

## MÁQUINA DE VETORES DE SUPORTE PARA CLASSIFICAÇÃO DE ANOMALIAS EM TRILHO A PARTIR DE CARACTERÍSTICAS DE TEXTURA DE IMAGENS DIGITAIS

### *A VECTOR SUPPORT MACHINE TO CLASSIFY RAIL ANOMALIES FROM DIGITAL IMAGE TEXTURE CHARACTERISTICS*

<sup>1</sup>Paulo César Lobo Rodriguez

<sup>2</sup>André Stanzani Franca

<sup>3</sup>Flávio Garcia Pereira

<sup>4</sup>Reginaldo B. Nunes

<sup>5</sup>Shirley P. N. Cani

<sup>6\*</sup>Mariana Rampinelli Fernandes

<sup>1</sup>Instituto Federal do Espírito Santo – campus Vitória. E-mail: paulocez.ar.eng@gmail.com

<sup>2</sup>Vale S/A. E-mail: andre.franca@vale.com

<sup>3</sup>Instituto Federal do Espírito Santo – campus Serra. E-mail: flavio.garcia@ifes.edu.br

<sup>4</sup>Instituto Federal do Espírito Santo – campus Vitória. E-mail: regisbn@ifes.edu.br

<sup>5</sup>Instituto Federal do Espírito Santo – campus Vitória. E-mail: shirleypnc@ifes.edu.br

<sup>6</sup>Instituto Federal do Espírito Santo – campus Vitória. E-mail: mariana.rampinelli@ifes.edu.br

\*Autor de correspondência

Artigo submetido em 15/02/2023, aceito em 07/06/2023 e publicado em 09/06/2023.

**Resumo:** O sistema ferroviário desempenha uma função importante no transporte de carga e de pessoas de um país. Para garantir a qualidade e segurança dos serviços, as empresas que detêm a concessão de malhas ferroviárias precisam ter como foco a manutenção e preservação dos trilhos. Este trabalho propõe uma ferramenta computacional que auxilia na classificação de danos encontrados na superfície dos boletos dos trilhos a partir de imagens capturadas por câmeras. Os trilhos foram classificados em três categorias, a depender do grau de severidade do dano apresentado no boleto: trilhos com o boleto em boas condições, trilhos com o boleto apresentando danos que podem ser reparados com esmerilhamento e trilhos com boletos apresentando danos severos que exigem substituição imediata. Neste trabalho foram executadas técnicas de extração de características a partir da análise de textura, espalhamento e distribuição estatística dos níveis de cinza das imagens dos trilhos. As características extraídas serviram de dados de entrada para um classificador de Máquina de Vetores de Suporte SVM. O método de classificação proposto atingiu uma acurácia média de 95,74% e uma precisão média de 96,21%. Os resultados alcançados mostram que a ferramenta proposta é promissora e pode ser aplicada na inspeção de trilhos.

**Palavras-chave:** processamento de imagens; ferrovia; inspeção de ferrovia; Máquina de Vetores de Suporte.

**Abstract:** The railway system plays an important role in the logistics of transporting cargo and people in the country. To guarantee the quality and safety of the railway service, the maintenance of tracks must always be on the focus of the companies that hold the railway concession. This work proposes a computational tool that assists classifying damage found on the surfaces of rail billets from images

captured by cameras. The rails were classified according to three levels of damage severity: rails with the billet surface in good condition, rails with damage to the billet surface that could still undergo grinding maintenance, and rails with severe damage to the billet surface and needing immediate replacement. In this work a method of extracting features from texture, scattering and statistical distribution of gray levels of pixels were executed and a Support Vector Machine technique was used as the classifier. The proposed method achieved an average accuracy of 95.74% and an average precision of 96.21%, proving to be a promising tool for using on railways inspection.

**Keywords:** image processing; railroad; rail inspection; Support Vector Machine.

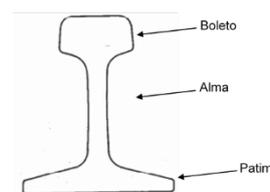
## 1 INTRODUÇÃO

A logística e a eficiência no uso de trens de carga é melhor quando comparadas ao uso de veículos rodoviários para o transporte de materiais em longas distâncias (ANTT, 2015). Por esse motivo, um sistema ferroviário eficiente e bem conectado é um diferencial de competitividade no transporte de carga em um país. No entanto, devido à dinâmica do contato roda-trilho, os trilhos podem apresentar severos e relevantes defeitos na superfície de contato (RCF – *rolling contact fatigue*). Tais defeitos impactam em sua vida útil e, conseqüentemente, segurança da ferrovia (HIGA; KINA; GAY NETO, 2022; MIRANDA *et al.*, 2019). Por isso, sua manutenção é um assunto de grande importância, não apenas pela segurança, mas também pelos custos associados ao seu mau planejamento ou, no extremo, à necessidade de paradas da ferrovia (BRINA, 1983). Além disso, desgastes ou avarias prematuras nos trilhos podem causar uma desistência precoce de investimento na exploração ferroviária, afetando a economia das empresas e do país. Defeitos mais severos, como fraturas no trilho, podem ocasionar acidentes de grandes proporções, sobretudo em trens de passageiros. A Figura 1 ilustra as partes que compõem o trilho do modelo Vignole (BRINA, 1983). O boleto é a parte mais susceptível a apresentar defeitos devido ao contato direto com as rodas do veículo ferroviário.

