

Avaliação da Condição da Via Permanente usando Dados de Dinâmica de Veículos Ferroviários: Uma Abordagem de Aprendizado de Máquina

Pedro H. O. Silva * Raphael D. Marotta ** Augusto S. Cerqueira *
Erivelton G. Nepomuceno *** Luiz A. S. Lopes ****

* *Programa de Pós-Graduação em Engenharia Elétrica,
Universidade Federal de Juiz de Fora, MG, Brasil,*

(*e-mail: silva.pedro@engenharia.ufjf.br, agosto.santiago@ufjf.edu.br*).

** *VLI Multimodal e Programa de Pós-Graduação em Engenharia de
Transportes, Instituto Militar de Engenharia (IME), RJ, Brasil,
(e-mail: raphael.marotta@vli-logistica.com.br)*.

*** *Centre for Ocean Energy Research Department of Electronic
Engineering Maynooth University, Ireland
(e-mail: erivelton.nepomuceno@mu.ie)*.

**** *Programa de Pós-Graduação em Engenharia de Transportes,
Instituto Militar de Engenharia (IME), RJ, Brasil,
(e-mail: laslopes@ime.eb.br)*.

Abstract: The safety and stability of freight train operations are closely related to the wheel-rail contact dynamic forces. To evaluate and monitor wheel-rail dynamic forces based on the accelerations of the wagon components, a methodology based on data processing and machine learning methods was developed. The experimental results show adequate performance, identifying critical values that relate to the condition of the railway. The model obtained helps railway specialists in the assessment of the quality of the railway, showing georeferenced indicators.

Resumo: A segurança e a estabilidade das operações de trens de carga estão intimamente relacionadas às forças dinâmicas de contato roda-trilho. Para avaliar e monitorar as forças dinâmicas roda-trilho com base nas acelerações dos componentes do vagão, foi desenvolvido uma metodologia baseada em métodos de processamento de informação e aprendizado de máquina. Os resultados experimentais validam o modelo, identificando criticidades que se relacionam com a condição da via. O modelo obtido auxilia os especialistas ferroviários na avaliação da qualidade da via, mostrando indicadores georreferenciados.

Keywords: rail defects; track quality; machine learning; acceleration data; wheel-rail contact dynamic forces; railroad dynamics.

Palavras-chaves: defeitos em via; qualidade da via; aprendizado de máquina; dados de aceleração; forças dinâmicas de contato roda-trilho; dinâmica ferroviária.

1. INTRODUÇÃO

Os sistemas ferroviários são um dos meios de transporte mais importantes e desempenham um papel crucial na economia mundial, sendo um tipo de transporte econômico e seguro. Por mais promissora que seja a indústria, uma parte significativa do orçamento é continuamente comprometida com reparos e manutenção (Federal Railroad Administration, 2013). Os descarrilamentos causados pela geometria da via compreendem uma parcela significativa dos acidentes ferroviários em todo o mundo, consistindo em 40% do total de acidentes (Lasisi and Attoh-Okine, 2018).

A demanda pela ferrovia está aumentando em diversos países, provocando um aumento da carga e velocidade do material rodante. A alta carga e velocidade do material rodante deterioram a infraestrutura da via permanente, e os defeitos ferroviários mais graves ocorrem quando a deterioração atinge um certo nível. A condição das vias férreas é um fator importante para garantir a operação segura dos trens, sendo necessário manter e gerenciar os trilhos adequadamente, incluindo manutenções preventivas (Tsunashima et al., 2014). Portanto, uma ferramenta para detectar e avaliar a gravidade dos defeitos da via é necessária para melhorar a capacidade de manutenção ferroviária.

Nos últimos anos, surgiram novas abordagens para monitorar a qualidade da via, como as medições de aceleração (medições dinâmicas), sendo um meio útil para obter

* Agradecemos à CAPES, VLI Multimodal, CNPq, INERGE, FAPEMIG e à Universidade Federal de Juiz de Fora (UFJF) pelo apoio.

informações relevantes sobre a qualidade (Malekjafarian et al., 2019; Chia et al., 2019; Wang et al., 2021). A relação da condição da via e as acelerações medidas no veículo ferroviário são possíveis devido a interação roda-trilho. As cargas na interface roda-trilho possuem uma parcela dinâmica e outra estática, sendo que o carregamento total será a soma dessas duas parcelas. A carga estática se deve ao peso do próprio veículo e sua distribuição de acordo com a posição que cada roda ocupa sobre o plano da via. Por outro lado, a parcela dinâmica é o resultado da equação de movimento dada pelas acelerações, amortecimento e rigidez dos componentes da via e material rodante (Karis et al., 2018).




