

Identificação Automática de Trechos da Estrada de Ferro Vitória a Minas com Dormentes Danificados

Leonardo Pessoa Freitas e Silva^{1,2*}, Guilherme Henrique Souza Lima², Natan Siller Laurett², Vitor Hugo Mendes Gomes², Vitor Martins Barbosa², Renato Lataliza Vasconcelos³, Luciano Cassaro³, Luciano Oliveira³, Agnaldo José da Rocha Reis⁴, Sarah Negreiros Carvalho Leite², Glauco Ferreira Gazel Yared².

¹ Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração, Universidade Federal de Ouro Preto e Instituto Tecnológico Vale.

² Departamento de Engenharia Elétrica da Universidade Federal de Ouro Preto, Rua 36, 115 - Loanda, 35931-008, João Monlevade, Minas Gerais.

³ Vale S.A, Diretoria de Engenharia e Gestão de Ativos, Av. Dante Michelini, 5500, 29090 900 Vitória, ES – Brasil.

⁴ Depto de Eng. de Controle e Automação da UFOP - Campus Morro do Cruzeiro s/n - 35.400-000 - Ouro Preto-MG.

e-mail: leonardo.silva@ufop.edu.br, guilherme.lima1@aluno.ufop.edu.br, natan.laurett@aluno.ufop.edu.br, vitor.gomes@aluno.ufop.edu.br, vitor.barbosa@aluno.ufop.edu.br, renato.lataliza@vale.com, oliveira.luciano@vale.com, luciano.cassaro@vale.com, reis@ufop.edu.br, sarah@ufop.edu.br, glauc@ufop.edu.br.

Resumo Os sistemas ferroviários são importantes para a logística do transporte de cargas em muitos países. A grande capacidade de carga, menores custos em comparação à atividades rodoviárias e aéreas, maior segurança, dentre outros fatores, contribuem para uma melhoria nos indicadores econômicos do país. Assim, com o intuito de garantir a confiabilidade e a segurança do transporte ferroviário, torna-se cada vez mais importante o monitoramento das condições da via permanente e a realização de manutenções planejadas. Neste contexto, o objetivo principal deste trabalho é apresentar um novo método de detecção de trincas ou fraturas em dormentes de aço na Estrada de Ferro Vitória-Minas (EFVM), baseado em técnicas de processamento de sinais e reconhecimento de padrões, utilizando, como base, os dados coletados pelos sensores de um Carro Controle já existente.

Palavras-Chaves: Dormentes de Aço, Detecção de Anomalias, Reconhecimento de Padrões, k-means.

1. INTRODUÇÃO

O sistema de transporte ferroviário é essencial para as atividades comerciais em vários países, desempenhando um papel importante na melhoria dos indicadores econômicos. Essas atividades estão associadas a custos operacionais mais baixos em comparação com atividades rodoviárias e aéreas. O aumento da demanda pelo transporte ferroviário contribui para a aceleração na deterioração dos componentes da via permanente, trazendo novos desafios relacionados às atividades de manutenção em busca de mais eficiência, redução de custos, ganho de produção e principalmente em questões de segurança.

O componente da via permanente que será abordado neste trabalho é o dormente de aço. A EFVM possui dormentes de aço na composição de sua estrutura ao longo de quase todo o seu

percurso. Um fator relevante, que vale tanto para os dormentes quanto para os outros componentes da superestrutura é que alguns parâmetros de desempenho da ferrovia precisam ser verificados e garantidos periodicamente de acordo com a Agência Nacional de Transportes Terrestres (ANTT) [2]. As condições estruturais dos dormentes devem ser monitoradas, dando uma atenção especial a trincas e fraturas. Trincados não visíveis podem piorar e se tornar uma fratura completa.

Diferentes métodos foram propostos até o momento para a análise das condições estruturais dos dormentes de madeira e de concreto. Sensores de emissão acústica foram aplicados para detectar problemas estruturais em dormentes de concreto [4]. Processamento de imagens, juntamente com técnicas de reconhecimento de padrões foram aplicadas para identificar problemas estruturais em dormentes de madeira [9]. Em alguns casos,

Ótimos resultados podem ser gerados em experimentos laboratoriais, mas não apresentam desempenhos compatíveis em campo, como é o caso das antenas de micro ondas. Algumas técnicas, como a de processamento de imagens, podem ter alta precisão mas requerem um alto custo computacional. Com relação aos dormentes de aço, até o momento não existe uma solução industrial robusta para avaliar as suas condições estruturais. Portanto, objetiva-se com este trabalho realizar o desenvolvimento de um sistema capaz de determinar os trechos da ferrovia que contém dormentes trincados ou fraturados de modo a contribuir com as equipes de manutenção no processo de inspeção.