Os defeitos observados no boleto do trilho são normalmente causados pela fadiga por contato. Tais anomalias são consideradas como defeitos superficiais e

geralmente provenientes de colapso ou fadiga de material (HIGA; KINA; GAY NETO, 2022; MACHADO *et al.*, 2009; MIRANDA *et al.*, 2019). Os defeitos no boleto do trilho são de origens, tipos e níveis de severidade diferentes.

Figura 1: Vista do perfil de um trilho do modelo Vignole e suas partes. O boleto é a superfície de contato com os rolamentos do trem.

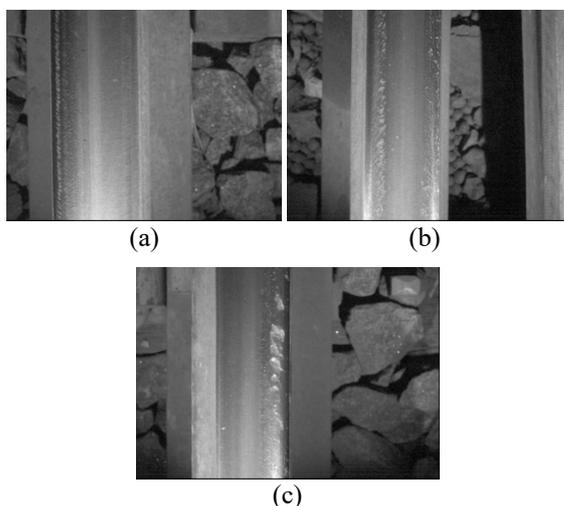


Fonte: Brina (1983).

Em geral, a inspeção da condição da superfície de rolamento é feita visualmente por um especialista, baseada apenas na condição do trilho e severidade do defeito, e é realizada em intervalos periódicos. Durante a análise, os especialistas classificam os trilhos, de acordo com a integridade do boleto. Neste trabalho os trilhos foram classificados em tipos A, B e C. O trilho tipo A é aquele cuja superfície do boleto é mais homogênea, não apresentando falhas ou ranhuras. O trilho do tipo B é aquele cujas falhas ou ranhuras já começam a ficar evidentes, mas ainda podem ser esmerilhados e voltar para a condição do tipo A. O trilho do tipo C é aquele cuja superfície do boleto apresenta desgastes com profundidade considerável e requerem atenção ou substituição imediata. A Figura 2 mostra imagens dos três tipos de classificação dos trilhos. A classificação correta dos danos dos trilhos favorece a

programação das ações de manutenção, esmerilhamento ou substituição dos trechos de trilho.

Figura 2: Imagens do boleto de trilhos do tipo (a) A, (b) B e (c) C.



Fonte: Material cedido pela empresa Vale e adaptado pelo autor.

Os trilhos do tipo A são trilhos sem defeitos ou com incidências de pequenas deformações e/ou defeitos superficiais em seu boleto. Já os trilhos do tipo B possuem algum problema na superfície do boleto e requerem esmerilhamento. Por fim, os do tipo C, possuem características defeituosas como ranhuras e/ou rachaduras profundas tanto no centro do boleto como nas laterais e, nesses casos de danos severos, exige-se a troca imediata dos trilhos.

Para agilizar o trabalho de inspeção da ferrovia, muitas empresas utilizam veículos capazes de coletar imagens dos trilhos, enquanto trafegam sobre eles, evitando, assim, o deslocamento de um especialista para campo. Isso proporciona um trabalho menos insalubre e mais confortável para o colaborador. Mesmo assim, o diagnóstico ainda é realizado por um especialista, que analisa as imagens coletadas e classifica o trilho de acordo com o defeito e sua necessidade de manutenção. Esse diagnóstico realizado por um especialista torna o processo subjetivo e sujeito à análise individual de cada profissional. Além disso, a análise visual

das imagens acarreta custo elevado em horas de trabalho.

Nesse contexto, este trabalho propõe um sistema de classificação de imagens baseado em algoritmos de processamento de imagem e aprendizado de máquinas. O objetivo desse sistema é classificar os trilhos de acordo com o nível de defeito encontrado em seu boleto, utilizando as imagens capturadas em campo. O uso do algoritmo proposto neste trabalho possibilitará o desenvolvimento de uma ferramenta para automatização e padronização da classificação dos trilhos de maneira mais assertiva. Desse modo, a ferramenta poderá proporcionar uma programação da manutenção de esmerilhamento do trilho mais eficiente nos trechos que realmente precisam de uma intervenção ou a troca do trilho defeituoso. Isso pode oferecer uma economia de tempo e recursos técnicos e financeiros, possibilitando que a empresa direcione seus esforços para demandas de maior prioridade.

## 2 REVISÃO DE LITERATURA

Nos últimos anos, muitas pesquisas sobre a detecção automática de falhas ferroviárias foram desenvolvidas. Um método para extrair diretamente os defeitos superficiais por análise de textura das imagens dos trilhos foi proposto em (MA *et al.*, 2016). Nesse trabalho, os autores determinaram a região de interesse utilizando o algoritmo de floresta aleatória para gerar um mapa da borda do trilho e a transformada de Hough para localizar os limites da superfície do boleto do trilho. Para extrair as características e analisar as imagens, utilizaram o algoritmo *texton dictionary*, e através do banco de filtros *Full Maximum Response (FMR8)*, que contém 38 filtros de baixa dimensão, retornaram 38 características do trilho que serviram de entrada para o classificador que utiliza a técnica de Máquina de Vetores de Suporte (SVM, do inglês *Support Vector Machine*). Esse método conseguiu classificar

problemas superficiais no boleto dos trilhos em oito categorias, alcançando uma acurácia de 82%.

