



INTELIGÊNCIA ARTIFICIAL NA PROSPECÇÃO DE DORMENTES DE MADEIRA

Letícia Santos Batista de Melo¹; Carolina Rodrigues Reigado²;

Lucas Silveira da Costa³

¹VLI Logística — Brasil

²VLI Logística — Brasil

³VLI Logística — Brasil

RESUMO

Este trabalho apresenta a modernização da prospecção de dormentes de madeira por meio da integração de um sistema automatizado de inspeção por imagem (LRAIL), técnicas de visão computacional baseadas em Redes Neurais Convolucionais Profundas (DCNN) e um pós-processamento por regras de negócio. O objetivo é reduzir a subjetividade da inspeção a pé e disponibilizar dados 2D/3D georreferenciados, consistentes e repetíveis, para apoiar orçamento e priorização de manutenção. Metodologicamente, caracterizaram-se os critérios da prospecção manual; descreveu-se o sistema de aquisição (imagens 2D e perfis 3D com GNSS de alta precisão); definiram-se faixas operacionais de visibilidade (cobertura superficial) como pré-requisito de aplicação dos modelos; desenvolveram-se e refinaram-se modelos de identificação de componentes e classificação de falhas; e testaram-se combinações de regras de negócio em múltiplas simulações, comparadas à prospecção de validação. Os resultados indicam que os modelos contemplam parcela substancial das características essenciais observadas em campo e que o desempenho é sensível à visibilidade; a regra selecionada apresentou maior aderência aos critérios definidos e foi adotada para compor a necessidade final de dormentes e orientar a redistribuição entre trechos, sem aumento do quantitativo global, cuja eficácia foi aferida por aderência à aplicação. Conclui-se que a abordagem eleva a qualidade informacional e a rastreabilidade do processo, ao mesmo tempo em que evidencia limitações ligadas à cobertura superficial e a classes mais desafiadoras, sinalizando próximos passos em treinamento contínuo dos modelos, seleção de variáveis (*feature selection*) e validação cruzada de novas regras de negócio implementadas como modelos de classificação.

Palavras-chave: *Inteligência Artificial, Inspeção de Dormentes, Manutenção Ferroviária, Prospecção Automatizada, Via Permanente.*

1. INTRODUÇÃO

A Transformação Digital consiste na integração estratégica de tecnologias digitais em todas as dimensões de uma organização, promovendo mudanças estruturais em seus processos, modelos operacionais e formas de entrega de valor. No contexto ainda incipiente da Indústria 4.0 no setor ferroviário brasileiro, a VLI Logística tem direcionado esforços para a adoção de soluções tecnológicas inovadoras voltadas à modernização dos processos de inspeção da via permanente. Essas iniciativas visam possibilitar a geração de dados de inspeção com maior frequência, confiabilidade e nível de detalhamento,



contribuindo para uma gestão mais eficiente dos ativos ferroviários e para a consolidação de uma estratégia de manutenção baseada em condição (KRAUS et al., 2021).

Alinhado à estratégia corporativa vigente e elaborado com periodicidade anual, o orçamento de manutenção da via permanente tem como principal insumo os dados provenientes das inspeções dos componentes de via. Atualmente, tais dados são obtidos por meio do método de prospecção a pé, o qual, além de extenuante, apresenta caráter predominantemente sensitivo e subjetivo. Essa característica limita a confiabilidade das informações coletadas, impactando diretamente a robustez das análises técnicas e a assertividade das decisões relacionadas ao planejamento e à priorização das atividades de manutenção (MCKINSEY & COMPANY, 2018).

Com vida útil limitada e elevada representatividade tanto na matriz de dormentes da Ferrovia Centro-Atlântica quanto no orçamento de manutenção da via permanente, os dormentes de eucalipto estão sujeitos a diversos modos de falha ao longo de sua vida operacional. Dentre os principais, destacam-se o fendilhamento e a formação de rachaduras, o apodrecimento do material, o desgaste mecânico na região sob a placa de apoio, bem como falhas nos sistemas de fixação, caracterizadas pelo arrancamento de pregos e parafusos.