Figura 1. Representação das forças atuantes na interface roda-trilho, estabelecendo relações geométricas das forças projetadas no plano de contato.

Recentemente, o aprendizado de máquina (*Machine Learning*) revolucionou uma ampla gama de campos, como visão computacional, processamento de linguagem natural e reconhecimento de fala. Com o crescimento na quantidade de dados coletados por dispositivos de sensores embarcados na ferrovia, o aprendizado de máquina está ganhando popularidade, melhorando a confiabilidade dos sistemas ferroviários e minimizando os custos e riscos operacionais (Yang et al., 2021). As concessionárias ferroviárias geralmente utilizam veículos especializados próprios ou contratados para avaliar a condição da via. O processo é geralmente lento e exige um alto custo, devido a necessidade de paralisar as atividades durante a avaliação de um determinado trecho. Em contrapartida, a utilização de dispositivos portáteis embarcados nos veículos requer pouco investimento, podendo ser utilizados para obter informações de aceleração, que podem ser representar de forma indiretamente a condição da via. Desta forma, o presente trabalho aborda a aplicação de aprendizado de máquina para diagnosticar as condições da via mediante os dados de aceleração, modos de vibração e parâmetros de dinâmica roda-trilho.

No estudo, foram utilizados dados de simulações de dinâmica multicorpos derivados de medições reais em campo. As simulações determinam as respostas dinâmicas como aceleração e esforços roda-trilho para uma determinada entrada de excitação de base, que no caso é devido a variação da geometria da via oriunda de medições em campo. O objetivo do trabalho é elaborar uma metodologia que viabilize a inferência das cargas da interface roda-trilho de forma indireta a partir dos dados de aceleração, utilizando

os dados de simulação como treinamento para o modelo de classificação. Os rótulos utilizados para estabelecer as classes do modelo foram baseados seguindo um conjunto de regras e valores contidos em normas de segurança ferroviária, principalmente nas normas estabelecidas pela FRA (Federal Railroad Administration, 2018). O projeto foi proposto para o vagão ferroviário do modelo HPD (*Hoppers*), em que o mesmo foi modelado e instrumentado para a aquisição dos dados do estudo.

Para alcançar os objetivos propostos foram usadas ferramentas de Seleção de Características (*Feature Selection*) e subamostragem (*Undersampling*) devido a natureza do problema. O conjunto de dados foram testados usando o modelo de classificação de Floresta Aleatória (*Random Forest*) implementado em linguagem Python. A avaliação do modelo foi realizada principalmente utilizando métricas de sensibilidade, precisão e acurácia. O modelo demonstrou alta sensibilidade, sendo capaz de classificar as criticidades priorizando a busca por irregularidades na via. O trabalho apresentado auxilia os especialistas ferroviários na avaliação da qualidade da via, mostrando indicadores de criticidade georreferenciados.

2. DINÂMICA FERROVIÁRIA E LIMITES DE SEGURANÇA OPERACIONAL

Para o entendimento do comportamento dinâmico dos veículos ferroviários, é necessário a compreensão das condições do próprio veículo, da via permeante e da operação (Iwnicki, 2006). A dinâmica ferroviária é essencial para aumentar a competitividade da ferrovia, possibilitando evitar acidentes, realizar o aumento seguro de velocidade no transporte e implementação de composições novas e maiores. A forma mais utilizada para garantir segurança no transporte ferroviário é analisar a relação entre os esforços presentes no contato roda-trilho. Os esforços podem ser determinados pela interação de vários efeitos não-lineares, incluindo a variação do ponto de contato entre a roda e o trilho, ângulo de contato, geometria da região de contato e as forças de interação.

Tabela 1. Limites de segurança ferroviária baseados nos parâmetros de alívio de roda e L/V .

