

PRIORIZAÇÃO DA SUBSTITUIÇÃO DE TRILHOS FERROVIÁRIOS POR ANÁLISE AUTOMATIZADA DE IMAGENS COM FOCO NA CONCENTRAÇÃO DE DEFEITOS

PRIORITIZATION OF RAILWAY TRACK REPLACEMENT THROUGH AUTOMATED IMAGE ANALYSIS WITH FOCUS ON DEFECT CONCENTRATION

Antonio Felipe Neves Santos¹
Matheus Sousa Barroso²

Resumo: A priorização da substituição de trilhos é fundamental para garantir a segurança e otimizar recursos na manutenção ferroviária. Este trabalho apresenta uma metodologia baseada em visão computacional e aprendizado de máquina para detectar defeitos superficiais e priorizar segmentos de via conforme a concentração de ocorrências, independentemente da severidade individual. Utilizando imagens capturadas em inspeções e processadas com o algoritmo YOLOv12, foram identificados padrões relacionados à fadiga de contato rolante (Rolling Contact Fatigue – RCF) e outros defeitos recorrentes. Os dados de detecção foram organizados em um índice de prioridade fundamentado na densidade de defeitos por segmento. Os resultados indicam que essa abordagem é efetiva para apoiar decisões de manutenção preventiva e substituição, permitindo alocar recursos de forma direcionada e aumentar a segurança operacional.

Palavras-chave: Manutenção ferroviária; Visão computacional; Aprendizado de máquina; Densidade de defeitos; Priorização de substituição.

Abstract: The prioritization of railway track replacement is essential to ensure safety and optimize maintenance resources. This paper presents a methodology based on computer vision and machine learning to detect surface defects and prioritize track segments according to the concentration of occurrences, regardless of individual severity. Using inspection images processed with the YOLOv12 algorithm, patterns related to Rolling Contact Fatigue (RCF) and other recurring defects were identified. Detection data were organized into a priority index based on defect density per segment. Results indicate that this approach is effective in supporting preventive maintenance and replacement decisions, enabling targeted resource allocation and increased operational safety.

KeyWords: Railway maintenance; Computer vision; Machine learning; Defect density;

Replacement prioritization.

SUMÁRIO

1 INTRODUÇÃO	3
2 FUNDAMENTAÇÃO TEÓRICA	3
2.1 Inspeção de trilhos	3
2.2 Visão computacional	4
2.3 Aprendizagem de máquina	5
2.4 Detecção de defeitos.....	6
3. METODOLOGIA	7
3.1 Coleta e preparação dos dados.....	7
3.2 Configuração e treinamento do modelo	8
3.3 Exportação e organização dos dados de detecção.....	9
3.4 Métricas de avaliação	10
3.5 Cálculo do índice de prioridade por densidade.....	10
4 RESULTADOS E DISCUSSÕES	10
4.1 Matriz de confusão.....	11
4.2 Resultados quantitativos do modelo.....	12
4.2.1 Precisão.....	12
4.2.2 Sensibilidade (<i>recall</i>)	12
4.2.3 <i>F1-score</i>	12
4.4 Análise da concentração de defeitos por segmento	14
5 CONCLUSÕES	16
REFERÊNCIAS	17

1 INTRODUÇÃO

A substituição de trilhos danificados é uma atividade crítica na gestão da via permanente. A decisão sobre quais trechos substituir primeiro deve considerar fatores técnicos e operacionais, além de restrições orçamentárias e de janela de intervenção. Tradicionalmente, a priorização se baseia em inspeções visuais e na experiência de campo, o que pode introduzir subjetividade. Com o avanço das técnicas de análise de imagens e aprendizado de máquina, torna-se possível quantificar, de forma objetiva e em larga escala, a concentração de defeitos ao longo da via. Este trabalho propõe um fluxo que integra detecção automática por visão computacional e um índice de prioridade baseado na densidade de defeitos por segmento, viabilizando um plano de substituição orientado por dados.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Inspeção de trilhos