2. SINAIS DE GEOMETRIA DA VIA PERMANENTE

Existem diversos mecanismos para o levantamento de parâmetros associados ao desgaste e desempenho da via permanente. Dentre estes, o Carro Controle tem sido utilizado para a leitura de características geométricas da via permanente, juntamente com filmagens da superestrutura, além de outros aspectos relevantes. Tais informações são importantes para a avaliação da saúde da linha ferroviária, a qual pode ser executada por meio da análise dos dados coletados de tal modo a se estabelecer uma correspondência entre as observações realizadas e as condições dos componentes da super e da infraestrutura ferroviária. Os sinais utilizados nesta pesquisa, fornecidos pelo Carro Controle, estão associados à geometria da via permanente. São eles, a saber: alinhamento (esquerdo e direito), nivelamento transversal e longitudinal (esquerdo e direito), bitola e empeno [1] [3]. A utilização destes sinais teve como base os conhecimentos dos especialistas que, ao longo dos anos perceberam uma relação existente entre eles e as condições dos componentes da via.

3. RECONHECIMENTO DE PADRÕES

À medida que nossa sociedade evolui com os avanços nas tecnologias de informação e a incorporação da digitalização à atividade industrial, a necessidade de manipulação e recuperação de informações estão se tornando cada vez mais importantes. Essa tendência, aliada ao crescente volume de dados disponíveis (*big data*) proporcionou o desenvolvimento de diversas pesquisas e aplicações de engenharia envolvendo ciência dos dados, mineração de dados e aprendizagem de máquina voltados para o Reconhecimento de Padrões (RP).

Apresentam-se na Figura 1 as etapas de um sistema de RP [5] [8]: sistema de aquisição de dados; sistema de pré-processamento para eliminar ruídos ou distorções; extrator de características (ou atributos), que cria um vetor de características com dados extraídos dos objetos adquiridos, reduzindo os dados a atributos, propriedades ou características; seletor de características, que analisa o conjunto de características e elimina as mais redundantes; e classificador, que analisa um padrão obtido e o classifica (ou reconhece).




Fig. 1 Sistema de Reconhecimento de Padrões.

A realização do pré-processamento sobre os dados, no caso desta pesquisa, é justificada pelas instabilidades e erros inesperados durante a leitura dos sensores do Carro Controle, produzindo inconsistências, como por exemplo dados não-numéricos ou até amplitudes incompatíveis com o restante das leituras em um momento específico. Nesse sentido, o processo de pré-processamento dos dados é indispensável para que as etapas posteriores do sistema de RP, principalmente as de treinamento e classificação, não comprometam a capacidade de generalização do sistema de RP.

Após a etapa de pré-processamento, uma série de análises podem ser realizadas para revelar características que as medições originais não apresentam de forma explícita, porém que podem contribuir para o estabelecimento dos padrões associados aos danos estruturais investigados. Em linhas gerais, os algoritmos de extração criam novas características a partir de transformações ou combinações do conjunto de características original. Dentre os extratores lineares podemos citar a transformada de Fourier (análise espectral) [6] e alguns parâmetros estatísticos como a média, desvio padrão, energia, função de auto correlação, entre outros.

Frequentemente os problemas de classificação enfrentam a necessidade de tratar o aspecto da elevada dimensionalidade dos dados, com o intuito de garantir que o conjunto de dados disponível seja suficiente para permitir o ajuste dos parâmetros intrínsecos dos modelos classificadores na etapa de treinamento e

também reduzir o custo computacional, que pode inclusive inviabilizar as etapas subsequentes. Existem algumas abordagens que possibilitam contornar esse tipo de problema, destacando-se as técnicas de seleção de características (atributos) e de redução de dimensionalidade. Os métodos de seleção de características visam determinar os parâmetros que são mais relevantes para o processo de classificação, principalmente do ponto de vista da discriminabilidade entre as classes, enquanto que os métodos de redução de dimensionalidade visam realizar transformações nos parâmetros de entrada de modo a reduzir a sua dimensão e ao mesmo tempo tentando preservar as informações mais relevantes (com maior variância). Nessa pesquisa, foram abordados dois métodos que utilizam as técnicas citadas, a Função Discriminante de Fisher (FDR) [8] e a Análise de Componentes Principais (PCA) [7].