Criticidade	Alívio de roda	L/V	
		carregado	vazio
Normal	$x \leq 50\%$	$x \leq 0,6$	$x \leq 0,6$
P2	$50\% \leq x < 60\%$	–	$0,6 \leq x < 0,8$
P1	$60\% \leq x < 85\%$	$0,6 \leq x < 0,8$	$0,8 \leq x < 1,0$
P0	$x \geq 85\%$	$0,8 \leq x < 1,0$	$x \geq 1,0$

Um dos principais parâmetros utilizados para garantir segurança e evitar descarrilamento por escalada de friso é a relação das forças laterais e verticais incidentes no contato roda-trilho. A relação pode ser verificada pelo ângulo do plano de contato, que traduz um limite entre a relação de forças no contato conforme mostrado na Figura 1. O limite é estabelecido por relações geométricas das forças projetadas no plano de contato representada por (Nadal, 1896, 1908):

$$\frac{L}{V} = \frac{\tan(\alpha) - \mu}{1 + \mu \tan(\alpha)}, \quad T = \mu N, \quad (1)$$

em que L e V são as forças laterais e verticais respectivamente, α é o ângulo do plano de contato, μ é o coeficiente de atrito entre as partes de contato, T é força tangencial e N é força normal. A Equação 1 é a formulação mais famosa e utilizada no campo ferroviário, sendo usada como indicador de segurança operacional mediante a limites e valores críticos para o coeficiente de descarrilamento.

Outro mecanismo de descarrilamento que geralmente ocorre em tangentes é o descarrilamento por alívio de força vertical. Neste cenário pode ocorrer uma redução do denominador V (força vertical) na relação L/V , ocasionando um aumento significativamente no indicador L/V atuante. O alívio de rodas normalmente está relacionado aos movimentos de corpos rígidos que provocam alterações na distribuição das forças verticais do vagão. Em cenários em que a taxa de alívio de roda atinge altos valores pode ocorrer o *wheel lift*, consistindo na ausência de contato da roda com o trilho instantaneamente.

3. METODOLOGIA

A variável dependente do modelo de multiclasse proposto possui o objetivo identificar as condições de criticidade da via permanente de acordo com a dinâmica do alívio de roda e L/V . As classes foram definidas seguindo um conjunto de regras e valores contidos nas normas estabelecidas pela FRA (Federal Railroad Administration, 2018). O estudo adota as normas para definir limites de segurança, agrupando a base de dados por criticidades em ordem crescente de gravidade:

- Normal, P2, P1, P0.

A Tabela 1 mostra os limites determinados pelas normas baseados nos valores de alívio de roda, L/V e nas condições de vagão carregado e vazio. As normas também estabelecem que os limites de criticidade devem ocorrer em uma janela de 1.5m de extensão da anormalidade, indicando assim uma criticidade. Com o intuito de realizar uma análise mais conservadora no aspecto de segurança operacional, na ocorrência de mais tipos de criticidade ao decorrer da janela de 1.5m, será considerado a criticidade mais restritiva desde que a mesma forme pelo menos 25% da extensão da janela.

Dessa forma, os parâmetros de limite de segurança possibilita a rotulação das criticidades, representando assim as quatro classes do problema proposto. O objetivo é usar as taxas de alívio de rodas e L/V para inferir as criticidades mediante os dados de sensores inerciais e informações operacionais do vagão.

3.1 Estudo de Caso

Para o problema proposto o vagão ferroviário do modelo HPD (*Hoppers*) foi modelado e instrumentado para a aquisição dos dados do estudo. Os vagões HPD são mundialmente reconhecidos para o transporte de grãos, açúcar, milho, soja, farelo, e entre outros. Os dados foram extraídos do *software* VAMPIRE[®] (*Vehicle Analysis Modeling Package in the Railway Environment*), que consiste

em um *software* de simulação dinâmica (multicorpos) que reproduz no ambiente virtual a interação entre o veículo ferroviário e a via permanente, sob determinadas condições de contorno baseada em dados reais de geometria.

Os dados foram gerados seguindo diferentes parâmetros, como o estado do vagão (vazio ou carregado), escalas de velocidade de 25, 35, 45, 60 e 70 km/h, como também foram considerados 10 diferentes trechos da malha ferroviária. Os trechos possuem características diferentes de operação e geometria, objetivando enriquecer o modelo proposto. Para cada combinação destes parâmetros foram extraídas diversas informações (*features*), conforme a Tabela 2.