A inspeção de trilhos constitui uma etapa essencial para preservar a integridade da superestrutura ferroviária. Ao longo do tempo, o contato repetitivo entre as rodas dos trens e a superfície dos trilhos gera esforços cíclicos capazes de originar defeitos progressivos, como desgastes e trincas superficiais. Entre as anomalias mais críticas está a fadiga de contato rolante (*Rolling Contact Fatigue* – RCF), apontada por Kapoor (2003) como um dos principais mecanismos de falha nos trilhos, caracterizada pelo surgimento de microtrincas resultantes da aplicação contínua de cargas.

Essas micro trincas, inicialmente quase imperceptíveis, tendem a se propagar para camadas mais profundas do metal, criando condições que podem culminar em rupturas graves. A dificuldade de detecção a olho nu, sobretudo nos estágios iniciais, reforça a necessidade de métodos automatizados para inspeção precoce (Ekberg et al., 2002). A correta identificação do RCF possibilita intervenções preventivas, como o esmerilhamento ou a substituição do trilho, antes que a condição se agrave.

Embora historicamente a inspeção fosse predominantemente manual, limitando-se à

percepção e interpretação visual dos inspetores (Liu et al., 2014), práticas mais modernas incorporam sistemas mecanizados com sensores e câmeras embarcadas em veículos especializados, como o Carro Controle e o RIV (*Rail Inspection Vehicle*). Esses equipamentos percorrem a via registrando imagens e dados de alta resolução, permitindo varreduras contínuas e precisas em longos trechos, com capacidade de identificar defeitos sutis que passariam despercebidos em inspeções convencionais. A automação da detecção, especialmente no caso do RCF, representa assim uma solução mais eficiente e confiável para aumentar a segurança e otimizar a manutenção da infraestrutura ferroviária.

2.2 Visão computacional

Visão computacional (VC) refere-se à área da inteligência artificial que busca extrair, analisar e interpretar informações a partir de imagens ou sequências de vídeo, de forma similar à percepção visual humana. Embora sistemas tradicionais ainda recorram a inspeção manual, a VC automatiza essa atividade através da aplicação de algoritmos robustos de processamento e análise, tornando-a ideal para inspeções de infraestrutura como trilhos ferroviários (Szeliski, 2010).

Na base das modernas soluções de VC estão as redes neurais convolucionais (CNNs), altamente eficientes na detecção de padrões visuais complexos. Construídas por camadas alternadas de convolução, função de ativação e *pooling*, as CNNs extraem automaticamente características da imagem — desde bordas até texturas finas — reduzindo a necessidade de engenharia manual das características (Goodfellow; Bengio; Courville, 2016).

Especificamente no contexto ferroviário, a aplicação de CNNs para detecção de defeitos em trilhos tem se mostrado efetiva. Faghieh-Roohi et al. (2016) empregaram uma rede convolucional profunda para examinar filmagens de superfície de trilhos e identificaram defeitos com alto nível de acurácia automática. Em um estudo mais recente, Passos et al. (2024) avaliaram diversas arquiteturas CNN em banco de dados reais e reportaram acurácia média de 83 % em defeitos leves e até 92 % em casos severos, com destaque para redes como *Inception-v3*.

As principais vantagens da visão computacional na inspeção ferroviária são sua escalabilidade, velocidade e consistência. Ao operar em tempo real e em grande volume, reduz-se a variabilidade causada por inspeções manuais e amplia-se a confiabilidade das decisões de manutenção *(Szeliski, 2010). Além disso, a integração de VC com sistemas de

localização (GPS) e IoT permite o monitoramento contínuo dos trilhos durante a operação da ferrovia (Faghih-Roohi et al., 2016).

Em síntese, a visão computacional, especialmente quando apoiada por CNNs, representa um salto tecnológico na inspeção ferroviária. Em nosso projeto, esse arcabouço teórico sustenta o desenvolvimento de uma solução que automatiza a identificação de defeitos superficiais em trilhos, com foco em precisão operacional e aplicabilidade prática imediata.

