



Universidade Federal de Juiz de Fora Programa de Pós-Graduação em
Engenharia Elétrica

Alexandre Lima de Carvalho

**IDENTIFICAÇÃO DE FALHAS EM TRILHOS DE FERROVIA BASEADO EM
CORRENTE PARASITA E INTELIGÊNCIA ARTIFICIAL**

Tese de Doutorado

Juiz de Fora
2025

ALEXANDRE LIMA DE CARVALHO

**Identificação de Falhas em Trilhos de Ferrovia Baseado em Corrente Parasita e
Inteligência Artificial**

Tese apresentada ao Programa de Pós -
Graduação em Engenharia Elétrica da Uni-
versidade Federal de Juiz de Fora, na área de
concentração em Sistemas de Energia, como
requisito para obtenção do título de Doutor
em Engenharia Elétrica.

Orientador: Prof. Augusto Santiago Cerqueira

Co-orientador: Prof. Leonardo de Melo Honório

Juiz de Fora
2025

ALEXANDRE LIMA DE CARVALHO

**Identificação de Falhas em Trilhos de Ferrovia Baseado em Corrente Parasita e
Inteligência Artificial**

Tese apresentada ao Programa de Pós -
Graduação em Engenharia Elétrica da Uni-
versidade Federal de Juiz de Fora, na área de
concentração em Sistemas de Energia, como
requisito para obtenção do título de Doutor
em Engenharia Elétrica.

Aprovada em 20 de maio de 2025.

Ficha catalográfica elaborada através do programa de geração automática da
Biblioteca Universitária da UFJF,
com os dados fornecidos pelo(a) autor(a)

Lima de Carvalho, Alexandre.

Identificação de falhas em trilhos de ferrovia baseado em corrente
parasita e inteligência artificial : identificação de falhas em trilhos de
ferrovia baseado em corrente superficial e inteligência artificial /
Alexandre Lima de Carvalho. -- 2025.

119 f.

Orientador: Augusto Santiago Cerqueira

Coorientador: Leonardo Mello Honório

Tese (doutorado) - Universidade Federal de Juiz de Fora,
Faculdade de Engenharia. Programa de Pós-Graduação em
Engenharia Elétrica, 2025.

1. Corrente Parasita. 2. Desgastes Superficiais em Trilhos. 3.
Inteligência Artificial. I. Santiago Cerqueira, Augusto , orient. II. Mello
Honório, Leonardo, coorient. III. Título.

Alexandre Lima de Carvalho

Identificação de Falhas em Trilhos de Ferrovia Baseado em Corrente Parasita e Inteligência Artificial

Tese apresentada ao
Programa de Pós-Graduação
em Engenharia Elétrica
da Universidade Federal de
Juiz de Fora como requisito
parcial à obtenção do título
de Doutor em Engenharia
Elétrica. Área de
concentração: Sistemas
Eletrônicos

Aprovada em 20 de maio de 2025.

BANCA EXAMINADORA

Prof. Dr. Augusto Santiago Cerqueira - Orientador

Universidade Federal de Juiz de Fora

Prof. Dr. Leonardo de Mello Honório - Coorientador

Universidade Federal de Juiz de Fora

Prof. Dr. Alexandre Bessa dos Santos

Universidade Federal de Juiz de Fora

Prof. Dr. André Luis Marques Marcato

Universidade Federal de Juiz de Fora

Prof. Dr. Eduardo Furtado de Simas Filho

Universidade Federal da Bahia

Profa. Dra. Milena Faria Pinto

Centro Federal de Educação Tecnológica Celso Suckow da Fonseca

Juiz de Fora, 07/05/2025.



Documento assinado eletronicamente por **Eduardo Furtado de Simas Filho, Usuário Externo**, em 20/05/2025, às 12:10, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Milena Faria Pinto, Usuário Externo**, em 20/05/2025, às 18:18, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Alexandre Bessa dos Santos, Professor(a)**, em 23/05/2025, às 07:38, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Leonardo de Mello Honorio, Professor(a)**, em 26/05/2025, às 10:03, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Andre Luis Marques Marcato, Professor(a)**, em 26/05/2025, às 10:09, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Augusto Santiago Cerqueira, Professor(a)**, em 07/07/2025, às 16:04, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf (www2.ufjf.br/SEI) através do ícone Conferência de Documentos, informando o código verificador **2380605** e o código CRC **B386602D**.

Aos meus amigos e irmãos.
Aos pais, pelo apoio e sustento.

AGRADECIMENTOS

Agradeço à minha esposa Fernanda Langoni e minhas filhas Fernanda de Oliveira Lima Carvalho e Maria Langoni de Carvalho, pelo encorajamento e apoio.

Aos professores Leonardo Honório e Augusto Cerqueira pela orientação, amizade e principalmente, pela paciência, sem a qual este trabalho não se realizaria.

Aos profissionais da área de via permanente da MRS Logística pelas orientações, principalmente o especialista João Serpa pelos conhecimentos passados e à MRS pela disponibilidade de tempo oferecido para a elaboração deste trabalho, aos apoiadores do projeto na MRS, Henrique Veloso, Cláudio Lopes e Danilo Vieira.

RESUMO

O transporte ferroviário é amplamente reconhecido como um setor vital para a economia de um país, oferecendo vantagens em relação ao transporte rodoviário, especialmente para grandes distâncias, uma vez que os custos por volume são menores na ferrovia e a taxa de acidentes é reduzida. Portanto, torna-se essencial investir na melhoria da confiabilidade dos ativos ferroviários, como locomotivas, vagões, suprimentos de energia, sinalização e via permanente, que é o conjunto de infraestruturas de suporte, como dormentes, trilhos, britas e demais fixações. Desse modo, a melhoria da confiabilidade desses ativos, aliada à estratégia logística, é crucial para estudos de aumento da velocidade e produtividade.

Neste sentido, este trabalho apresenta uma solução embarcada que contribui para o aumento da segurança e eficiência da manutenção da via permanente, impactando na elevação da confiabilidade, produtividade e na melhoria do desempenho do planejamento das manutenções, resultando na diminuição de paradas emergenciais e acidentes com impactos pessoais e econômicos. O sistema proposto localiza e identifica falhas superficiais em trilhos por meio de correntes parasitas, com a aplicação da transformada Wavelet e de rede neural convolucional, o mesmo foi embarcado em um veículo ferroviário para realização de testes em campo, que demonstrou a funcionalidade da proposta de localização de falhas e seu mapeamento. Testes em campo foram realizados para validar e avaliar o método de identificação de falhas, apresentando uma acurácia em torno de 98%. A comparação com outras técnicas de classificação mostrou que a rede convolucional é a mais adequada para a tarefa, oferecendo maior acurácia e precisão do que as demais técnicas consideradas.

Palavras-chave: Corrente Parasita, Desgastes Superficiais em Trilhos, Sistema Embarcado, Localização, Classificação, Inteligência Artificial.

ABSTRACT

Rail transport is widely recognized as a vital sector for a country's economy, offering advantages over road transport, especially for long distances, as costs per volume are lower in railways and accident rates are lower. Therefore, it becomes essential to invest in improving the reliability of railway assets, such as locomotives, wagons, power supplies, signaling, and permanent way. The permanent way refers to the set of supporting infrastructures such as sleepers, rails, ballast, and other fastenings. Consequently, improving the reliability of these assets, combined with a logistics strategy, is crucial to increasing the speed and productivity of transport. In this context, this work presents an embedded solution that contributes to increasing the safety and efficiency of permanent way maintenance, impacting the increase in reliability, productivity, and improving the performance of maintenance planning, consequently reducing emergency stops and accidents with personal and economic impacts. The proposed system locates and identifies surface defects in rails through eddy currents, the Wavelet transform, and a convolutional network. The system was embedded in a railway vehicle for field tests that demonstrated the feasibility of the proposal. Field tests were also performed to enable the design and evaluation of the fault identification method, presenting an accuracy of around 98%. Comparison with other classification techniques demonstrated that the convolutional network is the most suitable for the task, presenting higher accuracy and precision than the other techniques considered.

Keywords: Eddy Current, Rail Surface Defects, Embedded System, Location, Classification, Artificial Intelligence

LISTA DE ILUSTRAÇÕES

1	Representatividade de falhas em trilhos	25
2	Métodos indicados para detecção de falhas em trilhos	25
3	Tipos de anomalias: (a) <i>Squat</i> , (b) Solda e (c) Junta	27
4	<i>Squat</i>	28
5	Ângulos das sondas de ultrassom	41
6	Regiões de alcance Ultrassom x Correntes Parasitas	41
7	Veículo de inspeção por Ultrassom RD-33	42
8	Teste em rodas utilizando fluxo magnético	43
9	Sonda Lápis ACFM	45
10	Implantação da técnica - Laser Ultrassônico (a) Visão geral do sistema (b) Transporte do sistema em veículo rodoferroviário (c) Inspeções de seção inteira do trilho incluindo o boleto do trilho	45
11	Detecção de trinca em barra de junção	47
12	Teste em eixo utilizando partículas magnéticas	48
13	CNN conceitual [1].	57
14	Topologia básica da rede VGGNet [2].	58
15	Ilustração do processo de monitoramento de via com veículo.	61
16	Rudged Laptop - Dell Latitude 14	64
17	Aerocheck+	65
18	Sonda PT003, utilizada nesta configuração para os primeiros testes ma- nuais	65
19	Sistema proposto para os próximos passos do desenvolvimento	66
20	Diagrama do sistema	67

21	Aba Conexão	68
22	Aba Controles	69
23	Aba Monitoramento	70
24	Esquerda: Aba Câmera , registrando uma anomalia no trilho	70
25	Tela visualização de coordenadas	71
26	Diagrama do Sistema de Detecção	72
27	Sondas instaladas no veículo de inspeção. Na esquerda é possível visualizar a câmera; no centro é mostrado o suporte de fixação da sonda; à direita pode ser visualizado detalhes do suporte da sonda.	72
28	Diagrama sequencial para detecção de defeitos em superfícies dos trilhos.	75
29	Exemplo sinal adquirido após a leitura.	76
30	Exemplo de ruído de <i>heaviside</i> (degrau). O sinal adquirido pode ser visto em preto e o filtrado em vermelho.	77
31	Sinal após a retirada de spikes	78
32	Sinal padronizado após a retirada de <i>spikes</i>	79
33	Wavelet - cmor	81
34	Espectro de potência da CWT do sinal de uma junta.	81
35	Arquitetura da Rede Neural Convolucional.	82
36	Amostras das classes considerando: <i>squat</i> , junta, solda e ruído apresentados na sequência do sinal adquirido <i>Eddy Current</i> (EC) e seu <i>Wavelet Power Spectrum</i> (WPS).	84
37	Gráfico da relação de aquisição sinal x GPS	85
38	Relatório Final	85
39	Aquisição de amostras de forma manual	87
40	Sinal adquirido com veículo rodoferroviário em detalhes, a) Sinal original, b) Sinal indicado no sinal original com um círculo e c) Detalhe do trecho do sinal indicando deslizamentos laterais	87
41	Aquisição com veículo rodoferroviário deslizamentos laterais	88

42	Comparação entre aquisição de sinais. (a) Veículo. (b) Manual. Note que o sinal é similar em ambos os casos.	89
43	Amostras de junta.	90
44	Amostra de junta padronizada.	90
45	Um exemplo do processo de detecção de superfície de trilho. Na parte superior podemos ver um fragmento de sinal de cerca de 134 segundos amostrado em 7,5 kHz, onde o eixo horizontal indica o número da amostra. Os gráficos inferiores são versões de zoom do sinal. No gráfico à direita, o círculo azul indica a localização do registro GPS.	92
46	Estratégia de <i>Cross Validation</i>	93
47	Matriz Confusão para o conjunto de teste em cada dobra para a CNN.	95
48	Dataset utilizado nos métodos comparativos propostos.	97
49	Resultados médios dos métodos após o gridsearching.	98

LISTA DE TABELAS

1	Comparativo entre Correntes Parasitas e Ultrassom na Detecção de Defeitos	42
2	Falhas detectáveis por correntes parasitas [3].	44
3	Resumo e Desvantagens dos Métodos de Identificação de Defeitos em Trilhos	52
4	Total do Conjunto de Amostras	91
5	Quantidade de eventos por classe	93
6	Tabela de Dados - Treinamento por Partição	94
7	Acurácia da CNN para cada conjunto de teste.	96
8	Comparação de Métricas de Desempenho dos Modelos	97
9	Resultados dos Classificadores (%)	99
10	Resumo dos comparativo resultados dos Classificadores e CNN	100

LISTA DE ABREVIATURAS E SIGLAS

ACFM Medição por Campo de Corrente Alternada

ICA Análise de Componentes Independentes

DWT Transformada Discreta Wavelet

ECG Eletrocardiograma

EEG Eletroencefalograma

END Ensaios Não Destrutivos

ANNs *Artificial Neural Networks*

ANTT Agência Nacional de Transportes Terrestres

EC *Eddy Current*

RCF Rolling Contact Fatigue (Desgastes Superficiais em trilhos)

GPS Sistema de Posicionamento Global

SVTS Sistema de Verificação de Trincas Superficiais

CWT Transformada Contínua Wavelet

WPS Espectro de Potência da Wavelet

CNN Rede Neural Convolucional

QDA Análise Discriminante Quadrática

ACFM *Alternating Current Field Measurement*

RNA Rede Neural Artificial

R-CNN *Region-based Convolutional Neural Network*

SSD *Single Shot MultiBox Detector*

YOLO *You Only Look Once*

LRC Classificação de Regressão Logística

WPS *Wavelet Power Spectrum*

NDT Teste Não Destrutivo

IHC Interação Humano Computador

PS Espectro de Potência

VGGNet *Visual Geometry Group Net*

KNN *K-Nearest Neighbors*

QDA *Análise Discriminante Quadrática*

MLP *Multilayer Perceptron*

DT *Decision Tree*

RF *Random Forest*

ET *Extra Trees*

SUMÁRIO

1	INTRODUÇÃO	18
1.1	Contexto e Motivação	19
1.2	Objetivos	22
1.3	Organização da Tese	23
2	CONTEXTUALIZAÇÃO DO PROBLEMA E REVISÃO BIBLIOGRÁFICA	24
		24
		24
		25
2.1	Inspeção e Manutenção Preventiva	26
2.2	Categorias Estruturais em Defeitos Superficiais em Trilhos	27
2.2.1	Squat	27
2.2.2	Soldas	32
2.2.3	Juntas	35
2.2.4	Caracterização Final dos Problemas	39
2.3	Métodos de Inspeção	39
2.3.1	Radiografia Industrial	40
2.3.2	Ensaio por Líquidos Penetrantes	40
2.3.3	Ultrassom	40
2.3.4	Fluxo Magnético	42
2.3.5	Corrente Parasita	43
		44
2.3.6	Medição de Campo CA	44

2.3.7	Laser Ultrassônico	44
2.3.8	Faseamento Ultrassônico	45
2.3.9	Inspeção Visual	46
2.3.10	Partículas Magnéticas	47
2.4	Métodos Recentes de Identificação de Defeitos em Trilhos	48
2.5	Proposta do Trabalho	51
2.5.1	Transformada Contínua Wavelet	53
2.5.2	Rede Neural Convolucional	56
3	SISTEMA EMBARCADO PARA IDENTIFICAÇÃO DE FALHAS SUPERFICIAIS EM TRILHOS DE FERROVIA	59
3.1	Descrição	59
3.1.1	Hardware	63
3.1.2	Diagrama de Blocos das Etapas	65
3.1.3	Interface de Operação	67
3.2	Funcionamento do Sistema	71
3.3	Classificação Offline de Anomalias	73
4	RESULTADOS	86
4.1	Localização de Detecção de Defeitos	91
4.2	Classificação	92
4.2.1	Comparação com outros métodos	96
4.3	Comparação dos Resultados com a Literatura	100
4.3.1	Metodologia	101
4.3.2	Comparações	101
5	CONCLUSÕES E TRABALHOS FUTUROS	105
	Referências	107

1 INTRODUÇÃO

O transporte ferroviário é um dos modos de transporte mais antigos e importantes do mundo, tem sido usado por séculos para transportar mercadorias e pessoas de um lugar para outro. No Brasil, teve um papel fundamental no desenvolvimento econômico, especialmente durante a segunda metade do século XIX e início do século XX. Nos últimos anos, tem sido alvo de atenção por parte do governo, empresas e pesquisadores, com estudos direcionados em suas potencialidades e desafios [4].

O modal ferroviário é responsável pelo transporte de grande volume de mercadorias, desde matérias-primas até produtos acabados. Segundo dados da Agência Nacional de Transportes Terrestres (ANTT) [5], em 2024 foi responsável pelo transporte de mais de 600 milhões de toneladas de cargas, o que representa cerca de 30% do total de cargas transportadas no país, por ser um modo de transporte mais eficiente e econômico para transporte de grandes volumes de mercadorias em longas distâncias [6], contribuindo significativamente para a redução dos custos logísticos. Isso se deve ao fato de que trens transportam grandes volumes de cargas com um consumo menor de combustível comparado a outros modos de transporte.

A utilização do modal ferroviário permite a redução do tráfego de caminhões nas rodovias, contribuindo para a redução dos congestionamentos e do impacto ambiental provocado pela emissão de gases poluentes [7]. Porém, apesar de sua importância, ainda enfrenta muitos desafios, sendo um dos principais a falta de investimentos na infraestrutura ferroviária, visto que grande parte das ferrovias brasileiras ainda é operada com tecnologia obsoleta e com baixa capacidade de carga [8], incluindo linhas ferroviárias abandonadas ou subutilizadas.

A falta de investimentos em tecnologia e inovação é outro desafio para que a logística ferroviária possa se tornar mais eficiente e competitiva. Desta forma, é de vital importância o aporte em tecnologia e sistemas de informação que permitam um maior controle e monitoramento das operações ferroviárias [9].

Nesse contexto, a melhoria da confiabilidade aliada à estratégia logística é crucial para aumentar a velocidade e a produtividade do transporte [10]. Portanto, melhorias tecnológicas nos ativos ferroviários, como locomotivas, vagões, suprimentos de energia, sinalização e via permanente, tornam-se fundamentais [11]. Ativos de via permanente são definidos como o conjunto de camadas e elementos responsáveis pelo suporte dos trens que possibilitam seu deslocamento e têm na sua composição elementos como dormentes, trilhos, britas e demais fixações [12]. Para garantir sua confiabilidade, é necessário realizar inspeções regulares nestes elementos, além da adoção de práticas adequadas em sua construção e manutenção. Os trilhos, por exemplo, precisam ser inspecionados em relação ao desgaste, deformações e trincas para serem substituídos periodicamente [13]. Já os dormentes precisam ser inspecionados quanto a rachaduras, deformações e apodrecimento; britas necessitam ser limpas e recolocadas; fixações devem ser checadas em sua ausência ou quebras.

Para garantir a confiabilidade destes ativos, é necessário um programa adequado de manutenção preventiva e corretiva [14]. Esta última é uma estratégia de manutenção que busca prevenir a ocorrência de falhas ou defeitos em equipamentos e sistemas. No setor ferroviário, ela é essencial para garantir a segurança e a confiabilidade. Uma das áreas mais críticas para a manutenção preventiva é a análise de via, que envolve o monitoramento e a avaliação das condições da via-férrea. Trabalhos como Alvarenga et al.[15] neste sentido tem sido desenvolvidos para auxiliar na prevenção de acidentes com o aumento da confiabilidade.

1.1 CONTEXTO E MOTIVAÇÃO

Uma das metodologias utilizadas na manutenção preventiva é a inspeção por ultrassom, que consiste na checagem não destrutiva dos trilhos, é realizada por meio de um dispositivo que emite ondas sonoras de alta frequência, sendo capaz de detectar defeitos ou anomalias internas como trincas, fissuras e descontinuidades resultando uma técnica eficiente e precisa, porém requer investimentos significativos em equipamentos e treinamento dos operadores [16].

Outra metodologia é a inspeção por meio de correntes parasitas (*eddy current*) baseada na geração de correntes elétricas induzidas em um material condutor, como o trilho, de forma que por meio de um campo magnético variável, estas correntes parasitas geram um campo magnético secundário, cujas variações são monitoradas e analisadas para identificar descontinuidades, trincas, fissuras e outros defeitos superficiais [17].

Nos últimos anos, a pesquisa e o desenvolvimento na área de inspeção por correntes parasitas têm-se concentrado em melhorar a precisão e a velocidade de detecção, além de desenvolver técnicas avançadas de processamento de sinais e algoritmos de inteligência artificial para análise de dados [18]. Este tipo de inspeção tem sido realizada principalmente em componentes como trilhos, soldas e rodas de trens, sendo que a detecção de defeitos em trilhos é de particular importância devido ao elevado risco de falhas catastróficas que podem ocorrer se não forem identificados e tratados a tempo [13]. Portanto, este método tem demonstrado ser uma técnica eficaz para a detecção de trincas transversais em trilhos, incluindo a identificação de defeitos em soldas e áreas de desgaste [19].

Em relação a esta técnica, foram desenvolvidos sistemas automatizados de inspeção para linhas ferroviárias montados em veículos capazes de realizar inspeções em tempo real e em velocidades operacionais que permitem a detecção rápida e eficiente de defeitos e a tomada de decisões sobre a necessidade de intervenção e manutenção [20].

Apesar dos avanços nesta tecnologia, ainda existem desafios a serem superados para melhorar sua eficácia e eficiência. Um dos principais desafios é a calibração dos equipamentos e a interpretação dos sinais obtidos durante a inspeção [21], além disso, a presença de sujeira, corrosão e desgaste na superfície da via podem afetar a precisão e a confiabilidade dos resultados da inspeção [22]. Neste sentido, a pesquisa agregada ao desenvolvimento de novos equipamentos, técnicas de calibração, algoritmos de processamento de sinais e técnicas de inteligência artificial tem o potencial para abordar essas dificuldades e melhorar a aplicação deste método.

Com a implementação de ferramentas avançadas de inteligência artificial, como aprendizado de máquina e redes neurais profundas, estudos têm sido desenvolvidos para melhoria na eficiência e precisão da análise de dados na inspeção por correntes parasitas [23]. Essas ferramentas têm o potencial de automatizar a identificação e a classificação de defeitos, reduzindo a dependência do trabalho manual, melhorando a velocidade e a precisão das detecções. Com o avanço das técnicas de processamento de sinais e de inteligência artificial, *Artificial Neural Networks* (ANNs) e transformadas *wavelet* têm sido empregadas para melhorar a precisão, a eficiência da detecção e classificação de defeitos nas linhas ferroviárias [19, 24, 25], estas últimas são utilizadas para decompor os sinais de correntes parasitas em diferentes níveis de frequência e tempo, permitindo a extração de características distintas dos sinais [19], podendo ser utilizadas na identificação e classificação de diferentes tipos de defeitos nos trilhos. A transformada wavelet é especialmente adequada para a análise de sinais não estacio-

nários e ruidosos, como os sinais de correntes parasitas, proporcionando uma melhor localização no tempo e na frequência em comparação com outras técnicas de análise de sinais [24].

As ANNs são modelos computacionais inspirados no funcionamento do sistema nervoso humano capazes de aprender padrões complexos e não lineares a partir de um conjunto de dados de treinamento e têm atualmente sido aplicadas com sucesso na análise de sinais de correntes parasitas [25] tornando-as adequadas para a detecção e classificação de defeitos em linhas ferroviárias.

Uma abordagem é combinação da transformada wavelet e as redes neurais artificiais para melhorar o desempenho da análise de correntes parasitas. Inicialmente, a transformada wavelet é aplicada aos sinais de correntes parasitas para extrair características relevantes, em seguida estas são usadas como entrada para a rede neural treinada na identificar e classificar diferentes tipos de defeitos nas linhas ferroviárias [19, 24].

Outrossim, técnicas mais avançadas de aprendizado profundo, como as Rede Neural Convolutiva (CNN), têm sido usadas na análise de correntes parasitas em linhas ferroviárias [25]. Estas são capazes de aprender automaticamente características hierárquicas e invariantes a partir dos dados de entrada, eliminando a necessidade da extração manual de características através das transformadas *wavelet* ou outras técnicas de processamento de sinais. Isso resulta um desempenho de detecção e classificação de defeitos superior comparativamente às abordagens tradicionais baseadas em redes neurais e transformadas *wavelet*. Além da técnica proposta, outros métodos de classificação serão utilizados visando efetuar a comparação e validação dos resultados propostos.

Apesar de ser uma técnica eficiente, a inspeção por correntes parasitas apresenta algumas dificuldades que podem afetar sua aplicação na manutenção preditiva, como a suscetibilidade a alterações na permeabilidade magnética, profundidade de penetração limitada, necessidade de interpretação criteriosa dos sinais, sensibilidade a trepidações e irregularidades da superfície a ser inspecionada e calibração rigorosa. De acordo com [26], a calibração é um processo crítico para garantir a precisão e a confiabilidade dos resultados da inspeção por correntes parasitas, pode ser complexo e requerer alto nível de treinamento e experiência do operador.

Outra dificuldade está relacionada à interpretação dos resultados da inspeção, os sinais obtidos durante a inspeção por correntes parasitas podem ser complexos e difíceis de interpretar, segundo [27], a interpretação dos sinais pode ser afetada por fatores como

a forma e a orientação do defeito, a espessura da camada superficial da via, a presença de outras fontes de interferência, sujeira, corrosão e desgaste na superfície da via que poderão afetar a precisão e a confiabilidade dos resultados da inspeção.

Para superar essas dificuldades, são necessários investimentos em tecnologia, treinamento e pesquisa. De acordo com [28, 29], a aplicação da inspeção por correntes parasitas pode ser melhorada com o desenvolvimento de novos equipamentos e técnicas de calibração.

