

DETECÇÃO AUTOMÁTICA DE DEFEITOS EM TRILHOS FERROVIÁRIOS ATRAVÉS DE VISÃO COMPUTACIONAL

AUTOMATIC DETECTION OF DEFECTS IN RAILWAY TRACKS USING COMPUTER
VISION

DETECCIÓN AUTOMÁTICA DE DEFECTOS EN RAÍLES FERROVIÁRIOS A TRAVÉS DE
VISIÓN POR COMPUTADORA

Matheus Sousa Barroso¹
Jonathan Araujo Queiroz²

RESUMO: A Inteligência Artificial tem se mostrado uma ferramenta promissora na área de visão computacional. Neste trabalho, propõe-se a construção de uma solução utilizando técnicas de Machine Learning para a detecção de defeitos superficiais em trilhos. A partir de um conjunto de dados obtidos por meio de imagens dos trilhos, será desenvolvido um modelo capaz de identificar defeitos, visando aumentar a segurança e eficiência na manutenção ferroviária. Como resultados preliminares, foi criado um modelo de classificação que apresenta métricas de avaliação satisfatórias, evidenciando o potencial da aplicação para auxiliar nas inspeções de trilhos ferroviários.

Palavras-chave: Inteligência Artificial. Visão Computacional. Machine Learning. Trilhos Ferroviários. Detecção de Defeitos. Classificação de Defeitos. Manutenção Ferroviária.

ABSTRACT: Artificial Intelligence has proven to be a promising tool in the field of computer vision. This work proposes the development of a solution using Machine Learning techniques to detect surface defects in railway tracks. Based on a dataset obtained through track images, a model will be developed to identify defects, aiming to enhance safety and efficiency in railway maintenance. Preliminary results show that a classification model was created with satisfactory evaluation metrics, highlighting the potential of this application to assist in railway inspections.

7616

Keywords: Artificial Intelligence. Computer Vision. Machine Learning, Railway Tracks. Defect Detection. Defect Classification. Railway Maintenance.

RESUMEN: La Inteligencia Artificial se ha demostrado como una herramienta prometedora en el área de la visión por computadora. En este trabajo, se propone la construcción de una solución utilizando técnicas de aprendizaje automático (Machine Learning) para la detección de defectos superficiales en raíles ferroviarios. A partir de un conjunto de datos obtenido mediante imágenes de los raíles, se desarrollará un modelo capaz de identificar defectos, con el objetivo de aumentar la seguridad y la eficiencia en el mantenimiento ferroviario. Como resultados preliminares, se creó un modelo de clasificación que presenta métricas de evaluación satisfactorias, evidenciando el potencial de la aplicación para ayudar en las inspecciones de raíles ferroviarios.

Palabras clave: Inteligencia Artificial. Visión por Computadora, Aprendizaje Automático, Raíles Ferroviarios. Detección de Defectos. Clasificación de Defecto. Mantenimiento Ferroviario.

¹Discente, Universidade CEUMA.

² Graduado em Matemática (UFMA), especialista em Métodos Estatísticos Aplicados (UEMA), mestre (UFMA), doutor (UFMA) e pós-doutorado em Engenharia Elétrica (UFMA).

INTRODUÇÃO

Os trilhos ferroviários estão sujeitos a tensões mecânicas constantes devido ao contato contínuo com as rodas dos trens. Esse contato gera danos progressivos, como desgaste e trincas superficiais, que podem evoluir para defeitos graves, como a fadiga de contato (Rolling Contact Fatigue - RCF). Segundo Kapoor (2003), o RCF é uma das principais causas de falhas em trilhos ferroviários, e a detecção precoce desse tipo de dano é crucial para evitar acidentes e reduzir custos com manutenção corretiva.

Atualmente, a inspeção de defeitos em trilhos é amplamente realizada de maneira manual, através da análise visual de imagens capturadas por equipamentos especializados. No entanto, esse método é limitado pela subjetividade dos inspetores, o que pode levar à inconsistência na identificação e classificação dos defeitos (Resende e Pereira, 2015). Além disso, a inspeção manual pode ser ineficiente em grandes trechos ferroviários, onde a verificação contínua é necessária para garantir a integridade dos trilhos (Liu et al., 2014).