2.3 Aprendizagem de máquina

A aprendizagem de máquina, ou machine learning (ML), é uma subárea da inteligência artificial que tem como objetivo permitir que sistemas computacionais sejam capazes de reconhecer padrões e realizar previsões com base em dados históricos, sem depender de regras programadas de forma explícita. Segundo Alpaydin (2020), o princípio central da aprendizagem de máquina reside na capacidade de generalização, ou seja, na habilidade de um modelo aprender a partir de exemplos e aplicar esse aprendizado a novos dados não vistos. Diferentemente de abordagens baseadas em lógica determinística, os algoritmos de ML utilizam métodos estatísticos para construir representações matemáticas que relacionam entradas a saídas, a partir de um conjunto de treinamento.

Os principais paradigmas da aprendizagem de máquina são a aprendizagem supervisionada, não supervisionada e por reforço. Na aprendizagem supervisionada, o modelo é treinado a partir de dados rotulados, nos quais as respostas corretas já são conhecidas. O objetivo é ajustar os parâmetros internos do modelo para que ele consiga prever corretamente os rótulos de novos exemplos. A aprendizagem não supervisionada, por sua vez, trabalha com dados sem rótulos e busca encontrar padrões subjacentes, como agrupamentos ou estruturas latentes. Já na aprendizagem por reforço, o algoritmo aprende por meio da interação com um ambiente, tomando decisões com base em recompensas ou penalidades que recebe ao longo do tempo (Murphy, 2012).

Além disso, é importante destacar que o desempenho dos modelos de ML também está relacionado à forma como os dados são tratados. A presença de dados desbalanceados — quando uma classe de defeito aparece muito mais que outra — pode prejudicar significativamente os resultados. Para lidar com esse problema, técnicas de balanceamento de classes, como oversampling e undersampling, ou métodos sensíveis ao custo vêm sendo

utilizadas com bons resultados (He; Garcia, 2009). A curadoria do conjunto de dados, portanto, torna-se tão importante quanto o modelo em si.

Dessa forma, a aprendizagem de máquina não apenas representa o suporte algorítmico das soluções modernas de automação inteligente, como também oferece os fundamentos necessários para a construção de sistemas capazes de aprender com dados reais e adaptar-se continuamente a novas condições. Essa abordagem permite que modelos de classificação e detecção visual operem com alto grau de precisão, desde que sustentados por dados consistentes e técnicas adequadas de treinamento e validação.

2.4 Detecção de defeitos

A detecção de defeitos representa uma atividade de importância crítica na manutenção ferroviária, uma vez que falhas como trincas superficiais e desgaste excessivo comprometem a integridade estrutural dos trilhos e podem ocasionar acidentes severos. Na prática tradicional, inspetores analisam visualmente os trilhos para identificar esses danos, contudo, esse processo é lento, sujeito à fadiga humana e limitado quanto à identificação de defeitos sutis (Liu et al., 2014). Nessas condições, falhas em estágios iniciais podem passar despercebidas, reduzindo a eficácia das ações preventivas e elevando os riscos operacionais.

Para superar esses desafios, surgiram sistemas automatizados que utilizam visão computacional e aprendizagem de máquina para a detecção automática de defeitos ferroviários. Esses sistemas processam volumes elevados de imagens capturadas por câmeras embarcadas em veículos de inspeção e identificam automaticamente padrões associados a trincas, descontinuidades ou fadiga de contato (RCF). Ekberg, Kabo e Andersson (2002) defendem que a detecção automática de defeitos é essencial para melhorar a segurança e eficiência das operações ferroviárias, pois permite identificar anomalias que dificilmente seriam detectadas manualmente.