1.2 OBJETIVOS

Dentro deste contexto, o objetivo principal desse trabalho é o desenvolvimento de um sistema para identificação de defeitos superficiais em trilhos ferroviários baseado em correntes superficiais. O sistema desenvolvido propõe um método de monitoramento preventivo para verificação de características e trincas superficiais em linhas ferroviárias, em complementação aos sistemas baseados em ultrassom para detecção de trincas internas, melhorando a assertividade das inspeções periódicas nos trilhos, identificando e localizando trincas superficiais antes que elas possam causar problemas maiores.

Um veículo rodoferroviário, comumente utilizado em manutenção ferroviária, foi equipado com o sistema permitindo inspeções em alta velocidade (até 50 km/h) em longos trechos de linha, mesmo em condições climáticas adversas ou em trilhos contaminados por óleo, ou graxa.

Seu desenvolvimento inclui etapas e atividades de desenvolvimento, como:

1. Desenvolvimento de software para controle e análise, coordenando dados de sondas, sinais GPS (Global Positioning System) e imagens de câmeras.
2. Desenvolvimento de sistemas de acoplamento mecânico para câmeras e sondas, incorporando amortecimento e deslocamento lateral para assegurar a integridade e durabilidade dos componentes.
3. Desenvolvimento de algoritmos de filtragem digital para mitigação de ruídos e melhoraria na qualidade do sinal anterior à análise.
4. Integração dos módulos para operação conjunta do sistema (sondas, GPS e câmeras), possibilitando a localização precisa de falhas e apoio à manutenção preditiva.

O desenvolvimento proposto visa complementar os sistemas de ultrassom existentes, ao introduzir uma nova modalidade de inspeção focada na detecção de características trincas superficiais, apesar de, como dito anteriormente, as técnicas de ultrassom serem amplamente utilizadas para a detecção de trincas internas em linhas ferroviárias [30]. No entanto, a técnica de ultrassom não é eficaz na identificação de trincas superficiais [31], o sistema proposto aborda essa lacuna ao combinar a detecção de trincas internas e superficiais, melhorando a eficiência das inspeções periódicas e contribuindo para a manutenção preventiva e corretiva das linhas ferroviárias.

A proposta apresenta inovação acadêmica e industrial através da integração de várias tecnologias e etapas de desenvolvimento, incluindo software de controle e análise, sistemas de acoplamento mecânico, algoritmos de filtros digitais e a operação de correntes parasitas, GPS e câmera. Essa abordagem integrada, aplicada em campo mediante testes com especialistas e veículos na área de manutenção, permite a detecção e localização de trincas superficiais e características em condições adversas em velocidades de até 50 km/h, indicando uma melhoria significativa em relação às inspeções manuais e visuais tradicionais [32], melhorando a eficiência das inspeções periódicas.

1.3 ORGANIZAÇÃO DA TESE

No Capítulo 2, é feita a contextualização do problema, quais os tipos de características estruturais a serem detectadas e classificadas no sistema proposto, métodos de inspeção de forma geral e aplicados às ferrovias, definição do método proposto e revisão bibliográfica

No Capítulo 3 é descrito o sistema proposto, ilustrando e explicando o processo de rastreamento com utilização do veículo rodoferroviário, além de apresentar itens inerentes ao desenvolvimento do sistema.

O Capítulo 4 descreve os resultados de detecção, classificação, comparação com outros métodos e trabalhos da literatura, incluindo a metodologia utilizada.

O Capítulo 5 mostra a conclusão indicando avanços relevantes da solução e melhorias pontuadas nos próximos passos.

2 CONTEXTUALIZAÇÃO DO PROBLEMA E REVISÃO BIBLIOGRÁFICA

Dentre vários segmentos existentes para garantir a maior fluidez do transporte ferroviário, a manutenção dos trilhos e seu gerenciamento relacionados às trincas e desgastes superficiais são de extrema importância, uma vez que na ausência de manutenções adequadas ocorrerão paradas improdutivas, problemas de descarrilamento, falhas na sinalização, acidentes com perdas humanas e materiais [33].

Ainda é comum a inspeção de desgastes nos trilhos de forma visual. Desta forma, profundidade e severidades não são avaliadas com precisão devido à subjetividade do avaliador que também é afetada pelo desgaste físico, condições climáticas, etc. Além da baixa produtividade de registros diários, por depender de preenchimento manual em um percurso definido diário de no máximo 10 km, ocorrem retrabalhos para inserção destes dados no sistema de manutenção incluindo problemas de reconhecimento de escritas de anotações em campo [34]. Estes dados gerados pela avaliação, servirão de base para execução de serviços de esmerilhamento (raspagens da camada do trilho com um dispositivo mecânico), levando a situações de correções imprecisas e em muitos casos esmerilhamentos em profundidades desnecessárias, resultando na diminuição da vida útil do trilho e sua substituição em menor tempo, o que acarreta maiores gastos de material, mão de obra e interrupções desnecessárias. De acordo com [35] (Figura 1), os desgastes superficiais representam 50% dos modos de falha em trilhos. A Figura 2 [35] indica o método de correntes parasitas, do inglês *Eddy Current*, como possível solução para identificação deste tipo de falha de forma complementar ao método de ultrassom existente.




Figura 1: Representatividade de falhas em trilhos

[35]




Figura 2: Métodos indicados para detecção de falhas em trilhos

[35]

Este trabalho propõe o desenvolvimento de um sistema automatizado para a detecção e classificação precisa de falhas superficiais em trilhos ferroviários para aprimorar significativamente a assertividade da manutenção, permitindo intervenções mais pontuais e eficientes. Com isso, reduzindo substituições desnecessárias de componentes e otimizando a alocação de mão de obra, resultando em uma gestão mais eficiente

dos recursos com aumento na segurança e disponibilidade da malha ferroviária. Isso é feito com a interpretação da resposta dos sinais de corrente parasita emitidos por sensores acoplados aos veículos rodoferroviários, possibilitando a leitura da camada superficial superior dos trilhos, o conhecimento das características dos desgastes e sua localização. Este método proporciona melhores condições para a antecipação de decisões relacionadas às manutenções e substituições de trilhos, aumentando a segurança e a confiabilidade no transporte de bens, sendo identificado como método não destrutivo por não haver contato direto com o trilho.

2.1 INSPEÇÃO E MANUTENÇÃO PREVENTIVA

A inspeção de estruturas metálicas é uma etapa importante na garantia da integridade, segurança e confiabilidade das estruturas e equipamentos em diversos setores, como na indústria, na construção civil e no setor ferroviário. Neste contexto, os métodos de inspeção não destrutivos (Ensaio Não Destrutivo (END)) são amplamente utilizados para a detecção e monitoramento de defeitos, como trincas, corrosão e desgaste, sem comprometer a integridade das estruturas [36], estes métodos serão detalhados na seção 2.3 .

A segurança e a eficiência da operação ferroviária dependem integralmente de um programa rigoroso de manutenção preventiva. Essa prática, que consiste em identificar e corrigir proativamente falhas e desgastes na infraestrutura, é fundamental para garantir a integridade da via e evitar interrupções no serviço.

Inspeções periódicas e minuciosas em trilhos, dormentes e demais componentes estruturais são de grande importância na detecção precoce de quaisquer anomalias que possam comprometer a segurança da operação [37]. Ao identificar e corrigir esses problemas de forma antecipada, evita-se a ocorrência de acidentes e a degradação acelerada da infraestrutura.

Para uma compreensão mais aprofundada do tema, é necessário analisar os principais desafios enfrentados pela manutenção ferroviária. A partir desse diagnóstico, será possível apresentar as técnicas de inspeção mais adequadas para cada tipo de problema, otimizando os processos e garantindo a confiabilidade do sistema ferroviário.

2.2 CATEGORIAS ESTRUTURAIS EM DEFEITOS SUPERFICIAIS EM TRILHOS

A complexidade da infraestrutura ferroviária exige monitoramento constante para identificar e corrigir diversos tipos de defeitos. Entre as anomalias estruturais mais comuns em trilhos destacam-se os afundamentos (*squat*), problemas nas soldas e as irregularidades nas juntas. As inspeções preventivas visam detectar essas e outras irregularidades, garantindo a segurança e a confiabilidade da via.

Figura 3 ilustra as 3 classes citadas que são: Afundamentos (*squat*), soldas e juntas, comumente encontradas em trilhos. Embora soldas e juntas não representem defeitos superficiais, elas foram incluídas como padrões de referência para permitir a distinção entre esses elementos e os verdadeiros defeitos, otimizando os processos de inspeção e manutenção.




Figura 3: Tipos de anomalias: (a) *Squat*, (b) Solda e (c) Junta

2.2.1 SQUAT

O *squat* é um tipo de defeito estrutural que pode ocorrer em linhas ferroviárias caracterizado pelo desgaste e fadiga dos trilhos, resultando um achatamento no topo do trilho, levando a uma redução em sua altura e, conseqüentemente, a problemas de estabilidade e segurança, como descarrilamentos e acidentes [38]. É causado por esforços cíclicos ocorridos pelo peso e movimento dos trens e estão relacionados à passagem

frequente de trens pesados, curvas acentuadas, inclinações, irregularidades na superfície dos trilhos e condições climáticas adversas. Outros fatores como a qualidade dos materiais e a manutenção inadequada também podem contribuir para a ocorrência. Figura 4.



Figura 4: *Squat*

Seu impacto nas linhas ferroviárias pode ser grave e causar danos significativos à infraestrutura, aumentando os custos de manutenção e reduzindo a vida útil da via. A redução na altura do trilho causada pelo *squat* pode levar a instabilidade na via, elevando o risco de descarrilamentos e acidentes, além disso, acarreta o aumento do desgaste dos rolamentos dos vagões e das rodas dos trens, elevando os custos operacionais e reduzindo a eficiência da operação ferroviária [38].

Sua detecção precoce é um ponto importante na prevenção de danos mais graves e na redução dos custos de manutenção. Tradicionalmente a inspeção visual é a principal forma de detectar defeitos estruturais, incluindo o *squat*. No entanto, esse método é limitado em sua capacidade produtiva, requerendo grande esforço humano, considerando subjetividades na avaliação, bem como iluminação, ambiente hostil, clima, etc, tornando-o caro e demorado [34].

Este defeito aparece predominantemente em áreas planas da superfície do trilho [39] podendo crescer progressivamente, ramificando-se horizontalmente abaixo da superfície, separando-a do corpo do trilho.

Algumas metodologias podem ser utilizadas para identificar o *squat*, como a análise de vibração, a análise de imagem e a monitoramento remoto [40]. A análise de vibração pode ser utilizada analisando a presença do defeito nas mudanças das características

de vibração do trem. A análise de imagem, por sua vez, pode ser usada para detectar em imagens de trilhos capturadas por drones ou câmeras de monitoramento. O monitoramento remoto também pode ser utilizado, permitindo a detecção do defeito a partir de sensores instalados na via. A inspeção por laser é outra técnica utilizada para identificar o *squat* em linhas ferroviárias, nela são analisadas as variações na altura do trilho, utilizando um sistema de varredura a laser. Esta técnica é realizada em tempo real, permitindo a identificação imediata do defeito e a tomada de medidas de reparo.

Independentemente da metodologia utilizada, é importante que a identificação seja realizada de forma precisa e confiável, garantindo a segurança e a eficiência da operação ferroviária. Além disso, a identificação precoce é essencial para prevenir danos mais graves e reduzir os custos de manutenção.

Nos últimos anos, diversas técnicas automatizadas têm sido desenvolvidas para detecção do *squat* em linhas ferroviárias, dentre elas destaca-se o uso de algoritmos de aprendizado de máquina. Em um estudo recente, Kumar et al.[41] realizaram uma revisão sobre o uso de algoritmos de aprendizado de máquina na detecção do *squat*. Os autores destacaram que o uso desta ferramenta tem se mostrado bastante promissor, permitindo uma detecção mais precisa e rápida do defeito.

O processamento de imagens tem se mostrado uma ferramenta eficaz para a detecção de afundamentos (*squat*) em linhas ferroviárias. Qiu et al. [42] propuseram um método que envolve a captura de imagens da via e a aplicação de técnicas de processamento de imagem para identificar regiões com afundamentos. Os resultados obtidos pelos autores demonstram a alta precisão desse método.

Chen et al.[43] realizaram uma revisão sobre técnicas automatizadas para detecção de defeitos em linhas ferroviárias, incluindo o *squat* e destacaram que o uso de técnicas automatizadas tem se mostrado bastante eficiente, permitindo uma detecção mais rápida e precisa de defeitos.

A detecção de afundamentos (*squat*) por meio de aprendizado profundo representa um avanço significativo em relação aos métodos convencionais. Li et al. [44] demonstraram que é possível treinar redes neurais convolucionais para identificar esses defeitos com alta precisão, superando os resultados obtidos por técnicas tradicionais de processamento de imagens.

Singh et al.[45] desenvolveram um sistema de detecção baseado em sensores para identificação do *squat* em linhas ferroviárias, este consiste em instalar sensores na linha ferroviária para capturar informações sobre a deformação do trilho. desta forma

mostraram a capacidade de detecção com alta precisão, permitindo o conhecimento precoce do defeito.

Um estudo publicado em 2020 por Han et al.[46] propôs uma abordagem de detecção do *squat* em linhas ferroviárias baseada em CNNs. A abordagem utilizou imagens de alta resolução dos trilhos e foi capaz de detectar com precisão em diferentes condições ambientais, contribuindo com alta precisão e em tempo real, tornando a abordagem adequada para aplicações em larga escala.

Outro estudo recente, publicado por Huang et al.[47], propôs uma abordagem de detecção baseada em aprendizado de máquina. A abordagem utilizou dados de sensores instalados nos trilhos e foi capaz de detectar com alta precisão e em tempo real. Esta solução permitiu a detecção precoce, reduziu os custos de manutenção e melhorou a eficiência da operação ferroviária.

Um estudo realizado por Li et al.[48] propôs uma abordagem de detecção do *squat* baseada em imagens térmicas. Esta abordagem utilizou imagens térmicas dos trilhos e foi capaz de detectar com alta precisão mesmo em condições adversas, como chuva e neve. Esta técnica permitiu a detecção precoce, reduziu os custos de manutenção e melhorou a eficiência da operação ferroviária.

Uma abordagem baseada em inspeção por correntes parasitas foi proposta por Li et al.[44] que utilizou sensores de corrente parasita e foi capaz de identificar o defeito com alta precisão e em tempo real.

Um estudo publicado por Zhang et al.[49], propôs uma abordagem baseada em técnicas de inteligência artificial e análise de vibração utilizando dados de sensores de vibração instalados nos trilhos e foi capaz de fazer a detecção com alta precisão e em tempo real.

O trabalho Zhao et al.[50] propôs uma abordagem com a aplicação de ultrassom e análise de imagem usando aprendizado de máquina sendo capaz de identificar o defeito com alta precisão e em tempo real.

O trabalho Liu et al.[51] propôs o uso de aprendizado de máquina para a detecção do *squat* através de dados de sensores de corrente parasita instalados nos trilhos e foi capaz de detectar com alta precisão e em tempo real permitindo que o sistema aprendesse e se adaptasse a novos tipos de defeitos, tornando sua aplicação mais robusta e eficiente.

Em Wang et al.[52] foi proposta a detecção com o uso da análise de vibração e ANNs com sensores de vibração instalados nos trilhos sendo capaz de detectar o *squat*

com alta precisão e em tempo real.

Em relação à detecção de *squats*, conforme referenciado nos trabalhos acima expostos, este trabalho propõe uma nova metodologia que integra análise de corrente parasita (EC) com visão computacional para a detecção de *squats* em linhas ferroviárias. Essa combinação estratégica visa unir a capacidade de detecção não destrutiva da corrente parasita com o poder de identificação e classificação precisa da visão computacional, resultando em um sistema de inspeção robusto e eficiente.

Diferentemente de métodos que podem ter dificuldades em distinguir *squats* de outros defeitos como soldas ou juntas, a integração da visão computacional com EC permite uma identificação altamente precisa desta anomalia. A aplicação de visão computacional na análise de padrões visuais, reduzem significativamente os falsos alarmes frequentemente encontrados em sistemas puramente baseados em sensores, como os de vibração Wang et al.[49, 52] ou ultrassom Zhao et al.[50] traduzindo em um sistema mais confiável e menos propenso a interrupções desnecessárias na operação.

A natureza da inspeção por correntes parasitas, aliada à visão computacional, permite a detecção de falhas nos trilhos de forma não destrutiva e sem contato direto, contrastando com métodos necessitam de instalação de sensores físicos no trilho Singh et al.[45] ou contato direto para medição. A ausência de contato simplifica a operação e reduz o desgaste do equipamento de inspeção.

Algumas abordagens descritas podem ser sensíveis a variações ambientais ou de velocidade, a proposta de integração de EC e visão computacional, aliada à inteligência artificial, oferece maior adaptabilidade a diferentes condições de operação, como velocidade do trem e temperatura dos trilhos. O algoritmo da solução proposta disponibilizou uma ampla gama de dados para o treinamento do modelo de visão computacional, tornando o sistema mais robusto e eficiente do que aqueles baseados em uma única modalidade de sensor (e.g., termografia Li et al.[48]) ou processamento de imagem que pode ser afetado por iluminação Qiu et al.[42]. A utilização de inteligência artificial permite que o sistema aprenda e se adapte a novos tipos de defeitos ao longo do tempo, superando a rigidez de sistemas predefinidos.

O trabalho de Zhang et al. (2019) Zhang et al.[23] que propôs uma abordagem similar baseada em análise de imagem e inteligência artificial para detecção e classificação de defeitos, incluindo o *squat*, serve como um precedente que valida a promessa dessa integração. No entanto, o trabalho proposto se distingue pela exploração mais aprofundada da sinergia entre corrente parasita para detecção de anomalias internas e

visão computacional para caracterização superficial e contextualização, otimizando a acurácia e a robustez.

Embora a abordagem de análise inteligente utilizando corrente parasita e visão computacional apresente vantagens significativas em relação às abordagens existentes, ainda existem desafios a serem superados, sendo um dos principais desafios a necessidade de dados de treinamento de alta qualidade para os algoritmos de aprendizado de máquina e processamento de imagem, sendo necessário coletar e rotular grandes volumes de dados de diferentes condições de operação para garantir a precisão e a eficiência da detecção.

Outro desafio é a necessidade de equipamentos especializados para a coleta de dados, como sensores de corrente parasita e câmeras de alta resolução, que podem ser caros e requerem manutenção constante, o que pode limitar a aplicabilidade da abordagem em larga escala.

2.2.2 SOLDAS

Soldas são elementos estruturais fundamentais em linhas ferroviárias, possibilitam a união de trilhos de diferentes comprimentos e a continuidade da via. no entanto, podem causar problemas significativos, como falhas estruturais, desgaste excessivo e fadiga dos trilhos, impactando negativamente na segurança e na eficiência da operação ferroviária [53].

As falhas estruturais nas soldas podem ocorrer devido a uma série de fatores como a má qualidade do material, má execução da solda, excesso de tensão na solda e presença de defeitos pré-existentes nos trilhos. Essas falhas podem levar a problemas de estabilidade e segurança, aumentando o risco de descarrilamentos e acidentes, além de causar danos significativos nos componentes do trem, como eixos e rodas [54].

O desgaste excessivo e a fadiga dos trilhos nas áreas próximas às soldas também são problemas comuns em linhas ferroviárias, ocorrem pelo fato das soldas gerarem concentrações de tensão nos trilhos, aumentando o risco de desgaste e fadiga, que é especialmente preocupante, pois podem levar à formação de trincas e ao eventual colapso do trilho.

Além dos problemas estruturais, podem gerar problemas de manutenção e de gestão da via, uma vez que são pontos críticos na via que requerem manutenção regular e cuidadosa.

Para mitigar os problemas causados pelas soldas, diversas técnicas têm sido propostas e desenvolvidas nos últimos anos [55]. Uma das principais abordagens é o uso de soldas de alta qualidade e a execução cuidadosa da soldagem, garantindo a integridade e a resistência. Técnicas de monitoramento de longo prazo, como a inspeção por correntes parasitas e a análise de vibração, podem ser utilizadas para detectar problemas precocemente e permitir a realização de intervenções de manutenção preventiva.

O uso de técnicas de manutenção e gestão da via mais eficientes e precisas permitem a detecção precoce de problemas nas soldas, como trincas, corrosão e deformações. Assim, são considerados o uso de tecnologias avançadas de inspeção e monitoramento, a implementação de sistemas de gestão da via baseados em dados e a utilização de modelos de previsão de desempenho no planejamento de intervenções em manutenção de forma precisa e oportuna [56].

Uma das principais metodologias utilizadas para a identificação automática de soldas em linhas ferroviárias é a inspeção visual, ela consiste na observação direta dos trilhos por um inspetor que identifica as soldas por meio da aparência das junções dos trilhos. Embora seja uma técnica simples e de baixo custo, é limitada pela precisão, subjetividade do inspetor e baixa produtividade.

Outra técnica utilizada para a identificação automática de soldas é a inspeção por correntes parasitas baseada no princípio de que a presença de uma solda gera perturbações no campo magnético da via e detecta perturbações no campo magnético causadas pela solda, possibilitando a identificação automática da localização e das características das soldas, além da detecção precoce de problemas estruturais, otimizando as ações de manutenção [57].

A identificação automática de soldas em linhas ferroviárias apresenta diversas vantagens em relação às técnicas tradicionais de inspeção visual. Primeiramente, a identificação automática permite a detecção precoce de problemas estruturais, aumentando a segurança e a eficiência da operação ferroviária. Em consequência disso, possibilita a realização de intervenções de manutenção de forma mais precisa e eficiente, reduzindo os custos e os impactos na operação ferroviária. Por fim, possibilita a implementação de estratégias de gestão da via mais eficientes e baseadas em dados[58].

Apesar das vantagens, a identificação automática de soldas apresenta desafios e limitações. Por exemplo, a implementação de sistemas automatizados de inspeção requer investimentos significativos em equipamentos e infraestrutura, além de exigir a capacitação de profissionais qualificados para a análise e interpretação dos dados obtidos.

Além disso, outros fatores que podem causar interferência são fatores externos como condições climáticas adversas e interferências eletromagnéticas, incidindo na precisão e na confiabilidade dos resultados [59].

Ao longo das últimas décadas, diversos trabalhos acadêmicos têm sido desenvolvidos para aprimorar as metodologias utilizadas para a identificação automática de soldas em linhas ferroviárias.

Um estudo conduzido por Li et al.[60] propôs um método de detecção automática de soldas baseado em análise de imagens capturadas dos trilhos por meio de uma câmera seguida da aplicação de técnicas de processamento de imagem para identificar as soldas. Os resultados obtidos demonstraram a eficácia do método proposto, permitindo a detecção automática de soldas com uma taxa de precisão de 98,6%.

Outro estudo conduzido por Kim et al.[61] propôs um método de detecção automática de soldas usando imagens na captura de dados por câmeras instalados no trem seguida da aplicação de técnicas de aprendizado de máquina para identificação. Os resultados obtidos demonstraram a eficácia do método proposto de detecção com uma taxa de precisão de 96,7%.

Um estudo conduzido por Wang et al.[62] mostra uma técnica de detecção automática de soldas com a aplicação de correntes parasitas através da instalação de sondas no trem para detecção de sinais, seguida da análise dos sinais capturados. Os resultados obtidos demonstraram a eficácia do método proposto, permitindo a detecção automática de soldas com uma taxa de precisão de 98%.

Zhang et al.[63] mostra uma solução de detecção automática de soldas baseado na análise de vibrações capturadas por sensores de vibração instalados no trem, seguida da aplicação de técnicas de processamento de sinais para identificar as soldas. Os resultados obtidos demonstraram a eficácia do método proposto, propiciando a detecção automática de soldas com uma taxa de precisão de 95,8%.

Em geral, os estudos destacam a importância da identificação automática de soldas para a manutenção preventiva da via, permitindo a detecção precoce de problemas estruturais e a realização de intervenções de manutenção de forma mais eficiente e precisa. Além disso, os trabalhos ressaltam que a identificação automática de soldas pode reduzir o tempo e os custos associados à manutenção, uma vez que as intervenções podem ser programadas com antecedência, evitando interrupções inesperadas na operação das linhas ferroviárias.

Outro aspecto importante ressaltado pelos estudos é a possibilidade de mapeamento das soldas ao longo da via que auxilia na gestão e manutenção das linhas ferroviárias. Com a identificação automática das soldas, é possível registrar a localização exata de cada solda na via e acompanhar seu estado de conservação ao longo do, o que acarreta a realização de intervenções preventivas em soldas que apresentem um maior risco de falha, reduzindo o tempo e os custos associados à manutenção corretiva além de contribuir para o desenvolvimento de novas técnicas de fabricação, instalação de soldas mais resistentes e duráveis.

2.2.3 JUNTAS

As juntas são elementos estruturais importantes em linhas ferroviárias, responsáveis por conectar segmentos de trilhos e permitir a expansão e contração térmica dos trilhos de forma controlada, no entanto, podem gerar problemas significativos em termos de segurança e manutenção.

Um dos principais problemas associados às juntas é a possibilidade de fadiga estrutural e rachaduras nos trilhos próximos às juntas, a movimentação dos trilhos em relação às juntas pode causar ciclos de tensão e deformação que levam à fadiga do material e eventualmente ao surgimento de rachaduras e trincas que podem prejudicar a estabilidade e a segurança das linhas ferroviárias, aumentando o risco de descarrilamentos e acidentes [64].

Além disso, geram problemas de manutenção, já que esses elementos sofrem desgastes com o tempo e precisam ser substituídos periodicamente. Sua substituição pode ser uma operação complexa e demorada, envolvendo a interrupção da operação das linhas ferroviárias e a mobilização de várias equipes especializadas [65].

