral do veículo e reduzindo a velocidade crítica (Zhang, Hu, Wang, & Liu, 2025).

Sawley e Wu (2005) já demonstravam que rodas com cava comprometem a capacidade de esterçamento dos truques, elevando a resistência ao rolamento e as forças laterais, o que resulta em maior consumo de combustível e aceleração do desgaste da via. Investigações recentes, como as de Pacheco et al. (2024) focaram no impacto da cava em componentes específicos de vagões de carga, mostrando um aumento significativo das forças na suspensão primária e no prato pião, o que evidencia um ciclo de desgaste interdependente e prejudicial entre a roda e outros elementos do truque. Yang et al. (2023), por sua vez, investigaram a interação entre desgaste e fadiga, destacando como as condições de contato, agravadas por cavas, podem acelerar a degradação do material da roda.

Apesar deste conhecimento consolidado sobre os efeitos da cava, a previsão e o acompanhamento eficiente de sua evolução ainda enfrentam desafios significativos. Atualmente, os métodos mais difundidos para o monitoramento do perfil das rodas baseiam-se em medições de campo com equipamentos como o Miniprof™. Embora ofereça boa precisão, este método é essencialmente manual, demandando muito tempo e mão de obra especializada, o que inviabiliza uma avaliação de alta frequência em toda a frota. Como alternativa, sistemas automatizados *wayside*, como o *Wheel Profile Measurement System* (WPMS), permitem a inspeção de todas as rodas durante a passagem do trem. No entanto, a confiabilidade desses sistemas ainda é limitada por uma faixa de erro considerável (Lopes, Sousa, Santos, & Costa, 2024). Esta lacuna entre a importância do defeito e as limitações das técnicas de monitoramento reforça a necessidade de desenvolver metodologias complementares, como as baseadas em análise de sinais de sensores embarcados, que possam oferecer um diagnóstico indireto, porém contínuo e confiável, da severidade da cava.

Abordagens nessa linha foram exploradas por Kaliorakis (2023), que desenvolveu uma metodologia para a detecção de cava baseada em acelerômetros embarcados, validada tanto em simulação quanto em experimentos. Contudo, tal estudo focou exclusivamente em vagões de passageiros, cuja dinâmica difere substancialmente das operações de carga. Além disso, a referida metodologia permitiu apenas distinguir a presença ou ausência de cava, sem fornecer a magnitude do desgaste. Por fim, embora o uso de modelos autorregressivos tenha apresentado alta precisão estatística, tais modelos carecem de uma interpretação física direta.

Diante do exposto, o presente trabalho tem como objetivo principal propor uma metodologia sistemática para a investigação da correlação entre o desgaste do tipo cava em rodas ferroviárias e as leituras de sensores inerciais (acelerômetros e giroscópios) embarcados. Para tal, a metodologia emprega simulações dinâmicas multicorpos de um vagão ferroviário de carga, utilizando perfis de roda com diferentes profundidades de cava em cenários controlados de via. O objetivo central é identificar quais sensores, eixos de medição e respectivas características estatísticas apresentam maior sensibilidade e poder discriminatório para a detecção e quantificação indireta da profundidade da cava, estabelecendo as bases para o desenvolvimento futuro de um sistema de monitoramento contínuo e baseado em condição.

A formação de cavas nas rodas é um fenômeno de desgaste progressivo que ocorre ao longo de semanas, tornando sua evolução praticamente imperceptível durante uma única viagem. Por essa razão, a obtenção de uma única aferição confiável por ciclo de operação é suficiente para o monitoramento contínuo do componente. Embora a realização de múltiplas medições durante o trajeto pudesse adensar os dados, isso exigiria um método robusto o suficiente para isolar ruídos decorrentes de variações de velocidade, geometrias de via (curvas e tangentes) e condições ambientais. Para mitigar essa complexidade, este trabalho optou por desenvolver um modelo de classificação focado em uma janela operacional específica: via em tangente a velocidade constante. Essa abordagem restringe as variáveis dinâmicas do problema e simplifica a modelagem analítica, mantendo a viabilidade de aplicação prática do sistema, que pode ser programado para realizar a leitura apenas em trechos da malha que atendam a esses requisitos.

Para atingir este objetivo, é fundamental reconhecer que a base de qualquer sistema de diagnóstico confiável reside na qualidade e representatividade dos dados utilizados (Clemmensen, 2022). No contexto ferroviário, a disponibilidade de dados de alta fidelidade é o fator determinante para a eficácia das estratégias de manutenção preditiva. Entretanto, a obtenção de dados experimentais em ambientes operacionais reais apresenta obstáculos significativos. O isolamento de variáveis específicas, como o tamanho exato de uma cava em uma única roda, é complexo em campo. A logística necessária para substituir rodéis e criar combinações controladas de defeitos, aliada à necessidade de registrar a evolução do desgaste a cada viagem e à lentidão natural desse processo de degradação, torna a coleta de dados reais uma tarefa onerosa e de execução demorada. Além disso, as interferências externas da via e as variações de carregamento dificultam a correlação direta entre o sinal do sensor e o nível de falha.

Diante dessas limitações, a simulação de sistemas multicorpos surge como uma alternativa robusta e tecnicamente viável para a geração de dados. O emprego de modelos computacionais permite a exploração controlada de diversos cenários de desgaste e respostas sensoriais sem os custos proibitivos da instrumentação física em larga escala. Além disso, o ambiente virtual possibilita o isolamento de variáveis críticas, garantindo que a sensibilidade do método seja testada frente à severidade da cava sob condições operacionais parametrizadas. Essa abordagem está alinhada com o que (Bobadilla, 2023) define como o estado-da-arte em sistemas de CBM ferroviário: as metodologias híbridas, que integram o rigor físico das simulações computacionais à flexibilidade das técnicas baseadas em dados.

