



Identificação de Defeitos em Trilhos por Imagens

1º Rebeca Alves da Silva Lemos Passos ^{1*}, 2º Luiz Antônio Silveira Lopes¹, 3º Ben-Hur de Albuquerque e Silva¹, 4º Romero Pereira dos Santos², 5º Fernando César de Moura e Silva³, 6º Carmen Dias Castro¹

¹ Instituto Militar de Engenharia, Praça General. Tibúrcio, 80 - 22290-270, Urca – Rj.

² MRS Logística, Avenida Brasil, 2001 - 36060-010, Juiz de Fora – Mg.

³ CH. Vidon, R. Barão de Juiz de Fora, 47 - 36062-410, Santos Anjos, Juiz de Fora – Mg.

E-mail: 1º rebeca_gsm@hotmail.com, 2º laslopes@ime.eb.br, 3º benhur@ime.eb.br, 4º romero.santos@mrs.com.br, 5º fcs@chvidon.com.br, 6º carmendc14@gmail.com

Resumo O gerenciamento eficiente da manutenção da via permanente ferroviária é guiado por inspeções constantes, capazes de identificar os trechos da superestrutura que demandam intervenções a curto, médio e longo prazo. Com o desenvolvimento das técnicas de visão computacional nos últimos anos, sistemas automáticos de inspeção de via permanente passaram a ser desenvolvidos para detectar e tratar as falhas de diferentes naturezas, a fim de aumentar a eficiência da manutenção das ferrovias, reduzindo o tempo de inspeção, garantindo assim maior disponibilidade e confiabilidade do sistema. Este artigo descreve o desenvolvimento de uma metodologia de inspeção automática de trilhos baseada em visão computacional, classificando-o em trilho bom ou trilho danificado. A metodologia foi desenvolvida utilizando uma rede neural convolucional AlexNet, uma rede pré treinada para classificar imagens em até 1000 classes diferentes, e modificando camadas específicas da rede para adequá-la ao projeto. Espera-se, com o desenvolvimento dessa metodologia, contribuir com o avanço da digitalização e gerenciamento da manutenção de via permanente, promovendo, conseqüentemente, o aumento da eficiência operacional do modo ferroviário.

Palavras-Chaves: Via Permanente, Inspeção de Trilhos, Redes Neurais, Gerência de Manutenção.

1. INTRODUÇÃO

Trilho danificado é um dos diversos motivos que podem causar descarrilamentos de trem (MARCUCCI et al, 2016). Além do potencial de provocar incidentes e acidentes, os descarrilamentos causam danos aos ativos ferroviários e ao meio ambiente, gerando ainda um impacto negativo no custo de manutenção e na logística ferroviária (ZHAO et al, 2006).

As inspeções dos trilhos são, portanto, de extrema importância para se manter o bom estado de conservação das vias férreas e para tomada de decisões no planejamento dos trabalhos de manutenção, que devem ser constantes. As inspeções de trilhos geralmente são feitas a pé, dispondo de instrumentos manuais de medição, ou com

auxílio de veículos motorizados (RODRIGUES, 2012).

Atualmente, sistemas automáticos de inspeção de via permanente também passaram a ser desenvolvidos para detectar e tratar as falhas de diferentes aspectos, o que foi possível graças ao desenvolvimento das técnicas de visão computacional nos últimos anos. Acredita-se que a inspeção automática pode aumentar a eficiência da manutenção das ferrovias e reduzir o tempo de inspeção, garantindo vias mais confiáveis (MALIK, 2013).

As Redes Neurais Artificiais são empregadas com sucesso em processos de reconhecimento e classificação de padrões (HAYKIN, 1999) (SILVA, 2010). Dentre algumas que foram criadas, a rede AlexNet



tem apresentado alta popularidade pela sua eficiência em classificar variados objetos em imagens (KRIZHEVSKY et al. 2012). Nesse trabalho, a AlexNet foi modificada e treinada para identificar defeitos superficiais de trilhos nas imagens.

2. REVISÃO DE LITERATURA

Dada a importância da manutenção de ferrovias, o aprimoramento de sua gestão tem sido objeto de estudo de muitos pesquisadores, que usam técnicas de visão computacional, processamento de imagens e reconhecimento de padrões no intuito automatizar as inspeções dos componentes ferroviários.

Liu, Z et. Al. (2010), por exemplo, propôs um sistema automático baseado em visão computacional para inspecionar fragmentações no perfil do boleto e fissuras na superfície de trilhos. Os defeitos foram identificados por correspondência dinâmica de limite e recurso e avaliados por cálculo da porcentagem de desgaste da cabeça do trilho e comprimento das trincas na superfície.