Outro problema associado às juntas é a possibilidade de afrouxamento dos parafusos de fixação dos trilhos, prejudicando sua estabilidade e levando ao surgimento de defeitos como deformações e desalinhamentos. O monitoramento constante dos parafusos e a manutenção preventiva são, portanto, essenciais para garantir a segurança e a eficiência das linhas ferroviárias.

Para lidar com esses problemas, têm sido desenvolvidas diversas metodologias para a identificação e a manutenção das juntas nas linhas ferroviárias [66], [67] e [68]. Uma das abordagens mais comuns é a utilização de técnicas de inspeção automatizada, que como os demais itens estruturais, permitem a identificação precoce de defeitos e a realização de intervenções preventivas, estas técnicas incluem o uso de sensores de

vibração para monitorar a integridade dos trilhos, câmeras para detectar deformações e desalinhamentos como também técnicas de análise de imagem para identificação de trincas e rachaduras.

Técnicas no aprimoramento, fabricação e instalação das juntas nas linhas ferroviárias são realizadas no sentido de aumentar a durabilidade e a resistência das juntas, reduzindo a necessidade de manutenção e intervenções corretivas [66].

Uma das técnicas utilizadas para a identificação de defeitos em juntas ferroviárias é a inspeção visual, onde um operador humano realiza uma inspeção visual com intuito de identificar desalinhamentos, trincas e deformações. Trata-se de técnica mais antiga e ainda muito utilizada em todo o mundo, no entanto, sua eficácia é limitada devido à subjetividade dos operadores e às limitações na detecção de defeitos menores.

Para superar as limitações da inspeção visual, técnicas de inspeção automatizada têm sido criadas com a utilização de sensores, algoritmos de processamento de imagem e de detecção de anomalias para identificação. Um exemplo é a utilização de sensores de vibração instalados nos trilhos, que identificam anomalias nas juntas por meio da análise da vibração dos trilhos, sendo capaz de detectar defeitos como desalinhamentos, deformações e trincas com alta taxa de precisão.

Outra técnica utilizada para a identificação de defeitos em juntas é a análise de imagem com a utilização de câmeras de alta resolução para captar imagens das juntas e em seguida processá-las com algoritmos de detecção de defeitos para identificar trincas, rachaduras e outros defeitos nas juntas. Essa técnica tem se mostrado eficaz na detecção de defeitos menores nas juntas, além de poder ser utilizada em conjunto com outras técnicas, como a análise de vibração na obtenção de uma detecção mais precisa.

Outra técnica utilizada para a identificação de defeitos em juntas ferroviárias é a análise de imagem, nela são empregadas câmeras de alta resolução para captura de imagens detalhadas das juntas e, subsequentemente, processá-las com algoritmos de detecção de defeitos com objetivo de identificar precisamente trincas, rachaduras e outras anomalias.

Diversos trabalhos têm demonstrado a eficácia dessa abordagem. Por exemplo, Al-Sayed et al.[69] exploraram métodos de processamento de imagem e aprendizado de máquina para a classificação automatizada de defeitos em soldas de trilhos. No âmbito da inspeção em movimento, Roney et al.[70] desenvolveram um sistema de visão por máquina para inspeção automatizada de talas de junção a partir de veículos ferroviários, utilizando câmeras de alta resolução para identificar rachaduras por fadiga e parafusos

ausentes. Além disso, Cheng et al.[71] descreveram um sistema de imagem de talas de juntas que capta imagens detalhadas das talas, parafusos e folgas, empregando algoritmos para detectar exceções de segurança como trincas e parafusos perdidos.

Essa técnica tem se mostrado eficaz na detecção de defeitos menores nas juntas, oferecendo diversas vantagens como:

- **Não invasiva e sem contato:** Permite a inspeção a partir de veículos em movimento, sem necessidade de interrupção direta da operação.
- **Alta velocidade:** Possibilita a cobertura de grandes extensões de via em menor tempo.
- **Objetividade e consistência:** Elimina a subjetividade e a fadiga associadas à inspeção manual.
- **Registro e rastreamento:** As imagens podem ser arquivadas para análises futuras e para monitorar a progressão dos defeitos ao longo do tempo.
- **Segurança aprimorada:** Reduz a exposição de equipes de inspeção a riscos na via.

Contudo, a análise de imagem também apresenta algumas desvantagens:

- **Sensibilidade a condições ambientais:** O desempenho pode ser afetado por iluminação inadequada (sombras, brilho excessivo), chuva, neve, sujeira e detritos.
- **Limitação a defeitos superficiais:** A técnica é mais eficaz para defeitos visíveis na superfície e pode não detectar falhas internas. **Exigência computacional:** O processamento de grandes volumes de imagens de alta resolução requer capacidade computacional e armazenamento significativos.
- **Oclusão:** Defeitos podem ser mascarados por outros componentes ou obstruções na imagem.

Apesar das desvantagens, a análise de imagem pode ser utilizada em conjunto com outras técnicas, como a análise de vibração, para obter uma detecção mais precisa e abrangente dos defeitos em juntas.

Tecnologias baseadas em algoritmos de processamento de sinais, buscam identificar anomalias nas leituras dos sensores instalados nos trilhos, tendo capacidade de detecção

em tempo real e de serem utilizadas em conjunto com outras técnicas, como a análise de imagem na detecção mais precisa.

Técnicas de simulação e modelagem computacional são outra abordagem que tem sido adotadas para a identificação de juntas, elas consistem na criação de modelos computacionais e realização de simulações numéricas na análise do comportamento mecânico destas sob diferentes condições, tais como variações de temperatura, cargas e desgaste. Com base nas informações obtidas nas simulações, é possível identificar pontos críticos e possíveis defeitos nas juntas.

Além das técnicas citadas acima, novos materiais e processos de fabricação têm sido desenvolvidos para melhorar a qualidade e durabilidade das juntas [72]. Um exemplo disso é o uso de materiais compostos, como polímeros reforçados com fibra de carbono, para substituir as juntas de aço tradicionais, pois esses materiais oferecem maior resistência à fadiga e à corrosão, resultando uma vida útil mais longa.

Dentre os trabalhos acadêmicos recentes, podemos destacar a pesquisa de Chen et al. [73], que propõe um método de detecção de desalinhamento em juntas ferroviárias utilizando uma câmera de alta velocidade e algoritmos de processamento de imagem. Os resultados experimentais mostraram que a abordagem proposta é capaz de identificar com precisão o desalinhamento das juntas.

Outro estudo recente, Chen et al. [74] propõe uma abordagem baseada em aprendizado de máquina para a detecção automática de defeitos em juntas de trilhos ferroviários. A técnica proposta utiliza imagens de alta resolução para a identificação de trincas, rachaduras e outros defeitos nas juntas. Os resultados experimentais mostraram que a abordagem proposta apresenta uma alta taxa de precisão e pode ser utilizada para a detecção precoce de defeitos em juntas.

Li et al.[75] utiliza uma combinação de sensores de vibração e técnicas de processamento de sinais para a identificação de defeitos em juntas ferroviárias que é capaz de identificar de forma precisa e eficiente defeitos como desalinhamentos, deformações e trincas nas juntas. Os resultados experimentais mostraram que a abordagem proposta é capaz de detectar com sucesso defeitos em juntas de trilhos em tempo real.

A utilização de técnicas de simulação e modelagem computacional também têm se mostrado úteis para a identificação de problemas em juntas ferroviárias. O estudo apresentado em Sun et al.[76] propõe um modelo de simulação numérica para a análise do comportamento mecânico das juntas em linhas ferroviárias que permite a análise de fatores como a tensão e a deformação nas juntas, possibilitando a identificação de

problemas como desalinhamentos e trincas.

2.2.4 CARACTERIZAÇÃO FINAL DOS PROBLEMAS

Embora os dois últimos tipos de estruturas (soldas e juntas) não sejam defeitos superficiais como o '*squat*' e sim características construtivas, conforme citado anteriormente, eles podem ser incluídos como padrões de identificação para possibilitar o mapeamento de pontos de soldas e juntas, para permitir o aumento da eficiência da gestão da manutenção da via.

Além das três categorias principais analisadas neste estudo – 'juntas', 'soldas' e '*squat*' – foi incluída uma quarta categoria denominada 'ruído'. Esta categoria adicional abrange esmerilamentos e outras anomalias (desgastes) menos frequentes encontradas no campo de localização utilizado. A inclusão desta categoria é essencial para uma análise mais abrangente e precisa das condições dos trilhos, que incluem defeitos superficiais e irregularidades, embora menos comuns, podem impactar significativamente a integridade e a segurança da via férrea causadas por diferentes tipos de defeitos. Assim, a inclusão da categoria 'ruído' proporcionará uma visão mais completa e detalhada do estado dos trilhos pelo fato de abranger outros tipos de anomalias que futuramente possam ser categorizados, indicando problemas a serem sanados, contribuindo para a manutenção preventiva e a segurança operacional.

A detecção e classificação desses itens é uma tarefa desafiadora, porém essencial na garantia da segurança e eficiência da operação ferroviária.

2.3 MÉTODOS DE INSPEÇÃO

Existem diversas metodologias de manutenção preventiva disponíveis que podem ser utilizadas nas vias ferroviárias, cada uma delas apresenta vantagens e desvantagens, de forma que devem ser escolhidas conforme as características da via e as condições de operação. Em resumo, a escolha da metodologia mais adequada para identificar os principais problemas nas vias ferroviárias deve levar em conta as características da via e as condições de operação. Nas próximas seções serão mostrados em detalhes as características de cada problema e em seguida as principais técnicas de inspeção utilizadas nas ferrovias

2.3.1 RADIOGRAFIA INDUSTRIAL

A radiografia industrial é uma técnica END utilizada na inspeção de estruturas metálicas, baseada na absorção diferencial de radiação ionizante pelos materiais [77], que consiste no posicionamento de um filme radiográfico atrás da estrutura e posteriormente, expô-la à radiação ionizante, geralmente raios-x ou gama. Os defeitos no material, como trincas ou inclusões, causam variações na absorção da radiação resultando em diferentes densidades no filme radiográfico, é especialmente útil na detecção de defeitos internos e em áreas de difícil acesso, mas requer medidas de segurança rigorosas devido à radiação ionizante [78].

2.3.2 ENSAIO POR LÍQUIDOS PENETRANTES

Trata-se de um método END simples e eficiente para a detecção de descontinuidades superficiais abertas, como trincas, poros e dobras, em materiais não porosos, incluindo materiais metálicos [79]. A técnica consiste na aplicação de um líquido penetrante na superfície da estrutura, que penetra nas descontinuidades por ação capilar. Após um período definido, o excesso de líquido é removido e um revelador é aplicado que absorve o líquido penetrante das descontinuidades, tornando-as visíveis a olho nu ou sob luz ultravioleta. Este método é amplamente utilizado devido à sua simplicidade, baixo custo e alta sensibilidade para a detecção de defeitos superficiais [80]. Esta técnica aplicada em trilhos mostra as falhas após aplicação do líquido seguido da retirada do excesso permitindo [81] sua visualização. Embora o método de inspeção não destrutivo mais adotado em ferrovias seja o teste ultrassônico, a inspeção por líquido penetrante utilizando penetrantes visíveis é ideal para o exame de falhas identificadas, tanto antes quanto após a ação corretiva ser tomada. Neste sentido, outros métodos também podem ser utilizados para este tipo de inspeção.

2.3.3 ULTRASSOM

Este método propõe a identificação de falhas internas nos trilhos através de sondas ultrassônicas convencionais que transmitem ondas mecânicas no interior do trilho e através de sua reflexão ou dispersão, detectados por transdutores, mapeiam as falhas. Esta detecção ocorre através da amplitude das reflexões em função da variação no tempo. Os ângulos das sondas utilizados são 0, 37 ou 45 e 70 graus [3], Figura 5.

Esta técnica não identifica falhas superficiais, portanto deverá ser aplicada em




Figura 5: Ângulos das sondas de ultrassom
[3]

conjunto com outra técnica de forma complementar para cobrir todo o corpo do trilho, como, por exemplo, fluxo magnético ou correntes parasitas. Na Figura 6, são mostradas as regiões no trilho melhor inspecionadas conforme o alcance de métodos distintos (ultrassom e corrente parasita), nela podemos observar que apenas o ultrassom necessita de líquido acoplante e a área de leitura dos 2 métodos são complementares, enquanto em correntes parasitas as leituras são efetuadas próximo à superfície, no ultrassom a leitura se dá em áreas mais profundas. Já na Tabela 1, são descritas as atividades complementares destes métodos.

Este método é utilizado atualmente na MRS Logística SA [82] através do veículo rodoferroviário RD-33 (Figura 7). Esta atividade viabiliza a vistoria de quilômetros de linhas em velocidades de até 40 km/h com precisão ideal para a manutenção em níveis internacionais de segurança, possibilitando a prevenção de acidentes e redução de problemas decorrentes de falhas nos trilhos.




Figura 6: Regiões de alcance Ultrassom x Correntes Parasitas
[83]

Tabela 1: Comparativo entre Correntes Parasitas e Ultrassom na Detecção de Defeitos

Correntes Parasitas	Ultrassom
Boa capacidade de detecção de defeitos superficiais	Baixa capacidade de detectar defeitos de superfície
Capacidade razoável de detectar defeitos logo abaixo da superfície	Pequena capacidade para detectar defeitos logo abaixo da superfície
Impossibilidade de detectar defeitos profundos	Alta capacidade para detectar defeitos profundos
Sensores menos sensíveis à orientação da falha	Sinal de retorno muito dependente da orientação da falha
Não é necessário acoplante, resultados são estáveis	Necessidade de acoplante entre o sensor e o material inspecionado ocasionando variação de resultados
Alta velocidade de inspeção	Baixa velocidade de inspeção



Figura 7: Veículo de inspeção por Ultrassom RD-33
[82]

2.3.4 FLUXO MAGNÉTICO

O ensaio por partículas magnéticas é um método END utilizado na detecção de descontinuidades superficiais e subsuperficiais em materiais ferromagnéticos [84]. A técnica consiste na aplicação de um campo magnético na estrutura, utilizando ímãs permanentes ou correntes elétricas. Quando há um defeito na superfície do material, o campo magnético é distorcido, gerando um vazamento de fluxo magnético, desta forma as partículas magnéticas aplicadas à superfície são atraídas para a área do vazamento, formando um padrão visível, pelo fato das partículas serem fluorescentes (área verde da imagem), indicando a presença do defeito. Este método é rápido e de baixo custo, mas sua aplicação é limitada a materiais ferromagnéticos [85].

Em [86] é mostrado um sistema utilizando este método no qual é possível detectar as falhas de superfície nas rodas do trem, Figura 8. Este sistema inclui uma câmera digital para efetuar a varredura da superfície com a utilização de algoritmos de processamento de imagem digital. Neste caso, a detecção é feita em falhas no comprimento de 1 mm e espessura (largura) de 0,3 mm sendo totalmente automático e é capaz de detectar e classificar falhas com sucesso.




Figura 8: Teste em rodas utilizando fluxo magnético [86]

2.3.5 CORRENTE PARASITA

O ensaio por correntes parasitas é um método END baseado na indução de correntes elétricas na superfície de materiais condutores. Por meio de um campo magnético variável gerado por uma bobina [17], as correntes parasitas induzidas geram um campo magnético secundário, cujas variações são afetadas pela presença de defeitos ou variações na condutividade do material. A análise das variações do campo magnético secundário permite a detecção de descontinuidades superficiais e subsuperficiais, bem como a medição da espessura de revestimentos e a caracterização das propriedades do material. O ensaio por correntes parasitas é amplamente utilizado devido à sua alta sensibilidade, capacidade de inspeção em tempo real e aplicação em materiais ferromagnéticos e não ferromagnéticos [18, 87, 88, 89].

Recentemente foram desenvolvidos sistemas de detecção mediante correntes superficiais que indicam a presença de fissuras superficiais em trilhos através da alteração no valor dos campos magnéticos. Ao contrário da detecção por correntes superficiais (imagem ao lado, os sensores ultrassônicos padrão possuem pouca capacidade de detecção em defeitos próximos à superfície. Quase todos os defeitos de superfície podem ser detectados usando o método de inspeção de correntes superficiais[3].

A Tabela 2 [3] indica as falhas superficiais detectáveis através da inspeção com sensores de correntes superficiais, demonstrando como é complementar em relação ao teste de ultrassom.

Tabela 2: Falhas detectáveis por correntes parasitas [3].

Falha	Detectabilidade	Verificação
Topo trilho	Muito boa	Quantidade, localização e profundidade
Amassamento	Boa	Quantidade e localização
Recortes	Muito boa	Quantidade, localização e período
Queimaduras de rodas	Muito boa	Localização e extensão
Corrugações	Boa	Localização e período
Marcas de moagem	Muito boa	Quantidade, localização e período
Soldas	Boa	Localização, tipo e falta de fusão
Juntas	Muito boa	Localização, tipo

Como indicado em [3], o posicionamento das sondas para evitar flutuações devido ao levantamento da superfície de teste é muito importante, sendo o teste de inspeção de trilho especialmente complexo, uma vez que a sonda deve ser posicionada para cobrir toda a superfície para que a análise cubra toda área de interesse.

2.3.6 MEDIÇÃO DE CAMPO CA

As sondas *Alternating Current Field Measurement* (ACFM) se apresentam em [3] como tipo lápis padrão, Figura 9, ou sondas elementos múltiplos que podem ser personalizadas para otimizar a inspeção de componentes estruturais e maximizar a Probabilidade de Detecção (PoD) de defeitos de tamanho crítico. As sondas de lápis, detectam quebra de superfície em qualquer orientação, porém necessitam ficar entre 0° - 30° e 60° - 90° na direção do curso da sonda, esta desvantagem é superada quando são incorporados vários indutores de campo na superfície inspecionada em outras orientações. Esta situação é desejável em casos onde a falha tem características desconhecidas. Juntamente com os indutores adicionados, sensores adicionais são também incorporados para aproveitar ao máximo as direções adicionais do campo de entrada.

2.3.7 LASER ULTRASSÔNICO

Decross et al.[3] mostra que a Transportation Technology Center Inc. (TTCI) juntamente com a Tecnogamma implantou o primeiro sistema de ultrassom a laser para inspeção de trilhos em 2008, Figura 10(a), os testes preliminares mostraram que



Figura 9: Sonda Lápis ACFM
[90]

esta técnica pode ser usada em inspeções de seção inteira do trilho incluindo o boleto do trilho Figura 10 (c). O sistema é transportado em um veículo rodoferroviário, Figura 10(b), e pode operar a velocidades de até 32 km/h, contudo, a velocidade de inspeção ótima fica entre 8 km/h e 15 km/h. Nos testes foram observados que a taxa de detecção ainda não parece satisfatória e o custo do sistema é muito alto.




Figura 10: Implantação da técnica - Laser Ultrassônico (a) Visão geral do sistema (b) Transporte do sistema em veículo rodoferroviário (c) Inspeções de seção inteira do trilho incluindo o boleto do trilho

[3]

2.3.8 FASEAMENTO ULTRASSÔNICO

Em Fard et al. [91] é mostrado que para sistemas baseados em ultrassom a focagem eletrônica é uma vantagem, pois permite otimizar a forma e tamanho do feixe no local de descontinuidade esperado. [91] indica que as sondas são instaladas estaticamente

ao longo do lado do trilho e uma varredura completa da estrutura pode ser realizada em poucos segundos. Este método, por ter foco direcionado, aumenta a energia do raio, possibilitando a detecção de defeitos em partes mais profundas das soldas e ao escanear com o feixe focado ao longo de toda a falha, o comprimento transversal da mesma pode ser identificado. O Transportation Technology Center Inc.[92] relatou o uso viável deste método na detecção de defeitos transversais e na base do trilho, fornecendo uma inspeção bastante precisa do tamanho da falha através do trilho, porém são mais caros em termos de investimento inicial. Isso se deve à complexidade da tecnologia, que envolve múltiplos elementos transdutores, eletrônica sofisticada para controle de feixe e softwares avançados para aquisição e análise de dados. Para inspeção de trilhos, sistemas automatizados montados em veículos são particularmente complexos e, portanto, de alto custo.

2.3.9 INSPEÇÃO VISUAL

Como apresentado em [93], programas para automatizar a inspeção visual com câmeras acopladas em veículos rodoferroviários indicando localização e geometria começaram a substituir a inspeção de ativos manual. Serviços de Informação gerenciam a captura, análise e relatórios. Em [94], é descrito um novo sistema de inspeção visual de juntas em velocidades de até 112 km/h. O equipamento é montado com 4 câmeras montadas em um veículo ferroviário com objetivo de captar continuamente imagens de alta resolução de ambos os lados de cada trilho. Um sistema computacional de bordo analisa essas imagens em tempo real para detectar as juntas, cada imagem da barra de junção é analisada automaticamente pelo código do sistema, quanto existirem rachaduras visíveis por fadiga, conforme Figura 11, podendo também ser analisadas em busca de parafusos e outros defeitos. Ao detectar um defeito em potencial, o sistema emite aviso de áudio, marca a imagem com a posição GPS e exibe a imagem da barra de junção com defeitos destacados no tela, o operador pode confirmar ou rejeitar defeitos. No fim da inspeção, o operador pode gerar um relatório de pesquisa com a barra de localização GPS comum e os tipos de todos os defeitos. [94] concluiu que após testes em campo, o sistema provou que as trincas foram detectadas com taxas de falso alarme baixas (29% de detecções de possíveis rachaduras não foram confirmadas como rachaduras reais), porém o sistema ainda tem uma taxa relativamente alta de rachaduras não detectadas (15%).




Figura 11: Detecção de trinca em barra de junção
[94]

Em Xiong et al.[95] é apresentada uma técnica de escaneamento 3D com o uso de laser. Após a captura das imagens e a detecção automática de defeitos, é obtida a medição do desvio entre o perfil analisado e o modelo de trilho padrão. Posteriormente, são realizados os cálculos para cada perfil da imagem a laser, desta forma os pontos com grandes desvios são marcados como pontos candidatos a defeito. Neste sentido, um algoritmo adaptativo é proposto para registrar os conjuntos de pontos do perfil medido e do modelo de trilho padrão. A precisão é aprimorada para o nível submilimétrico, em suma, das 422 amostras de 5 tipos de falhas em trilhos utilizadas, 93,78% foram classificados corretamente.

2.3.10 PARTÍCULAS MAGNÉTICAS

Trata-se de uma técnica de ensaio não destrutivo utilizada para detectar descontinuidades superficiais em materiais ferromagnéticos. É comumente utilizada em indústrias que lidam com a fabricação ou manutenção de equipamentos de alta segurança, como as indústrias aeroespaciais, de petróleo e gás, automotiva, ferroviária e naval [96]. O processo de ensaio consiste na aplicação de um campo magnético na superfície do material e na aplicação de partículas magnéticas em pó. As partículas aderem às áreas onde há descontinuidades formando um padrão visível que pode ser facilmente identificado e avaliado pelos técnicos. É uma técnica de alta sensibilidade e precisão, capaz de detectar defeitos muito pequenos, sendo relativamente rápida e de baixo custo, tornando-a uma opção popular para a detecção de defeitos em massa em equipamentos e peças industriais [97].

Conforme Maass et al.[98], este método desempenha um papel importante na produção e manutenção de componentes ferroviários. Estes componentes são inspecionados para verificação de rachaduras na superfície e detecção de defeitos longitudinais (defeitos na direção axial). Willcox et al.[99] demonstra aplicações de testes rotineiros em eixos ferroviários em serviço, detectando qualquer rachadura por fadiga, sendo teste altamente sensível. O equipamento demonstrado é acessível ao eixo para efetuar medidas, mesmo equipado com rodas e possivelmente outros componentes, pois suas bobinas são divididas, sendo capazes de atravessar o eixo até o teste requerido em posições de difícil acesso, evitando retirar componentes montados (Figura 12). Seu uso em trilhos mostra-se pouco prático, uma vez que a aplicação de partículas é manual e seu uso em trilhos em larga escala é impraticável, custoso e moroso.




Figura 12: Teste em eixo utilizando partículas magnéticas
[99]

2.4 MÉTODOS RECENTES DE IDENTIFICAÇÃO DE DEFEITOS EM TRILHOS

Em Kuzman et al.[100], é apresentada uma análise de sinais de correntes superficiais para os 3 casos, a saber: Junta aparafusada de trilhos, soldagem de trilhos por eletrocontato e solda mittovaya em trilhos, as demais características são consideradas a quarta classe, portanto não houve estudo de detecção de desgastes superficiais. Para criar imagens de entrada na CNN, os sinais provenientes de 10 sondas alinhadas no perfil do trilho são convertidos em imagens nomeadas como deflectogramas, que mostram as linhas de intensidade dos sinais de cada canal em diversos tons de cinza. O algoritmo

foi implementado em python utilizando a biblioteca TensorFlow. O resultado dos dados de testes chegaram a 99,45% de precisão, porém o trabalho não mostra aplicações em campo e não trata da construção do sistema de aquisição para implementação em campo. Por fim, conclui-se que a aplicação do modelo de rede neural é bem-sucedido e suficiente para efetuar a tarefa de reconhecimento de elementos estruturais.

Em Cho et al.[101], o autor utilizou sinais de acelerômetros instalados no trem para capturar irregularidades nos trilhos, particularmente neste caso, 34 amostras de *squats* foram coletadas e posteriormente analisadas usando a transformada *wavelet*. Este método permite a identificação e classificação deste tipo de Rolling Contact Fatigue (Desgastes Superficiais em trilhos) (RCF) com uma precisão de previsão de 88,2%. O autor não detalhou o algoritmo utilizado, mas é possível notar a aplicação de métodos de previsão através da transformada *wavelet* em sinais RCF.