Para alcançar o propósito proposto, este artigo está organizado em cinco seções. A Seção 2 descreve a metodologia empregada, detalhando o modelo de simulação multicorpos, as condições de contorno e os perfis de desgaste analisados. Na Seção 3, é apresentada a metodologia de processamento dos dados. A Seção 4 discute os resultados obtidos, com foco na identificação dos sensores e parâmetros mais sensíveis à evolução da cava, além de perspectivas para trabalhos futuros. Por fim, a Seção 5 traz as conclusões do estudo.

2. SIMULAÇÕES COMPUTACIONAIS

Os dados para a análise do desenvolvimento do desgaste em rodas ferroviárias foram obtidos por meio de simulações dinâmicas multicorpos de um vagão amplamente utilizado nas ferrovias brasileiras, equipado com truques do tipo Ride Control. As simulações fornecem como resultados grandezas como acelerações e deslocamentos,

mensurados por sensores estrategicamente posicionados no truque. Essas grandezas constituem os parâmetros fundamentais para a avaliação do fenômeno do desgaste.

2.1. Modelo Multicorpos

O vagão de referência é um vagão ferroviário de carga de bitola métrica (GDE) equipado com o truque Ride Control. O Ride Control é um truque de três peças com carga por eixo de 27,5 t. A Figura 1 ilustra o vagão modelado empregando o programa SIMPACK®. O modelo de simulação foi previamente desenvolvido e validado em estudos anteriores (Ramos, Correa, Texeira, Kurka, & Santos, 2022; Correa, Ramos, S., Santos, & Santos, 2022; Pacheco, et al., 2024).




Figura 1. Modelo do vagão GDE-Ride Control no SIMPACK®.

O modelo considera todas as não linearidades da suspensão primária, incluindo as rigidezes longitudinal e lateral. A suspensão primária conecta o conjunto de rodas ao pedestal do quadro lateral por meio de um componente de rigidez feito em compósito (PAD) e é representada por três elementos de conexão que incorporam rigidezes verticais, laterais e longitudinais, bem como características de amortecimento (Lima, Baruffaldi, Manetti, Martins, & Santos, 2022).

A suspensão secundária, que conecta a travessa lateral à travessa central, é composta por cinco molas modeladas como elementos elásticos (“*bushing*”) com propriedades de rigidez e amortecimento definidas. Adicionalmente, há quatro cunhas de atrito, modeladas por meio de elementos de contato discretos, que mantêm contato permanente com a lateral e a travessa.

O prato pião é modelado utilizando um elemento mola-amortecedor acoplado a um elemento de atrito não linear. Em contrapartida, os ampara balanço são representados por um elemento elástico (“*bushing*”) com folga, refletindo o fato de que esse tipo de ampara balanço não mantém contato constante.

As forças de contato roda-trilho foram calculadas utilizando o método de Contato Elástico Discreto Semi-Hertziano do SIMPACK®, que calcula as forças normais e tangenciais considerando a geometria real da área de contato (Ayasse & Chollet, 2005).

Por fim, foram instalados cinco acelerômetros em cada travessa lateral, conforme ilustrado na Figura 2. Adicionalmente, foram posicionados giroscópios no centro de cada um dos corpos que compõem o sistema — a saber: caixa do vagão, travessa central, travessas laterais e rodeiros — totalizando seis unidades.




Figura 2. Modelo multicorpos do truque Ride Control no programa SIMPACK, indicando o posicionamento dos acelerômetros ao longo da estrutura.

2.2. Parâmetros de Simulação

Neste estudo, foi utilizada uma via em tangente com 1,05 km de comprimento. A via foi simulada com e sem irregularidades aleatórias. As irregularidades foram incorporadas utilizando funções de densidade espectral de potência (PSD), seguindo a normativa da *Federal Railroad Administration* (FRA), Equações 1-3. Para o presente trabalho foram utilizadas as irregularidades laterais, verticais e cruzadas (de bitola e superelevação) de Classe 4, representadas pelas seguintes equações

$$S_L(\Omega) = \frac{A_a \cdot \Omega_c^2}{\Omega^2 \cdot (\Omega^2 + \Omega_c^2)} \quad (1)$$

$$S_V(\Omega) = \frac{A_v \cdot \Omega_c^2}{\Omega^2 \cdot (\Omega^2 + \Omega_c^2)} \quad (2)$$

$$S_C(\Omega) = \frac{(A_a/b_i^2) \cdot \Omega_c^2}{(\Omega^2 + \Omega_s^2) \cdot (\Omega^2 + \Omega_c^2)} \quad (3)$$

nas quais Ω denota a frequência angular espacial; Ω_c , Ω_s denotam o número de onda crítico; A_a , A_v denotam os coeficientes de rugosidade; b_i denota a distância de referência entre os trilhos (bitola). A Tabela 1 apresenta os coeficientes, que variam em uma escala de 1 a 6, na qual os valores mais baixos representam a pior qualidade e os mais altos, a melhor qualidade.

Em conformidade com o objetivo deste trabalho, que consiste em propor uma metodologia sistemática para investigar a correlação causal entre o desgaste de rodas ferroviárias e as leituras de acelerômetros e giroscópios, foram analisados quatro níveis de desgaste medidos pela profundidade da cava: 0 mm (roda nova), 1 mm, 2 mm e 3 mm. Para tanto, foram adotados os mesmos perfis de roda empregados por Pacheco e colaboradores (Pacheco P. , Lopes, Costa, Santos, & Santos, 2024) (Figura 3). Para o trilho, adotou-se o perfil TR68, sem desgaste, com inclinação de 1:40. A velocidade é mantida constante em 60 km/h para todas as simulações, o que representa a velocidade operacional da ferrovia.

