



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

CATEGORIA 3

DETECÇÃO DE FALHAS EM MOLAS DE TRUQUES FERROVIÁRIO
UTILIZANDO PROCESSAMENTOS DE IMAGENS

AUTORES

INTRODUÇÃO

Nos últimos anos, a tecnologia de visão computacional tem sido amplamente utilizada em aplicações industriais envolvendo inspeção e controle de qualidade processos [Umar 2005], [Der-Baau 2011]. Como forma de tornar a inspeção mais eficiente, efetiva e objetiva, o uso da tecnologia de visão de máquina também aumentou nos domínios relacionados à operação ferroviárias, desde inspeção de via férrea à veículos ferroviários. [Gilbert 2017],[Resendiz 2013] ,[Christian 2013].



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Inspecionar ferrovias é particularmente importante porque descarrilamentos de composições, geralmente ocorrem quando há falhas nas rodas, truques ou eixos e em vias danificadas [Massimo 2016]. Descarrilamento pode gerar causalidades e fatalidades, resultando também em danos à via e aos trens [Jianmin 2006]. Além disso, também possui implicações financeiras como o custo de manutenção e o efeito na logística ferroviária. Em suma, inspecionar os componentes do vagão que pode causar descarrilamento é uma tarefa fundamental para a manutenção em uma ferrovia.

Os sistemas típicos de inspeção automatizada envolvem a aquisição de imagens, pré-processamento, extração de características e classificação. Entre os métodos de extração de características, a abordagem espectral é bem estabelecida especialmente em problemas onde as imagens são afetadas devido às condições ambientais, reflexão ou distorção do dispositivo de aquisição [Kang 2016],[Ravikumar 2011]. O filtro de Gabor é uma das mais utilizadas abordagens de extração de características aplicada à inspeção de componentes, principalmente devido à sua eficiência na extração do padrão de resposta, pois simula bem as células do córtex estriado, responsáveis pelas identificações de padrões visuais pelo cérebro humano, bem como a sua flexibilidade em termos de variação nas etapas de aquisição ou distorções locais [Yann 1998].

Com base no exposto, argumenta-se que uma abordagem para inspeção automática de componentes é necessária para obter informações detalhadas sobre diferentes



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

componentes do vagão de forma rápida e confiável. Neste trabalho, o componente analisado é a mola do truque ferroviário, que é responsável em absorver os impactos e distorções da via permanente, além disso oferecer equilíbrio dinâmico durante as inscrições em curva no processo de circulação do veículo ferroviário.

Em resumo, este artigo descreve uma proposta de inspeção automática de molas ferroviárias utilizando técnicas de pré-processamento e extração de características baseado em textura, usando a abordagem espectral. Mais especificamente, para etapa de pré-processamento utilizamos filtragem gaussiana para suavização das imagens e especificação de histograma para correção dos efeitos de iluminação, para etapa de segmentação utilizou-se a técnica de Template Matching [Gonzales 2008], na sequência foram extraídas as características da imagem baseado em textura utilizando a abordagem do filtro de Gabor [Jagdish 2013], na etapa de classificação utilizou-se Máquina de Vetor Suporte (SVM)

Os resultados são comparados com outras duas abordagens, a saber: (1) Uso de descritores utilizando Matrix do Concorrência e (2) Redes Neurais convolucionais, baseado no trabalho de [Rocha 2018]. O restante deste artigo é organizado da seguinte maneira. Seção 2 apresenta o problema alvo. Seção 3 descreve a metodologia utilizada para resolver o problema. A seção 4 enfoca os resultados experimentais e, finalmente,

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

a seção 5 discute os resultados e conclui o artigo apresentando os próximos passos para trabalhos futuros.

DIAGNÓSTICO

Um truque ferroviário é um componente localizado na região de infraestrutura de um veículo ferroviário (vagão, locomotiva) cuja função é transferir e distribuir os esforços normais para a via ferroviária. Nos conjuntos dos truques temos rodeiros, eixos e rolamentos (Fig. 1a). Normalmente, cada vagão é composto por dois truques e cada truque por quatro rodas, que fornece suporte para o corpo do veículo além de fornecer tração e frenagem do veículo [Iwnicki 2006]. O Shear Pad (Fig. 1b), oferece estabilidade ao veículo durante a inscrição em curvas e geralmente é fabricado com metal e revestimento de borracha, além da função principal e alguns momentos funciona como amortecedor.