O estudo de Delgado-Sotelo et al. (2023) [102] apresenta um método inovador para a classificação automática de fissuras de fadiga de contato por rolamento (RCF) em trilhos ferroviários. Os autores empregaram uma rede neural artificial (Rede Neural Artificial (RNA)) combinada com a técnica de avaliação não destrutiva por correntes parasitas, focando na análise de trincas artificiais de ângulo reto com profundidades variando de 1 a 7 mm em um cupom de calibração de trilho. Os resultados demonstraram que o método foi capaz de compensar eficazmente o enfraquecimento do sinal causado pelo efeito *lift-off* o qual é a distância da sonda para o trilho, permitindo a classificação de trincas mesmo com variações de *lift-off* de até 5,4 mm. Adicionalmente, a pesquisa investigou o impacto da inclinação da trinca nos sinais de correntes parasitas, observando variações nas amplitudes pico a pico entre trincas perpendiculares e anguladas (25 graus), evidenciando a robustez da abordagem proposta na identificação de descontinuidades.

No estudo apresentado por Kwon et al. [103], o autor utilizou um dispositivo de inspeção de corrente parasita de matriz de 16 canais para inspecionar a verificação do cabeçote e os defeitos de casca. Amostras com largura e profundidade conhecidas foram utilizadas para calibrar as sondas e conhecer a profundidade através da correlação com a fase do sinal de corrente parasita obtido pelas sondas divididas em partes reais e imaginárias. Após equalizar a correlação, o sinal 2D foi comparado aos sinais 3D, e foi comprovada uma precisão de + ou - 1 mm. Neste artigo, o autor não menciona detalhes do algoritmo utilizado na comparação, mas mostra o potencial do uso de correntes parasitas como uma possível solução para problemas dessa natureza.

O estudo de Liu et al. (2022) [104] propõe um método de identificação de danos em trilhos ferroviários baseado em aprendizagem profunda, utilizando sinais de vibração coletados por pastilhas cerâmicas piezoelétricas. A metodologia empregada envolve a combinação de múltiplas características dos sinais de vibração, as quais são posteriormente reconstruídas em mapas de tons de cinza para servirem como entrada para uma rede neural convolucional (CNN). Para otimizar o modelo e mitigar o problema de pesos implícitos e tamanhos de entrada variáveis, foi incorporada a técnica de pré-convolução e uma estrutura residual. Os resultados demonstraram que a CNN, ao integrar tanto a pré-convolução quanto a estrutura residual, apresentou uma capacidade superior de reconhecimento da presença de danos nos trilhos em comparação com outros métodos. A precisão do modelo foi notavelmente alta, com apenas 0,003% das amostras classificadas como danificadas sendo, na verdade, não danificadas, o que evidencia um elevado nível de confiança nas previsões de danos. A pesquisa conclui que essa arquitetura de CNN é eficaz, leve e altamente precisa, tornando-a adequada para as exigências contemporâneas da detecção de danos em trilhos.

O estudo de Chen e Yu (2025) [105] propõe uma abordagem inovadora para a reconstrução e classificação de defeitos em aço carbono a partir de sinais de correntes parasitas, utilizando uma rede neural convolucional de valor complexo (CV-CNN). A metodologia empregada capitaliza diretamente as informações de amplitude e fase inerentes aos sinais de impedância de valor complexo, superando as limitações dos métodos tradicionais focados apenas na detecção. O framework proposto integra operações de convolução, pooling e ativação especificamente projetadas no domínio de valor complexo, com destaque para uma estratégia de magnitude-based max pooling para aprimorar as características locais do defeito e suprimir ruídos. Notavelmente, a abordagem processa o sinal de valor complexo completo sem depender de parâmetros estruturais prévios ou dados de linha de base.

Os resultados experimentais, obtidos em espécimes de aço carbono com entalhes de usinagem por descarga elétrica (EDM) sob excitação multifrequência, confirmam as vantagens do método. O CV-CNN demonstrou uma precisão média de classificação de 85% para 16 categorias de defeitos, superando significativamente o modelo CV-FCNN. Além disso, a abordagem proporcionou melhorias substanciais na visualização de defeitos e no desempenho da classificação, contribuindo para uma solução promissora no campo de END para detecção de defeitos inteligente e precisa.

O estudo de Mi et al. (2023) [106] propõe um algoritmo de aprendizagem profunda para aprimorar a detecção de defeitos em superfícies de trilhos ferroviários,

abordando desafios como bordas inconspícuas, tamanho reduzido dos defeitos e interferência da textura de fundo. A metodologia envolve uma sequência de etapas de pré-processamento, incluindo extração da região do trilho, aprimoramento de imagem com Retinex aprimorado, modelagem de fundo por diferença e segmentação por limiar para obter um mapa de segmentação dos defeitos. Para a classificação dos defeitos, o método incorpora a rede Res2Net e o mecanismo de atenção CBAM (Convolutional Block Attention Module) para expandir o campo receptivo e otimizar os pesos de posição de alvos pequenos. Adicionalmente, a estrutura de aprimoramento de caminho bottom-up foi removida da arquitetura PANet para reduzir redundância de parâmetros e aprimorar a extração de características de pequenos alvos, resultando em um modelo YOLOv4 aprimorado.

Os resultados demonstraram que o método proposto alcançou uma precisão média de 92,68% na detecção de defeitos em trilhos e uma taxa de recall de 92,33%. Além disso, o tempo médio de detecção foi de apenas 0,068 segundos por imagem, o que atende aos requisitos de detecção em tempo real. A comparação com algoritmos de detecção de objetos de ponta, como *Faster Region-based Convolutional Neural Network* (R-CNN), *Single Shot MultiBox Detector* (SSD) e *You Only Look Once* (YOLO)v3, confirmou o desempenho superior do modelo YOLOv4 aprimorado em termos de precisão, recall e valor F1, indicando sua aplicabilidade robusta em projetos de detecção de defeitos ferroviários. A Tabela 3, mostra os resumos dos trabalhos indicando suas desvantagens e limitações.

2.5 PROPOSTA DO TRABALHO

Desenvolvimento de um sistema embarcado capaz de detectar, localizar e classificar anomalias na superfície de trilhos fazendo uso de uma sonda de EC, filtragem não linear para detecção de eventos online, Transformada Contínua Wavelet (CWT) e uma CNN para realizar a classificação usando dados da detecção dos sinais de desgaste de superfícies metálicas por meio de sondas de correntes parasitas. dando um passo adiante na manutenção preventiva de trilhos. Trabalhos recentes propõem o uso da transformada *wavelet* combinada com redes neurais profundas para processar imagens da superfície do trilho, o trabalho proposto conta com o sinal EC adquirido em campo, para manter a capacidade de detecção e classificação de anomalias.

Tabela 3: Resumo e Desvantagens dos Métodos de Identificação de Defeitos em Trilhos

Estudo	Método	Breve Resumo	Desvantagens/Limitações
Kuzman et al. (2018) [100]	Correntes Superficiais + CNN	Converte sinais de 10 sondas em imagens para CNN (TensorFlow). 99,45% de precisão em juntas e soldas. Não foca em desgastes superficiais.	Não mostra aplicações em campo; não detalha sistema de aquisição para campo. Foco restrito.
Cho et al. (2021) [101]	Acelerômetros + Transformada Wavelet	Usou acelerômetros e transformada <i>wavelet</i> para analisar <i>squats</i> em trilhos. Alcançou 88,2% de precisão na identificação de irregularidades (RCF).	Não detalhou o algoritmo. Foco em um tipo específico de defeito (<i>squats</i>).
Delgado-Sotelo et al. (2023) [102]	RNA + Correntes Parasitas	Classifica fissuras RCF com RNA e correntes parasitas. Compensa <i>lift-off</i> e analisa trincas artificiais (1-7 mm), mostrando robustez em discontinuidades.	Não mostra aplicações em campo.
Kwon et al. (2021) [103]	Corrente Parasita de Matriz (16 canais)	Utilizou dispositivo de corrente parasita de matriz (16 canais) para inspecionar cabeçote e defeitos de casca. Obteve precisão de ± 1 mm na profundidade.	Não menciona detalhes do algoritmo de comparação e não aplicou em atividades em campo.
Liu et al. (2022) [104]	Aprendizagem Profunda (CNN) + Vibração	Desenvolveu CNN (pré-convolução e residual) para identificar danos via sinais de vibração. Alta precisão (0,003% falsos positivos), sendo eficaz e leve.	Não classifica os danos por categorias e não informa aplicação prática.
Chen e Yu (2025) [105]	CV-CNN + Correntes Parasitas Complexas	Propõe CV-CNN para reconstrução/classificação de defeitos em aço carbono por correntes parasitas. Alcançou 85% de precisão para 16 categorias.	O trabalho valida o método experimental, necessitando de mais dados para defeitos mais complexos.
Mi et al. (2023) [106]	Aprendizagem Profunda (YOLOv4 aprimorado)	Propõe YOLOv4 aprimorado para detecção de defeitos superficiais. Otimiza bordas, tamanho e ruído. Alcançou 92,68% de precisão e 0,068 s/imagem em tempo real.	Apesar de usar bibliotecas mais atuais como o Yolo, não houve indicações de aplicações práticas.

2.5.1 TRANSFORMADA CONTÍNUA WAVELET

Uma das principais ferramentas utilizadas no processo identificação de defeitos superficiais em trilhos de ferrovias é a transformada *wavelet*, neste sentido mostra-se como uma técnica promissora para o sistema proposto, devido à sua capacidade de extrair características relevantes no tempo e na frequência.

A CWT é uma técnica matemática utilizada para analisar sinais não-estacionários, ou seja, sinais cujas características mudam ao longo do tempo. Esta técnica é bastante útil em diversas áreas, como processamento de sinais, análise de imagens, processamento de fala e reconhecimento de padrões. A CWT foi introduzida na década de 1980 por [107] e é baseada no uso de funções *wavelet*, que são pequenas ondas utilizadas para analisar sinais. A principal diferença entre a CWT e outras técnicas de análise de sinais, como a Transformada de Fourier, é que a CWT tem a capacidade de análise de sinais não-estacionários em diferentes escalas de tempo e frequência. Isso permite sua utilização da detecção de mudanças sutis em um sinal ao longo do tempo, o que não é possível com outras técnicas de análise de sinais.

A CWT é definida como a convolução do sinal original com uma função *wavelet*, conforme pode ser observado na Equação (2.1) em [108]

$$\text{CWT}_{a,b} = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \psi^*\left(\frac{t-b}{a}\right) dt \quad (2.1)$$

onde, a e b são parâmetros que controlam a escala e a localização da função *wavelet*, $f(t)$ é o sinal original, $\psi^*(t)$ é a função *wavelet* conjugada e o asterisco denota o complexo conjugado.

A função *wavelet* é escolhida para ter um comprimento finito e ser bem localizada no tempo e na frequência, devendo satisfazer algumas condições para garantir uma base completa para a análise de sinais. As *wavelets* utilizadas na CWT são funções matemáticas que além possuírem a capacidade de serem dilatadas ou comprimidas em diferentes escalas e capacidade de representar sinais com alta resolução em tempo, possuem algumas propriedades importantes citadas a seguir:

1. **Localização no tempo e na frequência:** As *wavelets* apresentam características de localização tanto no tempo quanto na frequência, o que permite analisar detalhes em diferentes escalas de tempo e frequência. Essa propriedade é útil, por exemplo, para detectar eventos transientes em sinais ou para separar componentes de diferentes frequências em um sinal [109].

2. **Ortonormalidade:** Uma família de *wavelets* é ortonormal se cada uma das funções é ortonormal em relação às outras. Isso significa que têm energia unitária e são mutuamente ortogonais, o que simplifica cálculos e análises [110].
3. **Invariância à translação:** As *wavelets* são invariantes à translação, o que significa que a transformada de um sinal deslocado no tempo é equivalente à transformada do sinal original deslocado. Essa propriedade é útil, por exemplo, para analisar sinais em diferentes momentos do tempo sem precisar recalcular a transformada para cada instante [109].
4. **Inversibilidade:** A transformada contínua *wavelet* é inversível, o que significa que é possível recuperar o sinal original a partir da transformada. Essa propriedade é importante para garantir a preservação das informações do sinal durante a transformação [110].
5. **Compressibilidade:** A CWT permite comprimir sinais de forma eficiente, removendo informações redundantes ou pouco relevantes em diferentes escalas de tempo e frequência. Essa propriedade é útil para armazenar e transmitir dados de forma mais eficiente [109].

Existem diferentes tipos de função *wavelets* como a *Haar*, *Daubechies*, *Morlet*, dentre outras. Cada uma delas com suas próprias características e aplicações conforme relacionado a seguir:

1. **Wavelets de Haar:** São as mais simples e foram as primeiras a serem utilizadas na CWT. Elas são úteis para detectar transições abruptas em sinais e para separar componentes de alta frequência em um sinal [109].
2. **Wavelets de Daubechies:** São uma família que apresentam características de regularidade e suavidade em diferentes escalas de tempo e frequência. Elas são úteis para comprimir sinais e para análises de sinais de voz e de imagem [110].
3. **Wavelets de Morlet:** As *wavelets* de *Morlet* são *wavelets* complexas que apresentam uma componente real e uma componente imaginária. Elas são úteis para analisar sinais com padrões oscilatórios, como sinais de Eletroencefalograma (EEG) e Eletrocardiograma (ECG) [109].
4. **Wavelets de Meyer:** São uma família de *wavelets* que apresentam características de regularidade em diferentes escalas de tempo e frequência, além de uma alta

resolução temporal e frequencial. Elas são úteis para analisar sinais de áudio e de música [110].

Uma das funções *wavelet* mais utilizadas é a *Morlet*, definida como:

$$\psi(t) = \pi^{-1/4} e^{i\omega_0 t} e^{-t^2/2} \quad (2.2)$$

onde, ω_0 é a frequência central da função *wavelet*, t a variável tempo e i a unidade imaginária. A presença de i na fórmula indica que a *wavelet Morlet* é uma função de valor complexo, o que permite que ela capture informações de fase e magnitude do sinal

A função *wavelet* e CWT são geralmente complexas, possuindo uma parte real e imaginária que pode ser representada como magnitude e fase [111]. O CWT permite descrever a intensidade da energia contida em cada frequência WPS, como mostrado:

$$WPS_{a,b} = \left| \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \psi^* \left(\frac{t-b}{a} \right) dt \right|^2 \quad (2.3)$$

Sua análise na escala de tempo e frequência é propiciada por meio da dilatação e deslocamento da função wavelet no tempo e são as mesmas da Equação (2.1). A dilatação no tempo aumenta a frequência da função wavelet, enquanto o deslocamento no tempo altera sua localização.

Um exemplo de aplicação da transformada wavelet em processamento de sinais para manutenção preventiva em linhas ferroviárias pode ser encontrado em um estudo realizado por Gao et al.[112]. Neste estudo, os autores utilizaram a Transformada Discreta Wavelet (DWT), que se trata de uma técnica que utiliza wavelets discretas para decompor um sinal em diferentes níveis de resolução, permitindo identificar características de diferentes frequências em um sinal [113]. No trabalho, a DWT é utilizada para análise de sinais de vibração em trilhos, permitindo identificar padrões de vibração característicos de diferentes tipos de defeitos, como desgaste, fissuras, entre outros.

Um estudo realizado por Mousavi et al.[114], os autores propuseram um método para detecção de defeitos em trilhos ferroviários usando a CWT. O método consiste em transformar o sinal de vibração do trilho em uma escala e uma frequência específicas, permitindo identificar as características do sinal que indicam a presença de defeitos. O método foi aplicado a sinais de vibração coletados em um trem em operação e os resultados mostraram que a técnica proposta é eficaz na detecção de defeitos superficiais em trilhos.

Em outro estudo, realizado por Guo et al.[115], foi proposta uma abordagem para detecção de defeitos em trilhos usando a CWT e a técnica de Análise de Componentes Independentes (ICA) . A CWT foi aplicada para decompor os sinais de vibração em diferentes escalas e frequências, enquanto a ICA foi utilizada para extrair os componentes independentes do sinal. Os resultados mostraram que a técnica proposta foi capaz de detectar defeitos em trilhos com alta precisão e sensibilidade.

Já no estudo de Yang et al.[116], foi proposto um método para detecção de defeitos em trilhos usando a CWT e a técnica de Classificação de Regressão Logística (LRC). O método consiste em aplicar a CWT para decompor os sinais de vibração em diferentes escalas e frequências e, em seguida, aplicar a LRC para detectar defeitos. O método foi testado em sinais de vibração coletados em um trem em operação e os resultados mostraram que a técnica proposta foi capaz de efetuar a detecção de defeitos superficiais em trilhos.

Outra aplicação da transformada wavelet em processamento de sinais para manutenção preventiva em linhas ferroviárias pode ser encontrada em um estudo realizado por Peng et al. [117]. Neste estudo, os autores utilizaram a DWT para analisar os sinais de vibração coletados de um trem de alta velocidade em operação. A partir da decomposição dos sinais em diferentes níveis de frequência, eles foram capazes de identificar e localizar diferentes tipos de defeitos na via-férrea, como juntas soltas, trilhos quebrados e desalinhamentos. Os resultados mostraram que a DWT é uma ferramenta eficaz para extrair as características dos sinais de vibração e melhorar a precisão e a confiabilidade da detecção de defeitos.

2.5.2 REDE NEURAL CONVOLUCIONAL

Uma rede neural convolucional é um tipo de rede multicamadas muito utilizada em aprendizado profundo [118] que possui grande capacidade no reconhecimento de padrões existentes em imagens, sendo robusta e com capacidade de reconhecer padrões com variabilidade significativa, mesmo com distorções e transformações geométricas [119]. A Figura 13 mostra um exemplo de topologia de uma rede convolucional, como o nome indica, a CNN utiliza a convolução como operação fundamental em suas camadas iniciais. A convolução na rede CNN consiste em deslizar um kernel sobre a imagem de entrada, multiplicando os valores dos pesos do kernel com os valores correspondentes da imagem e somando os resultados, gerando uma nova matriz de saída, que representará a presença ou ausência de características específicas na imagem [120]. Além das camadas

convolutivas, a Figura 13, ilustra o pooling, que reduz o número de parâmetros em caso de imagens muito grandes, a função de ativação ReLU que é a unidade linear retificadora responsável por permitir a saída de valores não negativos das matrizes. A camada totalmente conectada é alimentada pelo vetor achatado da matriz, a função de saída responsável pela classificação é a chamada SoftMax[121].




Figura 13: CNN conceitual [1].

Desde a proposta inicial das CNNs, diversas arquiteturas têm sido desenvolvidas e aprimoradas. Dentre elas, uma das mais conhecidas é a AlexNet, desenvolvida por [122] que consiste em 5 camadas convolucionais, seguidas por 3 camadas totalmente conectadas. Essa arquitetura obteve bons resultados na tarefa de classificação de imagens na base de dados ImageNet [123], impulsionando o avanço das CNNs.

Outras CNNs também foram propostas e se destacaram em diferentes tarefas de processamento de imagens. A arquitetura GoogleNet, proposta por [124], introduziu a ideia de módulos de inserção que combinam diferentes tipos de filtros em paralelo para extrair características em diferentes escalas. Por outro lado, a arquitetura ResNet, desenvolvida por [125], introduz blocos residuais para melhorar o treinamento de redes muito profundas, permitindo que a informação da entrada seja passada para a saída de forma mais direta, facilitando o treinamento de redes com mais de 100 camadas. A VGGNet, também conhecida como VGG, é uma CNN que se destaca por sua uniformidade e profundidade [126]. Ela foi desenvolvida pelo Grupo de Geometria Visual (do inglês *Visual Geometry Group*) da Universidade de Oxford e consiste em 16 camadas convolucionais, o que a tornou uma das redes mais profundas de sua época. Nela são utilizados kernels menores em suas camadas convolucionais, mais especificamente 3x3, o que aumentou a profundidade da rede e melhorou sua capacidade de generalização. A ideia por trás do uso de filtros menores se dá pelo fato de várias camadas convolucionais com filtros menores podem emular o efeito de uma camada convolucional com

um filtro maior, mas com menos parâmetros e maior não-linearidade [126], portanto, é conhecida por ser fácil de implementar, tornando-a uma escolha popular para extração de características de imagens [126]. Ela também se destacou em competições como a *ImageNet Large Scale Visual Recognition Challenge* (ILSVRC), onde alcançou quase 92,7% de precisão no top-5 [126]. Portanto, dentre as demais topologias ela se destaca por sua simplicidade e uniformidade, motivo pelo qual foi escolhida para ser utilizada neste trabalho, Figura 14 [127].




Figura 14: Topologia básica da rede VGGNet [2].

As CNNs são uma poderosa ferramenta para processamento de imagens e têm se mostrado eficazes em diversas aplicações. Com o avanço contínuo da pesquisa nessa área, espera-se que novas arquiteturas e técnicas de treinamento continuem a melhorar o desempenho das CNNs em tarefas desafiadoras, portanto, são indicadas como uma excelente ferramenta para classificar padrões transcritos pelo espectrograma da WPS.

3 SISTEMA EMBARCADO PARA IDENTIFICAÇÃO DE FALHAS SUPERFICIAIS EM TRILHOS DE FERROVIA

Este capítulo faz a descrição do sistema proposto, detalhando o desenvolvimento do sistema embarcado para identificação de falhas superficiais em trilhos de ferrovias.

3.1 DESCRIÇÃO

Para realizar o processo de verificação de trincas superficiais é necessário o desenvolvimento de um sistema capaz de percorrer longos trechos da via periodicamente. Para que isso seja possível, o sistema de monitoramento preventivo deve ser embarcado em veículos rodoferroviários utilizados para manutenção, amplamente utilizados em diversas aplicações, incluindo o monitoramento dos trilhos [128].

A proposta de embarcar o sistema de monitoramento preventivo em um veículo rodoferroviário é uma solução viável onde este tipo de veículo pode percorrer longos trechos da via ferroviária, possibilitando uma ampla cobertura de monitoramento, neste sentido o sistema embarcado pode ser facilmente controlado e configurado por meio de uma interface de usuário amigável, permitindo a análise de dados em tempo real e o gerenciamento das informações coletadas.

Uma alternativa para a detecção de trincas superficiais em trilhos ferroviários é a utilização da técnica de corrente parasita baseada na geração de campos magnéticos alternados em uma bobina, que induzem correntes elétricas parasitas no material do trilho. As variações nas correntes parasitas são detectadas por meio de um sensor eletromagnético, permitindo a identificação de descontinuidades na superfície do material [129]. A Figura 6 mostrou a distinção da região de operação entre o método de ultrassom e o de corrente parasita para ensaios não destrutivos.

Além disso, a corrente parasita oferece vantagens na detecção de defeitos em trilhos, como a capacidade de identificar trincas em superfícies revestidas ou pintadas e operar sem contato físico, o que pode ser um desafio para a técnica de ultrassom [129]. Ela

permite um diagnóstico abrangente de descontinuidades variadas (rachaduras, poros, inclusões) sem exigir preparação superficial, mesmo com água ou graxa. No entanto, suas limitações incluem a sensibilidade à posição e orientação do defeito em relação à bobina, além da necessidade de calibração precisa, influenciada pela geometria da bobina, frequência e propriedades elétricas do material.

O desenvolvimento de um sistema de verificação de trincas superficiais em trilhos é uma etapa importante no processo de manutenção preventiva em sistemas ferroviários. Sua implementação trás diversas vantagens, tais como a detecção de trincas antes que elas sejam visíveis a olho nu no boleto do trilho, a identificação de falhas em trechos que já foram inspecionados por meio de ultrassom, a capacidade de detecção de trincas menores do que 1 mm na superfície do trilho e a possibilidade de realização de testes em velocidades de até 50 km/h.

Para este desenvolvimento é necessário o acoplamento do equipamento a um veículo rodoferroviário, permitindo a realização de inspeções periódicas em longos trechos da via ferroviária. A integração com uma interface homem-máquina embarcada, permite o acompanhamento em tempo real dos dados coletados e a identificação das coordenadas dos locais onde as trincas foram detectadas. Essa informação pode ser posteriormente utilizada pela equipe de manutenção para ações corretivas ou preditivas.

Além disso, o sistema proposto deve ser capaz de captar imagens dos trilhos onde as falhas foram identificadas, permitindo uma avaliação pelo usuário das imperfeições identificadas.

Em resumo, o desenvolvimento de um sistema de verificação de trincas superficiais em trilhos ferroviários é um importante passo para a manutenção preventiva em sistemas ferroviários, sua implementação traz diversas vantagens, tais como a detecção precoce de falhas, a identificação de trechos com maior necessidade de manutenção e a possibilidade de realização de testes em velocidades de até 50 km/h, este sistema pode ser integrado a um veículo rodoferroviário de inspeção em trilhos, permitindo uma inspeção mais completa e abrangente. Abaixo é apresentado um resumo dos itens de desenvolvimento do sistema proposto:

- Desenvolvimento de um sistema para verificação de trincas superficiais baseado em correntes parasitas;
- Acoplamento do sistema a um veículo rodoferroviário para possibilitar inspeções periódicas das linhas, possibilitando o acompanhamento online através de inter-

face homem máquina embarcado;

- Indicação das coordenadas dos locais da linha onde trincas superficiais foram detectadas e posterior localização para ações corretivas ou preditivas pela equipe de manutenção;
- Captura de imagens dos trilhos onde o sistema identificar falhas;
- Desnecessária a preparação da superfície para o teste, funcionando mesmo em condições dos trilhos com água, óleo ou graxa;
- Os testes em velocidades de até 50 km/h;
- Classificação do eventos detectados.

A Figura 15, ilustra o processo em que um veículo rodoferroviário percorre a via rastreamento pontos contendo trincas superficiais. Nesse ponto, o sistema proposto identifica o dano no trilho e informa o operador, armazenando a leitura dos pontos identificados como falhas. As coordenadas geográficas destas posições e o registro da imagem são armazenadas pelo sistema, permitindo a identificação do local para a atuação da intervenção preventiva e programada.




Figura 15: Ilustração do processo de monitoramento de via com veículo.