Em Yaman, Karakose, Akin (2017), os autores extraem curvas características de cada imagem baseado em suas variâncias ao longo de cada linha de pixel da região do trilho. As entradas do classificador são o coeficiente angular, o valor de “a” e o valor de “b”, conforme pode ser visto na Figura 3 que ilustra as curvas de variâncias. O autor apresenta, nesse trabalho, uma tabela com cada tipo de problema do trilho classificado e com seus parâmetros preestabelecidos. Após a análise das imagens, essa tabela serve de base para a classificação do tipo de problema encontrado utilizando lógica *fuzzy*.

Em Min et al. (2018) foi utilizada visão computacional e técnica de aprendizado profundo para detecção de defeitos em trilho ferroviários em tempo real. Uma rede neural convolucional (CNN) foi treinada para análise de imagens capturadas da superfície dos trilhos e identificação de diferentes tipos de defeitos. O pré-processamento envolveu a aplicação de um filtro de mediana para reduzir o ruído nas imagens e, na sequência, a binarização para separar a área de interesse, neste caso o trilho, do restante da imagem. Após esta etapa, foram aplicados filtros morfológicos para remover ruídos adicionais e destacar os defeitos. O sistema apresentou uma alta precisão na detecção de defeitos em trilhos ferroviários, alcançando uma taxa de detecção de 96,7% para defeitos na superfície do trilho. Outro ponto importante apresentado no trabalho é que o sistema é capaz de detectar defeitos em diferentes condições climáticas e em velocidades de até 120 km/h, o que sugere que o sistema pode ser uma ferramenta valiosa para a manutenção preventiva de trilhos ferroviários.

A metodologia proposta em Jang et al. (2019) consiste em três etapas principais: aquisição de imagens, detecção de objetos e comparação de imagens. Na etapa de aquisição de imagens, são capturadas

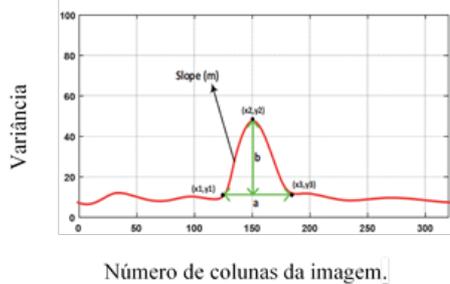
imagens dos trilhos ferroviários, usando uma câmera de alta resolução. Para a etapa de detecção de objetos foi treinada uma rede neural convolucional (CNN) para identificar e localizar diferentes objetos de interesse tais como trilhos, dormentes e fixadores. Na etapa de comparação de imagens, as imagens capturadas são comparadas com imagens de referência usando a técnica de contraste de Weber para detectar possíveis defeitos nos trilhos. Os resultados mostraram que a metodologia proposta é capaz de detectar com precisão diferentes objetos de interesse nos trilhos ferroviários, bem como identificar possíveis defeitos, como rachaduras e desgaste excessivo. A acurácia média da detecção de objetos foi de 96,5%, enquanto a acurácia média da detecção de defeitos foi de 92,3%.

O trabalho apresentado em (GAN *et al.*, 2020) propõe um método que compara o fundo de duas imagens e extrai de cada pixel da imagem características como o valor do pixel, valor médio, valor da mediana dos pixels com seus vizinhos. A ideia principal é comparar essas características de fundo de um trilho com defeito com um trilho sem defeito. Uma outra característica desse método, é que a avaliação é feita em tempo real através de um computador instalado a bordo do equipamento que está inspecionando a ferrovia.

Em Zhai, Ma (2022) foi proposto um algoritmo de detecção de defeitos na superfície dos trilhos baseado em um método de fusão de saliência multifuncional. Esse algoritmo combina características como textura, cor e orientação para identificar áreas de interesse e detectar defeitos com maior precisão. Segundo o autor, a abordagem multifuncional permite que o algoritmo se adapte a diferentes condições e tipos de defeitos, aumentando a eficácia da detecção. O algoritmo proposto também emprega uma etapa de pré-processamento para remover o ruído e melhorar a qualidade das imagens dos trilhos. Em seguida, são extraídas as características visuais dos

trilhos, tais como: histograma de cores e matriz de coocorrência de textura. Foi obtido 76,53% de acerto na localização do defeito no boleto.

Figura 3: Curva com os parâmetros de variância em função da coluna da imagem.



Fonte: Yaman, Karakose e Akin (2017).

Neste trabalho, os trilhos são classificados em três classes: tipo A, tipo B e tipo C. Assim como em Yaman, Karakose, Akin (2017), a técnica proposta utiliza análise das características de variância dos pixels. Além disso, utiliza informações de textura das imagens, a partir de uma abordagem estatística da matriz de coocorrência gerada de cada imagem. De cada tipo de trilho são extraídas características que servirão de entrada para o classificador utilizado neste trabalho, o SVM, assim como em Ma *et al.* (2016). Durante o desenvolvimento do trabalho, foi feito um treinamento do algoritmo e posterior classificação das amostras dos boletos dos trilhos em suas devidas classes.