Nesse contexto, as técnicas de visão computacional e aprendizado de máquina têm ganhado destaque como ferramentas eficazes para a detecção automática de defeitos em trilhos ferroviários. Com o avanço dos algoritmos de detecção de objetos, como o YOLOv10, é possível identificar e classificar defeitos de forma rápida e precisa, reduzindo a subjetividade e aumentando a eficiência das inspeções (Redmon et al., 2016). A detecção automática permite a identificação precoce de problemas, possibilitando a realização de manutenções preventivas, o que, de acordo com Waersted et al. (2021), aumenta significativamente a segurança das operações e prolonga a vida útil dos trilhos.

Essa abordagem tem o potencial de transformar a manutenção ferroviária, proporcionando maior confiabilidade nas operações e redução de custos operacionais associados à manutenção corretiva.

FUNDAMENTAÇÃO TEÓRICA

A detecção automática de defeitos em trilhos ferroviários com o uso de visão computacional e aprendizado de máquina vem ganhando destaque por proporcionar mais eficiência e segurança nas operações ferroviárias. Com o aumento da demanda por sistemas de transporte mais confiáveis e seguros, a detecção precoce de falhas, como as geradas pelo contato contínuo entre trilhos e rodas, é fundamental. Nessa seção, abordaremos a importância da

inspeção de trilhos, com destaque para a fadiga de contato (RCF), e exploraremos as técnicas de visão computacional e detecção de objetos aplicadas nesse contexto.

INSPEÇÃO DE TRILHOS

A inspeção de trilhos é um processo crítico para a manutenção da superestrutura ferroviária. Com o passar do tempo, o contato contínuo entre as rodas dos trens e os trilhos gera tensões repetitivas que resultam em defeitos progressivos, como trincas e desgastes superficiais. Um dos problemas mais graves que surgem desse processo é a fadiga de contato (Rolling Contact Fatigue - RCF). Segundo Kapoor (2003), o RCF é um dos principais mecanismos de falha em trilhos ferroviários, caracterizada pelo surgimento de trincas devido à repetida aplicação de cargas.

O RCF ocorre quando o contato constante entre as rodas e os trilhos causa microtrincas na superfície do trilho. Com o tempo, essas microtrincas se propagam para camadas mais profundas, criando condições que podem levar a falhas catastróficas. Um fator agravante é que esses defeitos nem sempre são visíveis a olho nu em seus estágios iniciais, tornando essencial a utilização de métodos automatizados para sua detecção precoce (Ekberg et al., 2002). A identificação correta do RCF permite que medidas preventivas, como o esmerilhamento dos trilhos ou sua substituição, sejam tomadas antes que o problema se agrave.

7618

Tradicionalmente, a inspeção de trilhos é realizada de forma manual, o que é limitado pela capacidade humana de detectar pequenos defeitos e pela subjetividade envolvida no processo de interpretação visual (Liu et al., 2014). Esse método, embora amplamente utilizado, não é suficiente para detectar defeitos sutis e pode ser ineficaz em linhas de grande extensão, onde a inspeção manual de grandes trechos é inviável. Dessa forma, a automação da detecção de defeitos, especialmente no caso do RCF, surge como uma solução mais eficaz e confiável para garantir a segurança das operações ferroviárias.

VISÃO COMPUTACIONAL

A visão computacional é uma área da inteligência artificial que visa extrair, analisar e processar informações visuais, permitindo que sistemas computacionais "vejam" e compreendam o conteúdo de imagens e vídeos. Ao simular a capacidade de percepção visual humana, os sistemas de visão computacional são capazes de automatizar tarefas que,

tradicionalmente, exigiam a intervenção humana, como a inspeção visual de defeitos e o reconhecimento de padrões.

Esses sistemas utilizam imagens digitais capturadas por câmeras e aplicam uma série de algoritmos para interpretar os dados visuais. A visão computacional pode ser usada em uma ampla gama de aplicações industriais, incluindo controle de qualidade, automação de processos, segurança e, no caso da infraestrutura ferroviária, na inspeção e manutenção de trilhos.

O processamento dessas imagens é feito por meio de redes neurais convolucionais (CNNs), que, segundo Goodfellow, Bengio e Courville (2016), são altamente eficazes para a detecção e reconhecimento de padrões visuais em grandes volumes de dados. As CNNs funcionam através da extração de características das imagens, permitindo a identificação de elementos como trincas superficiais, desgastes ou irregularidades em trilhos. Elas conseguem reconhecer padrões visuais complexos ao dividir as imagens em pequenas partes e processá-las camada por camada, aprendendo automaticamente a identificar padrões que representam defeitos.