O desenvolvimento envolve diversas etapas que exigem um alto grau de precisão e cuidado. Primeiramente é necessária o desenvolvimento ou aquisição de equipamento de injeção e leitura das correntes parasitas. Posteriormente, é preciso o desenvolvimento de software de controle e análise que seja capaz de coordenar as entradas de leitura das sondas, sinais do GPS e imagens registradas pelas câmeras sendo fundamental para que a análise dos dados coletados seja precisa e confiável, permitindo a identificação das trincas superficiais com a maior precisão possível.

Além disso, é necessário o desenvolvimento de sistemas de acoplamento mecânico tanto para as câmeras quanto para as sondas. O sistema de acoplamento mecânico

para câmera deve ser instalado na parte traseira do veículo, permitindo o seu disparo após a identificação de falhas pelo sistema. Já o sistema de acoplamento mecânico das sondas com o veículo deve prever um sistema de amortecimento e deslocamentos laterais, para não serem rígidos o suficiente e provocar a sua ruptura mecânica causada por imperfeições e adversidades que o trilho possa apresentar.

Outra etapa importante é o desenvolvimento de algoritmos de filtros digitais necessários para evitar a contaminação do sinal e sua descaracterização. Essa etapa é fundamental para que a análise do sinal seja precisa e confiável, permitindo a identificação das trincas superficiais de forma eficaz. Além disso, é necessário o uso do sistema de GPS, que permite a localização precisa dos trechos onde as trincas foram detectadas.

A seguir é apresentada uma lista das atividades que foram realizadas para o desenvolvimento do sistema:

- Em função de existirem no mercado equipamentos comerciais portáteis de correntes parasitas, com possibilidade de controle e aquisição de sinais por uma porta USB, optou-se pela aquisição de um equipamento (Aerocheck+ do fabricante EtherNDE) que atende aos requisitos necessários para a aplicação proposta [130];
- Desenvolvimento do Software de controle e análise que será capaz de coordenar as entradas de leitura das sondas, sinais do GPS, imagens registradas pelas câmeras e posteriormente a classificação de sinais;
- Desenvolvimento do sistema de acoplamento mecânico para câmera a ser instalado na parte traseira do veículo, possibilitando o disparo da foto após identificação de falhas pelo sistema;
- Desenvolvimento do sistema de acoplamento mecânico das sondas de correntes parasitas com o veículo;
- Desenvolvimento de algoritmos de filtros digitais necessários para evitar os *spikes* e ruídos no sinal e sua descaracterização, etapa necessária anterior à análise do sinal;
- Desenvolvimento dos métodos de detecção e classificação das falhas identificadas nos trilhos, como o janelamento, *threshold* e tamanho de amostras da janela.

3.1.1 *HARDWARE*

O sistema é basicamente composto por:

- Rugged Laptop (Dell Latitude 14), ver Figura 16, para aplicações profissionais que precisam de um computador confiável em ambientes exigentes, possui tela de 14 polegadas HD (1366 x 768) antirreflexo e processador Intel Core i5-8365U de 8^a geração oferecendo alto desempenho para tarefas complexas. Sua memória RAM de 8GB DDR4 garante multitarefas eficientes, enquanto o armazenamento SSD de 256GB oferece rápida inicialização e acesso aos dados. A bateria de longa duração garante até 10 horas de autonomia, permitindo trabalhos por longos períodos sem necessidade de recargas. Suas características principais são a certificação MIL-STD 810G que resiste a quedas, vibrações, temperaturas extremas e poeira, Tela Gorilla Glass que protege contra arranhões e impactos, teclado retroiluminado que permite digitar em ambientes com pouca luz e o leitor de smart card e TPM 2.0 que garante segurança para os dados;
- Detector de Correntes Superficiais Aerocheck+ [130] do fabricante EtherNDE, ver Figura 17, trata-se de um equipamento de inspeção por correntes parasitas com dupla frequência e medição de condutividade, projetado para detectar e avaliar falhas usando o método Teste Não Destrutivo (NDT) de correntes parasitas, efetua detecção de defeitos superficiais. Devido à sua faixa de frequência de 10Hz-12.8MHz, é capaz de detectar defeitos superficiais e subsuperficiais em componentes feitos de metais não ferrosos e suas ligas. Para este projeto ele é o responsável por receber os sinais adquiridos pela sonda PT003;
- Duas sondas PT003 do fabricante EtherNDE, Figura 18 para aplicações em inspeção de trilhos ferroviários utilizando o método de correntes parasitas para detectar falhas e anomalias na superfície dos trilhos, como trincas, corrosão e desgaste. Opera em frequências entre 20 kHz e 500 kHz, o que permite a detecção de falhas de diferentes tamanhos e profundidades, possui forma "WideScan" com 50 mm de largura, ideal para a inspeção da superfície do trilho. Utiliza o método de reflexão para detectar falhas, sua conexão ao equipamento de inspeção é através do conector Lemo de 4 vias. Suas informações são então processadas e analisadas pelo Aerocheck+;
- Módulo GPS Linx RXM-GPS-F4 LOT 1308 [131] para registrar a localização geográfica de cada ponto de medição, possui alta precisão e integração com o

software de aquisição de dados para correlacionar as informações espaciais com os dados coletados pelos outros sensores;

- Câmera de vídeo Basler 1600-25c-dn. Possui alta resolução e velocidade, taxa de quadros de 25 fps, possibilitando aplicações de visão artificial que exigem captura de imagens nítidas e precisas, com sensor CMOS de 1,6 megapixels e resolução de 1600 x 1200 pixels.;
- Housing TransPac TPH 4000, IP67, 24 V. Protege os componentes eletrônicos da câmera contra intempéries, vibrações e é impermeável (classificação IP67);
- Iluminador LED AXTON AT-32WB que fornece iluminação adicional para a câmera em ambientes com pouca luz, dotado de 32 Leds brancos de alta potência com luz homogênea e difusa para evitar reflexos e com baixo consumo para maior autonomia do sistema;
- Sistema de alimentação da câmera e do iluminador (step-up 12/24 V) cuja função é converter a tensão da bateria do veículo (24 V) para a tensão necessária para a câmera e o iluminador;
- Peças de acoplamento da sonda e câmera ao trilho para fixação da sonda e câmera ao veículo de forma segura e estável.



Figura 16: Rugged Laptop - Dell Latitude 14



Figura 17: Aerocheck+



Figura 18: Sonda PT003, utilizada nesta configuração para os primeiros testes manuais

3.1.2 DIAGRAMA DE BLOCOS DAS ETAPAS

A Figura 19 apresenta um diagrama de blocos referente as etapas relativas ao processamento de dados do sistema proposto. Na etapa *online*, onde ocorre a aquisição dos sinais, o processamento é efetuado no notebook indicado na Figura 16, na sequência, a etapa *offline* poderá ocorrer em qualquer computador que contenha o algoritmo proposto.

O processo começa com a etapa de inspeção dos trilhos, onde a aquisição dos sinais *online* é realizada por meio de duas sondas acopladas ao veículo próximas aos trilhos.




Figura 19: Sistema proposto para os próximos passos do desenvolvimento

Na etapa seguinte, são aplicados filtros digitais no sinal original para remover distorções e picos indesejados. A extração dos sinais provenientes da detecção por threshold é realizada na etapa de janelamento, seguida pela sua transformada CWT.

A classificação dos sinais pela CNN é então realizada com a saída das transformadas CWT da etapa anterior. O processo é finalizado com a emissão do relatório, que inclui as coordenadas e o tipo de classificação definido pelo modelo.

É importante enfatizar a funcionalidade do sistema Sistema de Verificação de Trincas Superficiais (SVTS) proposto, que desempenhará um papel fundamental na atividade de inspeção da equipe de manutenção. Ele é projetado para detector de forma *online*, ou seja, durante o processo de inspeção, as falhas superficiais nos trilhos. Uma vez realizada a detecção, o sistema adquire as coordenadas GPS e a imagem da câmera.

Por outro lado, a classificação desses sinais e a subsequente geração do relatório final da inspeção são realizadas posteriormente, ou seja, de forma *offline*.

Uma consideração prática importante para esta maneira de execução é dada pelo fato de não haver necessidade imediata de conhecer o resultado da classificação no local da inspeção. Isso ocorre porque o resultado será utilizado posteriormente no plano de manutenção programado. Portanto, não há urgência em ter os resultados da classificação imediatamente após a coleta dos dados.

3.1.3 INTERFACE DE OPERAÇÃO

Para operação do sistema de aquisição foi desenvolvida uma Interação Humano Computador (IHC) cujo objetivo é propiciar a manipulação dos processos e configurações do sistema nesta etapa. O fluxograma mostrado na Figura 20, sintetiza esta etapa onde o algoritmo instalado no notebook faz o processo de comunicação(serial) com o Detector de Correntes Parasitas (AeroCheck+), módulo GPS e câmera. Na sequência é instalado um divisor de sinais na saída do AeroCheck+ para as sondas de corrente parasita dos trilhos esquerdo e direito e finalmente a iluminação é instalada na saída da câmera com objetivo de reforçar a intensidade luminosa e melhorar a qualidade das imagens.




Figura 20: Diagrama do sistema

A Figura 21 mostra a tela inicial da IHC, nela é possível notar 4 abas que são: Conexão, Controles, Monitoramento e Câmera.

Na aba "Conexão" são feitas as conexões dos dispositivos externos, Aerocheck+, GPS e Câmera, nela é possível selecionar as portas na qual serão conectadas ao Rudged aptop - Dell Latitude 14. O Aerocheck+ e o GPS tem alimentação independente através de baterias e a Câmera é alimentada por 12V diretamente no veículo rodoferroviário, portanto à medida que os dispositivos são plugados no pc é necessário clicar nos botões "Conectar" de cada dispositivo.




Figura 21: Aba Conexão

Na Figura 22 é mostrada a tela após a conexão dos dispositivos, nela é feito o monitoramento da aquisição na seção "Modo" e são visualizados os valores de aquisição dos canais esquerdo e direito. Na seção "Configuração da Análise" é permitido configurar algumas opções como o "Tempo de Aquisição", habilitar a "Aquisição Contínua" e o registro das leituras do GPS através de "Armazenar GPS Trajetória" que grava todas as leituras no percurso. Em "Armazenar GPS Ponto de Falta" é efetuado o armazenamento dos pontos de threshold além de possibilitar "Armazenar Aquisições" para gravação em pastas no pc e habilitar a função "Adicionar Gráfico Monitoramento" para que o acompanhamento do sinal seja visualizado. A função "Plotar Toda a Aquisição" é pouco usada uma vez que esta modalidade de visualização é feita na etapa do processamento através do algoritmo offline. As opções de "Janela OffSet" e "Janela Alarme" são respectivamente para remover manualmente a flutuação do sinal e ajustar a largura da janela de detecção após identificado o alarme (threshold). Os ajustes "Ajuste Setor Alarme 1" e "Ajuste Setor Alarme 2" se referem aos recursos do Aerockeck+ para saídas com e sem filtros disponibilizados internamente. A seção "Controle Eddy Current" é

um espelho dos botões de comando e configurações do Aerocheck+ mostrando o botão indicador de "ALARM!" que fica altera sua cor para verde sempre que um threshold é detectado. Por fim podemos notar os indicadores em forma de esferas, onde sua função é indicar a conexão dos dispositivos, sendo verde indica conexão em funcionamento e vermelho indica sem conexão. O botão 'Iniciar Análise' inicia o processo de análise. Os ajustes apresentados, tem a funcionalidade somente no acompanhamento da interface, portanto o sinal gravado e seus respectivos pontos de GPS são os originais e serão processados no algoritmo offline. A seleção do diretório e o nome do arquivo a ser gravado é mostrado abaixo das esferas de status dos dispositivos.




Figura 22: Aba Controles

Na Figura 23, é mostrada a aba "Monitoramento" que permite acompanhar em tempo real o processo de aquisição dos sinais de correntes parasitas.




Figura 23: Aba Monitoramento

Na Figura 24, é mostrada a aba "Câmera" que possibilita o acompanhamento em tempo real de imagens do trajeto dos trilhos, registrando uma imagem que contem uma anomalia identificada pela sonda de corrente parasita.




Figura 24: Esquerda: Aba Câmera , registrando uma anomalia no trilho

Como resultado do processo de aquisição do SVTS, são armazenados os seguintes dados: sinal de leitura das sondas do Detector de Correntes Parasitas, coordenadas geográficas da trajetória do percurso realizado na análise, coordenadas geográficas dos pontos de trigger (detecção de falha), sequência de imagens do ponto onde o sistema acionou o trigger. A Figura 25 mostra a tela onde as coordenadas geográficas da trajetória e dos pontos de trigger são analisados permitindo auxiliar o operador nas etapas de reparo da via ferroviária.




Figura 25: Tela visualização de coordenadas

3.2 FUNCIONAMENTO DO SISTEMA

O sistema detecta, classifica e mapeia os defeitos na superfície da via, trazendo as informações estruturais da linha de superfície ferroviária.

A Figura 26 mostra um diagrama com a integração dos componentes SVTS no veículo de inspeção. Nela estão instaladas: a estrutura mecânica para fixação das sondas; o computador para controle e processamento de dados; o Sistema de Posicionamento Global (GPS) para capturar as coordenadas dos defeitos, e o sistema de câmeras para permitir a verificação dos defeitos detectados.




Figura 26: Diagrama do Sistema de Detecção

A Figura 27 mostra detalhes do sistema proposto em um veículo de inspeção equipado com SVTS. À esquerda, pode-se ver a câmera instalada na parte superior e duas sondas que realizam a análise através da EC. No meio, é possível observar o carrinho de fixação da sonda. Uma visão detalhada do carrinho de fixação pode ser vista à direita. Essas sondas EC são fixadas a uma distância de cerca de 2 mm da superfície do trilho.



Figura 27: Sondas instaladas no veículo de inspeção. Na esquerda é possível visualizar a câmera; no centro é mostrado o suporte de fixação da sonda; à direita pode ser visualizado detalhes do suporte da sonda.

O sistema proposto mapeia os defeitos do trilho nas regiões com squats e permite identificação de pontos contendo soldas e juntas na linha férrea, fornecendo dados para a gestão de trilhos de forma clara, agregando informações importantes para o gerenciamento e manutenção da via. Para que isso seja possível, o sistema deve monitorar periodicamente longos trechos da via. O sistema armazena o sinal das sondas EC, da rota do veículo, das coordenadas geográficas e das imagens dos defeitos ferroviários detectados.

Em geral, o veículo percorre o trecho analisado com velocidade constante entre 5 a 50 km/h. Inicialmente, o sinal sofre um ajuste para remover a flutuação da li-

nha de base, posteriormente uma filtragem não linear é aplicada para remover ruídos impulsivos e um limite é aplicado para detectar e localizar os defeitos do trilho.

Durante a inspeção realizada pelo SVTS, o sinal das bobinas de leitura da sonda de EC é adquirido continuamente para viabilizar o posterior processamento digital. O sinal EC resultante é captado a uma taxa de amostragem de 7,5 kHz, a taxa máxima permitida pelo equipamento de injeção e leitura de correntes superficiais. Essa etapa de aquisição garante a obtenção de dados precisos e detalhados sobre a condutividade do material sob inspeção.

Para otimizar a detecção de falhas, a frequência do sinal senoidal do equipamento, que provoca a reação do sinal EC, foi ajustada de forma empírica para 50 kHz. Essa escolha balanceia a capacidade de identificar pequenas falhas superficiais com a penetração do sinal no material do trilho, conforme descrito em [132], o equipamento possui uma ampla faixa de frequência de operação, variando de 20 Hz a 20 MHz, proporcionando flexibilidade significativa na geração e análise de sinais para diferentes aplicações.

O sinal senoidal injetado no trilho pela sonda é processado para calcular a amplitude e a fase, fornecendo informações valiosas sobre a estrutura interna do material. A amplitude do sinal EC representa a intensidade da condutividade elétrica, enquanto a fase indica sua posição no tempo em relação a uma referência, neste estudo a amplitude é utilizada para os cálculos, uma vez que os sinais serão analisados como amplitude em função do tempo servindo de entrada para transformada *Wavelet*.

Esses sinais são adquiridos a partir do sinal senoidal injetado pelas bobinas de leitura e disponibilizados através da saída USB a uma taxa máxima de 7,5 kHz.

Complementando a aquisição do sinal EC, o GPS registra a localização da sonda com uma taxa de 5 Hz. Embora essa taxa possa parecer baixa em comparação com as taxas associadas ao sinal EC, ela é suficiente para mapear toda a trajetória do objeto em estudo e fornecer uma resolução espacial inferior a 2,8 metros para velocidades de inspeção de até 50 km/h, pois mesmo nesta resolução os itens identificados são identificados no mapa de forma a atender a manutenção de campo.

3.3 CLASSIFICAÇÃO OFFLINE DE ANOMALIAS

O desenvolvimento do sistema de classificação offline envolveu testes manuais com o equipamento SVTS em um ambiente controlado, estes permitiram a identificação de

padrões nos sinais EC associados às anomalias, a partir desses padrões, foi desenvolvido o algoritmo de classificação robusto a serem aplicados aos dados adquiridos durante as inspeções em campo.

A escolha da classificação offline se baseou em dois fatores principais. Primeiro, a complexidade computacional do processo de classificação torna inviável sua realização em tempo real durante a inspeção, em segundo lugar, a natureza das inspeções com SVTS não exige uma resposta imediata sobre a presença ou ausência de anomalias.

A classificação offline elimina a necessidade de um sistema computacional embarcado no veículo rodoferroviário, reduzindo custos e complexidade de forma que o processamento dos dados pode ser realizado em um ambiente computacional robusto no escritório, com maior capacidade de processamento e recursos de armazenamento se necessário.

A Figura 28 apresenta um diagrama que ilustra os passos realizados para analisar a superfície do trilho e mapear os pontos com as características ou irregularidades a serem identificadas. Este processo envolve várias etapas, cada uma das quais desempenha um papel fundamental na obtenção de resultados precisos e confiáveis.




Figura 28: Diagrama sequencial para detecção de defeitos em superfícies dos trilhos.

A sequência dos blocos começa em "LÊ ARQUIVO" com a leitura de um arquivo dos sinais captados pelo sistema no formato txt, composto por 2 colunas relativas às leituras das sondas esquerda e direita. Na etapa "DEFINE VARIÁVEIS" ocorre a definição de variáveis relacionadas à fonte de aquisição, podendo ser determinadas para aquisições manuais ou através do veículo rodoferroviário, estas incluem o *delay*, que define o quanto será a largura da janela em amostras após a detecção, o Limite de Perturbação, foi definido por meio de verificação de amostras em campo para trilhos sem desgastes, levando em conta sua superfície não totalmente regular, ou seja, não

ideal, somada a ruídos provenientes de oscilações da sonda causadas pela estrutura de fixação em conjunto com oscilações do veículo de inspeção, o *Threshold*, que indica o nível do sinal mínimo a ser detectado pelo sistema, foi determinado em função da coleta de amostras em campo relativa às classes estudadas, neste sentido, foi determinado de maneira empírica durante a observação das coletas. Abaixo é mostrado um exemplo de sinal adquirido após a leitura, Figura 29, nela podemos identificar saturações do sinal proveniente do deslocamento lateral da sonda no suporte mecânico, pouco amortecimento do suporte causando saltos ou outras fontes de interferência [133]. Estas saturações são caracterizadas como ruído, composto de picos impulsivos estreitos com amplitude relativamente alta [134] com a unidade definida em mV.




Figura 29: Exemplo sinal adquirido após a leitura.

Em 'TIRA SPIKES' são aplicados filtros para retirada de ruídos do sinal original (ainda sem janelamento) sendo crucial para garantir que os dados sejam limpos e livres de ruídos indesejados que possam afetar a precisão dos resultados. Devido ao acoplamento da sonda com o trilho (ver Figura 27), é normal haver ruídos nas leituras devido a vibrações e interferências eletromagnéticas.

Figura 30 apresenta um trecho do sinal original adquirido com picos.

Outro tipo de ruído que pode ser encontrado no sinal adquirido é semelhante a um degrau de alta amplitude e pode ser visto na Figura 30. Este tipo de ruído pode ser modelado por uma função de *Heaviside* [135] e consiste em uma elevação repentina no nível do sinal devido à trepidação da sonda do sensor EC.




Figura 30: Exemplo de ruído de *heaviside*(degrau). O sinal adquirido pode ser visto em preto e o filtrado em vermelho.

A remoção de *spikes* no sinal adquirido é um passo importante no pré-processamento de dados, uma vez que esses eventos podem distorcer a análise e interpretação dos resultados. Neste trabalho, apresentamos um método utilizando uma abordagem de janela deslizante.

O método é implementado como uma instância em uma classe que recebe o sinal e aplica uma série de etapas para remover os *spikes*.

Uma janela de tamanho 50 é definida para detectar *spikes* no sinal. Esta janela deslizante é utilizada para iterar sobre o sinal, começando do início e avançando em incrementos de 1. Para cada posição i , verifica-se se todos os valores na janela são iguais ao valor em i . Se sim, isso significa que há um *spike* tipo degrau naquele trecho.

$$[\text{Se } \forall k \in [i, i + 49], \text{teste}[k] = \text{teste}[i]] \quad (3.1)$$

onde i é o índice atual, k é um índice dentro da janela atual e **teste** é o sinal de entrada.

Se um *spike* for detectado, todos os valores na janela são substituídos pelo valor médio do sinal. Essa abordagem permite remoção de forma eficaz, pois a janela deslizante detecta padrões de valores constantes que são característicos desse tipo de *spike*.

Após a remoção dos *spikes* em forma de pulso, o método aplica uma lógica detecção

e eliminação *spikes* impulsivos, este método envolve o cálculo da derivada do sinal utilizando a fórmula:

$$\left[\frac{\partial f}{\partial x} = \lim_{h \rightarrow 0} \frac{f(x+h) - f(x)}{h}\right] \quad (3.2)$$

onde $f(x)$ é o sinal original e h é o passo de amostragem.

Em seguida, os valores absolutos da derivada são calculados utilizando a fórmula:

$$[|g(x)| = \sqrt{g(x)^2}] \quad (3.3)$$

onde $g(x)$ é a derivada do sinal.

Os valores que têm uma derivada absoluta maior que 400, valor de limiar encontrado através da análise dos dados, são considerados impulsivos e substituídos pelo valor médio do sinal. Finalmente, um filtro de média móvel é aplicado ao sinal filtrado utilizando a fórmula:

$$[y[i] = \frac{1}{N} \sum_{j=0}^{N-1} x[i+j]] \quad (3.4)$$

onde $y[i]$ é o valor filtrado, $x[i]$ é o valor original, N é o tamanho do kernel do filtro e i é a posição do valor no sinal. Ao final da etapa 'TIRA SPIKES' o sinal adquirido se apresenta conforme a Figura 31, onde o nível DC do sinal se refere a ajustes de ganho no *Aerocheck+*.




Figura 31: Sinal após a retirada de spikes

No bloco "PADRONIZA SINAL", é implementado um método para garantir a comparabilidade e confiabilidade das análises, são implantados após a retirada de *spikes*.

Através da normalização são eliminadas as flutuações indesejadas da linha de base presentes nos sinais originais, as quais variam consideravelmente entre diferentes ocasiões. Essa normalização permite a justaposição e comparação precisa dos sinais, independentemente de suas características individuais. A Equação (3.5) apresenta a normalização utilizada:

$$s[n] = \frac{x[n] - \bar{x}}{\sigma} \quad (3.5)$$

onde $s[n]$ é o sinal normalizado na amostra n , $x[n]$ representa o sinal a ser normalizado, $\bar{x}$ é a média do sinal x e σ é o desvio padrão do sinal x .

Esse procedimento oferece os seguintes benefícios na análise:

- Comparabilidade: Permite a comparação precisa de diferentes sinais, mesmo com linhas de base distintas.
- Confiabilidade: Aumenta a confiabilidade das análises, eliminando o viés introduzido pelas flutuações da linha de base.
- Interpretabilidade: Facilita a interpretação dos resultados.
- Eficiência: Reduz o tempo e o esforço necessários em análise de sinais por eliminar a necessidade de pré-processamento manual para remover as flutuações da linha de base.

Abaixo, na Figura 32 é mostrado o sinal padronizado após a retirada de *spikes*.




Figura 32: Sinal padronizado após a retirada de *spikes*

Em seguida, no bloco 'JANELAMENTO', é realizada a detecção e separação do sinal através da variável *threshold* conforme indicado abaixo:

$$[|\text{sinalvet}[a1]| \geq \text{threshold}] \quad (3.6)$$

onde `sinalvet` é o vetor de sinal, `a1` é o índice atual e `threshold` é o valor limite.

Após a detecção, os pontos do sinal que excedem os limites predefinidos (*thresholds*) são utilizados como referências para a definição de janelas de análise. Para cada ponto acima do *threshold*, são considerados os valores de amostras que constituem um intervalo em torno desse ponto, tanto acima quanto abaixo. O tamanho do intervalo é definido por parâmetros específicos levando em consideração a origem da aquisição do sinal, no manual chega a 1500 amostras e na aquisição por veículo rodoferroviário 800 amostras.

O bloco subsequente, intitulado "DESCARTE DE JANELAS" desempenha um papel crucial na filtragem de dados. Ao assegurar que todos os valores de uma janela são positivos, o processo elimina ruídos provenientes de perturbações mecânicas, como os balanços da sonda. Essa medida é fundamental, pois oscilações positivas em todos os pontos de uma janela são associadas a interferências externas e não refletem as variações típicas do sinal, que são essenciais para a detecção de desgastes ou outras características relevantes nos trilhos. Dessa forma, a exclusão dessas janelas garante a qualidade dos dados utilizados nas etapas posteriores de análise. Portanto, se a condição for satisfeita, todos os valores na coluna são substituídos por zero e a janela é descartada. Este processo pode ser matematicamente representado como:

$$\text{Se } \forall j \in \{1, \dots, N\}, \text{filtered_sinalfinal}[j, i] > 0 \text{ então } \text{filtered_sinalfinal}[:, i] = 0$$

onde i se refere ao índice da janela, j é o índice da coluna atual e N é o número de amostras na matriz `filtered_sinalfinal`.