Tabela 1. Parâmetros da PSD para irregularidades FRA (Do, 2020).

Classes	A_v [cm ² rad/m]	A_a [cm ² rad/m]	Ω_s^2 [rad/m]	Ω_c^2 [rad/m]
1	1,2107	3,3634	0,6046	0,8245
2	1,0181	1,2107	0,9308	0,8245
3	0,6816	0,4128	0,8520	0,8245
4	0,5376	0,3027	1,1312	0,8245
5	0,2095	0,0762	0,8209	0,8245
6	0,0339	0,0339	0,4380	0,8245




Figura 3. Perfis de roda com cava utilizados no presente estudo [adaptado de (Pacheco P. , Lopes, Costa, Santos, & Santos, 2024)].

Para cada condição paramétrica avaliada, foram realizadas 200 simulações considerando a presença de irregularidades aleatórias na via, conforme o padrão da classe 4 da FRA. Adicionalmente, conduziu-se uma simulação complementar para cada parâmetro na ausência de tais irregularidades, a fim de estabelecer uma condição de referência. Os dados resultantes das simulações foram adquiridos com frequência de amostragem simulada de 100 Hz.

3. Processamento dos Dados

Após a obtenção dos dados provenientes das simulações realizadas, as séries temporais foram organizadas para permitir a identificação de padrões em perfis de roda idênticos e a detecção de divergências estruturais entre as diferentes classes de desgaste da cava. Cada simulação gerou sinais de aproximadamente 63 segundos e taxa de amostragem de 100 Hz. Todos os sinais foram padronizados com uma extensão final de exatamente 6.000 pontos.

O conjunto de dados consolidado é composto por medições provenientes de 16 sensores distintos (listados na **Tabela 2**), os quais monitoram grandezas associadas aos eixos longitudinal (x), transversal (y), vertical (z) e à magnitude absoluta. Considerando as quatro classes de severidade da cava, as 200 simulações realizadas por classe, os 16 sensores e as 4 magnitudes de cada sensor, o conjunto de dados consolidado totaliza 51.200 séries temporais.

Uma inspeção visual inicial foi conduzida para comparar os sinais no domínio do tempo, conforme exemplificado na **Figura 4a**. Entretanto, essa análise não revelou discrepâncias claras ou padrões consistentes entre os diferentes níveis de desgaste da roda. Buscando evidenciar possíveis assinaturas da falha, os sinais foram transformados para o domínio da frequência para a avaliação de suas Densidades Espectrais de Potência (PSD), ilustradas na **Figura 4b**. Contudo, a análise dos espectros também se mostrou inconclusiva, sem diferenças evidentes nos picos de frequência ou nas variações de amplitude. Para aprofundar a investigação, comparou-se o comportamento de sinais pertencentes à mesma classe de desgaste, mas originados de experimentos distintos (**Figura 5**). Observou-se que, mesmo sob condições idênticas de desgaste e geometria de via, emergem comportamentos discrepantes decorrentes puramente da variação estocástica do perfil de irregularidade da linha. Diante da sobreposição de características entre classes distintas e da alta variabilidade dentro de uma mesma classe, uma inspeção visual abrangente englobando diversos perfis e sensores confirmou a inviabilidade de se extrair tendências de forma manual.

Tabela 2: Siglas dos sensores usados, seus tipos e posições. Em conformidade com a **Figura 2**.

Sigla	Tipo de Sensor	Posição
A_1_L	Acelerômetro	Frente Superior da Travessa Lateral Esquerda
A_2_L	Acelerômetro	Centro Superior da Travessa Lateral Esquerda
A_3_L	Acelerômetro	Traseira Superior da Travessa Lateral Esquerda
A_4_L	Acelerômetro	Frente Inferior da Travessa Lateral Esquerda
A_5_L	Acelerômetro	Traseira Inferior da Travessa Lateral Esquerda
A_1_R	Acelerômetro	Frente Superior da Travessa Lateral Direita
A_2_R	Acelerômetro	Centro Superior da Travessa Lateral Direita
A_3_R	Acelerômetro	Traseira Superior da Travessa Lateral Direita
A_4_R	Acelerômetro	Frente Inferior da Travessa Lateral Direita
A_5_R	Acelerômetro	Traseira Inferior da Travessa Lateral Direita
G_Bo	Giroscópio	Centro da Travessa
G_SF_L	Giroscópio	Centro da Travessa Lateral Esquerda
G_SF_R	Giroscópio	Centro da Travessa Lateral Direita
G_Wa	Giroscópio	Centro do Vagão
G_Wh_B	Giroscópio	Centro do Rodeiro Traseiro
G_Wh_F	Giroscópio	Centro do Rodeiro Dianteiro




Figura 4: Séries temporais obtidas com diferentes tamanhos de cava pelo sensor G_SF_R em valor absoluto (a) e suas respectivas PSDs (b).




Figura 5: Séries temporais obtidas para diferentes experimentos com rodas novas pelo sensor G_SF_R em valor absoluto (a) e suas respectivas PSDs (b).