Dentro desse contexto, a fadiga por contato rolante (RCF) representa um dos problemas mais críticos. Essa forma de desgaste surge devido à repetida aplicação de tensões nas superfícies de roda e trilho, resultando em corrosões e trincas que se acumulam ao longo do tempo. O modelo desenvolvido por Ekberg et al. (2002) quantifica diferentes modos de fadiga superficial e do subsuperfície, propondo índices de dano que possibilitam prever a degradação dos componentes com precisão analítica.

Mais recentemente, estudos aplicam técnicas de visão computacional para automatizar esse processo. Bai et al. (2021) utilizam redes neurais profundas em um framework de detecção de defeitos em superfície de trilhos, alcançando alta acurácia mesmo em cenários com ruídos visuais ou padrões complexos. Outros autores utilizam abordagens como Faster R-CNN e YOLO para detecção em tempo real, demonstrando que a automação pode ser realizada com alto desempenho, embora exija conjuntos de dados rotulados de forma robusta (Bai et al., 2021).

Essas soluções automatizadas oferecem clara vantagem em comparação com métodos manuais: operam em tempo real, processam grandes volumes de dados com consistência e reduzem significativamente o viés causado pela variabilidade humana. Ao integrar modelos de detecção visual com ferramentas de manutenção preditiva, é possível agir antes que o defeito se torne crítico, reduzindo custos e riscos operacionais.

Em síntese, a detecção automática de defeitos em trilhos ferroviários, apoiada por visão computacional e algoritmos de aprendizado de máquina, constitui uma abordagem tecnicamente eficaz e confiável, capaz de superar limitações tradicionais, promover manutenção preventiva de forma contínua e garantir um elevado padrão de segurança na infraestrutura ferroviária.

3. 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.

3.1 Coleta e preparação dos dados

A primeira etapa do desenvolvimento metodológico consistiu na coleta e preparação de um conjunto de imagens voltado à identificação de defeitos do tipo Rolling Contact Fatigue (RCF) em trilhos ferroviários. A base inicial foi composta por 638 imagens capturadas em

diferentes condições de iluminação, ângulo e ambiente, com o objetivo de representar de maneira variada os cenários reais de operação. Essas imagens foram anotadas e organizadas na plataforma Roboflow, que oferece suporte à criação de conjuntos de dados estruturados e compatíveis com modelos de detecção de objetos.

No processo de anotação, as imagens foram rotuladas manualmente por meio da interface gráfica da plataforma, identificando visualmente os padrões associados a diferentes tipos de falhas superficiais. Após essa etapa, foi aplicado um processo de aumento de dados (data augmentation) com o objetivo de expandir a base original e melhorar a capacidade de generalização do modelo. Entre as transformações utilizadas, destacam-se o espelhamento horizontal e vertical (flip), que geram novas variações a partir das imagens originais sem comprometer a integridade visual dos defeitos. Esse procedimento elevou o total do conjunto para 1.624 imagens anotadas.

O uso de técnicas de aumento de dados tem sido amplamente recomendado em aplicações de visão computacional, principalmente em contextos onde a quantidade de imagens é limitada. De acordo com Shorten e Khoshgoftaar (2019), o data augmentation contribui para reduzir o overfitting, melhorar a precisão e tornar os modelos mais robustos diante de variações visuais comuns em ambientes reais.

Com a base final de imagens preparada, utilizou-se a API do Roboflow para exportação do dataset no formato compatível com o modelo YOLOv12, a versão mais recente da série You Only Look Once disponível até o momento da pesquisa. A estrutura dos arquivos, incluindo os rótulos no formato YOLO e os diretórios de treino, validação e teste, foi automaticamente organizada pela plataforma, otimizando o processo de integração com o ambiente de desenvolvimento.

3.2 Configuração e treinamento do modelo

Para a fase de treinamento, utilizou-se o algoritmo YOLOv12, uma das versões mais recentes da família You Only Look Once, projetada para tarefas de detecção de objetos em tempo real. O modelo foi escolhido por sua elevada eficiência computacional aliada à capacidade de detectar objetos de pequeno porte com alta precisão, o que é especialmente relevante no contexto da inspeção visual de defeitos em trilhos ferroviários.