Figura 1. Truque Ferroviários e seus componente

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Neste trabalho nos concentramos no desenvolvimento de algoritmos de processamento de imagem e visão para o conjunto do truque ferroviário. O componente de interesse será inicialmente a mola do truque (Fig. 1c), cuja função é de amortecimento dos danos e ruídos da via permanente (trilhos e dormentes), funciona especificamente como elemento de suspensão do veículo ferroviário. O foco principal será em danos como uma quebra ou falta do componente. Os algoritmos desenvolvidos buscam detectar nas imagens deste componente (obtido pelas câmeras), a identificação automática, onde o objetivo principal é identificar a quebra e não quebra de molas do truque ferroviário.

MATERIAS E MÉTODOS

O sistema implantado consiste em câmeras digitais com resolução de 3MP em que estão posicionadas a 1,8 m do veículo ao longo de um galpão de inspeção objetivando capturar imagens do vagão após o processo de descarregamento (Fig. 2).




Figura 2. Sistema Implantado para captura de imagens

Após a captura das imagens, inicia-se a etapa de transmissão para computadores para assim então executar os algoritmos de processamento de imagens para assim classificar

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

como mola normal (Fig. 3b) e mola quebrada (Fig. 3a). Os algoritmos de processamento de imagens segue o fluxograma de implementação e desenvolvimento conforme ilustração da Fig. 4.




Figura 3. Classificação das molas do truque

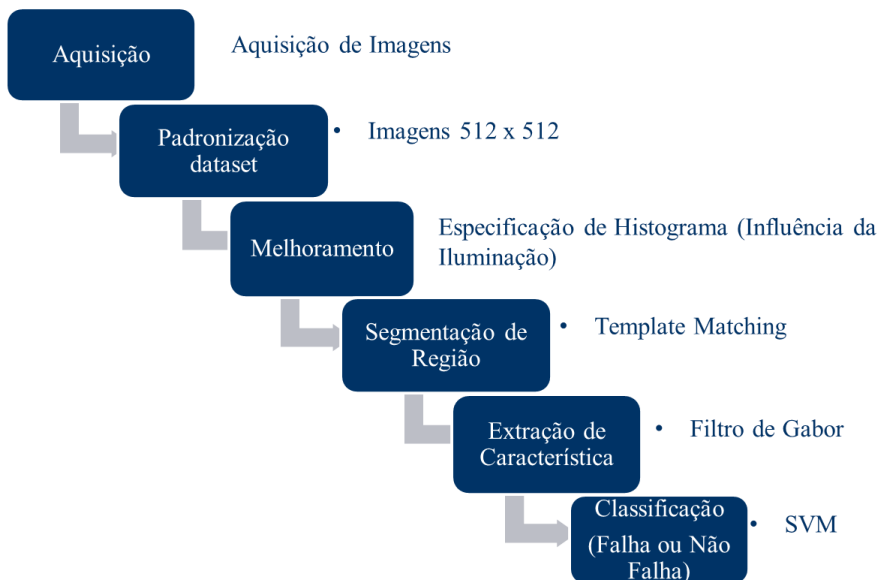


Figura 4. Metodologia aplicada



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

ANÁLISE DOS RESULTADOS

Nesta seção serão mostrados os resultados dos testes dos algoritmos implementados referentes a proposta de resolução de problemática de detecção automática de mola quebrada de truque ferroviário.

- **Melhoramento**

A primeira etapa consiste em reduzir os efeitos de iluminação durante a etapa de aquisição, para isso, utilizou-se a técnica de especificação de histograma. Onde verifica-se conforme ilustração da Fig.6 o resultado da implementação.