3.1. Análise de Características dos Sinais

Dada a insuficiência da observação direta dos sinais brutos e espectrais, se faz necessária a extração de atributos estatísticos, ou *features*, nos domínios do tempo e da frequência (Bendat, 2011). Essa abordagem visa sintetizar a informação contida nas 51.200 séries temporais em indicadores quantitativos sensíveis à evolução da cava, permitindo identificar quais sensores e eixos de medição possuem maior capacidade discriminatória para o diagnóstico da falha.

Para as séries temporais, computou-se um conjunto de sete indicadores: média, desvio padrão, valor máximo absoluto, raiz quadrada média (RMS), assimetria (*skewness*), curtose (*kurtosis*) e taxa de cruzamento por zero (*zero crossing rate*).

Complementarmente, a partir da distribuição no domínio da frequência do sinal, foram obtidos oito atributos espectrais: média, desvio padrão, máximo absoluto, frequência dominante, centroide espectral, largura de banda (*bandwidth*), entropia e RMS espectral. A **Tabela 3** detalha a nomenclatura, as siglas utilizadas, as definições físicas e as expressões matemáticas correspondentes a cada um desses métodos de cálculo.

Tabela 3: Siglas, nomes, equações e domínios de atuação dos descritores utilizados.

Sigla	Domínio	Nome da Feature	Equação (Simplificada)
mean_t	Tempo	Média Aritmética	$\frac{1}{N} \sum x_i$
std_t	Tempo	Desvio Padrão	$\sqrt{\text{Var}(x)}$
abs_max_t	Tempo	Valor Máximo Absoluto	$\max(x)$
rms_t	Tempo	Raiz da Média dos Quadrados	$\sqrt{\frac{1}{N} \sum x_i^2}$
skew_t	Tempo	Obliquidade (Skewness)	$E[(x - \mu)^3]/\sigma^3$
kurt_t	Tempo	Curtose (Kurtosis)	$E[(x - \mu)^4]/\sigma^4$
zcr_t	Tempo	Taxa de Cruzamento por Zero	N/A
mean_f	Frequência	Média do Espectro	$\frac{1}{M} \sum S_j$
std_f	Frequência	Desvio Padrão Espectral	$\sqrt{\text{Var}(S)}$
abs_max_f	Frequência	Pico Espectral Máximo	$\max(S)$
dom_freq_f	Frequência	Frequência Dominante	$\arg \max(S)$
centroid_f	Frequência	Centroide Espectral	$\frac{\sum f_j \cdot S_j}{\sum S_j}$
bandwidth_f	Frequência	Largura de Banda	$\sqrt{\text{Var}(f)}$
entropy_f	Frequência	Entropia Espectral	$-\sum P_j \ln(P_j)$
rms_f	Frequência	RMS Espectral	$\sqrt{\frac{1}{M} \sum S_j^2}$

A extração desses parâmetros permitiu reduzir a dimensionalidade do banco de dados original, de 6.000 pontos por série para apenas 15 atributos por sensor/eixo,

facilitando a comparação estatística entre os diferentes níveis de severidade da falha e a identificação dos sensores com maior sensibilidade diagnóstica.

3.2. Seleção de melhores sensores e descritores

Ao agrupar os dados por combinações de sensor (16), direção (4) e descritores (15), obtiveram-se 960 distribuições. Cada uma dessas distribuições é composta por 800 amostras, representando a totalidade dos experimentos realizados (200 por classe de cava).

Com o intuito de otimizar o espaço amostral e eliminar redundâncias, aplicaram-se dois critérios de filtragem. Primeiramente, aproveitou-se a simetria do material rodante: para sensores posicionados em locais equivalentes no vagão, foram considerados apenas os dados provenientes do lado direito. Em seguida, as distribuições remanescentes foram submetidas a uma análise de correlação (**Figura 6**). Esse teste revelou que a média, o desvio padrão e o RMS do espectro de frequências apresentavam comportamento estatístico altamente similar ao desvio padrão das séries temporais, com correlação superior a 0,98. Consequentemente, esses descritores foram descartados por não agregarem informação independente ao modelo. Após esse processo de seleção, o conjunto de dados foi reduzido para 528 combinações fundamentais (11 sensores, 4 direções e 12 descritores).




Figura 6: matriz de correlação entre os descritores dos sinais.

Dada a ainda elevada dimensionalidade desse conjunto, tornou-se necessário adotar um método capaz de ranquear as combinações com base em sua eficiência na

separação das classes de desgaste. Para este fim, utilizou-se o algoritmo *ReliefF* (Robnik-Šikonja, 2003).

A intuição por trás do *ReliefF* reside na sua capacidade de avaliar a qualidade das características com base em quão bem seus valores distinguem amostras que estão próximas umas das outras no espaço de busca. Diferente de métodos que analisam as variáveis de forma isolada, o *ReliefF* é sensível a interações entre atributos.

O funcionamento do algoritmo baseia-se em um processo iterativo: é selecionado aleatoriamente uma amostra do banco de dados e busca-se seus vizinhos mais próximos, tanto da mesma classe (*near-hits*) quanto de classes diferentes (*near-misses*). A essa amostra, se associa uma pontuação, de forma que:

- Se a amostra e seus *near-hits* possuem valores muito diferentes para um determinado descritor, o peso desse descritor é reduzido;
- Se a amostra e seus *near-misses* possuem valores muito diferentes, o peso do descritor é aumentado.

Dessa forma, ao final do processo, o *ReliefF* fornece um *ranking* onde as maiores pontuações indicam os sensores, direções e descritores que melhor capturam a assinatura dinâmica da cava, permitindo identificar indicadores mais sensíveis para o diagnóstico ferroviário.