Os classificadores são modelos matemáticos que incorporam um conjunto de regras capazes de estabelecer um mapeamento entre um dado padrão de entrada e uma determinada classe [8]. O processo de obtenção de um classificador consiste em três estágios: treinamento, validação e utilização. O treinamento emprega uma base de dados conhecida a priori, que pode ou não ser rotulada, e realiza o ajuste dos parâmetros intrínsecos do modelo a partir das classes desejadas na saída quando os rótulos se encontram disponíveis (supervisionado), ou a partir de outros métodos que não necessitam destas informações (não-supervisionado). Na etapa de validação pode-se avaliar a taxa de acerto que o classificador deve apresentar durante a sua utilização, indicando a precisão esperada durante a separação de classes. A etapa de operação consiste em gerar a aplicação com base nas melhores configurações definidas nas etapas anteriores, sendo possível aplicar o sistema para quaisquer novos dados desconhecidos, diferentes daqueles existentes na base de dados utilizadas nas etapas anteriores.

Nesta pesquisa, o algoritmo de classificação não-supervisionado, *k-means* [8], foi utilizado para reconhecer os padrões dos defeitos. O *k-means* é um algoritmo de clusterização que separa um conjunto de dados com base na sua semelhança, ou seja, com base na distância euclidiana entre eles. A distância euclidiana é responsável por apontar o quão próximo do centróide de cada classe (*cluster*) se encontra um determinado dado, e desta forma define a qual *cluster* ele pertence.

4. METODOLOGIA

A utilização da base de dados gerada pelo Carro Controle com a finalidade de identificação de danos existentes na via permanente pode contribuir com as atividades de manutenção preventiva e corretiva, de modo a assegurar a confiabilidade da ferrovia. Além disso, o processamento digital dos dados pode permitir que as análises sejam realizadas de forma sistemática e, desta forma, auxiliar a área de engenharia em relação ao planejamento e execução de intervenções na ferrovia. Em particular, este projeto de pesquisa se concentra na identificação de danos estruturais (trincas e fraturas) em dormentes de aço da EFVM.

4.1 Base de dados

O Carro Controle realiza a aquisição de dados durante inspeções bimestrais, totalizando seis inspeções anuais, o que produz um conjunto de arquivos nos quais, em geral, encontram-se identificados o ano, a inspeção, o trecho (*Entre-Housing*), o sentido (ida ou volta), tipo do elemento (tangente ou curva) e o quilômetro inicial e final de cada elemento. Nos experimentos realizados, foram considerados 34 elementos (curvas) de diferentes supervisões das inspeções realizadas no ano de 2019. No protocolo experimental, optou-se pela utilização dos dados provenientes da 3ª inspeção (realizada tipicamente em um período) para efeito de treinamento dos modelos. Para a etapa de validação foram escolhidos 4 elementos, dentre os 34, com os dados da 4ª, 5ª e 6ª inspeções de 2019, os quais se encontravam rotulados de acordo com a planilha de prospecção da ferrovia.

4.2 Definição da janela de dados

O tamanho da janela de dados deve ser obtido de modo a se estabelecer o melhor compromisso entre a quantidade de informações presentes nas amostras contidas na janela e a resolução espacial. Em geral, quanto menor for o tamanho da janela de dados, maior será a resolução espacial, porém menos informação estará contida na janela, enquanto janelas maiores possuem mais informações e menos resolução espacial.

Além disso, a quantidade de amostras contidas na janela também impacta na quantidade de parâmetros que serão extraídos, podendo contribuir para um aumento desnecessário da dimensionalidade do problema, dependendo da técnica de parametrização utilizada. Assim, neste trabalho foram avaliadas janelas de dados

contendo 30, 60, 90 e 120 amostras, sendo o deslocamento da janela unitário, ou seja, de apenas uma amostra.

4.3 Parametrização

Os sinais espaciais associados à geometria da via permanente, dentre outros, possuem informações intrínsecas que, a princípio, caracterizam o estado de operação de componentes da infraestrutura e da superestrutura ferroviária de forma interligada. Assim, as técnicas de parametrização buscam extrair informações capazes de revelar aspectos de interesse, como por exemplo os padrões de comportamento relacionados com danos estruturais.

Na abordagem baseada em parâmetros estatísticos, foram extraídas as seguintes informações a partir do sinal contido em cada janela de dados: energia, variância, taxa de cruzamento por zero, diferença entre amplitude máxima e mínima (variação da amplitude), derivadas primeira e segunda do sinal na posição espacial correspondente à janela de dados e função de autocorrelação. Tais parâmetros são calculados para cada um dos sete sinais considerados.