Rong, et al. (2016) desenvolveu um sistema a partir de redes neurais e análise SVD para detectar irregularidades nos trilhos e nas rodas dos vagões, comprometendo a dinâmica vagão-trilho. Para isso, dispôs de uma câmera FLEA3 para captura de imagens da via, um dispositivo sensor MPU6050 integrando acelerômetro e giroscópio para identificar vibrações, e um GPS para georreferenciamento, posicionados à frente da cabine do operador de trem.

Franca (2017) propôs a inspeção automática de dormentes utilizando técnicas de processamento de imagens, reconhecimento de padrões, fusão de características e heurísticas. As imagens foram capturadas através de um sistema de câmeras e iluminação instalado em um veículo ferroviário.

Rocha, et. al. (2017) dispôs de técnicas de deep learning para construir um sistema de inspeção automática de pad's, peça que suporta os quadros laterais do truque. Foi utilizado um detector em cascata para detectar o pad e redes neurais convolucionais

para classificá-lo em ausente, não danificado e danificado.

Os próximos tópicos descrevem em detalhes os métodos utilizados nesse trabalho para criar uma estrutura eficiente e prática para inspeção automática de trilhos.

3. MATERIAIS E MÉTODOS

3.1. Redes Neurais Artificiais (RNA)

As Redes Neurais Artificiais (RNA) têm como finalidade resolver problemas de inteligência artificial e foram criadas com base no que se conhece sobre o sistema nervoso dos seres vivos. Elas possuem inteligência, cometem erros, são capazes de aprender e apresenta comportamento imprevisível (HAYKIN, 1999) (SILVA, 2010).

Uma estrutura singela de RNA é constituída por uma camada de neurônios para receber os dados de entrada, uma camada oculta para o processamento dos dados oriundos da camada de entrada e uma camada de saída para gerar o resultado da rede (HAYKIN, 1999).

As redes neurais que apresentam mais de uma camada oculta são chamadas de Perceptrons de Múltiplas Camadas (Multilayer Perceptron – MLP). O número de camadas ocultas está relacionado com a profundidade da rede e quanto maior é o número, maior a capacidade da rede de extrair estatísticas de ordem elevada (HAYKIN, 1999).

Os dados processados pela rede produzem um resultado que é comparado com o resultado desejado, gerando um erro. Durante o processo de aprendizagem da rede, o algoritmo *Backward Error Propagation* pode ser usado para retropropagar o erro gerado na camada final e atualizar os pesos sinápticos de cada elemento das camadas ocultas. Esse processo então se repete até que a rede venha a convergir para o valor de saída desejado (SILVA, 2010).

3.2. Rede neural convolucional AlexNet

Redes neurais convolucionais (CNN) são redes de aprendizado profundo que não exigem pré-processamento das imagens nem

extração de características, sendo ainda flexíveis à translação e distorções (LECUN et al., 1998).

Uma CCN pode ser entendida em duas fases: Detecção de características e classificação. A detecção de características é realizada pelas camadas de convolução, que são os filtros de extração de características, a Unidade Linear Retificada (*Rectified Linear Unit* - ReLU), que é a função de ativação para retirada dos pontos que não interessam à rede e a função *pooling*, que reduz a dimensão da imagem (KRIZHEVSKY et al, 2012).

Após passar pelas camadas de detecção de características, a imagem é reduzida a um vetor e entra para a fase de classificação, esta por sua vez é composta pela camada de neurônios totalmente conectados entre si e a camada final de classificação ativada pela função *softmax* (SRIVASTAVA et al., 2014).

A AlexNet é uma CNN criada por Alex Krizhevsky em 2012 e pré-treinada para classificar imagens em até 1000 classes diferentes. Sua estrutura é formada por 5 camadas convolucionais, sendo algumas seguidas de *pooling*, duas camadas totalmente conectadas (*"Fully connected"*) e uma *softmax*. A rede possui 60 milhões de parâmetros e 500 mil neurônios (KRIZHEVSKY et al, 2012).

2.3.MATLAB (MATrix LABoratory)

O MATLAB é um software interativo que dotado de linguagem de programação para computação técnica e científica e *"toolboxes"*, que permitem a resolução de problemas particulares. Com a toolbox de Redes Neurais do MATLAB é possível aplicar e modificar, com alta versatilidade, vários tipos de redes neurais, alterando o número de camadas e algoritmos de treinamento (DEMUTH E BEALE, 2000).

Todas as fases desse trabalho foram desenvolvidas na plataforma do software MATLAB R2019b.