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

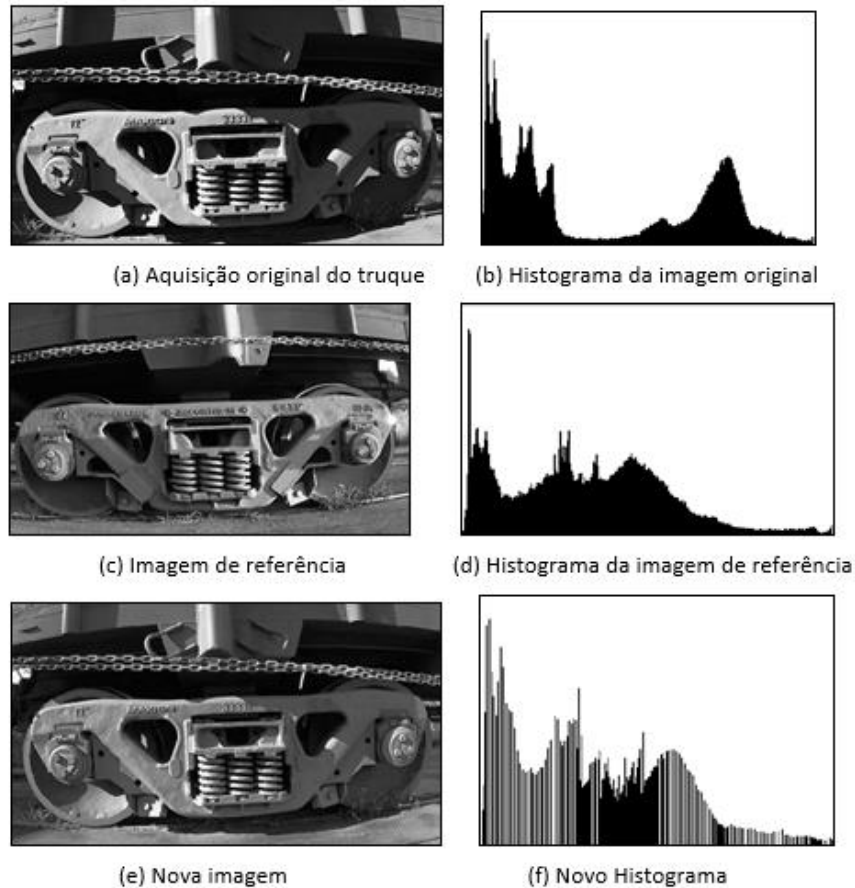


Figura 6. Resultado da aplicação de especificação de histograma na imagem do truque ferroviário.

Observa-se que o padrão de brilho da imagem de referência Fig. 6c é aplicado na imagem adquirida Fig.6a, resultado em uma nova imagem com padrões de brilho melhorado conforme Fig. 6e.

- **Segmentação**

Na próxima etapa utilizou-se a técnica do *template matching* para executar o isolamento apenas da parte da mola do restante da imagem conforme ilustração da

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Fig. 7. A região de interesse para o processo de segmentação foi marcada de forma manual pelo o usuário formando assim o modelo do *Template*.




Figura 7. Segmentação por template matching

A Fig. 7a ilustra a região de interesse marcada, enquanto a Fig. 7b ilustra a região isolada da mola formando uma nova imagem.

Na Tabela 1, verifica-se o resultado da aplicação do template matching no banco de dados de imagens, utilizando métricas tais como: Acurácia, DICE, Jaccard Index (JAC)

Tabela 1. Resultado do *Template matching*

Técnica	Acurácia (%)	DICE Index (%)	Jaccard index (JAC)
Template Matching	96,66	92,1	89,76

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

4.3. Extração de Característica Baseado em Textura

Para a etapa de extração de características utilizou-se a técnica baseada em textura espectral, implementando assim o filtro de Gabor, realizado a convolução da imagem de acordo com a máscara calculada pelo filtro, assim após a filtragem de Gabor, obteve-se características de uma imagem com mola normal (Fig.3b) e mola quebrada (Fig. 3a).

A Fig.8 ilustra o resultado da aplicação do filtro de Gabor da região segmentada da mola do truque ferroviário.




Figura 8. Resultado da aplicação de filtro de Gabor na imagem da mola segmentada

Na Fig.8a, verifica-se as características de uma mola normal, enquanto a Fig.8b podemos observar as características de uma mola quebrada.

Para a etapa de classificação, baseado nas características extraídas do filtro de Gabor obteve-se 256 características para cada imagem, utilizando assim 80% do dataset para treinamento do classificador, utilizou-se a abordagem de aprendizagem de máquina baseado em máquina de vetor suporte (SVM). Para a calibração do classificador foram



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

utilizadas 101 instancias, sendo 90 para mola em condições normais e 11 para molas em condições de falha, para cada instancia foram analisados 256 atributos retirados do filtro de Gabor.