### 3 EXTRAÇÃO DE CARACTERÍSTICAS DAS IMAGENS

Neste trabalho, uma importante informação para a classificação dos tipos de trilhos a partir da severidade dos danos em sua superfície é a textura. A abordagem adotada foi a estatística e diferentes descritores foram calculados a partir da matriz de coocorrência de níveis de cinza ou simplesmente matriz de coocorrência (MC) (MARTINS *et al.*, 2011).

A MC contém a probabilidade relativa  $P(i,j)$  com a qual dois *pixels* separados por uma distância  $d$  e em uma

direção  $\theta$  acontece na imagem, um com nível de intensidade de cinza  $i$  e o outro, com nível de cinza  $j$  (MARTINS *et al.*, 2011). Normalmente, a MC é usada com a frequência normalizada.

Uma vez que os trilhos estão na vertical nas imagens capturadas, suas marcas naturais de uso também se apresentam na vertical. Desse modo, em um trilho íntegro, como o apresentado na Figura 2a, existe uma tendência de a intensidade dos *pixels* manterem-se constantes em uma mesma coluna. Além disso, observou-se que os defeitos de desgastes que se quer identificar apresentam-se como uma mudança brusca na textura, e conseqüentemente de cor, no boleto, como pode ser visto nas Figura 2b-c. Dessa forma, uma hipótese levantada foi que a distância  $d = 1$  e o ângulo  $\theta = 90^\circ$  para o cálculo da MC seria mais adequado para detecção de tais defeitos, pois eles gerariam uma quebra na constância de intensidade dos pixels em uma mesma coluna. Os resultados de testes com outras MCs corroboraram com a hipótese. O número de níveis de cinza analisado foi de 256, resultando em uma MC quadrada de  $256 \times 256$ , com 65.536 posições.

A MC é sempre quadrada e simétrica, com os mesmos valores para os elementos situados em lados opostos da diagonal principal. O número de linhas e colunas é igual à quantidade de diferentes níveis de cinza da imagem. (NASCIMENTO, 2003).

#### 3.1 CARACTERÍSTICAS DE TEXTURA CALCULADAS A PARTIR DA MC

Algumas características de textura de uma imagem podem ser obtidas a partir da MC. Entre elas estão: o segundo momento angular (ASM, do inglês, *Angular Second Moment*), a energia, a homogeneidade, o contraste, a dissimilaridade e a correlação (HARALICK; SHANMUGAM; DINSTEIN, 1973).

O segundo momento angular avalia a imagem de acordo com a constância da intensidade de nível de cinza. Altos valores no descritor ASM usualmente significam que há uma distribuição aproximadamente uniforme ou periódica dos níveis de cinza ao longo da imagem. Uma distribuição não periódica de níveis de cinza de uma imagem acarreta valores das células da matriz de coocorrência baixos, levando o ASM a ser baixo também (SOUTO JUNIOR, 2010). Desse modo, valores mais baixos nessa característica estão relacionados à presença de mais defeitos no trilho.

Já a energia é a raiz quadrada do segundo momento angular e é também utilizada como medida de textura (NASCIMENTO, 2003), mede a uniformidade da imagem. Uma uniformidade igual a 1 significa que a textura da imagem é constante (GONZALEZ; WOODS, 2010). As Eq. 1 e 2 mostram o cálculo do ASM e da energia, respectivamente,

$$ASM = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} p(i, j)^2, \quad (1)$$

$$Energia = \sqrt{ASM}, \quad (2)$$

onde  $p(i, j)$  é um elemento de uma MC de tamanho  $Ng \times Ng$  e representa a probabilidade normalizada de ocorrência das intensidades de cinza  $i$  vizinha ao nível de cinza  $j$ , utilizando uma distância  $d = 1$  e ângulo  $\theta = 0^\circ$ .

A homogeneidade também mede o grau de variação local dos níveis de cinza entre pares de pixels. Quanto mais constante é uma imagem, maior é esta medida (SOUTO JUNIOR, 2010). Assim, com valores mais baixos de homogeneidade, aumenta-se a possibilidade de haver defeitos no trilho avaliado. O cálculo da homogeneidade a partir da MC é dado pela Eq. 3.

$$Homog = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} \frac{p(i, j)}{1+(i-j)^2}. \quad (3)$$

O contraste e a dissimilaridade também quantificam a variação local dos

níveis de cinza entre pares de pixels. Ao contrário das características anteriores, valores maiores de contraste e de dissimilaridade são obtidos para imagens compostas principalmente por níveis de cinza diferentes, como preto e branco (SOUTO JUNIOR, 2010). Os cálculos do contraste e da dissimilaridade são apresentados nas Eq. 4 e 5.

$$\text{Contraste} = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} (i - j)^2 p(i, j), \quad (4)$$

$$\text{Dissimilaridade} = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} |i - j| p(i, j). \quad (5)$$

O coeficiente de correlação é uma medida estatística que avalia o grau de associação linear (negativa ou positiva) entre duas variáveis quantitativas (SOUTO JUNIOR, 2010). A correlação em textura mede a associação linear de *pixels* em relação à sua vizinhança (NASCIMENTO, 2003).

$$\text{Correlação} = \frac{p(i, j) - \mu_x \mu_y}{\sigma_x^2 \sigma_y^2}, \quad (6)$$

onde  $\mu_x = \sum_{i=1}^{Ng} i \times p_x(i)$ ,  $\mu_y = \sum_{j=1}^{Ng} j \times p_y(j)$ ,  $\sigma_x^2 = \sum_{i=1}^{Ng} (i - \mu_x)^2 p_x(i)$  e  $\sigma_y^2 = \sum_{j=1}^{Ng} (j - \mu_y)^2 p_y(j)$  são as médias e as variâncias da distribuição marginal associada a  $p(i, j)$ , com  $p_x(i) = \sum_{j=1}^{Ng} p(i, j)$  e  $p_y(j) = \sum_{i=1}^{Ng} p(i, j)$ .