A aplicação de visão computacional para a detecção de defeitos em trilhos ferroviários traz diversas vantagens. Além de automatizar o processo de inspeção, os sistemas baseados em visão computacional oferecem precisão e velocidade, superando as limitações dos métodos de inspeção manual (Szeliski, 2010). Dessa forma, é possível realizar uma análise mais consistente e sistemática, reduzindo a subjetividade humana e aumentando a confiabilidade dos resultados. Com essa tecnologia, é possível identificar defeitos nos trilhos de maneira contínua e em tempo real, permitindo que as ferrovias mantenham um nível de segurança e eficiência elevados.

7619

APRENDIZAGEM DE MÁQUINA

A aprendizagem de máquina (Machine Learning - ML) é uma subárea da inteligência artificial que permite que sistemas computacionais aprendam a partir de dados, identificando padrões e realizando previsões sem a necessidade de serem explicitamente programados para cada tarefa específica. Em vez disso, os algoritmos de ML usam grandes conjuntos de dados para "treinar" modelos que podem generalizar e realizar previsões ou classificações em dados novos e não vistos.

A principal característica da aprendizagem de máquina é a capacidade de melhorar o desempenho de um modelo com o tempo à medida que ele é exposto a mais dados. Segundo Murphy (2012), os algoritmos de ML são especialmente eficazes para problemas em que não é

possível estabelecer regras fixas ou onde os dados são complexos e de grande volume, como acontece em sistemas de visão computacional e detecção de defeitos em trilhos ferroviários.

Os algoritmos de ML podem ser divididos em três categorias principais: supervisionada, não supervisionada e por reforço. Na aprendizagem supervisionada, o algoritmo é treinado com um conjunto de dados rotulados, onde as respostas corretas já são conhecidas. A partir desses dados, o algoritmo aprende a fazer previsões ou classificações sobre novos exemplos. Já na aprendizagem não supervisionada, o algoritmo trabalha com dados não rotulados e tenta identificar padrões ou agrupamentos dentro dos dados. Por último, na aprendizagem por reforço, o algoritmo aprende a tomar decisões interagindo com um ambiente dinâmico, recebendo recompensas ou penalidades com base nas suas ações.

Na detecção de defeitos em trilhos ferroviários, a aprendizagem supervisionada é a abordagem mais amplamente utilizada. Um modelo de aprendizagem de máquina pode ser treinado para classificar diferentes tipos de defeitos a partir de imagens rotuladas de trilhos, permitindo que ele aprenda a reconhecer padrões de falhas como trincas superficiais ou fadiga de contato (RCF). De acordo com Alpaydin (2020), essa abordagem oferece precisão e eficiência na detecção de padrões complexos, especialmente em grandes conjuntos de dados visuais.

A eficácia da aprendizagem de máquina em visão computacional depende, em grande parte, da qualidade e quantidade dos dados utilizados para treinamento. Quanto mais diversificado e robusto for o conjunto de dados, melhor será a capacidade do modelo de ML em generalizar e detectar defeitos sob diferentes condições. 7620

Em resumo, a aprendizagem de máquina é essencial para o desenvolvimento de sistemas automatizados de detecção de defeitos em trilhos, oferecendo uma forma de lidar com a complexidade dos dados visuais e permitindo que os modelos melhorem continuamente à medida que são expostos a mais informações.

DETECÇÃO DE DEFEITOS

A detecção de defeitos é uma tarefa essencial para garantir a segurança e a integridade de superestruturas críticas de uma ferrovia, como os trilhos. Defeitos como trincas superficiais e desgaste excessivo, podem comprometer resistência dos trilhos, levando a falhas catastróficas e acidentes. A detecção precoce desses problemas é vital para a manutenção preventiva e corretiva. No contexto ferroviário, a detecção de defeitos pode ser realizada tanto manualmente

quanto de forma automatizada, sendo a automação o foco crescente devido à sua precisão e eficiência.

Tradicionalmente, a inspeção manual tem sido amplamente utilizada em ferrovias, onde inspetores visuais analisam os trilhos em busca de sinais de desgaste, trincas superficiais ou outros tipos de danos. No entanto, esse método é limitado pela capacidade humana de identificar defeitos sutis, além de estar sujeito à variabilidade e à subjetividade do inspetor (Liu et al., 2014). Além disso, as inspeções manuais são demoradas e podem ser ineficientes em linhas ferroviárias de longa extensão.