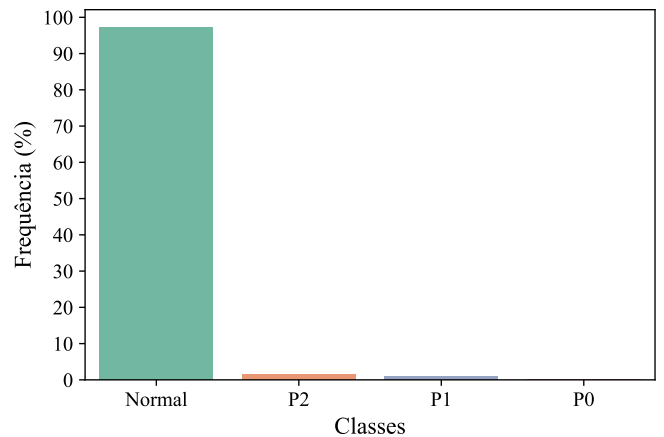


Figura 2. Histograma da frequência relativa das classes, mostrando o desbalanceamento no conjunto de dados.




Figura 3. Histograma da frequência relativa das classes, mostrando o conjunto de dados balanceado.

Uma das etapas realizadas foi a limpeza dos dados, padronização e organização das amostras, tratando possíveis irregularidades na base de dados. Outra etapa importante é processamento dos dados, seguindo as normas da FRA, a taxa de amostragem dos dados de aceleração devem ser de pelo menos 100 Hz. Deste modo, foi especificado no conjunto de dados simulados a frequência de amostragem $F_s = 200$ Hz. Os filtros de média móvel foram utilizados nos dados dos modos de vibração (*Roll*, *Pitch* e *Yaw*) e nas informações de alívio de roda e L/V que se relacionam com o rótulo de criticidade. A aplicação dos filtros de média móvel contribuem na eliminação de possíveis artefatos ou

Tabela 2. Descrição dos diferentes parâmetros ou características geradas e coletadas para o estudo de caso.

Feature	Tipo	Descrição
Timestamp	contínuo	Tempo de coleta dos dados em segundos (s).
Distance	contínuo	Distância percorrida em metros (m) considerando um ponto inicial zero.
Distance_km	contínuo	Distância percorrida em quilômetros (km) considerando a referência da via permanente.
Tipo_carga	categórico	Condição do vagão vazio ou carregado.
Trecho	categórico	Locais específicos da malha ferroviária.
Velocidade	categórico	Escalas de velocidade em (km/h).
Criticidade	categórico	Rótulo por criticidade crescente de gravidade baseado nos limites de segurança.
Acel_lat_caixa, Acel_lat_t_lider, Acel_lat_t_reboque	contínuo	Aceleração lateral da caixa, travessa líder e reboque em (m/s ²).
Acel_vert_caixa, Acel_vert_t_lider, Acel_vert_t_reboque	contínuo	Aceleração vertical da caixa, travessa líder e reboque em (m/s ²).
Roll_caixa, Roll_t_lider, Roll_t_reboque	contínuo	Movimento de rolagem na caixa, travessa líder e reboque em (rad/s).
Yaw_caixa, Yaw_t_lider, Yaw_t_reboque	contínuo	Movimento de guinada na caixa, travessa líder e reboque em (rad/s).
Pitch_caixa, Pitch_t_lider, Pitch_t_reboque	contínuo	Movimento de arfagem na caixa, travessa líder e reboque em (rad/s).
Ax_1_left_LV, Ax_1_right_LV, Ax_3_left_LV, Ax_3_right_LV	contínuo	Taxa de L/V (relação de forças lateral e vertical) nos diferentes eixos e lados do vagão (kN).
Ax_1_left_Unload, Ax_1_right_Unload, Ax_3_left_Unload, Ax_3_right_Unload	contínuo	Taxa de alívio de rodas nos diferentes eixos e lados do vagão (kN).

ruídos que podem influenciar na extração de informações e rotulação das criticidades.