Em sequência, o método identifica as janelas que contêm uma quantidade de cruzamentos por zero maior que 1. O cruzamento por zero ocorre quando o produto de dois valores consecutivos das amostras é negativo, desta forma ocorrerá o descarte de janelas onde o cruzamento por zero ocorre apenas uma vez, esta situação se refere aos balanços ou oscilações laterais da sonda, não caracterizando oscilações de sinais a serem detectados. A condição para contar um cruzamento por zero pode ser expressa como:

$$\text{indices} = \left\{ x \mid \sum_{k=1}^{N-1} [\text{filtered_sinalfinal}[k, x] \cdot \text{filtered_sinalfinal}[k+1, x] < 0] > \text{zerocross} \right\}$$

onde `filtered_sinalfinal` é a matriz de janelas, x é o índice da janela, k é o índice da linha e `zerocross` é o número de cruzamentos por zero predefinido

O próximo passo é execução da CWT de cada sinal detectado. Na sequência é gerada a figura do Espectro de Potência (PS) dos sinais que irá alimentar a rede CNN. Nela foi definida a transformada com a *wavelet* 'cmor' (Figura 33) com 50 escalas e o tempo definido conforme o número de amostras dos sinais.




Figura 33: Wavelet - cmor

As equações (2.1) e (2.3) apresentam o cálculo da CWT e do PS do sinal.

Onde $|CWT(s, \tau)|^2$ representa a magnitude quadrada da CWT, C_s é a norma da wavelet na escala s , $f(t)$ é o sinal a ser analisado, $\psi_{s,\tau}(t)$ é a função wavelet mãe escalada e deslocada, s é o parâmetro de escala da wavelet e τ é o parâmetro de translação da wavelet.

O resultado do espectro de potência da CWT é representado na figura 34 abaixo:




Figura 34: Espectro de potência da CWT do sinal de uma junta.

Em "CNN-CLASSIFICA SINAIS" o processo de classificação começa com o cálculo do WPS dos sinais janelados detectados que são os dados de entrada da CNN. A imagem WPS é processada pela CNN conforme ilustrado pelo diagrama mostrado na Figura 35.




Figura 35: Arquitetura da Rede Neural Convolucional.

As CNNs têm se destacado como uma das principais arquiteturas para tarefas de visão computacional, como classificação de imagens, detecção de objetos e segmentação semântica [136]. A MiniVGGNet, onde *Visual Geometry Group Net* (VGGNet), utilizada para o processamento das imagens WPS, é uma variante simplificada da VGGNet, projetada para ser mais leve e eficiente, mantendo um desempenho competitivo em tarefas de classificação de imagens [137], motivo pelo qual foi escolhida dentre outras arquiteturas.

Esta arquitetura CNN é implementada para receber o escalograma gerado através de CWT como imagem de entrada, considerando largura e altura originais em sequência separadas em três camadas de cores RGB (um acrônimo para o sistema de cores aditivas que combina vermelho, verde e azul).

Esta CNN é composta por várias camadas que desempenham funções específicas para a extração de características e classificação de imagens. A primeira é uma camada convolucional com 32 filtros, cada um de tamanho 3×3 , cada um convoluindo sobre a imagem de dimensões 32×32 pixels para extrair características locais gerando uma saída de forma $(32, 32, 32)$ como bordas e texturas. Em seguida, há uma camada de *pooling* que reduz a dimensionalidade da imagem, resumindo as características mais importantes em regiões menores, diminuindo a complexidade computacional e ajudando a prevenir *overfitting*, reduzindo também a dimensionalidade espacial da saída anterior para $(16, 16, 32)$ usando uma operação com janela 2×2 .

A segunda camada convolucional possui 64 filtros de tamanho 3×3 , resultando em uma saída de forma $(16, 16, 64)$. Esta camada aprofunda a extração de características, capturando padrões mais complexos. Em seguida outra camada de *pooling* é implementada, reduzindo a saída para $(8, 8, 64)$ e a dimensionalidade espacial, mantendo

as características mais relevantes, para prevenir *overfitting*, uma camada *dropout* é adicionada, desligando aleatoriamente 25% dos neurônios.

A camada de *flatten* transforma a matriz 2D resultante em um vetor 1D, preparando os dados para a camada totalmente conectada, sendo essencial para conectar as camadas convolucionais às camadas densas.

A primeira camada densa (*Dense*) possui 512 neurônios responsáveis por aprender combinações não-lineares das características extraídas pelas camadas convolucionais. Para prevenir *overfitting*, uma camada *dropout* é adicionada, desligando aleatoriamente 50% dos neurônios durante o treinamento forçando a rede aprender características mais robustas e generalizáveis. Por fim, a última camada densa possui 4 neurônios, correspondendo ao número de classes de saída.

Ao final do processamento da CNN, o sinal é classificado como *squat*, solda, junta ou ruído que são as quatro classes consideradas neste trabalho.

A Figura 36 mostra exemplos das quatro classes divididas em duas colunas. De cima para baixo na coluna esquerda podem ser vistas imagens das classes solda e junta adquirido pelo EC, seguido por sua WPS e respectivamente na coluna da direita com *squat* e ruído. Os sinais indicados são amostras típicas de cada classe, porém podem ocorrer variações nos perfis do trilho, ou seja, imperfeições na forma do mesmo, indicando algumas oscilações adicionais nos sinais adquiridos, deixando as formas finais não tão diferentes entre si em alguns casos.




Figura 36: Amostras das classes considerando: *squat*, junta, solda e ruído apresentados na sequência do sinal adquirido EC e seu WPS.

A aquisição automática de dados via veículo rodoferroviário, exige a sincronização do sinal de GPS com os demais sinais detectados para uma análise precisa. A frequência de aquisição do GPS, neste caso, menor que a dos outros sinais, necessita de uma abordagem específica para garantir a correta associação dos dados. Os desafios da sincronização são:

- Frequências de aquisição diferentes: O GPS coleta dados em intervalos maiores que a sonda.
- Desalinhamento temporal. Poderá levar a um desalinhamento entre os pontos dos sinais e os valores de GPS.

Desta forma, a solução seria a proporcionalidade entre vetores, que trata da proporcionalidade entre o tamanho dos vetores de dados, o sinal de GPS é associado a localização dentro do vetor de sinal dos pontos de detecção do *threshold* de cada janela dos sinais detectados (1,2,..., N-1, N). Desta forma, são mostrados o início e o fim da aquisição do sinal e do GPS. Pelo fato de terem frequência de aquisição diferentes, ou seja, a frequência de aquisição do GPS ser menor do que o sinal da sonda, Figura 37, cada porcentagem do vetor de um sinal detectado, corresponde um ponto no vetor de GPS na mesma proporção. Essa relação garante que os pontos dos sinais sejam sincronizados com seus respectivos valores de GPS. Os benefícios da proporcionalidade são:

- Sincronização precisa entre os sinais e o GPS.
- Associação correta dos valores de GPS aos pontos dos sinais.
- Análise precisa e confiável dos dados coletados.




Figura 37: Gráfico da relação de aquisição sinal x GPS

O processo envolve a atribuição das coordenadas com os pontos onde os sinais são detectados. Isso é feito visando gerar um relatório final que não apenas indica a localização, mas também classifica e registra a velocidade de aquisição dos sinais. Este relatório fornece uma visão completa dos resultados alcançados, permitindo a análise minuciosa dos dados coletados, oferecendo uma compreensão profunda do processo, Figura 38.

Nome do Arquivo	Classificação	Latitude	Longitude	Velocidade(km/h)
teste6	solda	-21.73250002	-43.39483663	11.46
teste4	solda	-21.73246664	-43.39485663	11.63
teste2	squat	-21.73243332	-43.39488167	11.57
teste8	squat	-21.73243332	-43.394885	11.65
teste3	squat	-21.73241669	-43.39489833	11.65
teste5	squat	-21.73236662	-43.39492834	11.37
teste7	solda	-21.73231667	-43.39494997	11.65
teste1	solda	-21.73231667	-43.39495665	11.61
teste9	solda	-21.73224998	-43.39499834	11.52
teste10	squat	-21.73223335	-43.3950083	11.67

Figura 38: Relatório Final

4 RESULTADOS

Para validar o método proposto de detecção e identificação de defeitos superficiais nos trilhos, uma série de testes de campo foram realizados na ferrovia MRS Logística (empresa que detém a concessão ferroviária na região sudeste do Brasil). O dispositivo para conectar os sensores EC ao veículo de inspeção proposto no SVTS pode ser removido e usado manualmente. As aquisições foram realizadas através da indicação de suas respectivas localizações por especialistas de manutenção, com isso foi garantida a qualidade das amostras para a execução do modelo. Vale ressaltar que o acoplamento do EC com o trilho foi mantido de forma idêntica ao do veículo rodoferroviário, o que contribui para manter o comportamento do sinal para os dois tipos de aquisições.

As amostras para construção do modelo foram extraídas em aquisições manuais, uma vez que a aquisição por veículo rodoferroviário seria moroso em função de tempo de liberação de acesso aos trilhos, além da ocorrência de problemas logísticos inesperados que causam a retirada antecipada do veículo rodoferroviário da linha. Dentro deste contexto é importante ressaltar que estas aquisições são mais produtivas, pois o acesso não depende de autorização de veículos na linha e a localização das amostras, direcionadas pelas equipes de manutenção que normalmente ficam em trechos distintos, pode ser acessadas diretamente a pé, o que seria impossível acessar com o veículo pelo fato da licença de acesso ser em trechos restritos, tornando o processo impraticável.

Para melhor entendimento, a Figura 39 mostra a aquisição manual. Nela o suporte com a sonda é deslocado por um colaborador sobre a amostra com o apoio de um bastão, usado como alavanca de auxílio, todo o dispositivo de hardware está conectado à sonda de forma idêntica de conexão ao veículo rodoferroviário. O conjunto de dados resultante da aquisição manual e utilizado no treinamento dos modelos está disponível em [138].



Figura 39: Aquisição de amostras de forma manual

A seguir são enumeradas algumas características resultantes de aquisições em campo, abaixo na Figura 40(a) é mostrado o sinal adquirido com o suporte da sonda acoplado ao veículo rodoferroviário com um trecho indicado por um círculo preto. A aquisição nestes primeiros testes indicaram possíveis melhorias no acoplamento mecânico relativo ao amortecimento e pequenos deslocamentos laterais. A Figura 40(b), mostra o segmento do sinal indicado na figura anterior ampliado e a Figura 40(c) mostra entre as amostras 165000 e 169000, a ocorrência de um deslize lateral da sonda sobre os trilhos, caracterizado pela perturbação do nível dc em relação ao restante do sinal.




Figura 40: Sinal adquirido com veículo rodoferroviário em detalhes, a) Sinal original, b) Sinal indicado no sinal original com um círculo e c) Detalhe do trecho do sinal indicando deslizes laterais

Na Figura 41(a), no mesmo sinal da Figura anterior é indicado o deslocamento da sonda para fora do trilho, o sinal apresenta formas de degraus. A Figura 41(b) mostra a ocorrência de forma geral, enquanto a Figura 41(c) mostra a ocorrência com maior detalhamento.




Figura 41: Aquisição com veículo rodoferroviário deslizes laterais

A Figura 42 apresenta dois exemplos de sinais característicos de juntas, adquiridos com uma frequência de amostragem de 7,5 kHz. O sinal obtido do veículo é exibido na parte superior e o adquirido manualmente na parte inferior. Na aquisição do sinal pelo veículo rodoferroviário, devido à maior velocidade em relação à aquisição manual, considerando aproximadamente o início da junta na coordenada 205600 e seu fim em 205750, o número de amostras é de 150. Enquanto na aquisição manual, em uma velocidade de 7 km/h aproximadamente, considerando o início na amostra 1750 e o fim na amostra 2500, resulta em um comprimento de 750 amostras, portanto, 5 vezes maior. A reamostragem dos sinais resolve este problema, promovendo a uniformização de todos os janelamentos após a detecção. Os perfis dos sinais são consistentes; a variação na quantidade de amostras é a única distinção, atribuível à forma como os dados foram capturados, conforme evidenciado nos resultados.




Figura 42: Comparação entre aquisição de sinais. (a) Veículo. (b) Manual. Note que o sinal é similar em ambos os casos.

No processo, optou-se por utilizar amostras coletadas manualmente que foram transformadas em imagens através da transformada *wavelet* e, conforme descrito anteriormente, utilizadas na rede CNN. As amostras são de origens diversas e foram cuidadosamente selecionadas para garantir a representatividade e diversidade dos dados.

A Figura 43 apresenta um exemplo de gráfico que ilustra os dados das juntas. Este gráfico foi elaborado para proporcionar uma visualização clara e intuitiva dos dados, permitindo uma compreensão mais profunda das características e padrões presentes nas juntas.




Figura 43: Amostras de junta.

Na Figura 44 é exibida a amostra de uma junta, escolhida para representar as características típicas encontradas nas juntas. É importante notar que esta amostra, juntamente com todas as outras amostras desta classe e das outras classes, foram reamostradas para um total de 10000 amostras. Este processo de reamostragem foi realizado para garantir que cada classe esteja adequadamente representada no conjunto de dados.




Figura 44: Amostra de junta padronizada.

A escolha do tamanho das janelas foi determinada pela definição das variáveis de delay (Manual ou Automático) no início do código, conforme ilustrado na Figura 28.

Esse processo ocorreu de forma empírica à medida que o processamento era executado. A premissa adotada foi a de que, uma vez definido o valor da variável, deveríamos usar a forma de onda mais longa dentre as classes a serem classificadas como referência, de modo a abranger os demais tipos de sinais. Caso a janela fosse curta, sinais com mais amostras seriam limitados, o que poderia mascarar seu perfil. Por outro lado, uma janela maior conteria muitas amostras de perfis de trilhos lisos e regulares, que não são de interesse para o estudo, além de incluir amostras desnecessárias e aumentar o custo de processamento do código. Eventuais perdas de janelamento completo da anomalia ocorreram em casos onde seu excedeu o valor determinado pelo janelamento nas amostras, que são nas classes *solda* e *squats*. Para evitar esta ocorrência é necessário aumentar o valor da variável *delay* da janela. De qualquer forma, o tamanho da janela não foi alterado para que a maioria dos sinais adquiridos não contivesse mais pontos que não pertencessem ao sinal original.

A Tabela (4) indica a quantidade de amostras utilizadas para desenvolvimento do modelo.

Tabela 4: Total do Conjunto de Amostras

Tipo	Total
<i>Squat</i>	874
Junta	1348
Solda	1029

As amostras foram coletadas manualmente em trechos contendo os defeitos e características construtivas avaliadas, estes foram percorridos a pé em diferentes pontos da ferrovia.

4.1 LOCALIZAÇÃO DE DETECÇÃO DE DEFEITOS

O sistema embarcado para detecção e localização de defeitos de trilhos, baseado em sinais EC, foi extensivamente avaliado em testes de campo. Os resultados e a metodologia desses testes serão minuciosamente detalhados nesta seção.

A Figura 45 exibe um fragmento de sinal com aproximadamente 134 segundos de duração, adquirido a uma taxa de 7,5 kHz. Nela é ilustrado o processo de detecção e localização de defeitos. No gráfico superior, o sinal adquirido é representado em preto, enquanto o sinal filtrado é mostrado com círculos vermelhos e azuis, os quais

indicam os defeitos detectados. O eixo horizontal representa o número da amostra. Nos gráficos inferiores, são apresentadas versões ampliadas do sinal ao redor da amostra 3994 para uma melhor visualização. No gráfico à direita, o círculo azul localiza o carimbo GPS. Como mencionado anteriormente, a primeira etapa da detecção online envolve a remoção do offset do sinal, seguida pela aplicação do filtro mediano e do filtro *Heaviside*.




Figura 45: Um exemplo do processo de detecção de superfície de trilho. Na parte superior podemos ver um fragmento de sinal de cerca de 134 segundos amostrado em 7,5 kHz, onde o eixo horizontal indica o número da amostra. Os gráficos inferiores são versões de zoom do sinal. No gráfico à direita, o círculo azul indica a localização do registro GPS.

Após a detecção online do defeito, ou seja, do ponto de detecção (pico do sinal - *threshold*), uma janela com uma largura pré-determinada de 2000 amostras, em casos de aquisição manual, é selecionada ao redor deste ponto. Essas janelas de sinal são processadas pela CWT e então classificadas pela CNN.

4.2 CLASSIFICAÇÃO

A Tabela (5) mostra a quantidade de eventos por classe, usados no treinamento e teste da rede CNN nesta seção e em diversos métodos na próxima. A classe 'ruído' foi incorporada para considerar falsos positivos na detecção, ou seja, sinais sem defeitos superficiais que possam vir a ser apresentados ao classificador.

Para avaliar a CNN, utilizaremos a validação cruzada *K-fold* com 5 dobras. Esse

Tabela 5: Quantidade de eventos por classe

Qtde de Eventos	Classe
1348	Junta
1029	Solda
874	<i>Squat</i>
736	Ruído

método é amplamente reconhecido em aprendizado de máquinas por sua eficácia em avaliar o desempenho de modelos de maneira robusta, assegurando boa generalização. A técnica divide o conjunto de dados em K partes iguais, e neste caso, $K = 5$, como ilustrado na Figura 46. Em cada iteração, um subconjunto serve como conjunto de teste, enquanto os outros quatro são empregados para o treinamento do modelo. Com cinco iterações, obtemos uma estimativa mais confiável do desempenho do modelo em dados não vistos. A validação cruzada pode nos orientar na escolha dos hiperparâmetros que maximizam o desempenho médio, minimizando o risco de *overfitting* em um conjunto específico de dados.

Figura 46: Estratégia de *Cross Validation*.

Os dados foram utilizados na mesma quantidade da Tabela (5), portanto não houve criação de amostras sintéticas para balanceamento para em seguida serem divididos em 5 conjuntos. O critério utilizado no treinamento do modelo da CNN e no modelo da validação dos demais métodos de classificação, que serão mostrados nos próximos parágrafos, foi o mesmo, ou seja, *StratifiedKFold*. Este método introduz uma aleatoriedade controlada que garante a representatividade das classes, evitando a divisão puramente aleatória, onde cada amostra teria a mesma chance de ir para o conjunto de treino ou teste, sem qualquer consideração pelas classes, isso levaria a avaliações de modelo menos confiáveis, pois o modelo poderia ser testado em conjuntos que não representam bem a distribuição real das classes. Com este método, as avaliações de modelo mais robustas e confiáveis e a preservação da distribuição das classes em cada subconjunto é priorizada. A Tabela (6) mostra a quantidade de eventos de teste em cada partição.

A quantidade de amostras de classes em cada partição foi definida pelo algoritmo das partições, mantendo a proporcionalidade da estratégia de *Cross Validation*.

Tabela 6: Tabela de Dados - Treinamento por Partição

Classe	partição 1	partição 2	partição 3	partição 4	partição 5
Junta	288	260	262	281	258
Ruído	145	154	138	133	166
Solda	200	199	216	206	208
<i>Squat</i>	165	185	182	177	165
Total	798	798	798	797	797

O desenvolvimento do modelo da CNN foi feito através da iteração nas partições do método *K-fold*, divididos em conjuntos de treino (4 partições) e teste (1 partição) e treinados por até 100 épocas. A cada iteração, um novo modelo MiniVGGNet é construído e treinado com os dados da partição atual. A parada antecipada foi utilizada para interromper o treinamento se não houver melhoria na eficiência por 10 épocas consecutivas, restaurando os pesos que resultaram na melhor acurácia.

Após o treinamento, o modelo é avaliado com os dados de teste. As previsões do modelo são comparadas com os rótulos verdadeiros para o cálculo da acurácia.

A Figura 47 exibe a matriz de confusão para o conjunto de teste de cada partição. Os valores localizados na diagonal principal indicam classificações corretas, enquanto aqueles fora da diagonal representam erros. A avaliação das matrizes relativas às cinco partições revela uma alta eficiência global da CNN, além de um bom equilíbrio entre as classes.




Figura 47: Matriz Confusão para o conjunto de teste em cada dobra para a CNN.

As matrizes de confusão fornecem informações detalhadas sobre o desempenho do modelo, destacando verdadeiros positivos, falsos positivos, verdadeiros negativos e falsos negativos para cada classe. Ao examiná-las, percebe-se que as dobras 5 e 4 apresentaram os melhores resultados, enquanto a primeira dobra teve o pior desempenho, embora próximo ao das demais. A Tabela (7) mostra a acurácia para cada conjunto de teste e revela um valor médio de 98 ± 1 %, destacando a boa eficiência do método sugerido.

Tabela 7: Acurácia da CNN para cada conjunto de teste.

dobra 1	dobra 2	dobra 3	dobra 4	dobra 5	Acurácia Média
95,6%	98,0%	98,2%	97,6%	98,9%	$98,0 \pm 1,0$ %

4.2.1 COMPARAÇÃO COM OUTROS MÉTODOS

Nesta seção, conduzimos uma análise comparativa empregando uma variedade de métodos de classificação comumente mencionados na literatura acadêmica. A lista apresentada é diversificada e completa, incorporando uma gama de técnicas estabelecidas e amplamente adotadas em vários campos de pesquisa. Esta seleção de métodos visa cobrir um espectro diversificado de abordagens de classificação – desde modelos baseados em instâncias *K-Nearest Neighbors* (KNN), passando por modelos interpretáveis *Decision Tree* (DT), ensembles robustos *Random Forest* (RF) e *Extra Trees* (ET), até redes neurais flexíveis *Multilayer Perceptron* (MLP) e modelos estatísticos com premissas de distribuição *Análise Discriminante Quadrática* (QDA). Essa diversidade permite não apenas identificar o modelo de melhor desempenho, mas também compreender as razões por trás de sua eficácia, fornecendo percepções valiosas sobre a natureza do problema e as características dos dados.

Inicialmente, temos o KNN, que é um algoritmo de aprendizado supervisionado baseado em instâncias que classifica novas instâncias com base na semelhança com as instâncias existentes [139]. Aqui nomeado de KNN.

A DT e o ET, são algoritmos de aprendizado de máquina que utilizam uma estrutura de árvore para representar uma série de possíveis caminhos de decisão e seus resultados. A RF, é um algoritmo que combina várias árvores de decisão, construindo-as durante o treinamento e, para classificar uma nova instância, agrega as previsões das árvores individuais [140].

O MLP é uma rede neural artificial com múltiplas camadas de nós em uma direção

acíclica. O QDA é um classificador que utiliza a probabilidade Bayesiana e supõe que as medições para cada classe são distribuídas conforme a distribuição gaussiana [140].

Foram utilizados os mesmos dados que geraram a transformada *wavelet* das imagens da CNN, a Figura 48 apresenta o dataset já normalizado e padronizado através da reamostragem para 10000 pontos cada linha, onde cada linha representa uma classe identificada na coluna "TARGET". As classes são numeradas respectivamente por valores de "TARGET" de 1 a 4.

	0	1	2	3	4	5	6	7	8	9	...	9991	9992	9993	9994	9995	9996	9997	9998	9999	TARGET
0	0.087970	0.087970	0.132456	0.132456	0.132456	0.132456	0.132456	0.132456	0.132456	0.132456	...	0.755266	0.755266	0.755266	0.755266	0.755266	0.799752	0.799752	0.799752	0.799752	1
1	-0.413294	-0.413294	-0.413294	-0.413294	-0.413294	-0.413294	-0.413294	-0.413294	-0.413294	-0.413294	...	2.303835	2.303835	2.303835	2.303835	2.303835	2.303835	2.258550	2.258550	2.258550	1
2	0.421249	0.421249	0.421249	0.421249	0.421249	0.421249	0.421249	0.386718	0.386718	0.386718	...	-0.580149	-0.580149	-0.580149	-0.580149	-0.580149	-0.614680	-0.614680	-0.614680	-0.614680	1
3	0.308420	0.308420	0.308420	0.308420	0.308420	0.308420	0.308420	0.308420	0.308420	0.308420	...	1.322789	1.322789	1.322789	1.322789	1.322789	1.322789	1.322789	1.322789	1.300737	1
4	-0.256639	-0.256639	-0.256639	-0.256639	-0.227561	-0.227561	-0.198483	-0.198483	-0.198483	-0.198483	...	-0.285717	-0.285717	-0.285717	-0.285717	-0.285717	-0.285717	-0.285717	-0.285717	-0.285717	1
5	0.768464	0.768464	0.768464	0.768464	0.768464	0.768464	0.768464	0.768464	0.768464	0.768464	...	1.167656	1.167656	1.167656	1.167656	1.191138	1.191138	1.191138	1.191138	1.191138	1
6	0.035912	0.035912	0.035912	0.065592	0.065592	0.065592	0.065592	0.065592	0.065592	0.065592	...	0.926293	0.926293	0.926293	0.926293	0.955973	0.955973	0.955973	0.955973	0.955973	1
7	-0.051010	-0.051010	-0.051010	-0.051010	-0.051010	-0.051010	-0.051010	-0.051010	-0.051010	-0.051010	...	2.303835	2.303835	2.303835	2.303835	2.303835	2.303835	2.303835	2.303835	2.303835	1
8	0.205858	0.205858	0.205858	0.205858	0.205858	0.205858	0.205858	0.205858	0.205858	0.224671	...	-1.073398	-1.073398	-1.073398	-1.092211	-1.092211	-1.092211	-1.092211	-1.092211	-1.092211	1
9	-0.969192	-0.969192	-0.969192	-0.969192	-0.992674	-0.992674	-0.992674	-0.992674	-1.016156	-1.016156	...	0.087491	0.087491	0.087491	0.087491	0.087491	0.087491	0.087491	0.087491	0.087491	1

10 rows x 10001 columns

Figura 48: Dataset utilizado nos métodos comparativos propostos.