Para fornecer uma análise abrangente exibimos os principais resultados na Tabela 2 onde resume os percentuais de precisão e o recall para o conjunto de dados, onde a precisão é o número de itens classificado corretamente dividido pelo total de itens no *dataset* e o *recall* corresponde ao número de exemplos positivos classificados corretamente divididos pelo número total de exemplos positivos.

Tabela 2. Resultado do algoritmo de classificação baseado em SVM

Método	Precisão %	Recall %
Filtro de Gabor + SVM	95,8	C1 = 96,87 C2 = 100%

Observa-se que o algoritmo apresentou boa precisão no processo de classificação, para avaliar o algoritmo de forma mais assertiva seria necessário maior quantidade de exemplos da condição de mola falha visto que para este trabalho foram utilizados apenas 11 exemplos.



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Podemos comparar a abordagem proposta neste artigo com a abordagem descrita no trabalho de [Rocha 2018], onde inicialmente utilizou com etapa de extração de características a técnica denominada matriz de concorrência e como classificador utilizou SVM e finalizou a análise utilizando uma abordagem baseada em redes neurais convulsionais.

Tabela 3. Estudo comparativo com outras abordagens

Método	Precisão %	Recall %
Filtro de Gabor + SVM	95,8	C1 = 96,87 C2 = 100%
GLCM + ANN	96,73	C1 = 98,04 C2 = 97,14
CNN	99,19	C1=100 C2=98,88

Observa-se que o método proposto apresenta resultados semelhantes de termos de precisão e uma pequena melhoria no parâmetro de recall para a classe 2 (mola quebrada).

CONCLUSÕES

Neste trabalho, propusemos uma abordagem baseada em processamento de imagens para inspeção de componente de vagão. Visto que a inspeção é necessária para evitar descarrilamentos durante a operação ferroviária. Descarrilamentos é um problema



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

sério nas ferrovias, porque podem gerar tantas perdas financeiras, bem como perdas pessoais e mortes. Então, é necessário inspecionar os componentes do vagão que podem causar descarrilamento. De acordo com a literatura ferroviária, um desses componentes é a mola do truque. A mola do truque possui a função de amortecimento durante a circulação do veículo na via férrea. Devido ao grande número de vagões no processo de inspeção e por causa das limitações da inspeção humana (visual) [Park 1996], é necessário usar técnicas de inspeção automática para classificar rapidamente o bloco e avisar sobre possíveis defeitos neste componente. Em todos os métodos, uma forte vantagem da abordagem proposta neste trabalho é observada, principalmente em relação à precisão.

REFERÊNCIAS BIBLIOGRÁFICAS

- B Park, YR Chen, M Nguyen, and H Hwang. 1996. Characterizing multispectral images of tumorous, bruised, skin-torn, and wholesome poultry carcasses. *Transactions of the ASAE* 39, 5 (1996), 1933–1941.
- B Park, YR Chen, M Nguyen, and H Hwang. 1996. Characterizing multispectral images of tumorous, bruised, skin-torn, and wholesome poultry carcasses. *Transactions of the ASAE* 39, 5 (1996), 1933–1941.
- Christian Whler. 2013. *3D Computer Vision. Efficient Methods and Applications*. Springer-Verlag London, 382. [h.p://www.springer.com/gp/book/9781447141495](http://www.springer.com/gp/book/9781447141495)
- Corinna Cortes and Vladimir Vapnik. 1995. Support-vector networks. *Machine Learning* 20, 3 (01 Sep 1995), 273–297. [h.ps://doi.org/10.1007/BF00994018](http://doi.org/10.1007/BF00994018)
- Der-Baau Perng, Hsiao-Wei Liu, and Ching-Ching Chang. 2011. Automated SMD LED inspection using machine vision. *The International Journal of Advanced Manufacturing Technology* 57, 9 (01 Dec 2011), 1065–1077. [h.ps://doi.org/10.1007/s00170-011-3338-y](http://doi.org/10.1007/s00170-011-3338-y)