As componentes de vibração entre 2 e 10 Hz estão intimamente relacionados à instabilidade, como a frequência de vibração se relaciona com a velocidade do trem por meio da relação básica entre comprimento de onda, frequência e velocidade, essa faixa de frequência pode ser utilizada para descrever as irregularidades da via. Desta forma, é determinante o uso de filtros passa-baixa nos dados de aceleração, sendo recomendado filtros do tipo passa-baixa Butterworth de segunda ordem com corte de

10 Hz. Além disso, foi utilizada a técnica de filtragem *Forward-backward filtering* que resulta em uma saída com redução de defasagem.

3.2 Seleção de Características

Ao construir um modelo de aprendizado de máquina, é raro que todas as variáveis no conjunto de dados sejam úteis para construir o modelo proposto. Adicionar variáveis redundantes e irrelevantes reduz a capacidade de generalização do modelo e também pode reduzir o desempenho geral de um classificador. Desta forma, o presente trabalho implementa os seguintes métodos de seleção de características:

- Métodos que identificam variáveis altamente correlacionadas, caso duas características ou mais são altamente correlacionadas, podemos selecionar uma delas e descartar as demais sem perder muita informação;
- Identificação e descarte de recursos que possuem uma alta fração de valores constantes;
- Determinação de um subconjunto de recursos que são relevantes para o resultado usando o algoritmo de Boruta (Kursa and Rudnicki, 2010; Kursa et al., 2010). O resultado é composto usando validação cruzada;
- Ranqueamento de recursos com eliminação de características recursivas e seleção com validação cruzada do melhor número de características, determinando o número mínimo de características necessárias para maximizar o desempenho do modelo.

3.3 Subamostragem

Uma característica inerente de dados baseados em problemas reais é o desequilíbrio na quantidade de amostras das diferentes classes. Conforme a Figura 2, o problema proposto possui conjunto de dados desbalanceado, sendo um aspecto compreensível devido a natureza do problema causado pela extensão dos trechos abordados e os eventos raros de irregularidade. Basicamente, o conjunto de dados desbalanceado é um conjunto de dados em que há muito mais pontos de dados para uma categoria do que para outras.

Devido aos poucos casos de anormalidade nas maiores criticidades, o modelo de treinamento poderá só se especializar nas classes majoritárias. Nessa situação, os algoritmos tendem a prever apenas os dados da classe majoritária. As características das classes minoritárias são tratadas como ruído e muitas vezes ignoradas, assim gerando uma alta probabilidade de erro de classificação da classe minoritária em relação à classe majoritária.

Existem diversas técnicas para lidar com desbalanceamento das classes, os métodos mais usados e populares são baseados na reamostragem. Nesta estratégia, focamos no balanceamento das classes nos dados de treinamento (pré-processamento de dados) antes de fornecer os dados como entrada para o algoritmo de aprendizado de máquina. O principal objetivo de equilibrar as classes é aumentar a frequência da classe minoritária ou diminuir a frequência da classe majoritária. Desta forma, podemos obter uma melhor proporção de instâncias para ambas as classes. Neste trabalho foi escolhida a subamostragem das amos-

tras da classe majoritária, particularmente foi utilizado o método *One-Sided Selection* (Kubat and Matwin, 1997).




Figura 4. Gráfico de dispersão usando valores de duas características da base de dados desbalanceada.




Figura 5. Gráfico de dispersão usando valores de duas características da base de dados balanceada, mostrando o resultado da reamostragem.

O método *One-Sided Selection* é uma técnica de subamostragem que combina as metodologias *Tomek Links* e *Condensed Nearest Neighbor* (Batista et al., 2000). Especificamente, *Tomek Links* são pontos ambíguos no limite da classe que são identificados e removidos na classe majoritária, enquanto que o *Condensed Nearest Neighbor* é usado para remover amostras redundantes da classe majoritária que estão distantes do limite de decisão. Conforme a Figura 4 e 5, um diagrama de dispersão do conjunto de dados original e transformado foram criados, usando o método de reamostragem. A Figura 5 mostra que a maioria das amostras restantes da classe majoritária pertencem ao redor do limite de decisão das classes e são amostras sobrepostas a classe minoritária. Basicamente, a vantagem do método é balancear os números de amostras mantendo eventos raros e eliminando os redundantes, ajudando no desempenho e generalização do modelo. A Figura 3 mostra o histograma de frequência relativa da base de dados transformada.