A arquitetura do YOLOv12 incorpora avanços significativos em relação às versões anteriores, como o uso de camadas otimizadas para a extração de características visuais de

alta densidade, aprimoramentos no mecanismo de ancoragem e estratégias mais eficazes de balanceamento entre precisão e velocidade. Essas características tornam o YOLOv12 adequado para aplicações industriais em que há a necessidade de realizar inferência rápida e com acurácia elevada mesmo em ambientes com ruído visual.

O treinamento do modelo foi realizado em ambiente Python com suporte a GPU, utilizando a biblioteca oficial da arquitetura YOLO, disponível via repositório GitHub. O conjunto de dados foi dividido em três grupos: 80% das imagens para treino, 10% para validação e 10% para teste, respeitando uma distribuição balanceada entre as classes de defeito anotadas. Durante a configuração dos hiperparâmetros, foram definidos: taxa de aprendizado inicial (learning rate) de 0.001, tamanho do batch em 32 imagens por iteração, e um total de 30 épocas de treinamento.

A estrutura de diretórios foi mantida conforme o padrão da arquitetura YOLO, com os arquivos de anotação no formato .txt, seguindo o estilo YOLO (classe, centro x, centro y, largura e altura normalizados), e o arquivo data.yaml especificando os caminhos das imagens e a quantidade de classes.

Para avaliar o desempenho dos modelos, foram geradas as métricas de Precisão, Acurácia, Sensibilidade (Recall) e F1-Score, que são amplamente utilizadas em problemas de classificação binária e multiclasse em visão computacional. Essas métricas foram extraídas com o apoio das bibliotecas de visualização nativas do YOLOv12, incluindo gráficos de evolução da perda, curva de precisão e matriz de confusão.

3.3 Exportação e organização dos dados de detecção

Além da detecção visual dos defeitos, uma etapa essencial no fluxo de trabalho foi a organização estruturada das informações resultantes para fins de análise técnica e integração com sistemas de gestão da via permanente. Para isso, foi adotada uma abordagem baseada na extração de metadados diretamente a partir dos nomes dos arquivos gerados durante o processo de inferência.

As imagens resultantes das detecções realizadas com o YOLOv12 foram nomeadas seguindo um padrão padronizado, contendo campos informativos separados por delimitadores. Essa estrutura semântica no título da imagem permitiu aplicar técnicas simples de segmentação de strings (string split) para extrair automaticamente os dados descritivos de cada ocorrência.

Com essas informações extraídas, foi possível montar uma tabela de registro de defeitos detectados, com colunas organizadas da seguinte forma:

- Imagem (nome ou ID)
- Linha ferroviária
- Quilômetro (km)
- Lado do trilho (esquerdo ou direito)
- Tipo de defeito
- Quantidade total de defeitos por imagem

Esses dados foram então exportados para formatos abertos como CSV ou Excel, facilitando a visualização e o cruzamento com outras bases.

3.4 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.

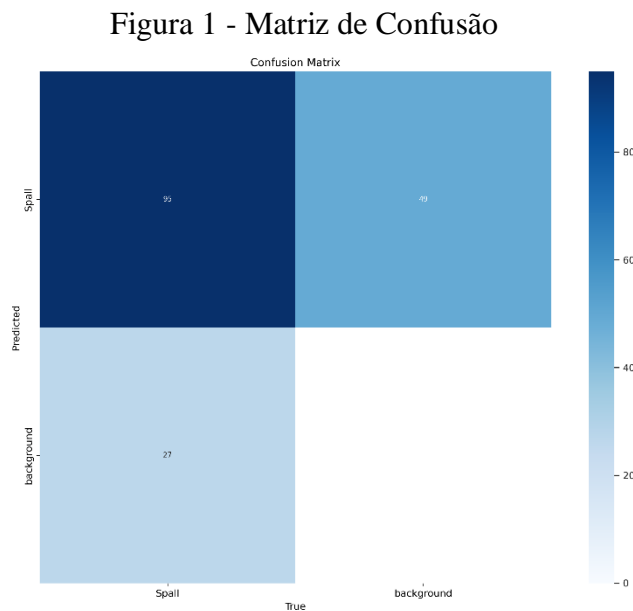
3.5 Cálculo do índice de prioridade por densidade