4.METODOLOGIA

Através de uma parceria com a MRS Logística S.A, foi criado um banco de dados com 236 imagens de superfícies de trilhos da malha

ferroviária sob sua concessão, com o auxílio de um Veículo de Inspeção de Trilhos (RIV-Rail Inspection Vehicle). Das imagens coletadas, 193 continham trilhos bons e 43 algum tipo de defeito.

O banco de imagens foi transferido manualmente para um computador e disponibilizado para treinamento da rede neural que, posteriormente, seria capaz de classificar as imagens em trilho bom (classe 1) e trilho danificado (classe 2). As figuras abaixo mostram exemplos das imagens que compõem as classes da rede.



Fig. 1 Imagem de Trilho bom, coletada pelo RIV



Fig. 2 Imagem de Trilho com defeito, coletada pelo RIV

Por dispor de um banco de dados muito pequeno, foi utilizada a técnica de aumento de dados *"DataAugmentation"* para aumentar ilusoriamente o número de imagens de treinamento. Nessa técnica, o algoritmo *"augmentedImageDatastore"* aplica transformações nas imagens de treinamento

de forma aleatória, utiliza essas imagens para treinar a rede e depois as descartam. Esse processo ajuda a reduzir o “overfitting”, evento onde a rede memoriza os exemplos de treinamento e não generaliza o aprendizado para novas situações (DEMUTH E BEALE, 2000).

As operações utilizadas para o aumento dos dados foram rotação aleatória de imagens entre -10° e 10°, translação aleatória de -3 a 3 pixels na horizontal e na vertical, e reflexão. As imagens também foram redimensionadas em 227 x 227 para se adequar a entrada da rede utilizada para classificação, a AlexNet.

Tabela 1. Detalhes do conjunto de dados

| Classes | Nº de Imagens de treinamento após técnica de aumento de dados | Nº de Imagens de Teste |
|-------------------|---|------------------------|
| Trilho bom | 540 | 58 |
| Trilho danificado | 120 | 13 |

A AlexNet foi treinada para classificar variados objetos como lápis, mouse, celular e até animais. Neste trabalho, a AlexNet foi modificada para classificar trilhos, através da transferência de aprendizado. Esta metodologia geralmente é mais fácil e mais rápido do que criar uma nova rede, além de exigir um banco de imagens menor para treinamento (KRIZHEVSKY et al. 2012).

Para ajustar a AlexNet ao projeto, foram realizadas modificações nas camadas “Fully conected” e “softmax”. A rede, que teria capacidade para classificar imagens em até 1000 classes diferentes, passou então a executar apenas duas classificações: trilho bom e trilho danificado.

5.RESULTADOS

Foi disponibilizado 70% do banco de dados para o treinamento da rede, essas imagens passaram por todo processo de aumento de dados, enquanto os outros 30% do banco foram utilizados para validar a rede, sendo apenas redimensionadas. A figura 3 exemplifica 6 imagens de treinamento após passarem pelo algoritmo “augmented Image Datastore”



Fig. 3 Imagens pré-processadas

A rede foi treinada em 30 épocas, com 16 iterações por época e cada iteração utilizou um mini lote de 10 imagens. Foi utilizada uma pequena taxa inicial de aprendizagem de $3e^{-4}$ para concentrar a aprendizagem nas camadas modificadas. O treinamento foi realizado por uma CPU simples e teve duração de 23 min e 4 segundos.

A rede desenvolveu sua precisão de classificação ao longo do treinamento e ao final, obteve uma acurácia de 100% na classificação das imagens de treinamento e de 83,10% nas imagens de validação.

Na matriz de confusão a seguir (Fig. 3) é ilustrado o resultado da classificação das imagens de validação. Todas as imagens que continham trilhos danificados foram classificadas corretamente pela rede. Já entre as imagens que continham trilhos bons, 46 foram classificadas corretamente e 12 foram classificadas como trilho danificado.

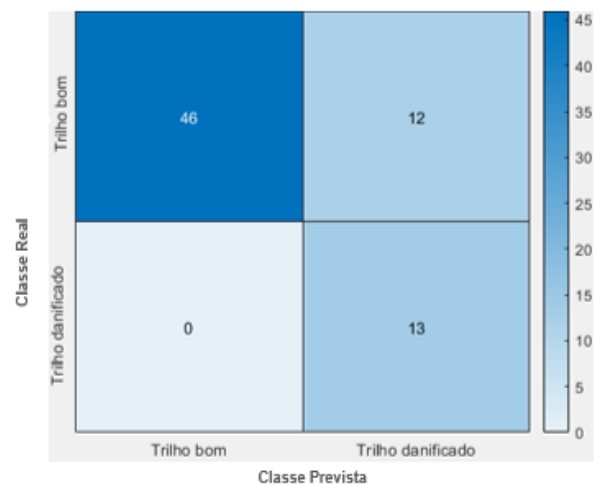


Fig. 3 Matriz de confusão

6. DISCUSSÃO E CONCLUSÃO

Este trabalho propôs a aplicação de um modelo de reconhecimento de padrões de defeitos em trilhos, a partir da utilização de redes neurais artificiais.