4. RESULTADOS

Os dados foram testados usando diferentes modelos de classificação, como *Random forest*, *Gradient Boosting* e *K-Nearest Neighbors* (Bishop, 2006; Silva et al., 2021), sendo realizado comparações usando as métricas de desempenho para selecionar o mais adequado para o problema proposto. O modelo escolhido foi o Floresta aleatória (*Random forest*), sendo posteriormente avaliado realizando um ajuste do hiper-parâmetro e otimização. O ajuste de hiper-parâmetro visa encontrar um conjunto de parâmetros que produz um modelo ideal que minimiza uma função de erro predefinida em dados independentes fornecidos. A validação cruzada também foi utilizada para estimar o desempenho de generalização.

Os algoritmos foram implementados em linguagem Python e executados utilizando uma máquina com *Intel Core i5*, CPU 2.5 GHz e 16 Gb RAM. Em todos os métodos apresentados foram aplicados os mesmos conjuntos de dados de treinamento (80%) e validação (20%), empregando a validação cruzada de 5 *fold*s. Nas métricas de avaliação de desempenho, a acurácia não é uma boa indicação geral de como o modelo performou, devido que o problema proposto exibe um alto desbalanceamento na quantidade de amostras das classes. As métricas mais importantes para a validação do modelo são a sensibilidade e precisão. A sensibilidade pode ser usada em uma situação em que os Falsos Negativos (FN) são considerados mais prejudiciais que os Falsos Positivos (FP). Por exemplo, o modelo proposto deve priorizar a busca por irregularidades na via, ou seja criticidades, mesmo que classifique algumas condições normais como críticas (situação de Falso Positivo) no processo. Portanto, o modelo deve ter alta sensibilidade, pois classificar criticidades como normal pode ser um risco para segurança operacional dos veículos ferroviários.

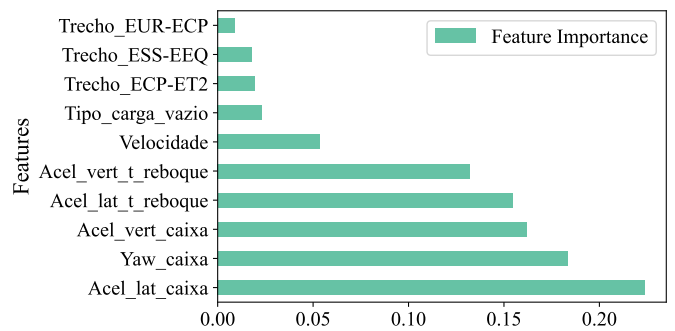


Figura 6. Gráfico de importância das características (*features*) usando o modelo de floresta aleatória.

A Figura 7 representa a matriz de sensibilidade na validação do modelo, caracterizando os casos positivos que foram identificados corretamente. A matriz mostra que a sensibilidade na classe de criticidade P0 obteve os menores valores de sensibilidade, provavelmente em decorrência da escassa quantidade de amostras para o treinamento desta classe (veja Figura 3). Ao verificar a classe Normal o erro de predição é dividido entre as classes P2 e P1, com um erro mínimo de predição de P0 com casos positivos de Normal. As demais classes obtiveram bons resultados de sensibilidade, com valores acima de 90%.




Figura 7. Matriz de confusão baseada na métrica de sensibilidade usando os dados de validação.

A matriz de precisão representada pela Figura 9, caracteriza a quantidade de classificações corretas da classe positiva do modelo. Ao analisar a matriz é notado que as classificações corretas da classe positiva de P0 e Normal são altas com valores de 93 %, mostrando uma menor quantidade de Falsos Positivos e indicando uma alta precisão nas duas classes da extremidade. O modelo possui uma dificuldade em prever as classes intermediárias P1 e P2, com menor valor de precisão em P2. A Tabela 3 mostra um resumo dos resultados das métricas calculadas na validação do modelo. Conforme os resultados mostrados na tabela, a média harmônica entre precisão e sensibilidade (F1-Score) apresenta valores entre 0,73 e 0,98, exceto para a classe P2. Isso pode indicar que a classe de criticidade P2 não está bem definida no problema, e talvez deve ser eliminada visando uma gradação realista das criticidades.