### 3.2 CARACTERÍSTICAS DE DISPERSÃO

A variância é uma medida de dispersão que diz o quão distante de uma média, um valor se encontra (DEVORE, 2006). Analisando as imagens dos trilhos do tipo A, tipo B e tipo C, observou-se que existe um padrão que se repete em todas as situações. Nos trilhos tipo A, sua superfície é mais homogênea, com pouca variação de cor e textura. Já nos trilhos do tipo B e tipo C, existem deformidades que descaracterizam a superfície do trilho. Desse modo, a variância do nível de cinza

na imagem do trilho pode ser um parâmetro que representa o grau de defeito do trilho.

### 3.3 CARACTERÍSTICAS DE DISTRIBUIÇÃO DOS PIXELS

Além da textura e da dispersão, também foi analisado a tendência de distribuição dos valores dos pixels nas imagens dos boletos dos trilhos. Nessa análise, foram consideradas duas características das distribuições: a assimetria e a curtose (DEVORE, 2006).

#### 3.3.1 Assimetria

A assimetria, como o nome explica, é uma medida que avalia quão assimétrica é uma distribuição de dados. Uma distribuição é simétrica quando seus valores de média, mediana e moda coincidem. A comparação entre o valor da média e o valor da moda, dá, portanto, uma indicação da inclinação da distribuição.

#### 3.3.2 Curtose

Denomina-se curtose o grau de achatamento da distribuição de frequência de um histograma (DEVORE, 2006). A distribuição normal é a distribuição de referência denominada mesocúrtica; quando uma distribuição tem uma curva mais concentrada (mais aguda em sua parte superior), a denominação é leptocúrtica; finalmente, quando a distribuição é uma curva mais aberta e achatada, é chamada de platicúrtica. No processamento de imagens digitais, os valores de curtose são interpretados em combinação com ruído e resolução da imagem. Valores altos de curtose podem estar associados com baixo ruído e baixa resolução (GONZALEZ; WOODS, 2010).

## 4 CLASSIFICADOR

Este trabalho utiliza a técnica de SVM para classificar os trilhos em três tipos de classes a depender do grau de severidade dos defeitos dos boletos: tipo A (trilho sem

defeitos ou ranhuras), tipo B (trilho com falhas ou ranhuras evidentes, mas não caracterizando defeitos significativos) e tipo C (trilhos que apresentam defeitos significativos), conforme mostrado na Figura 2.

A técnica de SVM foi a adotada para ser o classificador pois, de acordo com (BOSER; GUYON; VAPNIK, 1992), os classificadores treinados com o algoritmo SVM são capazes de obter margens de separação mais amplas e, ao mesmo tempo, apresentam uma baixa taxa de erros de classificação.

Esta técnica busca um limiar de classificação linear que maximize a margem de separação entre as classes das amostras.

Após o treinamento, o SVM traça o hiperplano representado pela linha, capaz de dividir as duas classes de dados. A classificação de novas amostras dá-se pela distância destas à margem de separação (hiperplano), descrita por vetores (MÜLLER; GUIDO, 2016). Neste trabalho foi utilizado um SVM com kernel linear por de ser o mais simples do ponto de vista de implementação, e menos propenso à ocorrência de *overfitting* (ROSEBROCK, 2014).

Outras informações acerca do ambiente de desenvolvimento e ferramentas que foram utilizadas neste trabalho são: linguagem de programação *Python*, por ser uma linguagem limpa e concisa com bom suporte para entradas/saídas numéricas, imagens e plotagens diversas (PILIFRIM, 2012); o ambiente de desenvolvimento usado foi o *Jupyter* (KLUYVER et al., 2016); a biblioteca usada para a criação e manipulação de dados foi a *Pandas*; para a manipulação das imagens e plotagem dos gráficos foram usadas a *OpenCV* (BRADSKI, 2000), *Matplotlib* (HUNTER, 2007) e *Numpy* (VAN DER WALT; COLBERT; VAROQUAUX, 2011); na manipulação dos algoritmos de aprendizado de máquina foi usada a biblioteca *Scikit-learn*. (ROSEBROCK, 2014).

## 5 EXPERIMENTOS

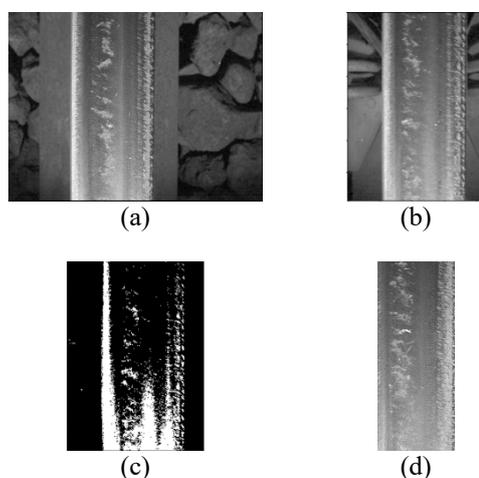
### 5.1 BASE DE DADOS

A base de dados estruturada para este trabalho é composta de 520 imagens capturadas por um veículo de inspeção de ferrovia, usualmente chamado de RIV (*Rail Inspection Vehicle*). Nessa base, foram usadas 156 imagens do tipo A, 154 imagens do tipo B e 210 do tipo C. As imagens possuem dimensão de  $1200 \times 1600$  pixels.