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

- Edgar Osuna and Federico Girosi. 1998. Reducing the run-time complexity of Support Vector Machines. In International Conference on Pattern Recognition.
- Farnaz Farokhian, Chunlan Yang, Hasan Demirel, Shuicai Wu, Iman Beheshti, Automatic parameters selection of Gabor filters with the imperialism competitive algorithm with application to retinal vessel segmentation, *Biocybernetics and Biomedical Engineering*, Volume 37, Issue 1, 2017, Pages 246-254, ISSN 0208-5216, <https://doi.org/10.1016/j.bbe.2016.12.007>
- Jagdish Lal Raheja, Sunil Kumar, Ankit Chaudhary, Fabric defect detection based on GLCM and Gabor filter: A comparison, *Optik - International Journal for Light and Electron Optic* Volume 124, Issue 23, 2013, Pages 6469-6474, ISSN 0030-4026, <https://doi.org/10.1016/j.ijleo.2013.05.04>.
- Je-Kang Park, Bae-Keun Kwon, Jun-Hyub Park, and Dong-Joong Kang. 2016. Machine learning-based imaging system for surface defect inspection. *International Journal of Precision Engineering and Manufacturing-Green Technology* 3, 3 (01 Jul 2016), 303–310. <https://doi.org/10.1007/s40684-016-0039-x>
- Jianmin Zhao, AHC Chan, and AB Stirling. 2006. Risk analysis of derailment induced by rail breaks—a probabilistic approach. In *Reliability and Maintainability Symposium, 2006. RAMS'06. Annual*. IEEE, 486–491.
- Joan Buciu A. Gacsadi, 2009, “Gabor Wavelet Based Features for Medical Image Analysis and Classification”.
- John Shawe-Taylor and Nello Cristianini. 2004. *Kernel Methods for Pattern Analysis*. Cambridge University Press, New York, NY, USA.
- Massimo Macucci, Stefano Di Pascoli, Paolo Marconcini, and Bernardo Tellini. 2016. Derailment detection and data collection in freight trains, based on a wireless sensor network. *IEEE Transactions on Instrumentation and Measurement* 65, 9 (2016), 1977–1987.
- Rafael C. Gonzalez and Richard E. Woods. 2008. *Digital image processing*. Prentice Hall, Upper Saddle River, N.J.
- Rafael L. Rocha, Ana Carolina Q. Siravenha, Ana Cláudia S. Gomes, Gerson L. Serejo, Alexandre F. B. Silva, Luciano M. Rodrigues, Júlio Braga, Giovanni Dias, Schubert R. Carvalho, Cleidson R. B. de Souza A deep-learning-based approach for automated wagon component inspection SAC '18: Proceedings of the 33rd Annual ACM Symposium on Applied Computing April 2018



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

- Resendiz, J. M. Hart, and N. Ahuja. 2013. Automated Visual Inspection of Railroad Tracks. IEEE Transactions on Intelligent Transportation Systems 14, 2 (June 2013), 751–760. [h.ps://doi.org/10.1109/TITS.2012.2236555](https://doi.org/10.1109/TITS.2012.2236555)
- S. IWnicki. 2006. Handbook of Railway Vehicle Dynamics. CRC Press, 548.
- S. Ravikumar, K. I. Ramachandran, and V. Sugumaran. 2011. Machine Learning Approach for Automated Visual Inspection of Machine Components. Expert Syst. Appl. 38, 4 (April 2011), 3260–3266. [h.ps://doi.org/10.1016/j.eswa.2010.09.012](https://doi.org/10.1016/j.eswa.2010.09.012)
- Umar Sahbaz Khan, Javaid Iqbal, and Mahmood A. Khan. 2005. Automatic Inspection System Using Machine Vision. In Proceedings of the 34th Applied Imagery and Pattern Recognition Workshop (AIPR '05). IEEE Computer Society, Washington, DC, USA, 210–217. [h.ps://doi.org/10.1109/AIPR.2005.20](https://doi.org/10.1109/AIPR.2005.20)
- X. Gibert, V. M. Patel, and R. Chellappa. 2017. Deep Multitask Learning for Railway Track Inspection. IEEE Transactions on Intelligent Transportation Systems 18, 1 (Jan 2017), 153–164. [h.ps://doi.org/10.1109/TITS.2016.2568758E](https://doi.org/10.1109/TITS.2016.2568758E).
- Yann LeCun, Leon Bo.ou, Yoshua Bengio, and Patrick Ha.ner. 1998. Gradient- Based Learning Applied to Document Recognition. In Proceedings of the IEEE, Vol. 86. 2278–2324. [h.p://ieeexplore.ieee.org/document/726791/](https://ieeexplore.ieee.org/document/726791/)