Neste sentido foi utilizada novamente a técnica *K-fold* de validação cruzada com $K = 5$.

A Tabela 8 mostra um resumo das métricas de *F1-score*, *Recall* e *Precision* para os seis classificadores avaliados, revelando a superioridade consistente do modelo *Extra Trees*, que obteve os melhores resultados em todas as métricas. Este desempenho robusto sugere melhor capacidade de generalização e um equilíbrio otimizado entre a detecção de instâncias positivas e a precisão das previsões. Os algoritmos de ensemble, como RF e ET, demonstraram grande eficácia, superando métodos como a DT e QDA, que apresentou o desempenho mais baixo, indicando limitações em sua capacidade de modelar as relações complexas dos dados. O MLP e o KNN exibiram desempenhos competitivos, porém não superaram a ET.

Tabela 8: Comparação de Métricas de Desempenho dos Modelos

Modelo	F1-score	Recall	Precision
DT	0.799	0.8049	0.8053
ET	0.9307	0.9322	0.9298
MLP	0.8681	0.8687	0.8686
KNN	0.8514	0.8586	0.8766
QDA	0.6257	0.6398	0.7361
RF	0.8346	0.8367	0.8374

O resultado das matrizes confusão dos métodos são apresentados na Figura 49, onde são mostradas as médias das matrizes confusão de cada um dos 6 métodos. Podemos notar que o resultado de ET 5 obteve uma quantidade menor de amostras fora da diagonal principal, como também falsos negativos, representados pelas células na linha horizontal, além de menos falsos positivos representados pelas células na linha vertical.



Figura 49: Resultados médios dos métodos após o gridsearching.

A Tabela (9) apresenta os resultados de cada método em relação a cada *fold* na coluna "partição" e a acurácia média.

Os resultados das partições para os cinco métodos de classificação apresentados mostram variações significativas em termos de acurácia média e seu desvio padrão. O classificador Vizinho mais Próximo apresentou uma acurácia média de 85,1%, variando de 83,2% a 87,0% nas diferentes partições da validação cruzada. O desvio padrão de 1,3% indica uma consistência razoável entre as partições, sugerindo que o modelo é relativamente estável, embora com algumas flutuações no desempenho.

Tabela 9: Resultados dos Classificadores (%)

	partição 1	partição 2	partição 3	partição 4	partição 5	Acurácia Média
KNN	83,2%	84,5%	87,0%	84,7%	86,3%	85,1 $\pm$ 1,3%
DT	81,5%	81,2%	79,2%	79,9%	80,6%	80,5 $\pm$ 0,8%
ET	93,5%	93,7%	93,0%	94,7%	92,8%	93,6 $\pm$ 0,7%
RF	84,3%	83,7%	83,2%	85,3%	85,4%	84,4 $\pm$ 0,9%
MLP	87,5%	90,0%	89,1%	87,8%	87,8%	88,4 $\pm$ 0,9%
QDA	55,5%	62,0%	56,8%	56,6%	57,5%	57,7 $\pm$ 2,3%

A DT apresentou uma acurácia média de 80,5%, com resultados variando entre 79,2% e 81,5% nas diferentes partições da validação cruzada. O baixo desvio padrão de 0,8% indica uma boa consistência entre as partições, sugerindo que o modelo é relativamente estável. No entanto, a acurácia média, a mais baixa entre os métodos avaliados, sugere que a DT pode não estar capturando adequadamente a complexidade dos dados, sofrendo possivelmente de sub-ajuste.

O modelo ET destacou-se com a maior acurácia média, atingindo 93,6%, com resultados que variaram de 92,8% a 94,7% nas diferentes partições da validação cruzada. O baixo desvio padrão de 0,7% sugere alta consistência e robustez, indicando que o modelo é uma escolha confiável para este conjunto de dados.

A RF apresentou uma acurácia média de 84,4%, com variações entre 83,2% e 85,4%. O desvio padrão de 0,9% indica uma boa consistência, embora ligeiramente inferior ao Extra Trees, possivelmente devido à menor profundidade das árvores.

A MLP teve uma acurácia média de 88,4%, variando de 87,5% a 90,0%. O desvio padrão de 0,9% mostra que o modelo é relativamente consistente. Finalmente, o QDA apresentou a menor acurácia média de 57,7%, com variações significativas entre 55,5% e 62,0%. O desvio padrão de 2,3% indica uma alta variabilidade, sugerindo que o modelo pode não ser adequado para este conjunto de dados.

Diante dos resultados obtidos, podemos concluir que os modelos ET e MLP se destacaram como os mais eficazes e consistentes, apresentando as maiores acurácias médias e os menores desvios padrão. Em contrapartida, o modelo QDA demonstrou menor confiabilidade neste cenário.

A Tabela (10) mostra os resultados da rede CNN e os demais métodos tratados em ordem decrescente de acurácia. Nela é possível notar que a CNN teve a melhor acurácia média (98,0 $\pm$ 1,0%), seguido por Extra Trees (93,6 $\pm$ 0,7%) e MLP (88,4 $\pm$ 0,9%).

A escolha do emprego de um conjunto robusto de métricas de avaliação, compreendendo *Precision*, *Recall* e *F1-score*, além da acurácia global, não se trata de uma redundância metodológica, mas sim da necessidade para assegurar a completude e a validade da análise de desempenho de modelos de classificação. Embora o modelo ET tenha demonstrado consistentemente o melhor desempenho em todas as métricas avaliadas, incluindo a acurácia, essa observação dos efeitos às causas não invalida a prerrogativa metodológica de uma avaliação multifacetada. A acurácia, por sua natureza agregada, pode ser enganosa em cenários com desbalanceamento de classes, onde um modelo pode exibir alta acurácia simplesmente por prever majoritariamente a classe dominante, falhando em identificar corretamente as instâncias da classe minoritária, frequentemente a de maior interesse prático, porém a apresentação detalhada das demais métricas valida a robustez de sua superioridade, confirmando que seu alto desempenho não é um artefato de uma distribuição enviesada, mas sim o reflexo de uma capacidade genuína de classificar com precisão e abrangência em todas as classes, fortalecendo as conclusões e a generalização.

Diante dos resultados apresentados, podemos concluir que a CNN se destaca como o classificador com o melhor desempenho, superando os demais modelos avaliados. Essa constatação valida a hipótese inicial da pesquisa, que propunha a combinação da Transformada *Wavelet* com a CNN como uma abordagem promissora para o problema em questão, explorando a capacidade da CWT de extrair informações relevantes dos dados e da CNN de classificar esses padrões de forma eficaz.

Tabela 10: Resumo dos comparativo resultados dos Classificadores e CNN

Classificador	$\mu \pm \sigma$
CNN	$98,0 \pm 1,0\%$
ET	$93,6 \pm 0,7\%$
MLP	$88,4 \pm 0,9\%$
KNN	$85,1 \pm 1,3\%$
RF	$84,4 \pm 0,9\%$
DT	$80,5 \pm 0,8\%$
QDA	$57,7 \pm 2,3\%$

4.3 COMPARAÇÃO DOS RESULTADOS COM A LITERATURA

Nesta seção, apresentaremos uma comparação crítica dos resultados da pesquisa com os encontrados em outros estudos relevantes na área. O objetivo é contextualizar os resultados da tese no panorama científico atual, destacando suas similaridades,

diferenças e implicações.

4.3.1 METODOLOGIA

Para realizar a comparação, serão utilizados os seguintes critérios:

- Metodologia de pesquisa: Abordagens metodológicas utilizadas nos estudos comparados.
- Resultados obtidos: Principais resultados e conclusões de cada estudo.
- Análise comparativa: Discussão das similaridades e diferenças entre os resultados da tese e os da literatura.

4.3.2 COMPARAÇÕES

O trabalho de Yilmaz et al.[141], aborda um tema de alta relevância prática e industrial, posicionando o trabalho na pesquisa em inspeção automatizada de infraestruturas ferroviárias, seu principal ponto forte de potencial impacto na segurança operacional e na otimização da manutenção preditiva. O uso de técnicas de deep learning reflete uma abordagem metodológica promissora para problemas de detecção visual complexos. Entretanto, a generalidade da menção a "técnicas de deep learning" no título sugere falta de especificidade quanto às arquiteturas neurais ou contribuições metodológicas originais propostas, o que poderia indicar uma limitação em termos de inovação algorítmica. Além disso, a robustez e a generalização de tais sistemas são frequentemente contingentes à qualidade e diversidade do conjunto de dados de treinamento, bem como à validação em condições operacionais variadas (e.g., iluminação, ruído), aspectos que o resumo e o título não detalham, que podem representar pontos fracos ou lacunas para a aplicação em cenários reais.

O artigo de Choi et al. [142], destaca-se pela aplicação de uma arquitetura específica e reconhecida de deep learning, a *Fast R-CNN*, para a detecção de defeitos em superfícies de trilhos. Essa escolha metodológica confere ao trabalho um ponto forte significativo, pois demonstra a utilização de uma técnica de última geração no campo da visão computacional para um problema de elevada importância prática na manutenção ferroviária. A especificidade do método empregado sugere uma abordagem focada e potencialmente eficaz para a tarefa de avaliação de defeitos. Contudo, as possíveis limitações do estudo, inferidas pelo título, podem residir na abrangência dos "defeitos de superfície", que podem variar em natureza e complexidade, e na generalização

para condições operacionais adversas (e.g., diferentes iluminações, sujeiras, velocidade de inspeção) que não são explicitamente abordadas. Além disso, a contribuição do trabalho pode ser primariamente aplicativa, com a necessidade de uma análise mais aprofundada da originalidade na adaptação do *Fast R-CNN* ou na proposta de um novo framework comparativo com outras arquiteturas para validação.

O artigo de Dong et al.[143] aborda um desafio de alta relevância na área END: a avaliação quantitativa do tamanho de defeitos em testes por correntes parasitas. A escolha metodológica de empregar a transformada *wavelet* para processamento de sinal e o realce por pseudocores para visualização é um ponto forte notável, indicando uma abordagem técnica específica e potencialmente eficaz para aprimorar a detecção e, principalmente, a caracterização de defeitos. A ênfase na avaliação do tamanho eleva a contribuição do trabalho além da mera detecção, oferecendo uma capacidade de quantificação valiosa para a manutenção preditiva. No entanto, uma potencial limitação do estudo pode residir na ausência de uma comparação explícita com outras técnicas de processamento de sinal ou de *machine learning* que também poderiam ser aplicadas à avaliação do tamanho de defeitos em ECT, o que restringiria a contextualização do avanço proposto. Adicionalmente, a robustez dessas técnicas em cenários reais com ruído, variabilidade de materiais e condições operacionais diversas do ECT necessitaria de validação aprofundada, aspectos que não são detalhados.

O estudo de [144] também utiliza a transformada wavelet com sondas diferenciais, de forma semelhante à presente tese. O trabalho conclui sobre a imunidade das sondas, mas enfrenta dificuldades na modelagem do ruído devido ao uso de amostras artificiais. Além disso, não apresenta resultados voltados a aplicações em ambientes reais, uma vez que se trata de um estudo de avaliação de métodos não destrutivos. A similaridade entre os trabalhos reside no emprego da transformada wavelet com sondas diferenciais; as diferenças estão no fato de que a presente tese utiliza dados reais e se concentra na aplicação em ambientes reais, enquanto [144] utiliza amostras artificiais e foca na avaliação de métodos.

O trabalho de [145] propõe um sistema de monitoramento de trilhos que utiliza um acelerômetro instalado na roda do vagão para detectar imperfeições. O sistema utiliza a análise da potência média da wavelet para diferenciar entre squats leves e severos, com uma taxa de acerto de 78% para squats leves e 15% de alarmes falsos. As similaridades se dão pelo fato de ambos os trabalhos utilizam a análise da wavelet. As diferenças são que em [145] o estudo é focado na detecção de squats leves e severos e a presente tese visa a um diagnóstico mais abrangente de imperfeições nos trilhos. Desta

forma, apesar de [145] propor uma solução prática, ainda não é possível detectar com precisão satisfatória, squats leves comparativamente ao índice apresentado no trabalho desta tese.

O trabalho de [145] propõe um sistema de monitoramento de trilhos que utiliza um acelerômetro instalado na roda do vagão para detectar imperfeições. O sistema utiliza a análise da potência média da wavelet para diferenciar entre squats leves e severos, com uma taxa de acerto de 78% para squats leves e 15% de alarmes falsos. Ambos os trabalhos compartilham o uso da análise de wavelet. No entanto, enquanto Molodova et al. (2013) focam na detecção de squats leves e severos, a presente tese visa um diagnóstico mais abrangente de imperfeições nos trilhos. Dessa forma, embora [145] proponham uma solução prática, a precisão na detecção de squats leves (78%) é bastante inferior à alcançada no presente trabalho, que apresenta um índice de acerto superior.

Em Miao et al.[146], o autor apresenta um método de detecção usando uma rede CNN com imagens de escória, fissuras e buracos nos trilhos geradas por laser 3D convertidas em 2D. A classificação obteve o melhor resultado com uma rede VGG16 que alcançou uma precisão de 97%. Estudos de outros modelos ficaram como melhorias em [146]. Em comparação aos resultados obtidos com o atual estudo, com a técnica de aquisição não ser a mesma adotada, seu resultado ficou um pouco abaixo do alcançado com sondas de eddy current, além disso, é possível considerar que sinais provenientes de eddy current possibilitam trabalhos futuros para predição de profundidade dos RCFs detectados, o que não é possível conseguir com análise de imagens 2D.

Em Miao et al.[146], os autores apresentam um método de detecção de defeitos em trilhos utilizando uma CNN e imagens 2D, obtidas a partir de dados 3D gerados por laser. A melhor precisão alcançada foi de 97%, utilizando a arquitetura VGG16. O estudo também sugere o desenvolvimento de outros modelos como melhorias futuras. Comparando com os resultados obtidos no presente estudo, que utiliza uma técnica de aquisição diferente (sondas de correntes parasitas), observa-se que o desempenho alcançado com as sondas é ligeiramente superior. Adicionalmente, os sinais provenientes de correntes parasitas possibilitam a predição da profundidade dos RCFs detectados, o que não é possível com a análise de imagens 2D.

Em Cho et al.[101], os autores utilizaram sinais de acelerômetros instalados no trem para detectar irregularidades nos trilhos, analisando a frequência de *squats* por meio da transformada *wavelet*. Os resultados alcançaram uma precisão de 88,2%, com 10,5%

de falsos alarmes, desempenho inferior ao estudo apresentado nesta tese, que obteve precisão superior a 98%. Adicionalmente, o estudo é preliminar e não possui aplicação prática.

Em Kwon et al.[103], os autores utilizam um dispositivo de inspeção por correntes parasitas com um arranjo de 16 canais para inspeção manual de trilhos a velocidades de até 2 km/h. A partir dos dados coletados, é gerada uma imagem que representa os valores dos 16 canais, na qual picos de sinal são analisados para estimar a profundidade de desgastes. Embora ambos os estudos utilizem o método de detecção por correntes parasitas, o trabalho de [103] se diferencia por utilizar um arranjo com maior número de canais e por comparar os sinais 2D com dados 3D, alcançando uma precisão de ± 1 mm na estimativa da profundidade. Adicionalmente, o estudo não automatiza o processo de detecção e classificação de anomalias, diferentemente da proposta apresentada nesta tese.

5 CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho apresenta um sistema embarcado inovador para detecção e identificação de defeitos superficiais em trilhos ferroviários, representando um avanço significativo na área de manutenção preditiva. A solução proposta não apenas mapeia os defeitos, mas também otimiza o processo de manutenção, oferecendo vantagens tangíveis para a indústria ferroviária.

A principal inovação deste trabalho reside na sua abordagem prática e foco na aplicação direta em ambiente real. Diferentemente de estudos anteriores que se basearam em simulações de laboratório [145, 146, 147], este sistema foi testado em condições reais de operação, com dados coletados em campo sob a supervisão de especialistas em manutenção ferroviária. Essa validação em ambiente real garante a relevância e aplicabilidade dos resultados para a indústria.

O sistema embarcado proposto oferece uma série de benefícios práticos para a manutenção ferroviária:

- Otimização do processo de retificação: Ao mapear os defeitos com precisão, o sistema permite que a retificação corretiva seja direcionada apenas para as áreas afetadas, evitando desgastes desnecessários e prolongando a vida útil dos trilhos.
- Agilidade na manutenção: A identificação rápida e precisa dos defeitos permite que a manutenção seja realizada de forma mais ágil, reduzindo o tempo de interdição da linha férrea, minimizando os impactos na operação ferroviária.
- Facilidade de incorporação: O sistema é projetado para ser facilmente integrado em qualquer veículo de inspeção ferroviária, tornando-o uma ferramenta versátil e acessível para diferentes operadoras ferroviárias.
- Robustez e facilidade de operação: Os componentes do sistema são robustos e de fácil operação, permitindo a realização de inspeções periódicas com agilidade e eficiência.

- Avanços Técnicos e Metodológicos. Além da sua aplicação prática, o trabalho também apresenta avanços técnicos e metodológicos relevantes:
 - Combinação inovadora de técnicas: O método proposto combina uma CNN com a Transformada *Wavelet* como ferramenta de pré-processamento, resultando em maior acurácia e precisão na detecção de defeitos em comparação com outros métodos avaliados.
 - Superação das limitações de dados: Apesar das limitações na aquisição de grandes conjuntos de dados e diferentes tipos de anomalias, o estudo demonstrou a eficácia do sistema com dados coletados manualmente em campo, evidenciando seu potencial para aplicações em cenários reais.

Abaixo são pontuados os próximos passos:

- Melhoria do acoplamento da sonda: O aprimoramento do acoplamento da sonda com o trilho pode aumentar a flexibilidade do sistema e permitir a detecção de defeitos em diferentes tipos de trilhos e condições de operação.
- Avaliação para diferentes anomalias: A avaliação do método proposto para outros tipos de anomalias na superfície do trilho pode ampliar sua aplicabilidade e torná-lo uma ferramenta ainda mais completa para a manutenção ferroviária.
- Estimativa de profundidade e comprimento: A capacidade de estimar a profundidade e o comprimento das anomalias pode fornecer informações mais detalhadas sobre a gravidade dos defeitos, auxiliando na tomada de decisões mais assertivas sobre as ações de manutenção.

Em resumo, este estudo não só contribui para o avanço tecnológico na detecção de defeitos em trilhos ferroviários, como também estabelece um novo padrão de aplicação prática na área, com resultados que beneficiam diretamente a manutenção e operação do sistema ferroviário.

REFERÊNCIAS

- 1 SAHA, S. *A Comprehensive Guide to Convolutional Neural Networks — the ELI5 way*. [S.l.]: Towards Data Science (Medium), 2018. <<https://ise.ncsu.edu/wp-content/uploads/sites/9/2022/08/A-Comprehensive-Guide-to-Convolutional-Neural-Networks-%E2%80%94-the-ELI5-way--by-Sumit-Saha--Towards-Data-Science.pdf>>. Acessado em: 23 de julho de 2025.
- 2 VARSHNEY, P. *VGGNet-16 Architecture: A Complete Guide*. [S.l.]: Kaggle. <<https://www.kaggle.com/code/blurredmachine/vggnet-16-architecture-a-complete-guide>>.
- 3 DECROOS, K. *Assessment report on suitable methods for structural integrity inspection of embedded girder rails*. [S.l.]: Predictive Maintenance employing Non-intrusive Inspection and Data Analysis, 2009. 1-100 p.
- 4 Modal Connection. *Investimento em terminais são gargalos do setor ferroviário*. 2023. Disponível em: <<https://modalconnection.com.br/artigos/investimento-em-terminais-sao-gargalos-do-setor-ferroviario/>>.
- 5 ANTT. *Agência Nacional de Transportes Terrestres*. 2020. Disponível em: <<https://www.antt.gov.br>>.
- 6 SILVA, R. D.; SILVA, G.; SILVA, M. D. Transporte ferroviário de cargas no brasil: panorama, desafios e perspectivas. *Revista de Logística e Transportes*, v. 1, p. 1–15, 2021.
- 7 AMARAL, G.; ARAÚJO, J. D. Análise do transporte ferroviário no brasil. *Revista de Engenharia e Tecnologia*, v. 10, n. 1, p. 14–23, 2018.
- 8 SILVA, E.; OLIVEIRA, F. D. Investimentos em infraestrutura ferroviária no brasil. *Revista de Administração e Negócios*, v. 9, n. 2, p. 10–25, 2020.
- 9 CÁSSIA, M.; SOUZA, C. D. Tecnologia e inovação no setor ferroviário brasileiro. *Revista de Engenharia e Tecnologia*, v. 12, n. 1, p. 30–41, 2020.
- 10 ANDRADE, A. R.; DEKKER, R.; FIOOLE, P.-J. Railway infrastructure maintenance: A survey of planning models. *European Journal of Operational Research*, Elsevier, v. 264, n. 3, p. 931–950, 2017.
- 11 ZHAO, J.; CHAN, A. H.; BURROW, M. P. Reliability analysis of railway systems: a review. *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit*, SAGE Publications Sage UK: London, England, v. 230, n. 4, p. 1083–1101, 2016.
- 12 ESVELD, C. *Modern railway track*. [S.l.]: MRT-Productions, 2001.

- 13 LI, Z.; LUO, X.; ZHANG, W.; ZHOU, W. Railway track inspection and maintenance: A literature review. *Journal of Traffic and Transportation Engineering (English Edition)*, Elsevier, v. 2, n. 5, p. 351–365, 2015.
- 14 SAMUELSSON, J.; STENSTRÖM, C. Maintenance management in the railway sector: a framework for planning and scheduling. *Journal of Quality in Maintenance Engineering*, Emerald Group Publishing Limited, v. 22, n. 3, p. 218–235, 2016.
- 15 ALVARENGA, T. A.; CERQUEIRA, A. S.; NOBREGA, R. A.; HONORIO, L. M.; VELOSO, H. et al. Identification and localization of track circuit false occupancy failures based on frequency domain reflectometry. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 20, n. 24, p. 7259, 2020.
- 16 MRS Logística. *Ultrassom: Um super aliado na prevenção de acidente*. Disponível em: <<https://www.youtube.com/watch?v=QBELYv23nrqg>>.
- 17 UDPA, L.; UDPA, S. S. Eddy current nondestructive evaluation. *Encyclopedia of Materials: Science and Technology*, Elsevier, p. 2569–2575, 2004.
- 18 MOOK, G.; BOLLER, C. Advanced signal processing and artificial intelligence techniques for eddy current non-destructive testing and evaluation. *Insight-Non-Destructive Testing and Condition Monitoring*, SAGE Publications Sage UK: London, England, v. 59, n. 4, p. 190–196, 2017.
- 19 ROSADO, L.; PESSOA, J.; RAMOS, H. Eddy current testing signal analysis using wavelet transform and artificial neural networks. *Journal of Nondestructive Evaluation*, v. 35, n. 3, p. 41, 2016.
- 20 CHADY, T.; MOCZKO, P.; SIKORA, R. Application of eddy current testing in the diagnosis of railway infrastructure. *Diagnostyka*, v. 20, n. 1, p. 25–31, 2019.
- 21 JOLICOEUR, S.; LESSARD, S. Eddy current testing of rail track. *Insight-Non-Destructive Testing and Condition Monitoring*, British Institute of Non-Destructive Testing, v. 61, n. 3, p. 144–151, 2019.
- 22 MOOSAVI, S. A. et al. Eddy current non-destructive testing: a review. *Journal of Nondestructive Evaluation*, v. 39, n. 2, p. 1–15, 2020.
- 23 ZHANG, S.; WANG, X.; GAO, H.; PENG, Y. Deep learning for crack detection in railway tracks. *IEEE Access*, v. 7, p. 95945–95955, 2019.
- 24 YANG, G.; ZHANG, W. Wavelet and deep learning techniques for crack detection in railway tracks. *Insight-Non-Destructive Testing and Condition Monitoring*, v. 59, n. 1, p. 18–25, 2017.
- 25 LIU, Z.; DU, J.; LIU, S.; SUN, J.; XU, X. Eddy current pulsed thermography with artificial neural networks for quantitative evaluation of cracks in ferromagnetic materials. *NDT and E International*, v. 105, p. 1–10, 2019.
- 26 JOLICOEUR, M. Calibration in eddy current testing. *Insight-Non-Destructive Testing and Condition Monitoring*, British Institute of Non-Destructive Testing, v. 61, n. 1, p. 15–21, 2019.