### 5.2 DETERMINAÇÃO DA REGIÃO DE INTERESSE

O sistema de câmera que captura a imagem do boleto do trilho está instalado em uma posição fixa no veículo. Desse modo, definiu-se a região de interesse (ROI, do inglês *region of interest*) da imagem de tamanho  $1200 \times 800$ , que é uma janela que contém o boleto, mesmo que sua posição na imagem esteja um pouco deslocada. O uso da ROI no processamento das imagens diminui o custo computacional do algoritmo proposto (GONZALEZ; WOODS, 2010).

Figura 4: Imagem do trilho: (a) imagem original; (b) imagem original recortada (c) após limiarização; (d) imagem original recortada separando a região de interesse: o boleto do trilho.



Fonte: Material cedido pela empresa Vale a adaptada pelo autor.

Em seguida, a imagem recortada, foi binarizada de modo a destacar o boleto do trilho, utilizando uma limiarização, como mostrado na Figura 4.

Após a etapa de determinação da ROI, foram executadas as etapas de extração das características das imagens descritas nas seções seguintes.

### 5.3 EXTRAÇÃO DE CARACTERÍSTICAS DA IMAGEM

A partir da ROI da imagem original, foram calculadas as características apresentadas na Seção 3 que pudessem representar a diferença de cada tipo de trilho. Tais características são listadas na Tabela 1.

Tabela 1: Características extraídas das imagens

#	Variável no algoritmo	Característica <sup>5</sup>
1	<u>MAX_VAR</u>	<b>Máxima variância por linha</b>
2	<u>SUM_LIN</u>	<b>Soma das variâncias por linha</b>
3	<u>SUM_COL</u>	<b>Soma das variâncias por coluna</b>
4	<u>ENERGIA_IMG</u>	Energia
5	HOMOGENEIDADE	Homogeneidade
6	<u>CONTRASTE</u>	<b>Contraste</b>
7	DISSIMILARIDADE	Dissimilaridade
8	<u>CORRELAÇÃO</u>	<b>Correlação</b>
9	ASM	Segundo momento angular
10	MAX_CURTOSE	Valor máximo da curtose por coluna
11	MIN_CURTOSE	Valor mínimo da curtose por coluna
12	<b>MEAN_CURTOSE</b>	<b>Valor médio da curtose por coluna</b>
13	<b>VAR_CURTOSE</b>	<b>Variância da curtose por coluna</b>
14	ASSIM_CURTOSE	Assimetria da curtose por coluna
15	<b>CURTOSE</b>	<b>Curtose por coluna</b>
16	<b>MAX_CURTOSE_LIN</b>	<b>Valor máximo da curtose por linha</b>
17	<b>MIN_CURTOSE_LIN</b>	<b>Valor mínimo da curtose por linha</b>
18	<b>MEAN_CURTOSE_LIN</b>	<b>Valor médio da curtose por linha</b>
19	<b>VAR_CURTOSE_LIN</b>	<b>Variância da curtose por linha</b>
20	<b>ASSIM_CURTOSE_LIN</b>	<b>Assimetria da curtose por linha</b>
21	<b>CURTOSE_LIN</b>	<b>Curtose por linha</b>

<sup>5</sup> Características em negrito foram utilizadas como entrada no modelo do segundo experimento. Características sublinhadas foram utilizadas como entrada no modelo do terceiro experimento.

Fonte: próprio autor.

Para a escolha das características mais relevantes para a classificação do trilho em A, B ou C, foi usado o teste estatístico  $\chi^2$ , cujo resultado pode ser visto na Figura 5, sendo as variáveis ordenadas da de maior para a de menor relevância.

#### 5.4 AVALIAÇÃO DOS MODELOS

Os modelos propostos foram treinados e validados utilizando a técnica de validação cruzada (KOHAVI, 1995). Esta técnica consiste em separar as imagens utilizadas para treino e validação em *K-folds* (pastas contendo as imagens). A cada rodada de treino e validação, *K-1 folds* são utilizados para treino e 1 *fold* é utilizado para validação. Neste trabalho, todas as imagens da base de dados (520 imagens) foram divididas em  $K = 10$  *folds*, e consequentemente, 10 etapas de treinamento e validação foram realizadas.

Figura 5: Relevância das características conforme teste estatístico  $\chi^2$ . A primeira variável superior “SUM\_COL” (Soma das variâncias por coluna) mostra-se como a mais relevante para a classificação.



Fonte: Próprio autor.

Em cada rodada de treinamento e validação foram utilizadas duas métricas de desempenho para avaliar o classificador, a acurácia e a precisão. Para o cálculo das métricas, as imagens classificadas pelo classificador foram separadas em quatro classes distintas: as imagens que foram classificadas corretamente como positivas,

chamadas de VP (verdadeiros positivos); as que foram corretamente classificadas como negativas, chamadas de VN (verdadeiros negativos); as imagens erroneamente classificadas como positivas, chamadas de FP (falsos positivos); e as erroneamente classificadas como negativas, chamadas de FN (falsos negativos).