Para superar essas limitações, sistemas automatizados de detecção de defeitos vêm sendo desenvolvidos com base em tecnologias de visão computacional e aprendizado de máquina. Esses sistemas são capazes de processar grandes volumes de dados visuais capturados por câmeras montadas em veículos de inspeção ferroviária, identificando automaticamente padrões de defeitos. Segundo Ekberg et al. (2002), a detecção automática de defeitos é crucial para aumentar a segurança e eficiência das operações ferroviárias, já que permite identificar problemas que passariam despercebidos em uma inspeção manual.

Os tipos de defeitos que podem ser detectados automaticamente variam, desde trincas superficiais e fissuras, até desgastes causados pela fadiga de contato (RCF). O RCF, como descrito por Kapoor (2003), é um dos principais problemas enfrentados pela infraestrutura ferroviária, surgindo a partir de tensões repetidas nas superfícies de contato entre as rodas e os trilhos. A detecção automática desses defeitos é fundamental para implementar medidas preventivas, como o esmerilhamento dos trilhos ou sua substituição antes que ocorra uma falha mais grave.

Em resumo, a detecção automatizada de defeitos em trilhos ferroviários oferece uma solução eficiente e precisa para a manutenção preditiva e corretiva, reduzindo a dependência de métodos manuais e aumentando a confiabilidade das operações ferroviárias.

METODOLOGIA

Foi realizado seguindo o método científico, estruturado nas etapas de observação, formulação de hipóteses, experimentação e análise de resultados. O desenvolvimento do sistema foi realizado utilizando uma combinação de bibliotecas e ferramentas voltadas para visão computacional e aprendizado de máquina. As principais ferramentas utilizadas foram o YOLOv10 para detecção de objetos e o Roboflow para preparação e ampliação do conjunto de

dados. A experimentação consistiu no treinamento e avaliação de dois modelos de aprendizado de máquina, utilizando diferentes abordagens de processamento de dados para comparar seus desempenhos.

COLETA E PREPARAÇÃO DOS DADOS

Para o treinamento do modelo, foi utilizada uma base de 638 imagens contendo diferentes tipos de RCFs. As imagens foram rotuladas e classificadas usando a plataforma Roboflow, uma ferramenta que facilita a anotação e o processamento de grandes volumes de dados visuais.

No Roboflow, as imagens foram organizadas e rotuladas, e, para aumentar a robustez do modelo e melhorar sua capacidade de generalização, foi aplicada uma técnica de aumento de dados. Entre as técnicas de aumento utilizadas, foi realizado o flip horizontal e vertical das imagens, o que permitiu aumentar o conjunto de dados sem perder a qualidade das imagens originais. Esse processo resultou em um total de 1.624 imagens classificadas após o aumento de dados. De acordo com Shorten e Khoshgoftaar (2019), o aumento de dados é uma técnica eficaz para melhorar a precisão e o desempenho de modelos de visão computacional, especialmente em conjuntos de dados menores.

Com o uso da API da plataforma, foi possível baixar o conjunto de dados diretamente para o ambiente de desenvolvimento e configurar o dataset no formato adequado para o treinamento do YOLOv10.

TREINAMENTO DO MODELO COM YOLOV10

O modelo de detecção foi treinado utilizando o YOLOv10, uma versão aprimorada do algoritmo YOLO (You Only Look Once), conhecida por sua eficiência e precisão em tarefas de detecção de objetos em tempo real. O YOLOv10 foi escolhido por sua capacidade de realizar detecções rápidas e precisas, mesmo em imagens com múltiplos objetos e sob diferentes condições de iluminação.

Para o treinamento, foram utilizados modelos pré-treinados disponibilizados pelo repositório do YOLOv10. Esses modelos variam em complexidade, desde versões menores como o YOLOv10n, até versões mais robustas, como o YOLOv10l. O modelo selecionado para o treinamento foi o YOLOv10n, que foi ajustado com base no conjunto de dados de defeitos fornecido. O processo de treinamento foi realizado por 30 épocas, com um batch size de 32,

permitindo que o modelo fosse exposto a um grande número de exemplos durante o treinamento.

COMPARAÇÃO DE ABORDAGENS ALGORÍTMICAS

Para avaliar a eficácia da detecção de defeitos, foram testadas duas abordagens distintas utilizando o modelo YOLOv10. A primeira abordagem, denominada Modelo Padrão, utilizou as imagens originais dos trilhos sem qualquer modificação adicional. Essa configuração permitiu que o modelo considerasse todo o contexto visual das imagens, incluindo elementos externos, como vegetação e objetos adjacentes, que poderiam interferir nas detecções. A hipótese para essa abordagem era de que o contexto completo das imagens poderia contribuir para a sensibilidade do modelo, aumentando sua capacidade de detectar defeitos em diferentes condições visuais.