A segunda abordagem consiste no cálculo da Transformada Discreta de Fourier (DFT) para o sinal contido no interior da janela, por meio do algoritmo da Transformada Rápida de Fourier (FFT), seguido da determinação do módulo da amplitude, o que tipicamente produz, para cada sinal, uma quantidade de parâmetros que é metade do tamanho da janela utilizada.

4.4 Seleção de características e redução de dimensionalidade

Os sete sinais que descrevem as características geométricas da via permanente são parametrizados de modo que as informações extraídas sejam capazes de caracterizar a presença de danos em dormentes de aço. Este trabalho, particularmente, enfrenta o problema da elevada dimensionalidade do espaço de características ou atributos, mesmo quando se considera a janela com 30 amostras. Outro aspecto importante está relacionado com o fato de que a existência de parâmetros espúrios no vetor de características não contribui para o êxito na classificação e ainda traz um ônus computacional e, portanto, devem ser evitados.

Assim, neste problema, torna-se indispensável a aplicação de um método para a seleção dos

parâmetros mais relevantes ou para redução de dimensionalidade. Neste sentido, utilizou-se o valor do FDR como uma medida para estabelecer o grau de importância de cada parâmetro disponível. Desta forma, é possível definir a dimensão do espaço de características (atributos) que se deseja trabalhar, considerando apenas aquelas mais relevantes do ponto de vista da discriminabilidade ou separabilidade entre as classes de padrões envolvidas no problema, uma vez que o FDR atribui pesos maiores aos parâmetros que maximizam as distâncias entre as classes e minimizam a variabilidade intraclasse.

Diferentemente, a técnica de PCA, que também foi empregada neste trabalho, não leva em consideração qualquer aspecto inerente ao problema de classificação, pois apenas realiza uma rotação na base ortonormal formada por todos os possíveis parâmetros, de tal modo que os eixos desta base estejam alinhados com as direções de maior variação dos dados. Desta forma, a PCA é capaz de reduzir o espaço de parâmetros para representação dos dados, porém não leva em consideração se as direções ao longo das quais ocorre uma menor variância dos dados trazem informações importantes do ponto de vista de um problema de classificação.

4.5 Classificadores

No treinamento não-supervisionado, o ajuste dos parâmetros intrínsecos do modelo é realizado sem conhecer a priori a correspondência entre os dados de entrada do problema e as possíveis classes existentes e, conseqüentemente, sem qualquer medida de erro cometido na saída.

Para a implementação do *k-means*, variou-se o número de *clusters* com o objetivo de encontrar a quantidade que melhor ajusta ao sistema. Dessa forma, foram testados de 2 a 7 *clusters* para cada configuração definida. Um algoritmo foi desenvolvido para identificar quais classes estavam associadas ao padrão de defeito, utilizando-se os dados de treinamento dos 4 elementos rotulados (3ª inspeção).

4.6 Avaliação de Desempenho

Os resultados obtidos pelo sistema de diagnóstico foram avaliados a partir de duas medidas de desempenho: Taxa de Acerto (TA) na detecção dos dormentes danificados e Taxa de Falsos Positivos (TFP). A primeira delas é definida pela razão entre o número de dormentes identificados corretamente como defeituosos pelo classificador e o número total de dormentes danificados existentes nos elementos da EFVM

que foram considerados no experimento. A segunda é definida pela razão entre o número de dormentes identificados erroneamente como danificados e a quantidade total de dormentes de aço existentes nos elementos da EFVM que foram considerados nos experimentos. Assim, para um determinado valor aceitável da máxima taxa de falsos positivos, haverá um desempenho correspondente em termos da taxa de acerto na detecção dos dormentes danificados. Neste trabalho admitiu-se uma taxa de falsos positivos máxima de 40%, com o intuito de encontrar um desempenho considerável na detecção de trechos contendo dormentes defeituosos e, ao mesmo tempo, sem exercer um grande esforço em vão durante o processo de inspeção.

5. RESULTADOS

Para os experimentos, utilizaram-se os dados referentes à terceira inspeção de 2019 dos 34 elementos selecionados para efeito de treinamento dos modelos. Para a validação dos modelos obtidos, foram utilizados os dados da 3ª, 4ª e 5ª inspeção de 4 desses elementos. Dessa forma, aproximadamente 74% dos dados foram utilizados durante o treinamento e outros 26% para validação.