Embora o ranqueamento via *ReliefF* seja eficaz para identificar a sensibilidade individual de cada descritor, ele não é suficiente para garantir a formação de um conjunto otimizado de diagnóstico. Variáveis que apresentam alto desempenho individual podem ser altamente correlacionadas, introduzindo redundância e elevando desnecessariamente o custo computacional e de instrumentação. Para viabilizar essa identificação, torna-se necessário o desenvolvimento de uma métrica de avaliação robusta que permita comparar quantitativamente diferentes arranjos de dados.

O Modelo de Misturas Gaussianas (GMM) (Reynolds, 2009) foi adotado como o núcleo desta métrica de avaliação por ser uma abordagem de agrupamento (*clustering*) probabilística altamente flexível. O GMM assume que os dados são gerados a partir de uma combinação de várias distribuições normais, cada uma com seus próprios parâmetros de média e covariância. Ao contrário de algoritmos de agrupamento rígido, o GMM atribui a cada ponto uma probabilidade de pertencer a cada grupo, o que o torna ideal para lidar com a sobreposição dos sinais.

Para elevar a precisão do modelo nos experimentos deste artigo, aplicou-se uma adaptação na fase de inicialização: uma pequena parcela dos dados (5% das amostras de cada classe, totalizando cerca de 10 por classe) foi utilizada para estimar os parâmetros iniciais das gaussianas. Essa estratégia de semi-supervisão pode acelerar significativamente o processo de convergência do modelo e garantir que cada distribuição gaussiana esteja previamente associada a uma classe real de cava.

A fim de garantir que as gaussianas finais calculadas pertencessem à mesma classe que os pontos usados para sua aproximação inicial, utilizou-se o algoritmo conhecido como Método Húngaro (Kuhn, 1955), para realizar o mapeamento entre os *clusters* identificados e as classes reais. Assim, a separabilidade é convertida em uma métrica de desempenho clássica, o *F1-score* (Yacoub, 2020) médio por classe, que varia de 0 a 1, de forma a melhor avaliar métodos que tenham uma menor taxa de falsos positivos e falsos negativos.

Com a métrica de avaliação estabelecida, implementou-se um algoritmo de busca exaustiva estruturado para explorar o vasto espaço de possibilidades de instrumentação e extração de características. O algoritmo opera de forma sistemática em três níveis:

1. **Espaço de Sensores:** O algoritmo inicia testando todas as combinações possíveis de um a três sensores. Para cada combinação de sensores selecionada, o modelo recupera as k combinações de descritores e direções de maior relevância individual (conforme o ranking do *ReliefF*) associados a cada sensor, criando um conjunto de candidatos pré-filtrado.
2. **Espaço de Características e Dimensionalidade:** Definido o conjunto de descritores candidatos, o algoritmo realiza uma nova varredura exaustiva, testando todas as combinações possíveis desses atributos em espaços de uma a cinco dimensões. Esta etapa permite identificar interações não lineares entre descritores de diferentes sensores que, embora possam parecer irrelevantes isoladamente, apresentam alto poder discriminatório quando combinados.
3. **Avaliação e Armazenamento:** Para cada projeção dimensional gerada, o GMM é executado e o *F1-score* médio é calculado. O algoritmo armazena a combinação específica de sensores, direções de medição, descritores, dimensionalidade do espaço e a pontuação obtida.

Essa abordagem exaustiva minimiza a chance de combinação potencialmente ótima ser negligenciada. O resultado deste processo é um mapeamento completo da capacidade diagnóstica de cada configuração de instrumentação, permitindo selecionar o conjunto de sensores que oferece a precisão necessária com o menor custo de hardware possível. Os dados resultantes desta análise são detalhados na seção a seguir.

3. RESULTADOS E DISCUSSÃO

A partir da busca exaustiva, foram identificadas as combinações de um a três sensores que, associadas aos descritores de maior relevância, maximizam a separabilidade das classes de cava através do modelo GMM em espaços de uma a cinco dimensões.

O melhor desempenho unidimensional foi obtido pelo valor absoluto do sinal do giroscópio da travessa lateral direita (G_SF_R), conforme apresentado na **Figura 7**. Através dos *box-plots*, observa-se que as distribuições referentes aos estados "sem cava" (0 mm) e "cava máxima" (3 mm) apresentam-se paradoxalmente próximas, com uma frequência média mais baixa em comparação às demais. Por outro lado, as classes de 1 mm e 2 mm também se agrupam entre si, porém com uma frequência média superior. O histograma conjunto na mesma figura confirma essa tendência, evidenciando uma inseparabilidade crítica entre esses dois grupos de classes quando analisados sob apenas uma dimensão. Esse fenômeno pode ser robustamente explicado pelas dinâmicas de contato roda-trilho não-lineares associadas a diferentes estágios de desgaste de cava. Trata-se, essencialmente, do reflexo direto da transição entre regimes de contato roda-trilho fundamentalmente distintos: de um lado, um regime de desgaste progressivo, correspondente às cavidades de 1 mm e 2 mm, no qual o aumento da atividade dinâmica decorre da alteração da conicidade equivalente; de outro, um regime de desgaste severo, característico da cavidade de 3 mm, no qual a formação do friso falso impõe uma dinâmica substancialmente diferente. Nesse contexto, embora métricas unidimensionais específicas — como a frequência do sinal de aceleração angular — possam sugerir, do ponto de vista estatístico, uma similaridade entre a condição de desgaste severo e a condição de roda nova (0 mm), tal proximidade decorre de mecanismos físicos completamente diversos, o que reforça a complexidade da análise e a necessidade de interpretação multifatorial dos resultados.