A segunda abordagem, denominada Modelo Crop, aplicou um corte nas imagens para isolar exclusivamente a região do trilho. Esse processo teve como objetivo remover possíveis interferências externas e focar diretamente na área de interesse, onde os defeitos ocorrem. A hipótese subjacente era de que o isolamento do trilho reduziria a ocorrência de falsos positivos, melhorando a precisão geral do modelo.

7623

Ambas as abordagens foram configuradas e treinadas utilizando os mesmos parâmetros, como o número de épocas e o tamanho dos lotes, para garantir uma comparação justa entre os modelos.

MÉTRICAS DE AVALIAÇÃO

Após o treinamento, os dois modelos foram avaliados utilizando um conjunto de imagens de teste. A análise de desempenho foi realizada com base em métricas padrão de aprendizado de máquina, como precisão, sensibilidade, acurácia e F1-Score. A precisão avaliou a proporção de detecções corretas em relação ao total de detecções realizadas, enquanto a sensibilidade mediu a capacidade dos modelos de identificar corretamente todos os defeitos reais. A acurácia foi utilizada para fornecer uma visão geral do desempenho, considerando tanto os acertos quanto os erros. Já o F1-Score ofereceu uma métrica harmônica que equilibra precisão e sensibilidade, sendo particularmente relevante em cenários com classes desbalanceadas.


RESULTADOS E DISCUSSÕES

Nesta seção, analisamos os resultados do treinamento de ambos os modelos (Modelo Padrão e Crop), com base na matriz de confusão gerada durante o processo. A seguir, discutimos o desempenho do modelo em termos de suas métricas de avaliação e duas detecções realizadas com sucesso na pratica.

MATRIZ DE CONFUSÃO


A matriz de confusão apresentada na Figura 1 oferece uma visão detalhada do desempenho do Modelo Padrão, enquanto a Figura 2 representa a visão detalhada do Modelo Crop. As matrizes contêm duas classes: Spall (defeito específico detectado) e Background (ausência de defeitos).

Figura 1: Matriz de Confusão – Modelo Padrão



Fonte: Matriz gerada pelo autor durante o treinamento

Figura 2: Matriz de Confusão – Modelo Crop



Fonte: Matriz gerada pelo autor durante o treinamento

True Positives (TP): O Modelo Padrão (Figura 1) identificou corretamente 86 defeitos como Spall, ou seja, 86 previsões corretas de presença de defeitos. Enquanto o Modelo Crop (Figura 2) identificou 57 previsões corretas de presença de defeitos.

False Positives (FP): No Modelo Padrão (Figura 1) ocorreu em 25 casos, onde o modelo detectou um defeito inexistente, classificando incorretamente áreas de Background como defeituosas. Enquanto no Modelo Crop (Figura 2) ocorreram 14 casos.

True Negatives (TN): Ambos os modelos classificaram o áreas como Background, sem defeitos presentes.

False Negatives (FN): Em 36 casos, o modelo Modelo Padrão (Figura 1) falhou em detectar o defeito, indicando a presença de falsos negativos. Enquanto o Modelo Crop (Figura 2) falhou em 35 casos

CALCULOS DE AVALIAÇÃO

Com base nos valores obtidos na matriz confusão segue abaixo os cálculos de Precisão, Sensibilidade, Acurácia e F1-Score para cada modelo:

- Cálculos Modelo Padrão:

$$precisão = \frac{TP}{TP + FP} = \frac{86}{86 + 25} = \frac{86}{111} \cong 0,7748$$

$$sensibilidade = \frac{TP}{TP + FN} = \frac{86}{86 + 36} = \frac{86}{122} \cong 0,7049$$

$$\text{acurácia} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{86 + 0}{86 + 0 + 25 + 36} = \frac{86}{147} \cong 0,5850$$

$$F1 = 2 * \frac{\text{precisão} * \text{sensibilidade}}{\text{precisão} + \text{sensibilidade}} = 2 * \frac{0,7748 * 0,7049}{0,7748 + 0,7049} \cong 0,7383$$