O índice de prioridade P adotado neste estudo é calculado pela densidade de defeitos em janelas móveis de 250 m (10 blocos de 25 m): $P = (\text{ocorrências na janela}) / (\text{extensão da janela em km})$. Janelas com maior P são priorizadas para substituição.

4 RESULTADOS E DISCUSSÕES

4.1 Matriz de confusão

A matriz de confusão gerada durante a fase de avaliação do modelo de detecção (Figura 1) fornece uma análise quantitativa da capacidade do sistema em classificar corretamente os defeitos nos trilhos ferroviários. Essa matriz é composta por quatro valores principais: Verdadeiros Positivos (TP), Falsos Positivos (FP), Falsos Negativos (FN) e Verdadeiros Negativos (TN), os quais são utilizados para o cálculo das principais métricas de desempenho do modelo.



Fonte: gerada pelo autor (2025)

Com base na figura apresentada, observa-se a seguinte distribuição:

- Verdadeiros Positivos (TP): 95 imagens com defeitos corretamente identificadas como "Spall".
- Falsos Positivos (FP): 49 imagens sem defeitos classificadas incorretamente como "Spall".
- Verdadeiros Negativos (TN): 0 áreas como *Background*, sem defeitos presentes.

- Falsos Negativos (FN): 27 imagens com defeitos que não foram detectadas, classificadas como "*background*".

4.2 Resultados quantitativos do modelo

A performance do modelo foi avaliada por meio de métricas clássicas utilizadas em problemas de classificação, com base na matriz de confusão obtida após a fase de inferência. Abaixo, são descritos os cálculos e os valores obtidos:

4.2.1 Precisão

A precisão mede a proporção de predições positivas corretas em relação ao total de predições positivas feitas.

$$\textit{precisão} = \frac{TP}{TP + FP} = \frac{95}{95 + 49} = \frac{95}{144} \cong 0,6597$$

4.2.2 Sensibilidade (*recall*)

A sensibilidade representa a capacidade do modelo em identificar corretamente os casos positivos (defeitos reais).

$$\textit{sensibilidade} = \frac{TP}{TP + FN} = \frac{95}{95 + 27} = \frac{95}{122} \cong 0,7786$$

4.2.3 *F1-score*

O *F1-score* é a média harmônica entre precisão e sensibilidade, fornecendo uma medida balanceada entre os dois indicadores.

$$F1 = 2 * \frac{\textit{precisão} * \textit{sensibilidade}}{\textit{precisão} + \textit{sensibilidade}} = 2 * \frac{0,6597 * 0,7786}{0,6597 + 0,7786} \cong 0,7130$$

Com esses dados podemos montar a seguinte tabela:

Tabela 1 - Métricas de avaliação do modelo de detecção automática de defeitos.

Métrica	Valores Calculados
Precisão	0,6597
Sensibilidade	0,7786
<i>F1-Score</i>	0,7130


Fonte: Tabela gerada pelo autor (2025)

Figura 2 - Exemplo de Detecção 1



Fonte: Foto resultante do conjunto de teste gerada pelo algoritmo (2025)