Figura 7: Distribuição dos centroides da PSD do sensor G_SF_R (valores absolutos) para cada valor de cava: *Box-plot* (à esquerda) e *histograma* (à direita)

Os modelos bidimensionais via GMM trouxeram melhorias significativas na capacidade discriminatória do sistema. A **Figura 8** apresenta os dois melhores resultados obtidos para espaços de duas dimensões, utilizando um e dois sensores, respectivamente. Em ambos os cenários, confirma-se a alta sensibilidade do giroscópio da travessa lateral (G_SF_R).

A primeira combinação utiliza exclusivamente o sensor G_SF_R, associando seu componente absoluto ao sinal de rotação em torno do eixo z. Este arranjo alcançou um *FI-score* médio de 0,916. A segunda combinação, que atingiu um melhor desempenho, com *FI-score* médio de 0,946, utiliza o sinal absoluto do sensor G_SF_R em conjunto com o sinal de rotação em torno do eixo y (movimento de arfagem) do sensor localizado no rodeiro traseiro (G_Wh_B).

Como pode ser observado na **Figura 8**, essas combinações bidimensionais foram consideravelmente mais eficazes na distinção dos dados. Notavelmente, os componentes adicionados em relação à análise unidimensional corrigiram a sobreposição anterior: tanto no eixo z de G_SF_R quanto no eixo y de G_Wh_B, a classe de 3 mm passa a apresentar uma frequência média superior a todas as outras. Este resultado alinha-se às observações de Pacheco et al. (Pacheco P. , Lopes, Santos, & Santos, 2025), que demonstraram que, para cavidades de 3 mm, o contato desloca-se para a região oposta ao friso, concentrando-se na área do friso falso e provocando incrementos na aceleração lateral e na dissipação de energia no contato roda-trilho. Isso permitiu ao modelo isolar com precisão a condição de desgaste severo (3 mm) da condição de roda íntegra (0 mm), superando a ambiguidade observada anteriormente.

Ao analisar o mapa de calor (*heatmap*) da contribuição individual de cada sensor, presente na **Figura 9**, observa-se que, mesmo utilizando cinco dimensões (cinco descritores) no modelo GMM, não foi possível atingir a pontuação ideal de 1,0 para o *FI-score*. Entretanto, sensores localizados no rodeiro frontal, nas travessas laterais e o sensor A_1_R apresentaram um desempenho satisfatório, com *FI-score* médio superior a 0,95.




Figura 8: Melhores combinações de sensores, descritores e direções usando um sensor (acima), e dois sensores (abaixo). Gráficos (a) e (d) mostram os dados rotulados e não rotulados usados como entrada do GMM; gráficos (b) e (e) mostram as classes preditas para cada ponto e as áreas preditas de cada classe; gráficos (c) e (f) mostram os dados e seus rótulos originais. Eixos dos gráficos (a), (b) e (c) mostram o centroide do sensor G_SF_R absoluto (horizontal) e em torno de z (vertical). Eixos dos gráficos (d), (e) e (f) mostram o centroide do sensor G_SF_R absoluto (horizontal) e G_Wh_B em torno de y (vertical).

Também pode ser observado que a eficiência do diagnóstico aumenta significativamente ao considerar combinações de dois sensores: nesse cenário, todos os instrumentos analisados participaram de ao menos um arranjo com pontuação mínima de 0,99, com alguns casos atingindo o valor máximo de 1,0. Nas combinações compostas por três sensores, essa eficácia plena foi observada para todos os sensores do conjunto experimental.

O segundo mapa de calor da **Figura 9** detalha os melhores resultados obtidos para cada par específico de sensores. Os dados confirmam o elevado desempenho dos giroscópios nos rodeiros e do sensor A_2_R que, em qualquer combinação testada, mantiveram resultados de, ao menos, 0,99. Em contrapartida, o sensor posicionado no corpo do vagão apresentou os índices de sensibilidade mais baixos da pesquisa, embora seus piores resultados ainda tenham mantido um *F1-score* de 0,92.

Estes resultados são fisicamente coerentes com a dinâmica ferroviária. Espera-se que os sensores nos rodeiros sejam os mais sensíveis aos efeitos da cava, por estarem em contato direto com o elemento que apresenta o defeito. Da mesma forma, os sensores nas travessas laterais demonstram alta sensibilidade por estarem posicionados imediatamente acima das rodas, contando apenas com a suspensão primária para mitigar as vibrações. Por fim, a menor sensibilidade do sensor no corpo do vagão justifica-se por este estar

dinamicamente mais afastado e isolado da interface roda-trilho pelos dois estágios de suspensão, o que atenua a assinatura do defeito no sinal capturado.




Figura 9: Melhor desempenho de cada sensor para cada número de sensores utilizados em qualquer dimensão do GMM, e melhor desempenho de cada combinação específica de dois sensores para GMM em duas dimensões.

Por fim, a análise da **Figura 10** permite avaliar o impacto do número de sensores e da dimensionalidade do modelo GMM na separabilidade das classes. Observa-se que, para qualquer dimensão testada, o melhor desempenho obtido com apenas um sensor mantém-se a uma distância máxima de 0,03 no *F1-score* em relação aos arranjos com dois ou três sensores. Esse comportamento demonstra que, embora a redundância espacial ajude na robustez, um único instrumento já é capaz de fornecer níveis elevados de separabilidade para o diagnóstico da cava, se posicionado corretamente.

Em relação à dimensionalidade do espaço de características, nota-se um crescimento expressivo na precisão conforme novos descritores são integrados à análise. Esse ganho é mais acentuado até a quarta dimensão, que apresentou os melhores resultados globais ou índices praticamente indistinguíveis daqueles obtidos com cinco dimensões. Isso sugere que, para este problema específico, um conjunto de quatro descritores representa o ponto de saturação da informação útil para o modelo.