A principal contribuição deste trabalho é a aplicação de redes neurais como ferramenta de aquisição de dados para embasar as tomadas de decisões no gerenciamento de manutenção de trilhos, otimizando o mesmo. A eficiência do gerenciamento de manutenção é fundamental na prevenção de descarrilamentos e redução de custos de manutenção.

A arquitetura de rede proposta apresentou um desempenho muito animador, classificando corretamente 83,1 % dos dados de validação e 100% do pior caso (trilhos danificados). Contudo, o conjunto de dados de validação é muito pequeno, sendo importante analisar o desempenho da arquitetura diante de um desafio maior.

A ocorrência de marcas de esmerilhamento e manchas no trilho pode explicar a confusão da rede em classificar trilhos bons como defeituosos, o que sugere maior número de exemplos com esse caso.

Propõe-se para trabalhos futuros treinar a AlexNet com um banco de dados maior, variando os parâmetros de treinamento. Além disso, seria interessante comparar o desempenho da AlexNet com outras redes pré-treinadas e destreinadas.

AGRADECIMENTOS

A Deus, que é o autor de toda sabedoria, a CAPES, pelo apoio financeiro e à MRS pela colaboração técnica.

REFERÊNCIAS

DA SILVA, Ivan Nunes; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. Redes Neurais Artificiais para engenharia e ciências aplicadas curso prático. São Paulo: Artliber, 2010.

DEMUTH, Howard B.; BEALE, Mark H. Neural network toolbox; for use with MATLAB; computation, visualization, programming; user's guide, version 4, Math Works, 2000.

FRANCA, André Stanzani. Identificação e Monitoramento de Dormentes de Ferrovias Usando Processamento de Imagens. Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Espírito Santo, Vitória, Brasil, 2017.

HAYKIN, Simon. Neural Networks, A comprehensive Foundation, Bookman Editora, 2ª edição, 1999.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, Geoffrey E., Imagenet classification with deep convolutional neural networks. Advances in neural information processing systems, Lake Tahoe, Estados Unidos, 2012.

Y. Lecun, et al., Gradient-based learning applied to document recognition. Proceedings of the IEEE, November (1998), pag. 2278-2324.

LIU, Z et al. Inspection of rail surface defects based on image processing. 2nd International Asia Conference on Informatics in Control, Automation and Robotics, China, 2010, p. 472-475.

M. Macucci et al., Derailment detection and data collection in freight trains, based on a wireless sensor network. IEEE Transactions on Instrumentation and Measurement, Sept (2016), pag. 1977-1987.

MALIK, Qurrat-ul-Ain. Novel methods of object recognition and fault detection applied to non-destructive testing of rail's surface during production. 2013. Tese de Doutorado. Manchester Metropolitan University.

ROCHA, R et al., Avaliação de técnicas de Deep Learning aplicadas à identificação de peças defeituosas em vagões de trem, Workshop of Industry Applications (WIA) in the 30th Conference on Graphics, Patterns and Images (SIBGRAPI'17), E. Clua and FLC Padua, Eds., Niterói, RJ, Brazil. 2017.

RODRIGUES, Daniela Dias. Manutenção e conservação de vias férreas: análise de casos práticos. Coimbra: Instituto Superior de Engenharia de Coimbra, 2012.

D. Rodrigues et al., Classificação automática do tipo de ferro fundido utilizando reconhecimento de padrões em imagens de microscopia. Matéria (Rio. J), Agosto (2017).

J. Rong et al., Rail Track Irregularity Detection Method Based on Computer Vision and Gesture Analysis. International Journal of Online and Biomedical Engineering (iJOE), (2016).

N. Srivastava et al., Dropout: a simple way to prevent neural networks from overfitting, The journal of machine learning research, January (2014), pag. 1929-1958.

ZHAO, J.; CHAN, A. H. C.; STIRLING, A. B. Risk analysis of derailment induced by rail breaks - probabilistic approach, RAMS'06. Annual Reliability and Maintainability Symposium, Newport Beach, CA, USA, August 2006.