Figura 3 - Exemplo de Detecção 2

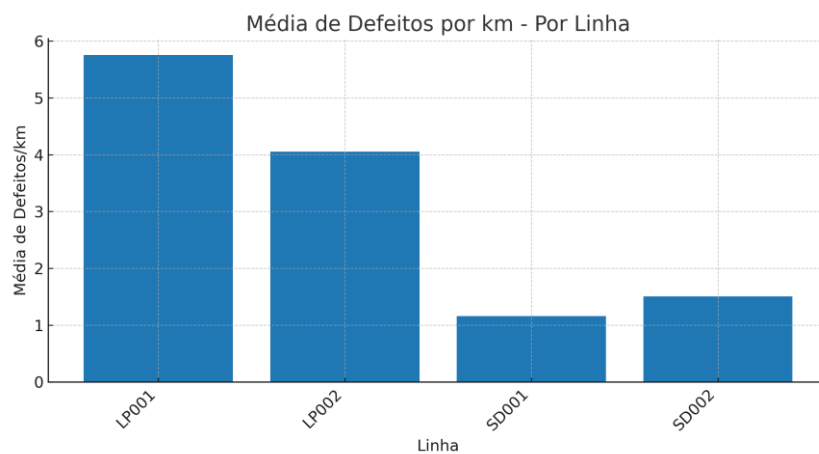


Fonte: Foto resultante do conjunto de teste gerada pelo algoritmo (2025)

4.4 Análise da concentração de defeitos por segmento

A Tabela 1 resume a densidade média de defeitos por linha. Observou-se variação entre linhas, refletindo regimes operacionais, tráfego e histórico de manutenção. O Gráfico 1 apresenta a média de defeitos por km em cada linha.

Gráfico 1 – Média de defeitos por km por linha.



Fonte: Autor (2025)

Para identificar concentrações locais críticas, aplicou-se uma janela deslizante de 250

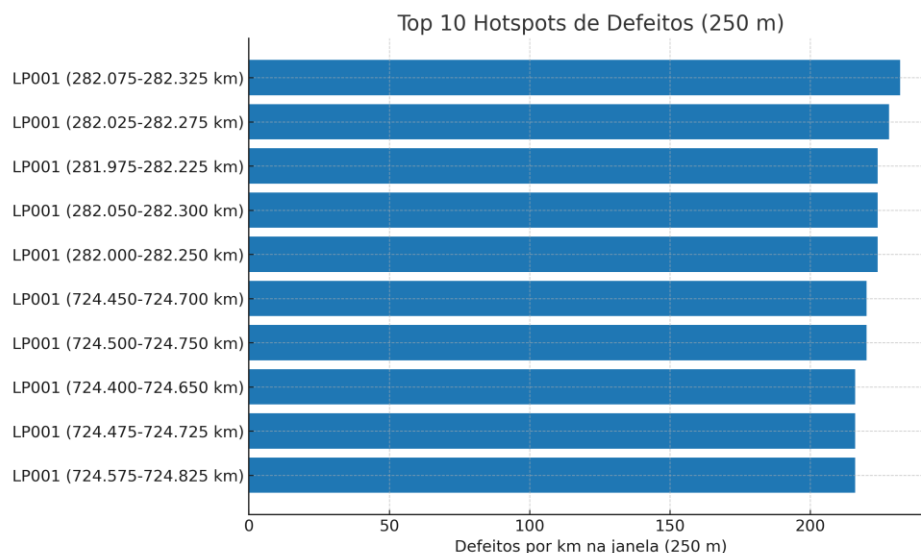
m ao longo de cada linha. A Tabela 2 lista os 10 principais *hotspots* (maiores valores de P) e o Gráfico 2 ilustra visualmente esse ranking.