É importante ressaltar que os sensores foram tratados em sua configuração triaxial. Conforme observado nos resultados anteriores, a agregação de informações de um mesmo tipo de sensor e posição, porém em direções distintas, contribui significativamente para o poder discriminatório do sistema. A análise sugere que a diversidade direcional dos sinais captura nuances da dinâmica do vagão que seriam perdidas em análises unidimensionais, validando a escolha pela instrumentação triaxial.

A partir dessas observações, vislumbram-se oportunidades para o aprimoramento da técnica em estudos subsequentes. A validação da metodologia com dados experimentais e a investigação da influência da rotulação inicial no desempenho do GMM são etapas fundamentais para a sua consolidação. Além disso, a comparação com modelos autorregressivos e a realização de testes de *benchmark* poderão evidenciar ganhos em eficiência de cálculo. Outras frentes de expansão envolvem a adaptação do modelo para trajetos mais longos em vias complexas, a avaliação da metodologia em cenários com diferentes irregularidades de via e carga nos vagões, o teste de sensibilidade para

diferentes gradientes de desgaste em múltiplas rodas, a avaliação da robustez do sistema mediante a adição de ruído e, por fim, a aplicação desta mesma abordagem na detecção de outros defeitos mecânicos no vagão. Esta última aplicação está em consonância com o objetivo de criar um vagão auto-inspecionável, capaz de informar qual é o risco atual em mantê-lo em serviço, permitindo a definição do melhor momento para a manutenção.




Figura 10: Desempenho máximo de *F1-score* medio por dimensão do GMM e número de sensores utilizados.

4. CONCLUSÃO

O presente estudo permitiu o desenvolvimento e a validação de uma metodologia eficaz para a identificação de desgaste em rodas ferroviárias (cava), utilizando simulações multicorpos e técnicas de processamento de sinal. A abordagem proposta foi capaz de filtrar, dentro de um extenso espaço amostral de sensores triaxiais e descritores, as combinações mínimas necessárias para distinguir a presença e a intensidade da cava com elevada precisão.

Os resultados demonstram que a utilização de um conjunto reduzido de instrumentos, apenas um ou dois sensores, é suficiente para obter uma separabilidade robusta das classes de desgaste, desde que se utilizem sensores triaxiais, que se revelaram essenciais para capturar a complexidade da dinâmica do contacto roda-trilho. A análise através de descritores de sinais não só permitiu a automatização do processo, como levou a uma fundamentação física dos resultados, validando os achados perante a teoria estabelecida de dinâmica ferroviária.

No que concerne à localização dos sensores, observou-se que o posicionamento em componentes mais próximos da interface de contacto, como o rodeiro ou a travessa lateral, oferece uma sensibilidade superior, como esperado. Em contrapartida, a instrumentação na caixa do vagão apresenta um desempenho inferior devido à atenuação provocada pelas suspensões primária e secundária. Contudo, verificou-se que a combinação de dois sensores triaxiais, independentemente da sua localização, assegura resultados satisfatórios para a detecção do problema.

Por fim, a aplicação do modelo de Misturas Gaussianas mostrou-se adequada para a classificação dos dados. O sucesso do algoritmo foi potenciado pela estratégia de aproximação inicial utilizando uma pequena parcela de dados rotulados, o que conferiu maior estabilidade ao processo de separação das classes.

5. AGRADECIMENTOS

Os autores desejam expressar seu agradecimento à Vale S.A. pelo financiamento deste estudo (processo nº 23068.043918/2025-21) e pelo apoio técnico. Também ao CNPq (Processo nº: 303582/2023-5), concedente da bolsa de produtividade de um dos autores.

6. REFERÊNCIAS

- Ahmad, R. &. (2012). An overview of time-based and condition-based maintenance in industrial application. *Computers & industrial engineering*, 63(1), 135-149.
- Ayasse, J., & Chollet, H. (2005). Determination of the wheel rail contact patch in semi-Hertzian conditions. *Vehicle System Dynamics*, 43(3), pp. 161-172. doi:<https://doi.org/10.1080/00423110412331327193>
- Bendat, J. S. (2011). *Random data: analysis and measurement procedures*. New Jersey: John Wiley & Sons.
- Clemmensen, L. H. (2022). Data representativity for machine learning and ai systems. arXiv preprint.
- Correa, P. H., Ramos, P. G., S., T. L., Santos, G. F., & Santos, A. A. (2022). Dynamic simulation of a heavy-haul freight car under abnormal braking application on tangent and curve. *Vehicle System Dynamics*, pp. 1-16. doi:<https://doi.org/10.1080/00423114.2022.2113807>
- Do, N. T. (2020). Evaluating Track Stiffness and Rail Bending Moments using Vertical Track Deflection Measurements Considering the Effects of Track Geometry. *PhD Thesis, Departament of Civil and Environmental Engineering, University of Alberta*.
- Kaliorakis, N. S. (2023). On-board random vibration-based robust detection of railway hollow worn wheels under varying traveling speeds. *Machines*, 933.
- Kuhn, H. W. (1955). The Hungarian method for the assignment problem. *Naval Research Logistics*, 83-97.
- Lima, E. A., Baruffaldi, L. B., Manetti, J. L., Martins, T. S., & Santos, A. A. (2022). Effect of truck shear pads on the dynamic behaviour of heavy haul railway cars. *Vehicle System Dynamics*, 60(4), 1188-1208. doi:<https://doi.org/10.1080/00423114.2020.1858120>
- Lopes, L. R., Sousa, L. F., Santos, F. C., & Costa, S. S. (2024). Aplicação de aprendizagem de máquina como estratégia para aumento de precisão de dados de profundidade de cava fornecido por equipamentos waysides. In: *Anais do VII Simpósio de Engenharia Ferroviária. Anais*. Campinas. doi:10.29327/vii-simposio-de-engenharia-ferroviaria-410736.806970
- Nussbaumer, H. J. (1981). *Fast Fourier transform and convolution algorithms*. Berlin: Springer.
- Pacheco, P. A., Magelli, M., Lopes, M. V., Correa, P. A., Zampieri, N., Bosso, N., & Santos, A. A. (2024). The effectiveness of different wear indicators in quantifying wear on railway wheels of freight wagons. *Railway Engineering Science*. doi:<https://doi.org/10.1007/s40534-024-00334-8>