O cálculo da acurácia e da precisão dá-se pelas Eq. 7 e 8 (FACELI *et al.*, 2011).

$$\text{Acurácia} = \frac{VP+VN}{\text{total de amostras}} \quad (7)$$

$$\text{Precisão} = \frac{VP}{(VP+FP)} \quad (8)$$

## 6 RESULTADOS E DISCUSSÃO

No primeiro experimento foram utilizadas as 21 características extraídas das imagens do boleto do trilho como entrada do classificador SVM. As métricas de avaliação do classificador utilizadas foram a acurácia e a precisão, calculadas a partir da validação cruzada com 10 *folds*. O desempenho desse modelo pode ser visto na Tabela 2.

Tabela 2: Acurácia e precisão realizados na validação cruzada com 10 *folds* para o modelo com 21 características de entrada

Teste <i>k</i>	Acurácia (%)	Precisão (%)
1	94,23	94,37
2	94,23	94,79
3	100,0	100,0
4	94,23	94,95
5	94,23	94,77
6	92,30	93,92
7	98,07	98,19
8	98,07	98,16
9	94,23	94,95
10	86,53	95,23
<b>Média</b>	<b>94,61</b>	<b>95,93</b>

Fonte: Próprio autor.

Apesar do bom desempenho alcançado pelo classificador, também foram testados modelos com menos características, com objetivo de diminuir a complexidade do modelo proposto. A escolha das características baseou-se no

grau de relevância individual que elas apresentaram no teste mostrado na Figura 5.

No segundo teste, foram utilizadas 14 características como entrada do novo modelo, destacadas em negrito na Tabela 1. A Tabela 3 mostra o resultado da precisão e acurácia calculadas para o teste com 14 características.

Tabela 3: Acurácia e precisão realizados na validação cruzada com 10 *folds* para o modelo com 14 características de entrada

Teste <i>k</i>	Acurácia (%)	Precisão (%)
1	98,11	98,22
2	96,23	96,65
3	98,11	98,22
4	100,0	100,0
5	92,31	93,22
6	94,23	95,19
7	98,04	98,16
8	98,04	98,13
9	94,12	94,85
10	88,24	89,47
<b>Média</b>	<b>95,74</b>	<b>96,21</b>

Fonte: Próprio autor.

O terceiro experimento utilizou nove características, escolhidas a partir da sua relevância individual, como mostrado na Figura 5. Foram usadas como entrada do novo modelo as variáveis sublinhadas na Tabela 1. A Tabela 4 mostra o resultado da precisão e acurácia calculadas na partição de teste das 10 iterações da validação cruzada, bem como a média desses resultados.

Tabela 4: Acurácia e precisão realizados na validação cruzada com 10 *folds* para o modelo com 21 características de entrada

Teste <i>k</i>	Acurácia (%)	Precisão (%)
1	91,23	93,30
2	94,33	94,37
3	98,17	98,19
4	96,10	96,48
5	87,82	89,40
6	80,32	83,66
7	89,51	90,51
8	95,92	96,36
9	88,05	89,14
10	74,30	91,45
<b>Média</b>	<b>89,58</b>	<b>92,29</b>

Fonte: Próprio autor.

A partir do terceiro experimento, foi possível observar que, com nove características, há uma queda no desempenho do sistema. Esse fato nos indica que não é recomendável retirar tantas informações do modelo. Apesar de diminuir o desempenho médio do modelo, ele alcança uma acurácia média de 89,58% e uma precisão média de 92,29%, que são bons índices para o classificador.

Observando o resultado dos 10 testes com 14 características de entrada, constata-se que, em todas as iterações, o modelo apresentou acurácia e precisão superiores a 90% na maioria das iterações, com média de 95,74% para acurácia e de 96,21% para precisão. Tais resultados mostram-se promissores e o uso dessa ferramenta em campo pode ser uma alternativa para otimizar a inspeção do nível de severidade dos defeitos no boleto dos trilhos, auxiliando o inspetor em uma atividade importante e exaustiva.

## 7 CONCLUSÕES

Este trabalho teve por objetivo criar um modelo de aprendizado de máquina que fosse capaz de analisar e classificar imagens do boleto do trilho da ferrovia em três classes. Usando técnicas de processamentos digitais de imagens, foram extraídos descritores que serviram de entrada para o algoritmo de classificação supervisionado SVM.

Para isso, foram utilizadas 520 imagens capturadas em campo em um sistema de inspeção real. As imagens foram avaliadas quanto às características de textura do boleto do trilho e de variância dos valores de pixels da imagem. Usando a matriz de coocorrência de níveis de cinza, análise de dispersão e de distribuição dos pixels, foram encontrados 21 descritores estatísticos. A quantidade de descritores utilizados como parâmetro de entrada foi variada e os resultados foram comparados. O melhor resultado foi alcançado com a utilização de 14 descritores. O modelo alcançou precisão e acurácia de 96,21% e

95,74% respectivamente, o que mostra que essa é uma ferramenta de uso promissor na operação em campo em um ambiente parcialmente controlado.

Como trabalhos futuros, novos testes podem ser realizados utilizando imagens de outras ferrovias. Além disso, uma interface amigável deve ser desenvolvida para aplicação desse sistema em ambiente industrial. Por fim, propõem o estudo de outras técnicas mais robustas de aprendizado profundo, que poderiam melhorar o desempenho do sistema proposto.

### AGRADECIMENTOS

Os autores agradecem à Vale pelo financiamento do projeto “Inspeção Automática de Ferrovia e Porto” e pela cessão das imagens utilizadas neste trabalho.