- Cálculos Modelo Crop:

$$\text{precisão} = \frac{TP}{TP + FP} = \frac{57}{57 + 14} = \frac{57}{71} \cong 0,8028$$

$$\text{sensibilidade} = \frac{TP}{TP + FN} = \frac{57}{57 + 35} = \frac{57}{92} \cong 0,6196$$

$$\text{acurácia} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{57 + 0}{57 + 0 + 17 + 35} = \frac{57}{106} \cong 0,5377$$

$$F1 = 2 * \frac{\text{precisão} * \text{sensibilidade}}{\text{precisão} + \text{sensibilidade}} = 2 * \frac{0,8028 * 0,6196}{0,8028 + 0,6196} \cong 0,6984$$

Com esses dados podemos montar a seguinte tabela:

Tabela 1: Comparação Final

| Métrica | Modelo Padrão | Modelo Crop |
|---------------|---------------|-------------|
| Precisão | 0,7748 | 0,8028 |
| Sensibilidade | 0,7049 | 0,6196 |
| Acurácia | 0,5850 | 0,5377 |
| F1-Score | 0,7383 | 0,6984 |

Fonte: Tabela gerada pelo autor


A análise revelou que o Modelo Crop apresentou maior precisão em comparação ao modelo padrão, demonstrando que o isolamento do trilho foi eficaz para melhorar a identificação correta dos defeitos em relação ao total de detecções realizadas. No entanto, o modelo padrão apresentou maior sensibilidade e acurácia em comparação ao modelo com crop, indicando uma maior capacidade de detectar defeitos menores ou em condições visuais

desafiadoras e identificar corretamente tanto defeitos quanto elementos não defeituosos, ainda que com mais falsos positivos. O Modelo Padrão também se destacou no F1-Score, que equilibra precisão e sensibilidade, embora o isolamento do trilho tenha melhorado a precisão, ele impactou negativamente a sensibilidade, comprometendo o equilíbrio geral entre as métricas.

Esses resultados indicam que o modelo padrão, ao considerar o contexto completo das imagens, oferece um desempenho geral mais equilibrado, enquanto o Modelo Crop pode ser mais útil em cenários onde a redução de falsos positivos é prioritária.


A seguir, analisamos duas detecções realizadas com sucesso de cada modelo de um mesmo defeito, com base nas imagens geradas durante a inferência.

Figura 3: Exemplo de Detecção 1 - Modelo Padrão




Fonte: Foto resultante do conjunto de teste gerada pelo algoritmo

Figura 4: Exemplo de Detecção 1 - Modelo Crop




Fonte: Foto resultante do conjunto de teste gerada pelo algoritmo

Figura 5: Exemplo de Detecção 2 - Modelo Padrão



Fonte: Foto resultante do conjunto de teste gerada pelo algoritmo

Figura 6: Exemplo de Detecção 2 - Modelo Crop



Fonte: Foto resultante do conjunto de teste gerada pelo algoritmo

Exemplificando de maneira prática o que foi obtido nas métricas, ao compararmos as Figuras 3 e 4 percebemos a maior precisão do modelo Crop em relação ao Modelo Padrão (0,81 e 0,87 respectivamente). Entretanto ao compararmos as Figuras 5 e 6 vemos a maior capacidade do Modelo Padrão em identificar defeitos menores ainda que com menor precisão.

REFERÊNCIAS

ALPAYDIN, E. Introduction to Machine Learning. 4. ed. Cambridge: MIT Press, 2020.

EKBERG, A.; KABO, E.; ANDERSSON, H. An engineering model for rolling contact fatigue. *Wear*, v. 253, n. 1-2, p. 228-239, 2002.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. Deep Learning. Cambridge: MIT Press, 2016.

JOHNSON, A. Data augmentation and dataset management with Roboflow. Roboflow Blog, 2021. Disponível em: <https://blog.roboflow.com/data-augmentation-dataset-management/>. Acesso em: 16 out. 2024.

KAPOOR, A.; FLETCHER, D. I.; FRANKLIN, F. J. The Role of Wear in Enhancing Rail Life. In: Proceedings of the 29th Leeds-Lyon Symposium on Tribology, v. 41, p. 331-340, 2003.

MURPHY, K. P. Machine Learning: A Probabilistic Perspective. Cambridge: MIT Press, 2012.

REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. You Only Look Once: Unified, Real-Time Object Detection. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016. p. 779-788. Disponível em: <https://arxiv.org/abs/1506.02640>. Acesso em: 16 out. 2024.

SHORTEN, C.; KHOSHGOFTAAR, T. M. A survey on image data augmentation for deep learning. *Journal of Big Data*, v. 6, n. 1, p. 1-48, 2019.

SZELISKI, R. Computer Vision: Algorithms and Applications. London: Springer, 2010.