Outro resultado significativo para avaliar é a importância das características (*Feature Importance*), que se refere no uso de técnicas que calculam uma pontuação para as características de entrada para o modelo. Uma pontuação mais alta significa que a característica específica terá um efeito maior no modelo que está sendo usado para prever uma determinada variável. Para o problema proposto essa avaliação é significativa para a compreensão da base de dados, ajudando a entender quais recursos são irrelevantes para o modelo, e determinando quais recursos atribuem mais ao poder preditivo. Na perspectiva prática, é importante para

Tabela 3. Relatório geral das métricas de desempenho na validação das diferentes classes.

	Precisão	Sensibilidade	F1-Score
P0	0,9281	0,7428	0,8251
P1	0,6097	0,9074	0,7293
P2	0,2471	0,9317	0,3906
Normal	0,9985	0,9525	0,9750
weighted avg	0,9834	0,9512	0,9636
macro avg	0,6959	0,8836	0,7300
Acurácia	-	-	0,9512




Figura 8. Mapa georreferenciado indicando as coordenadas das criticidades classificadas na via permanente, neste exemplo é mostrado as criticidades (■ P0) e (■ P1).

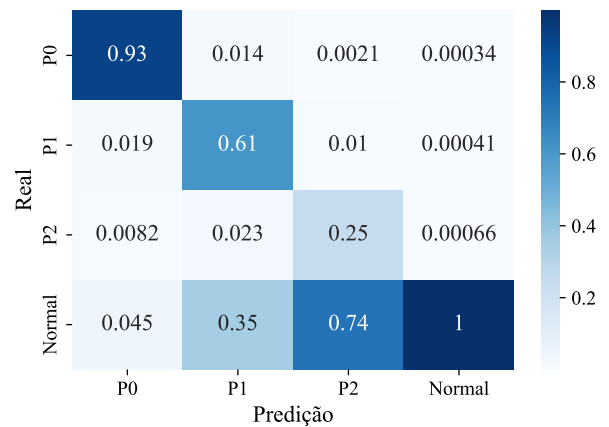


Figura 9. Matriz de confusão baseada na métrica de precisão usando os dados de validação.

definir quais sensores e locais que são mais significativos na análise de dinâmica ferroviária. A Figura 6 representa o gráfico de importância da características usando o modelo de floresta aleatória. O gráfico exibe maior grau de poder preditivo pela aceleração lateral, modo *Yaw* e aceleração vertical medidos na caixa.

Os resultados de predição foram gerados utilizando as informações de georreferenciamento, indicando as criticidades na via permanente mostrados na Figura 8. O mapa indica os possíveis pontos de anormalidade na via permanente, revelando os locais que necessitam de análise da manutenção.

5. CONCLUSÃO

O presente trabalho descreveu uma metodologia para avaliar a condição da via permanente mediante graus de criticidade, usando dados de aceleração, modos de vibração e parâmetros de esforços roda-trilho. O modelo de classificação foi criado baseando em dados gerados por simulação multicorpos, que indiretamente recebe *input* de dados reais de geometria da via. A simulação e os parâmetros para geração do banco de dados são validados constantemente no decorrer das atividades da concessionária ferroviária, sendo dados confiáveis à restrição do problema proposto, como tipo de vagão, velocidades e pátios analisados. Os

resultados mostraram que existe uma relação contundente entre as informações de aceleração medidas e a condição da via.

O modelo criado obteve uma alta performance no geral considerando as métricas de sensibilidade, precisão e F1-Score, com exceção da classe de criticidade P2. O modelo foi capaz de classificar as criticidades, exibindo menor desempenho na classe P2. Os resultados demonstram que os limites utilizados na rotulação da classe P2 podem ser melhorados ou o problema deve ser restringido, removendo a classe P2 para um melhor desempenho geral do modelo.

O trabalho resultou em uma ferramenta para auxiliar os especialistas ferroviários na busca por irregularidades utilizando apenas as informações de aceleração e variantes como modos de vibração. As informações de aceleração são mais acessíveis e com menor custo devido que são utilizados dispositivos embarcados nos veículos. Portanto, o modelo de classificação realiza a inferência das cargas da interface roda-trilho de forma indireta utilizando dados de aceleração, resultando em um algoritmo que informa os níveis de criticidade da via analisada.