- Pacheco, P., Lopes, M., Costa, M., Santos, G., & Santos, A. (2024). Impact of wheel hollow wear on heavy-haul vehicle components. *Proceedings of the Sixth International Conference on Railway Technology: Research, Development and Maintenance*. doi:10.4203/ccc.7.9.11
- Pacheco, P., Lopes, V., Santos, G., & Santos, A. (2025). Impact of worn wheel profiles on energy dissipation. *International Mechanical Engineering Congress & Exposition*.
- Pacheco, P., Reis, T., Ramos, P., Santos, G. d., & Santos, A. d. (2023). Wear and fatigue-oriented wheel profile optimized for heavy haul. *VI Simpósio de Engenharia Ferroviária*. Campinas. doi: 10.17648/sef-2023-165737
- PEREIRA, C. M. (2024). Challenges of decarbonization program in Brazilian rail systems: a study of the heavy haul and passenger railway. Brasília, Brazil: Instituto de Transporte e Logística.
- Ramos, P., Correa, P., Texeira, L., Kurka, P., & Santos, A. (22-25 de August de 2022). Dynamic Effect of Hollow-Worn Wheels for Freight Rail Vehicles in a Consist. *Proceedings of the Fifth International Conference on Railway Technology: Research, Development and Maintenance*. doi:doi: 10.4203/ccc.1.21.4
- Reynolds, D. A. (2009). Gaussian mixture models. *Springer City*, 659-663.
- Robnik-Šikonja, M. &. (2003). Theoretical and empirical analysis of ReliefF and RReliefF. *Machine learning*, 23-69.
- Sawley, K., & Wu, H. (2005). The formation of hollow-worn wheels and their effect on wheel/rail interaction. *Wear*, 258, pp. 1179–1186. doi:doi:10.1016/j.wear.2004.03.029
- Stow, J. (2019). Field Testing and Instrumentation of Railway Vehicles. Em S. S. Iwnicki, *Handbook of Railway Vehicle Dynamics, Second Edition (2nd ed.)* (pp. 723-760). CRC Press.
- Wang Z, G. D. (2025). A survey on countermeasures of railway vehicle stability decrease caused by the evolution of hollow-worn wheels. *Journal of Vibration and Control*, 864-877.
- Yacoub, R. &. (2020). Probabilistic extension of precision, recall, and f1 score for more thorough evaluation of classification models. *Proceedings of the first workshop on evaluation and comparison of NLP systems*, 79-91.
- Yang, Y., Ling, L., Wang, J., & Zhai, W. (2023). A numerical study on tread wear and fatigue damage of railway wheels subjected to anti-slip control. *Friction*, 11, pp. 1470–1492. doi:10.1007/s40544-022-0684-8
- Yenealem, H. G., Redda, D. T., & Mohammedseid, A. (2023). Influence of Axle Load on the Wear of Railway Wheel Material. *Hindawi Modelling and Simulation in Engineering*. doi:10.1155/2023/6730640
- Zhai, W., Stichel, S., & Ling, L. (2025). Train-track coupled dynamics problems in heavy-haul rail transportation. *Vehicle System Dynamics*, 63, pp. 1187–1240. doi:10.1080/00423114.2025.2494834
- Zhang, L., Hu, J., Wang, C., & Liu, Z. (2025). The Impact of Hollow Wear on the Stability of High-Speed Railway Vehicles. *Appl. Sci.*, 15. doi:10.3390/app15074060

ANALYSIS OF THE CORRELATION BETWEEN SENSOR SIGNALS IN RAILWAY BOGIES AND WHEEL WEAR THROUGH MULTIBODY SIMULATION

ABSTRACT

This study presents a methodology for the detection and classification of railway wheel wear (hollow wear) using multibody simulation and signal processing techniques. The primary objective was to identify minimal combinations of sensors and features within a broad sample space capable of distinguishing different levels of wear with high accuracy. The methodology was based on the extraction of features from triaxial sensor signals and the application of Gaussian Mixture Models (GMM) for data class separation. The GMM initialization strategy was optimized using a small portion of labeled data, which contributed to the classification's success. The results demonstrate that employing triaxial sensors is essential for capturing wheel-rail contact dynamics, achieving an average F1-score per class of 0.98 with a single sensor and 1.0 with two. It was found that system sensitivity is higher when sensors are positioned on components close to the defect, such as the wheelset or the side frame, in contrast to instrumentation on the car body, which experiences greater signal attenuation from the damping systems. Feature analysis allowed for the physical validation of the findings in accordance with railway dynamics theory, highlighting the methodology's potential for condition-based maintenance applications.

Keywords: Railway dynamics; Wheel wear; Multibody simulation; Instrumented railway vehicle; Condition based monitoring; Sensor sensibility.