Implementou-se uma rotina para determinar o desempenho obtido para as quatro janelas de dados (tamanhos 30, 60, 90 e 120), com dois métodos de parametrização (estatística e espectral), utilizando-se métodos de seleção de características ou redução de dimensionalidade (FDR e PCA), por meio do classificador *k-means*, considerando-se 31 combinações possíveis dos setes sinais característicos da geometria da linha. Além disso, variou-se a complexidade (número de *clusters*) do *k-means* de 2 a 7, o número de componentes principais da PCA de 10 a 50, com saltos de 10, e o número de parâmetros da FDR de 2 a 15 com saltos unitários.

Os experimentos iniciais foram executados e os resultados obtidos procuraram identificar a configuração que forneceu a maior taxa de acerto na identificação dos dormentes danificados, considerando-se apenas aqueles desempenhos que apresentaram taxa de falsos positivos menor do que 40%. A Figura 2 indica os melhores resultados obtidos, para os diferentes tamanhos das janelas de dados, utilizando a parametrização espacial e a FDR como método de seleção de características. Da mesma forma, a Figura 3 apresenta os melhores resultados, mas agora utilizando a PCA como método de redução de dimensionalidade. O melhor resultado obtido, ao analisar esses

primeiros resultados, foi utilizando a janela de tamanho 120 e a PCA (66,3% de taxa de acerto na detecção dos dormentes defeituosos e 39,28% de taxa de falso positivo).

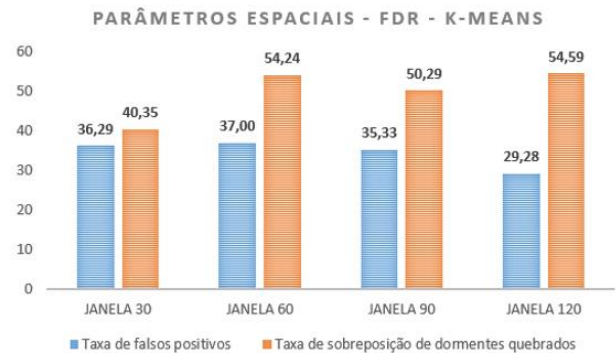


Fig. 2 Resultados percentuais obtidos da taxa de acerto na detecção dos dormentes defeituosos e de falso positivo, utilizando parametrização espacial e a FDR como método de seleção de características.




Fig. 3 Resultados percentuais obtidos da taxa de acerto na detecção dos dormentes defeituosos e de falso positivo, utilizando parametrização espacial e a PCA como método de redução de dimensionalidade.

Posteriormente, analisaram-se os resultados obtidos para os diferentes tamanhos de janelas, utilizando a parametrização espectral e a FDR como método de seleção de características, obtendo os resultados apresentados pela figura 4. Por fim, foram encontrados os melhores resultados utilizando a análise espectral e a PCA como método de redução de dimensionalidade (Figura 5). O melhor resultado obtido para estas análises, e também o melhor resultado geral, foi utilizando a janela de tamanho 120 e a PCA (74,55% de taxa de acerto na detecção dos dormentes defeituosos e 39,85% de taxa de falso positivo).

Ao final das execuções, foram geradas imagens com os dados da saída do modelo, com o objetivo de verificar a correspondência entre os *clusters* gerados pelo classificador e os rótulos de um determinado elemento. Um exemplo desta análise está apresentada na Figura 6, em que as linhas verticais indicam o início (ciano) e o fim (vermelho) dos rótulos de defeito do elemento e

a linha laranja pontilhada indica o *cluster* apontado pelo classificador. Neste exemplo, foram utilizadas 4 classes para a geração do modelo, sendo que o *cluster* 3 representou a classe de defeito, enquanto os outros *clusters* (1, 2 e 4) estavam associadas aos dados saudáveis.

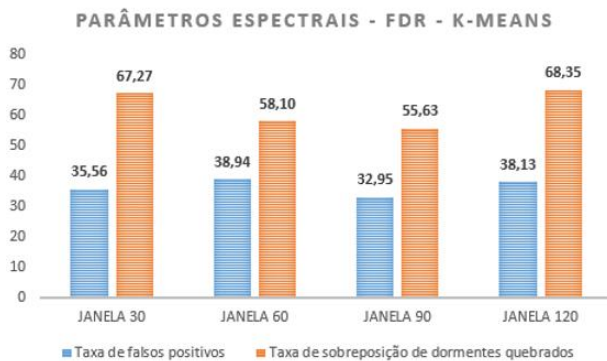


Fig. 4 Resultados percentuais obtidos da taxa de acerto na detecção dos dormentes defeituosos e de falso positivo, utilizando parametrização espectral e a FDR como método de seleção de características.