### REFERÊNCIAS

ANTT. **Extensão da Malha Ferroviária**. Disponível em: <http://portal.antt.gov.br/index.php/content/view/4751/Ferroviaria.html>>. Acesso em: 21 jun. 2019.

BRINA, H. L. **Estradas de ferro**. Rio de Janeiro: LTC, 1983.

BRADSKI, G. The OpenCV Library. **Dr. Dobb's Journal of Software Tools**, 2000.

BOSER, B. E.; GUYON, I. M.; VAPNIK, V. N. A training algorithm for optimal margin classifiers. **Proceedings of the fifth annual workshop on Computational learning theory - COLT '92**, 1992.

DEVORE, J. L. **Probabilidade e Estatística para a Engenharia e Ciências**. 6a. ed. São Paulo: Cengage, 2006.

FACELI, K. *et al.* **Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina**. São Paulo: LTC, 2011.

GAN, J. *et al.* Online Rail Surface Inspection Utilizing Spatial Consistency and Continuity. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, v. 50, n. 7, p. 2741–2751, jul. 2020.

GONZALEZ, R. C.; WOODS, R. E. **Processamento Digital de Imagens**. São Paulo: Pearson, 2010.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural Features for Image Classification. **IEEE Transactions on Systems, Man, and Cybernetics**, v. SMC-3, n. 6, p. 610–621, nov. 1973.

HIGA, D. N.; KINA, E. J.; GAY NETO, A. Wheelset-rail mechanical model for a steady-state dynamic condition and prediction of rolling contact fatigue locci. **Vehicle System Dynamics**, v. 60, n. 1, p. 281–308, 2 jan. 2022.

HUNTER, J. D. Matplotlib: A 2D Graphics Environment. **Computing in Science & Engineering**, v. 9, n. 3, p. 90–95, 2007. Disponível em: <<http://ieeexplore.ieee.org/document/4160265/>>.

JANG, J. *et al.* **Intelligent Image-Based Railway Inspection System Using Deep Learning-Based Object Detection and Weber Contrast-Based Image Comparison**. **Sensors**, v. 19, n. 21, p. 4738, 31 out. 2019.

KLUYVER, T. *et al.* Jupyter Notebooks—a publishing format for reproducible computational workflows. **Positioning and Power in Academic Publishing: Players, Agents and Agendas**, p. 87–90, 2016.

KOHAVI, R. A study of cross-validation and bootstrap for accuracy estimation and model selection. 1995, San Francisco, CA, USA: [s.n.], 1995. p. 1137–1143.

- LI, Q.; REN, S. A Visual Detection System for Rail Surface Defects. **IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)**, v. 42, n. 6, p. 1531–1542, nov. 2012.
- PILIFRIM, M. **Dive into Python**. [S.l.: s.n.], 2012. v. 104. Disponível em: <<https://academic.oup.com/jnci/article-lookup/doi/10.1093/jnci/djs084>>.
- MA, K. *et al.* Texture classification for rail surface condition evaluation. mar. 2016, [S.l.]: IEEE, mar. 2016. p. 1–9.
- MACHADO, A. *et al.* **Manual Técnico da Via Permanente**. Rev. ed. [S.l.]: VALE S. A., 2009.
- MARTINS, J. G. *et al.* Uso de descritores de textura extraídos de GLCM para o reconhecimento de padrões em diferentes domínios de aplicação. 2011, [S.l.]: Elsevier, 2011.
- MIRANDA, G. *et al.* **Atlas de Defeitos em Trilhos**. . Pará: [s.n.], 2019.
- MIN, Y. *et al.* **Real time detection system for rail surface defects based on machine vision**. EURASIP Journal on Image and Video Processing, v. 2018, n. 1, 11 jan. 2018.
- MÜLLER, A. C.; GUIDO, S. **Introduction to Machine Learning with Python: A Guide for Data Scientists**. 1. ed. New York, NY, USA: [s.n.], 2016.
- NASCIMENTO, J. P. R. do. **Análise e classificação de imagens baseadas em características de textura utilizando matrizes de co-ocorrência**. 2003. Dissertação (Mestrado) - Programa de Pós-Graduação em Informática, Setor de Ciências Exatas da Universidade Federal do Paraná, 105 f. 2003.
- ROSEBROCK, A. **Practical Python and OpenCV**. [S.l.: s.n.], 2014
- SOUTO JUNIOR, C. A. **Avaliação de descritores de textura para segmentação não-supervisionada de imagens**. 2010. Dissertação (Mestrado) - Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, 138 f. 2010.
- VAN DER WALT, S.; COLBERT, S. C.; VAROQUAUX, G. The NumPy Array: A Structure for Efficient Numerical Computation. **Computing in Science & Engineering**, v. 13, n. 2, p. 22–30, mar. 2011. Disponível em: <<http://ieeexplore.ieee.org/document/5725236/>>.
- YAMAN, O.; KARAKOSE, M.; AKIN, E. A vision based diagnosis approach for multi rail surface faults using fuzzy classification in railways. out. 2017, [S.l.]: IEEE, out. 2017. p. 713–718.
- YEN, H. Machine Vision System for Surface Defect Inspection of Printed Silicon Solar Cells. 2012, [S.l.: s.n.], 2012. p. 422–424.
- ZHAI, H.; MA, Z. **Detection algorithm of rail surface defects based on multifeature saliency fusion method**. **Sensor Review**, 1 jun. 2022.