Tabela 2 – Top 10 *hotspots* (250 m)

1. LP001: 282.075–282.325 km | ocorrências=58 | P=232.0/km
2. LP001: 282.025–282.275 km | ocorrências=57 | P=228.0/km
3. LP001: 281.975–282.225 km | ocorrências=56 | P=224.0/km
4. LP001: 282.050–282.300 km | ocorrências=56 | P=224.0/km
5. LP001: 282.000–282.250 km | ocorrências=56 | P=224.0/km
6. LP001: 724.450–724.700 km | ocorrências=55 | P=220.0/km
7. LP001: 724.500–724.750 km | ocorrências=55 | P=220.0/km
8. LP001: 724.400–724.650 km | ocorrências=54 | P=216.0/km
9. LP001: 724.475–724.725 km | ocorrências=54 | P=216.0/km
10. LP001: 724.575–724.825 km | ocorrências=54 | P=216.0/km

Fonte: Autor (2025)

Gráfico 2 – Top 10 *hotspots* de defeitos (250 m)



Fonte: Autor (2025)

5 CONCLUSÕES

A aplicação de ferramentas modernas, como sistemas de reconhecimento de imagens integrados à manutenção ferroviária, representa um avanço significativo na gestão da via permanente. Ao permitir a identificação automatizada de defeitos e a priorização objetiva dos trechos mais degradados, essas tecnologias aumentam substancialmente a confiabilidade operacional, direcionando recursos para pontos críticos e reduzindo o risco de falhas catastróficas. A análise baseada em dados concretos assegura que os trechos prioritários correspondam às áreas de maior comprometimento estrutural, potencializando o efeito das intervenções preventivas.

Além da detecção e priorização, a evolução natural desse processo passa pela classificação automatizada dos defeitos conforme sua severidade. Esse aprimoramento permitirá decisões ainda mais precisas sobre o tipo de manutenção a ser adotada — seja a substituição total do trilho ou a aplicação de esmerilhamento para corrigir imperfeições superficiais e prolongar a vida útil do ativo. Integrar esses sistemas a rotinas contínuas de inspeção mecanizada, como as realizadas com o Carro Controle ou o RIV, garante não apenas uma visão abrangente do estado da via, mas também uma base sólida para estratégias de manutenção preditiva e otimização do ciclo de vida dos trilhos.

REFERÊNCIAS

ALPAYDIN, E. Introduction to machine learning. 4. ed. Cambridge: MIT Press, 2020.

BAI, T.; GAO, J.; YANG, J.; YAO, D. A study on railway surface defects detection based on machine vision. *Entropy*, v. 23, n. 11, art. 1437, 2021.

DOMINGOS, P. The master algorithm: how the quest for the ultimate learning machine will remake our world. New York: Basic Books, 2015.

EKBURG, A.; KABO, E.; ANDERSSON, H. An engineering model for rolling contact fatigue of railway wheels. *Fatigue & Fracture of Engineering Materials & Structures*, v. 25, n. 10, p. 899–909, 2002.

FAGHIH-ROOHI, S.; HAJIZADEH, S.; NÚÑEZ, A.; BABUSKA, R.; DE SCHUTTER, B. Deep convolutional neural networks for detection of rail surface defects. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS – IJCNN, 2016. Proceedings [...]. [S. l.: s. n.], 2016.

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

HE, H.; GARCIA, E. A. Learning from imbalanced data. *IEEE Transactions on Knowledge and Data Engineering*, v. 21, n. 9, p. 1263–1284, 2009.

LIU, X.; LOVETT, A.; DICK, T.; SAAT, M. R.; BARKAN, C. P. Optimization of ultrasonic rail-defect inspection for improving railway transportation safety and efficiency. *Journal of Transportation Engineering*, v. 140, n. 10, art. 04014048, 2014.

MURPHY, K. P. Machine learning: a probabilistic perspective. Cambridge: MIT Press, 2012.

PASSOS, R. A. S. L. et al. An in-depth assessment of convolutional neural networks for rail surface defect detection. *Research, Society and Development*, Rio de Janeiro, v. 11, n. 8, p. 1–17, 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, 2010/2022 ed.

ZHAO, R.; YAN, R.; CHEN, Z.; MAO, K.; WANG, P.; GAO, R. Learning to monitor machine conditions with graph neural network models. *Mechanical Systems and Signal Processing*, v. 120, p. 149–172, 2019.

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.