Fig.5 Resultados percentuais obtidos da taxa de acerto na detecção dos dormentes defeituosos e de falso positivo, utilizando parametrização espectral e a PCA como método de redução de dimensionalidade.

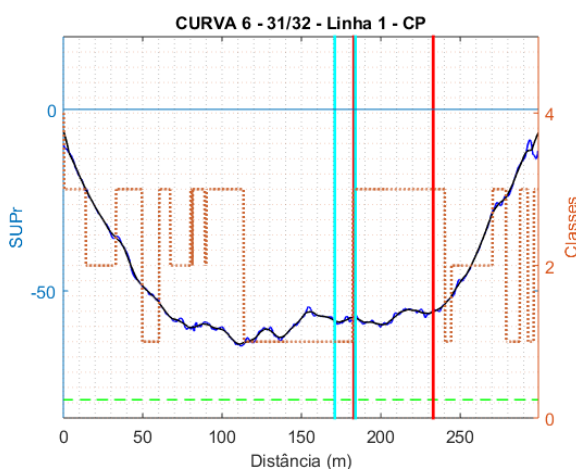


Fig. 6 Informações da saída de um dos modelos gerados para um dos elementos da base.

6. CONCLUSÃO

A hipótese inicial de que os sinais da geometria da linha (nivelamento longitudinal e transversal, alinhamento, empeno e bitola) podem ser utilizados para a localização dos trechos da ferrovia em que se encontram dormentes de aço danificados foi comprovada, e os resultados iniciais obtidos nos experimentos se mostraram promissores. As análises realizadas permitiram identificar uma melhor configuração considerando todas as variações utilizadas, que consiste na utilização da janela de dados com 120 amostras, método de parametrização espectral, o método de redução de dimensionalidade (PCA) e o seu respectivo número de componentes principais (10). Para essas configurações, o desempenho encontrado foi de 74,55% de taxa de acerto na detecção dos dormentes defeituosos e 39,85% de taxa de falso positivo.

Os estudos em andamento têm mostrado que os resultados atuais, apresentados, podem sofrer uma melhora no desempenho, ao considerar os dados, separadamente, por supervisão/linha. Além disso, a utilização de outros classificadores, como por exemplo os classificadores supervisionados, podem potencializar o desempenho atual na detecção de dormentes defeituosos. Portanto, como trabalhos futuros, espera-se a implementação de novas técnicas, como por exemplo, outros métodos de redução de dimensionalidade ou seleção de características, outros métodos de parametrização (transformada Wavelet, por exemplo), diferentes tamanhos de janelas, novos classificadores (Redes Neurais e Máquina de Vetores de Suporte, por exemplo), entre outras abordagens.

7. AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPQ), do Instituto Tecnológico Vale (ITV) e da Universidade Federal de Ouro Preto (UFOP). Os autores agradecem também a Vale S.A. pelo suporte de infraestrutura e financeiro dado a este projeto de pesquisa.

8. REFERÊNCIAS

- [1] ABNT. "NBR 16.387: Via Férrea - Classificação de Vias" 2ª edição.
- [2] ANTT. Fiscalização do Transporte Ferroviário de Cargas, 2ª ed., abril 2018.

-
- [3] BRINA, H. L. *Estradas de Ferro – Via Permanente*. Editora UFMG, 1988.
- [4] CLARK, A. *Damage Detection in Railway Prestressed Concrete Sleepers using Acoustic Emission*, IOP Conference Series: Materials Science and Engineering, 2017.
- [5] JAIN, A. K., MURTY, M. N., FLYNN, P. J. “*Data Clustering: A Review*”, ACM Comput. Surv., v. 31, n. 3, pp. 264–323, set. 1999.
- [6] OLIVEIRA, H. *Análise de Sinais para Engenheiros: Uma abordagem via WAVELETS*, 2007.
- [7] SMITH, L. I. “A Tutorial on Principal Components Analysis”, p. 27, 2002.
- [8] THEODORIDIS, S., KOUTROUMBAS, K. *Pattern Recognition & Matlab Intro*. 4th ed. USA, Academic Press, Inc., 2010.
- [9] YELLA, S., DOUGHERTY, M., K., G. N. “*Condition monitoring of wooden railway sleepers*”, Transportation Research, 2009.