- 27 MOOSAVI, A.; LI, X. Eddy current testing signals: challenges and opportunities. *Materials Evaluation*, American Society for Nondestructive Testing, v. 78, n. 1, p. 73–84, 2020.
- 28 NIU, C.; LI, X. Recent advances in eddy current testing technology. *Journal of Nondestructive Evaluation*, Springer, v. 39, n. 1, p. 1–15, 2020.
- 29 NIU, H. et al. The application of eddy current testing technology in non-destructive testing of rail. *Journal of Physics: Conference Series*, v. 1529, n. 1, p. 012102, 2020.
- 30 YI, J.; LIU, Y.; TIAN, G. Y. Real-time detection of railroad defects based on gabor filter and svm. *Journal of Intelligent Transportation Systems: Technology, Planning, and Operations*, Taylor and Francis, v. 21, n. 6, p. 529–539, 2017.
- 31 THOMAS, P.; ZHU, Y. Non-destructive testing techniques for rail track—a review. *Insight-Non-Destructive Testing and Condition Monitoring*, Emerald Group Publishing Limited, v. 49, n. 1, p. 25–32, 2007.
- 32 LI, Y.; REN, J.; HE, X. The development of a rail surface crack detection system based on machine vision technology. *Measurement*, Elsevier, v. 93, p. 85–95, 2016.
- 33 TEIXEIRA, J. *Justiça absolve réus do descarrilamento que matou oito pessoas em Rio Preto*. 2022. Disponível em: <<https://www.diariodaregiao.com.br/cidades/riopreto/justica-absolve-reus-do-descarrilamento-que-matou-oito-pessoas-em-rio-preto-1.1005770>>.
- 34 LANDIM, M. Visão computacional aplicada à inspeção em amv com drone. In: *30ª Semana de Tecnologia Metroferroviária*. [s.n.], 2024. Disponível em: <https://semanadetecnologia.com.br/30semana/files/artigos/799_artigo_iaparainspecaoferroviaria.pdf>.
- 35 LOGÍSTICA, M. Permanent plan master plan 2018-2022 mrs: Internal documents - pdv via permanente 2018-2022 mrs. In: . [S.l.: s.n.], 2018.
- 36 (ASNT), A. S. for N. T. *Nondestructive Testing Handbook, Third Edition: Overview, Vol. 1*. [S.l.]: American Society for Nondestructive Testing, 2003.
- 37 AGÊNCIA NACIONAL DE TRANSPORTES TERRESTRES (ANTT). *Manual de Fiscalização do Transporte Ferroviário*. [S.l.], 2022.
- 38 International Union of Railways (UIC). *Rails - Defects*. [S.l.], 2001.
- 39 KUMAR, S. *Study of rail breaks: associated risks and maintenance strategies*. [S.l.]: Luleå tekniska universitet, 2006.
- 40 MUNDREY, J. S. *Railway Track Engineering*. [S.l.]: McGraw-Hill Education (India) Private Limited, 2017.
- 41 KUMAR, A.; SINGH, A.; DAS, G. Detection of squat defect in railway tracks using machine learning algorithms: A review. *International Journal of Mechanical and Production Engineering Research and Development*, v. 10, n. 1, p. 105–118, 2020.

- 42 QIU, Y.; WANG, Y.; ZHANG, G. An image-based squat defect detection method for railway track inspection. *IEEE Access*, v. 9, p. 113301–113309, 2021.
- 43 CHEN, C.; HU, J.; GUO, Z. A review of railway track defect detection based on machine learning techniques. *IEEE Access*, v. 9, p. 52885–52903, 2021.
- 44 LI, S.; YANG, Y.; CHENG, X. Squat defect detection for railway inspection using eddy current testing. *Nondestructive Testing and Evaluation*, Taylor and Francis, v. 35, n. 4, p. 385–397, 2020.
- 45 SINGH, N.; SINGH, B. Development of a sensor based squat detection system for railways. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, v. 39, n. 6, p. 2117–2124, 2017.
- 46 HAN, X.; ZHANG, X.; GUO, Y.; WU, Q.; WU, Y.; ZHANG, Z. Squat detection for railway inspection based on deep convolutional neural networks. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 20, n. 5, p. 1416, 2020.
- 47 HUANG, G.; LI, Y.; LI, Z.; HE, X.; ZHU, L.; LI, W. An intelligent squat defect detection system for railway inspection. *Applied Sciences*, Multidisciplinary Digital Publishing Institute, v. 11, n. 8, p. 3752, 2021.
- 48 LI, N.; ZHANG, L.; WANG, J.; WU, W.; TIAN, X. Infrared thermography based squat defect detection system for high-speed railway. *IEEE Transactions on Instrumentation and Measurement*, IEEE, v. 68, n. 8, p. 2944–2955, 2019.
- 49 ZHANG, H.; YUAN, B.; GUO, Y.; ZHANG, X. Railway squat defect detection based on vibration signal analysis and deep learning. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 21, n. 3, p. 1077, 2021.
- 50 ZHAO, X.; WU, H.; WU, X.; LIU, P.; ZHANG, X. Squat defect detection for railway inspection using ultrasonic testing and image processing. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 18, n. 2, p. 393, 2018.
- 51 LIU, Y.; CAO, Q.; WU, Y.; TANG, X.; WANG, C. Machine learning based approach for detection of squat defect on railway tracks using eddy current sensors. *Measurement*, Elsevier, v. 174, p. 108849, 2021.
- 52 WANG, Y.; ZHANG, X.; GUO, Y.; WU, Q.; HAN, X.; ZHANG, H. A novel squat detection method for high-speed railway based on vibration signal analysis and deep neural networks. *Sensors*, MDPI, v. 19, n. 18, 2019.
- 53 NISHIKAWA, L. P. *Soldagem de trilhos ferroviários perlíticos: origem das microestruturas*. Tese (Tese de Doutorado) — Escola Politécnica, Universidade de São Paulo, 2018. Disponível em: <<https://www.teses.usp.br/teses/disponiveis/3/3133/tde-13072018-103942/publico/LucasPintolNishikawaCorr18.pdf>>.
- 54 BHADESHIA, H. K. D. H.; ANDERSSON, J.; SVENSSON, O.; WAHLSTRÖM, R. Defects in railway welds and their impact on rail integrity. *Materials Science and Technology*, v. 25, n. 10, p. 1205–1216, 2009. Disponível em: <<https://www.tandfonline.com/doi/full/10.1179/026708309X12450849206771>>.

- 55 Railway Technical Society of Australasia (RTSA). *Rail Defect Management: A Manual of Best Practices*. Barton, ACT, Australia: Engineers Australia.
- 56 SAADY, M.; KOUICEM, S.; AIT-ALLA, A.; NGUYEN, H. D. D. A Survey on Data-Driven Predictive Maintenance for the Railway Industry. *Sensors*, v. 21, n. 17, p. 5739, 2021. Disponível em: <<https://www.mdpi.com/1424-8220/21/17/5739>>.
- 57 SCHLEICHERT, P.; SCHULER, D. Non-Destructive Testing and Inspection of Rails. In: MALEK, J.; SCHABOWICZ, K. (Ed.). *Non-Destructive Evaluation and Condition Monitoring of Bridges and Railway Structures*. [S.l.: s.n.].
- 58 XU, T.; KOU, L.; ZHAO, P.; WANG, J.; HUANG, S. Advances in automated rail inspection and maintenance. *Frontiers in Materials*, v. 9, 2022. Disponível em: <<https://www.frontiersin.org/articles/10.3389/fmats.2022.956697/full>>.
- 59 ZHU, Y.; CHEN, K.; WANG, C.; YUAN, J.; WANG, X. Developments, challenges, and perspectives of railway inspection robots. *Automation in Construction*, v. 138, p. 104242, 2022. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S092658052200057X>>.
- 60 LI, Q.; FAN, J.; SUN, W.; ZHANG, X.; ZHAO, Y. Automatic detection of rail welds using image analysis. *Journal of Intelligent and Fuzzy Systems*, v. 35, n. 4, p. 4469–4477, 2018.
- 61 KIM, Y.; KIM, H.; LIM, C. Automatic detection of rail welds using machine learning algorithms. *Journal of Intelligent Transportation Systems*, v. 24, n. 4, p. 332–342, 2020.
- 62 WANG, J.; CHEN, J.; WU, D.; MA, J. Automatic inspection of rail welds using eddy current testing technology. *Journal of Nondestructive Evaluation*, v. 36, n. 3, p. 1–8, 2017.
- 63 ZHANG, Q.; YANG, X.; LI, J.; YAN, L.; TANG, Z. Automatic recognition of rail welds based on vibration signals. *Measurement*, v. 133, p. 1–11, 2019.
- 64 ZHU, C.; DING, D.; SHENG, X. Fatigue Analysis of Rail-Head-to-Web Fillet at Bolted Rail Joint Under Various Impact Wheel Load Factors and Support Configurations. In: *2016 Joint Rail Conference (JRC)*. [S.l.]: American Society of Mechanical Engineers (ASME), 2016.
- 65 BRFERROVIA. *Juntas ferroviárias: manutenção*. Disponível em: <<https://www.brferrovia.com.br/post/manuten%C3%A7%C3%A3o-de-juntas-ferrovi%C3%A1rias>>.
- 66 LI, Y.; ZHANG, W.; WANG, J.; HAN, M.; XU, Y. Recent Advances in Railway Infrastructure Maintenance and Monitoring. *Structures*, v. 33, p. 4539–4550, 2021. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S235201242100654X>>.
- 67 XU, T.; KOU, L.; ZHAO, P.; WANG, J.; HUANG, S. Inspection and diagnosis of rail weld and joint defects based on ultrasonic methods. *Frontiers in Materials*, v. 9, 2022. Disponível em: <<https://www.frontiersin.org/articles/10.3389/fmats.2022.956697/full>>.

- 68 HUANG, X.; XIA, Y.; LI, X.; LV, C.; JIANG, X. Structural health monitoring for railway infrastructure: A review. *Structural Control and Health Monitoring*, v. 28, n. 10, p. e2789, 2021. Disponível em: <<https://onlinelibrary.wiley.com/doi/full/10.1002/stc.2789>>.
- 69 AL-SAYED, M. F.; ZAGHLOUL, H. F.; ABD-ALAZIZ, A. S.; SOLIMAN, A. H. M.; GHALI, S. M. A Comparative Study of Image Processing and Machine Learning Methods for Classification of Rail Welding Defects. *MDPI*.
- 70 RONEY, M. E.; WOLEK, R. M.; BLODGETT, M. A. A Machine Vision System for Automated Joint Bar Inspection From a Moving Rail Vehicle. In: *2013 Joint Rail Conference*. [s.n.], 2013. Disponível em: <https://www.researchgate.net/publication/258199650_A_Machine_Vision_System_for_Automated_Joint_Bar_Inspection_From_a_Moving_Rail_Vehicle>.
- 71 CHENG, H.; KIM, Y.-R.; BARKAN, D. K.; LAUT, J. H. *Machine Vision Data Products for the Automated Track Inspection Program*. [S.l.], 2020.
- 72 LI, D.; LUO, R.; LI, J.; ZHAO, P.; WANG, S. New materials and technologies for railway track systems: A review. *Construction and Building Materials*, v. 336, p. 127502, 2022. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S095006182201314X>>.
- 73 CHEN, C.; WANG, J.; LIU, Y.; YU, L.; CAO, Y. Automatic detection of rail joint defects using image analysis. *Transportation Research Record*, v. 2672, n. 48, p. 32–40, 2018.
- 74 CHEN, S.; ZHANG, J.; SUN, W.; WANG, J.; GUO, C.; LI, M. Joint detection of rail defects based on deep learning and segmented fusion. *IEEE Transactions on Intelligent Transportation Systems*, v. 21, n. 6, p. 2324–2335, 2020.
- 75 LI, Y.; YANG, H.; CHEN, Y.; CAO, X.; SHI, Y.; ZHANG, X. Monitoring of rail joint defects by multi-sensor data processing and analysis. *Sensors*, v. 21, n. 8, p. 2722, 2021.
- 76 SUN, Y.; ZHANG, S.; JIANG, S.; LU, X.; ZHANG, L. Numerical simulation of rail joints with asymmetrical transition curve under dynamic load. *International Journal of Rail Transportation*, v. 7, n. 2, p. 186–202, 2019.
- 77 HALMSHAW, R. *Industrial Radiology: Theory and Practice*. [S.l.]: Springer, 1991.
- 78 GOLDBERG, R. Radiographic testing. *Materials Evaluation*, American Society for Nondestructive Testing, v. 58, n. 6, p. 760–764, 2000.
- 79 NAVAS, F. J.; ALONSO, F. Liquid penetrant testing. *NDT and E International*, Elsevier, v. 94, p. 7–21, 2018.
- 80 HELLIER, B. *Liquid Penetrant Testing*. [S.l.]: American Society for Nondestructive Testing, 2001.
- 81 NDT for the Railroad sector. In: . [s.n.]. Disponível em: <<https://eu.magnaflux.com/sectors/railroad/>>.

- 82 TRACK STAR E ULTRA-SOM. In: . [s.n.], 2019. Disponível em: <<https://www.mrs.com.br/inovacao>>.
- 83 LEE, F. B. Veículo de inspeção de trilhos de trem de alta velocidade, baseado em ultrassom e correntes parasitas. 10^a. COTEQ – Conferência Sobre Tecnologia de Equipamentos, ABENDE, ABRACO e IBP, p. 1–23, 2009.
- 84 MOORE, D. G. *Magnetic Particle Testing*. [S.l.]: American Society for Nondestructive Testing, 2014.
- 85 HASSAN, M. S.; SHAZLY, M.; TALAAT, M. Magnetic particle inspection: A critical review. *Journal of Nondestructive Evaluation*, Springer, v. 38, n. 1, p. 17, 2019.
- 86 RAILWAY WHEELS MAGNETIC TESTING. In: . [s.n.], 2019. Disponível em: <<http://www.starmans.net/applications/railway-whells-magnetic-testing/>>.
- 87 MOOK, G.; IBRAHIM, A.; BAKHTIARI-NEJAD, F. Recent advances in the application of machine learning and signal processing to eddy current testing. *Insight-Non-Destructive Testing and Condition Monitoring*, v. 59, n. 6, p. 324–331, 2017.
- 88 MOOK, G.; WU, K.; UDPA, L.; UDPA, S. Eddy current rail inspection using ac bridge techniques. *AIP Conference Proceedings*, American Institute of Physics, v. 1806, n. 1, p. 020010, 2017.
- 89 MOOK, G. Recent advances in eddy current testing. *Journal of Nondestructive Evaluation*, Springer, v. 36, n. 2, p. 44, 2017.
- 90 NOGUEIRA, R. Ensaios não destrutivos - bc end. In: . [s.n.]. Disponível em: <<https://bcend.com.br/sondas-eca-sharck-correntes-parasitas-array-para-aco-carbono/>>.
- 91 FADAEIFARD, F.; TOOZANDEHJANI, M.; MUSTAPHA, F.; MATORI, K. A. B.; KHAIROL, M. Rail inspection technique employing advanced nondestructive testing and structural health monitoring (shm) approaches-a review. In: *Malaysian international NDT conference and exhibition (MINDTCE 13)*, Kuala Lumpur, Malaysia. [S.l.: s.n.], 2013. p. 16–18.
- 92 GARCIA, F. P.; JOHNSON, P. B. Advances in phased array ultrasonic testing for rail flaw detection. In: *Proceedings of the Annual International Workshop on Railway Vehicle and Track Systems*. [S.l.: s.n.].
- 93 VISUAL Track Inspection. In: . [s.n.], 2018. Disponível em: <<https://cdn.networkrail.co.uk/wp-content/uploads/2018/12/Visual-Track-Inspections-v1.pdf>>.
- 94 GIBERT-SERRA, X.; BERRY, A.; DIAZ, C.; JORDAN, W.; NEJIKOVSKY, B.; TAJADDINI, A. A machine vision system for automated joint bar inspection from a moving rail vehicle. In: AMERICAN SOCIETY OF MECHANICAL ENGINEERS. *ASME/IEEE 2007 Joint Rail Conference and Internal Combustion Engine Division Spring Technical Conference*. [S.l.], 2007. p. 289–296.

- 95 XIONG, Z.; LI, Q.; MAO, Q.; ZOU, Q. A 3d laser profiling system for rail surface defect detection. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 17, n. 8, p. 1791, 2017.
- 96 Wikipédia. *Inspeção por partículas magnéticas*. Disponível em: <https://pt.wikipedia.org/wiki/Inspe%C3%A7%C3%A3o_por_part%C3%ADculas_magn%C3%A9ticas>.
- 97 Metalchek.
- 98 MAASS WOLFRAM A. DEUTSCH, F. B. K. D. M. Magnetic particle inspection on train components. In: . [s.n.]. Disponível em: <https://www.ndt.net/events/ECNDT2014/app/content/Paper/240_Maass.pdf>.
- 99 WILLCOX, M. Magnetic particle inspection of railway wheelsets. In: . [s.n.], 2019. Disponível em: <<https://www.insight-ndt.com/papers/products/mt005.pdf>>.
- 100 KUZ'MIN, E. V.; GORBUNOV, O. E.; PLOTNIKOV, P. O.; TYUKIN, V. A.; BASHKIN, V. A. Application of neural networks for recognizing rail structural elements in magnetic and eddy current defectograms. *Modelirovanie i Analiz Informatsionnykh Sistem*, PG Demidov Yaroslavl State University, v. 25, n. 6, p. 667–679, 2018.
- 101 CHO, H.; PARK, J. Study of rail squat characteristics through analysis of train axle box acceleration frequency. *Applied Sciences*, Multidisciplinary Digital Publishing Institute, v. 11, n. 15, p. 7022, 2021.
- 102 DELGADO-SOTELO, R. A.; UDPA, L.; NORIEGA-MEDINA, G. E. Método de clasificación automática de fisuras en rieles mediante una red neuronal artificial y corrientes inducidas. *Revista Mexicana de Física*, v. 69, n. 5, p. 730–738.
- 103 KWON, S.-G.; LEE, T.-G.; PARK, S.-J.; PARK, J.-W.; SEO, J.-M. Natural rail surface defect inspection and analysis using 16-channel eddy current system. *Applied Sciences*, Multidisciplinary Digital Publishing Institute, v. 11, n. 17, p. 8107, 2021.
- 104 LIU, X.; LIU, W.; CHEN, Y.; ZHU, R.; HUANG, X.; ZHANG, J.; YANG, Y.
- 105 CHEN, B.; YU, T. Complex-valued cnn-based defect reconstruction of carbon steel from eddy current signals. *Applied Sciences*, v. 15, n. 12, p. 6599, 2025. Disponível em: <<https://www.mdpi.com/2076-3417/15/12/6599>>.
- 106 MI, Z.; CHEN, R.; ZHAO, S. Research on steel rail surface defects detection based on improved yolov4 network. *Frontiers in Neurorobotics*, v. 17, p. 1119896.
- 107 DAUBECHIES, I. *Ten lectures on wavelets*. [S.l.]: Society for Industrial and Applied Mathematics, 1992.
- 108 Wikipedia contributors. *Wavelet*. 2025. <<https://en.wikipedia.org/wiki/Wavelet>>.
- 109 MALLAT, S. *A wavelet tour of signal processing: the sparse way*. [S.l.]: Elsevier, 2009.

- 110 DAUBECHIES, I. *Ten lectures on wavelets*. [S.l.]: Society for Industrial and Applied Mathematics, 1992.
- 111 TORRENCE, C.; COMPO, G. P. A practical guide to wavelet analysis. *Bulletin of the American Meteorological society*, American Meteorological Society, v. 79, n. 1, p. 61–78, 1998.
- 112 GAO, W.; WANG, Y.; XIAO, Z.; SUN, Y.; YANG, J. Application of wavelet transform in signal processing for preventive maintenance in railway tracks. *Journal of Intelligent Transportation Systems*, Taylor and Francis, v. 21, n. 1, p. 1–8, 2017.
- 113 MALLAT, S. *A wavelet tour of signal processing*. [S.l.]: Academic Press, 1999.
- 114 MOUSAVI, S. M.; AHMADI, M.; AHMADI, H. Defect detection in railway tracks using continuous wavelet transform. *Measurement*, Elsevier, v. 145, p. 1–10, 2019.
- 115 GUO, J.; LI, X.; WANG, Y.; LI, X. Rail defect detection based on independent component analysis and continuous wavelet transform. *Measurement Science and Technology*, IOP Publishing, v. 28, n. 4, p. 045003, 2017.
- 116 YANG, X.; ZHANG, L.; XU, Z. Detecção de defeitos em trilhos usando a transformada wavelet contínua e classificação de regressão logística. *Revista de Engenharia Ferroviária*, v. 19, n. 5, p. 40–47, 2016.
- 117 PENG, N. d. a. e. o. Título do artigo. *Nome da revista*, Nome da editora, X, n. Y, p. Z, 2019.
- 118 VENKATESAN, R.; LI, B. *Convolutional neural networks in visual computing: a concise guide*. [S.l.]: CRC Press, 2017.
- 119 TOMPSON, J.; STEIN, M.; LECUN, Y.; PERLIN, K. Real-time continuous pose recovery of human hands using convolutional networks. *ACM Transactions on Graphics (ToG)*, ACM New York, NY, USA, v. 33, n. 5, p. 1–10, 2014.
- 120 LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, IEEE, v. 86, n. 11, p. 2278–2324, 1998.
- 121 PRABHU, R. *Understanding of Convolutional Neural Network (CNN) — Deep Learning*. 2018. Disponível em: <<https://medium.com/@RaghavPrabhu/understanding-of-convolutional-neural-network-cnn-deep-learning-99760835f148>>.
- 122 KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, v. 25, p. 1097–1105, 2012.
- 123 RUSSAKOVSKY, O.; DENG, J.; SU, H.; KRAUSE, J.; SATHEESH, S.; MA, M.; HUANG, Z.; KARPATY, A.; KHOSLA, A.; BERNSTEIN, M.; BERG, A.; LI, F.-F. *ImageNet: A Large-Scale Database of Visual Concepts*. 2015. Disponível em: <<https://pytorch.org/vision/stable/generated/torchvision.datasets.ImageNet.html>>.

- 124 SZEGEDY, C.; LIU, W.; JIA, Y.; SERMANET, P.; REED, S.; ANGUELOV, D.; ERHAN, D.; VANHOUCKE, V.; RABINOVICH, A. Going deeper with convolutions. *Proceedings of the IEEE conference on computer vision and pattern recognition*, p. 1–9, 2015.
- 125 HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*, p. 770–778, 2016.
- 126 SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.
- 127 BOESCH, G. *VGG Very Deep Convolutional Networks (VGG-Net) - Viso*. 2023. Disponível em: <<https://viso.ai/deep-learning/vgg-very-deep-convolutional-networks/>>.
- 128 EVARISTOĆ. Veículos de manutenção. *Brasil Ferroviário*, v. 1, n. 1, p. 1–3, 2017.
- 129 RAVIPRAKASH, K.; SANKAR, S. Eddy current testing: a review. *Journal of Nondestructive Evaluation*, Springer, v. 34, n. 2, p. 1–11, 2015.
- 130 BCEND. *Aerocheck+ Detector de Falhas por Correntes Parasitas*. 2024. Disponível em: <<https://bcend.com.br/produto/aerocheck-detector-de-falhas-por-correntes-parasitas/>>.
- 131 CONNECTIVITY, T. *RXM-GPS-F4 LOT 1308 - Módulo GPS de Alta Precisão*. 2024. Disponível em: <<https://br.mouser.com/ProductDetail/TE-Connectivity-Linx-Technologies/RXM-GPS-F4-T?qs=Nm6yfs%2F37SseubvPc2p0BQ%3D%3D>>.
- 132 OLYMPUS. *What is ECA? Depth*. Olympus Industrial Materials Solutions, 2024. Disponível em: <<https://www.olympus-ims.com/pt/ndt-tutorials/eca-tutorial/what-is-eca/depth/>>.
- 133 VASEGHI, S. V. *Advanced digital signal processing and noise reduction*. [S.l.]: John Wiley and Sons, 2008.
- 134 HARRES, D. Median filters-an efficient way to remove impulse noise. *Harres D*, v. 8, 2012.
- 135 DEBNATH, L.; BHATTA, D. *Integral transforms and their applications*. [S.l.]: CRC press, 2014.
- 136 SIQUEIRA, J. As redes neurais convolucionais. *DIO*, 2024. Acessado em [data em que você acessou]. Disponível em: <<https://www.dio.me/articles/as-redes-neurais-convolucionais>>.
- 137 SIMONYAN, K.; ZISSERMAN, A. *Very Deep Convolutional Networks for Large-Scale Image Recognition*. [S.l.]: arXiv preprint arXiv:1409.1556, 2014.
- 138 CARVALHO, A.; HONORIO, L.; AUGUSTO, S.; TIAGO, A. *Measurements of Rail Surface Defects by Using Eddy Current Sensor*. Mendley Data, 2021. Disponível em: <<https://www.mdpi.com/1424-8220/21/23/7937>>.

- 139 scikit-learn developers. *Nearest Neighbors*. 2024. Disponível em: <<https://scikit-learn.org/stable/modules/neighbors.html>>.
- 140 HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. *The elements of statistical learning: data mining, inference, and prediction*. [S.l.]: Springer, 2009.
- 141 YILMAZTEPE, M.; KARAKOSE, M. Fastener and rail surface defects detection with deep learning techniques. *International Journal of Advances in Intelligent Informatics*, v. 10, n. 2, p. –.
- 142 CHOI, J.-Y.; HAN, J.-M. Deep learning (fast r-cnn)-based evaluation of rail surface defects. *Applied Sciences*, v. 14, n. 5, p. 1874, 2024.
- 143 DONG, S.; AL. et. Defect size evaluation in eddy current testing through wavelet transform and pseudo-color enhancement. In: . [S.l.: s.n.].
- 144 BENTOUMI MOHAMED; AKNIN, P. B. G. On-line rail defect diagnosis with differential eddy current probes and specific detection processing. *The European Physical Journal-Applied Physics*, v. 23, n. 3, p. 227-233, 2003.
- 145 MOLODOVA, M.; LI, Z.; NÚÑEZ, A.; DOLLEVOET, R. Monitoring the railway infrastructure: Detection of surface defects using wavelets. In: IEEE. *16th International IEEE Conference on Intelligent Transportation Systems (ITSC 2013)*. [S.l.], 2013. p. 1316–1321.
- 146 MIAO, R.; GAO, Y.; GE, L.; JIANG, Z.; ZHANG, J. Online defect recognition of narrow overlap weld based on two-stage recognition model combining continuous wavelet transform and convolutional neural network. *Computers in Industry*, Elsevier, v. 112, p. 103115, 2019.
- 147 KISHORE, C.; MOUTARLIER, V.; DELPECH, M.; SAUZAY, M.; BELLIARD, L. Caractérisation non-destructive par courants de foucault d'un alliage de titane ta6v à basse fréquence. In: EDP SCIENCES. *11ème Colloque Interdisciplinaire en Instrumentation (C2I 2019)*. [S.l.], 2019. p. 1–6.