Em trabalhos futuros é desejado expandir as características ou *features*, analisando e comparando as correlações entre as *features* consideradas neste problema e as informações de geometria, como curvatura, nivelamento transversal, alinhamento, nivelamento longitudinal e bitola da via. Outro ponto, é a experimentação de novas técnicas de extração de parâmetros considerando os sinais em domínio da frequência, utilizando técnicas como Transformada Wavelet para criar novas *features*.

AGRADECIMENTOS

Agradecemos à CAPES, VLI Multimodal S.A., CNPq, INERGE, FAPEMIG e à Universidade Federal de Juiz de Fora (UFJF) pelo apoio.

REFERÊNCIAS

- Batista, G.E.A.P.A., Carvalho, A.C.P.L.F., and Monard, M.C. (2000). Applying One-Sided Selection to Unbalanced Datasets. In *Advances in Artificial Intelligence: Lecture Notes in Computer Science*, 315–325. Springer Berlin Heidelberg.
- Bishop, C. (2006). *Pattern Recognition and Machine Learning*. Springer.
- Chia, L., Bhardwaj, B., Lu, P., and Bridgelall, R. (2019). Railroad Track Condition Monitoring Using Inertial Sensors and Digital Signal Processing: A Review. *IEEE Sensors Journal*, 19(1), 25–33.
- Federal Railroad Administration (2013). *Track Safety Standards and Improving Rail Integrity*. FRA.
- Federal Railroad Administration (2018). *Track and Rail and Infrastructure Integrity Compliance Manual*. FRA.
- Iwnicki, S. (2006). *Handbook of railway vehicle dynamics*. CRC Press.
- Karis, T., Berg, M., Stichel, S., Li, M., Thomas, D., and Dirks, B. (2018). Correlation of track irregularities and vehicle responses based on measured data. *Vehicle System Dynamics*, 56(6), 967–981.
- Kubat, M. and Matwin, S. (1997). Addressing the Curse of Imbalanced Training Sets: One-Sided Selection. In *Proceedings of the Fourteenth International Conference on Machine Learning*, 179–186. Morgan Kaufmann.
- Kursa, M.B., Jankowski, A., and Rudnicki, W.R. (2010). Boruta – A System for Feature Selection. *Fundamenta Informaticae*, 101(4), 271–285.
- Kursa, M.B. and Rudnicki, W.R. (2010). Feature Selection with the Boruta Package. *Journal of Statistical Software*, 36(11), 1–13.
- Lasisi, A. and Attoh-Okine, N. (2018). Principal components analysis and track quality index: A machine learning approach. *Transportation Research Part C: Emerging Technologies*, 91, 230–248.
- Malekjafarian, A., O'Brien, E., Quirke, P., and Bowe, C. (2019). Railway track monitoring using train measurements: An experimental case study. *Applied Sciences*, 9(22).
- Nadal, M.J. (1908). Locomotives á Vapeur. *Collection Encyclopédie Scientifique, Bibliothèque de Mécanique Appliquée et Génie*, 186.
- Nadal, M. (1896). Theorie de la Stabilité des locomotives, Part II: mouvement de lacet. *Annales des Mines*, 10(232).
- Silva, P.H.O., Cerqueira, A.S., and Nepomuceno, E.G. (2021). Hybrid Method Based on NARX models and Machine Learning for Pattern Recognition. In *Anais do XV Simpósio Brasileiro de Automação Inteligente (SBAI 2021)*. SBA.
- Tsunashima, H., Matsumoto, A., Mori, H., and Asano, A. (2014). Track condition monitoring system using on-board sensing device. *Civil-Comp Proceedings*, 104.
- Wang, H., Berkers, J., van den Hurk, N., and Layegh, N.F. (2021). Study of loaded versus unloaded measurements in railway track inspection. *Measurement: Journal of the International Measurement Confederation*, 169.
- Yang, C., Sun, Y., Ladubec, C., and Liu, Y. (2021). Developing machine learning-based models for railway inspection. *Applied Sciences*, 11(1), 1–15.