Nesse contexto e com o objetivo de ampliar a qualidade, a confiabilidade e a robustez dos dados relativos à condição dos principais itens componentes do orçamento de manutenção, a VLI Logística empreendeu a modernização do atual processo de prospecção por meio da aquisição de um sistema automatizado de inspeção de componentes de via por imagem, baseado na integração de lasers, câmeras e algoritmos de inteligência artificial, cujas técnicas de visão computacional desempenham papel central no processamento e na interpretação dos dados captados em campo. Em especial, as Redes Neurais Convolucionais Profundas (*Deep Convolutional Neural Networks* – DCNN) são empregadas para a análise automática de imagens, possibilitando a identificação, a classificação e a localização de defeitos em componentes da via de forma objetiva e padronizada. A utilização dessas técnicas reduz a subjetividade inerente às inspeções visuais tradicionais, possibilita a repetibilidade das avaliações e contribui para a geração de informações consistentes e escaláveis sobre a condição dos ativos, em alinhamento com os fundamentos da Indústria 4.0 e da manutenção baseada em condição (ZHAO et al., 2024).

A iniciativa descrita neste trabalho materializa a aplicação de técnicas avançadas de visão computacional à inspeção da via permanente. Nesse sentido, o objetivo deste artigo é relatar as principais etapas de desenvolvimento, implementação e avaliação da tecnologia de inspeção automatizada atualmente em uso na VLI Logística, evidenciando seus impactos na qualidade dos dados de inspeção e no suporte à tomada de decisão em manutenção baseada em condição.

2. DESENVOLVIMENTO

O desenvolvimento do presente trabalho foi estruturado de forma a refletir a evolução metodológica adotada na modernização do processo de inspeção da via permanente, partindo da caracterização dos critérios empregados na prospecção manual tradicional até a aplicação operacional da tecnologia desenvolvida. Inicialmente, são apresentados os defeitos e características historicamente observados na inspeção a pé,



utilizados como referência técnica. Em seguida, descrevem-se o sistema de inspeção por imagem, as etapas de desenvolvimento e refinamento dos modelos de visão computacional, bem como o procedimento de coleta de dados em campo. Por fim, é abordada a aplicação das informações geradas no suporte à redistribuição de dormentes, integrando o desenvolvimento tecnológico à prática de manutenção ferroviária.

2.1. Critérios da Prospecção a Pé

A prospecção manual dos componentes da via permanente constitui uma atividade operacionalmente extenuante, de caráter sensível e fortemente dependente da experiência da equipe responsável. Realizada, em geral, com periodicidade anual e com o objetivo de subsidiar a elaboração do orçamento de manutenção do exercício subsequente, essa atividade baseia-se na avaliação visual e funcional dos dormentes de madeira ao longo da via. Durante a inspeção a pé, são observadas e registradas diversas características associadas à condição estrutural e ao desempenho do dormente, conforme apresentado na Tabela 1, as quais fundamentam sua classificação quanto ao estado de conservação e à necessidade de intervenção.

Tabela 1. Características avaliadas na prospecção manual para classificação do dormente de madeira.

Categoria	Característica
Condição	Bom; inservível; faltante; soterrado
Posição	Sequenciamento; sob solda; sob junta metálica
Som à Percussão	Oco; grave
Fissuras	Trincas alinhadas à fixação; trincas transversais e/ou longitudinais totais; trincas nas extremidades do dormente; esmagamento na extremidade do dormente
Placa de Apoio	Afundamento; deslocamento lateral; apodrecimento e/ou formação de furos sob a placa
Fixações	Furo ovalizado; fixação solta e/ou alta

2.2. Sistema de Inspeção por Imagem

Em função das características avaliadas durante a prospecção manual, tornou-se necessária a adoção de uma tecnologia capaz não apenas de realizar a avaliação visual da condição dos componentes da via permanente, mas também de extrair informações métricas tridimensionais, contemplando largura, comprimento e profundidade dos defeitos identificados. Tal requisito é fundamental para a adequada caracterização de fenômenos como desgaste mecânico, apodrecimento e deformações locais dos dormentes, os quais não podem ser plenamente avaliados por inspeções bidimensionais convencionais.

O *Laser Rail Inspection System* (LRAIL), desenvolvido pela Pavemetrics, é um sistema avançado de inspeção ferroviária baseado em visão computacional, capaz de realizar, em uma única passagem, a aquisição simultânea de imagens bidimensionais de

alta resolução e perfis tridimensionais de componentes da via permanente. Utilizando sensores a laser e câmeras integradas, o sistema captura dados detalhados da via, que são processados por algoritmos de inteligência artificial para detecção, medição e classificação automática de suas condições. Além disso, o sistema é equipado com sensores GNSS de alta precisão e com correção de posicionamento em tempo real, fornecendo precisão centimétrica e georreferenciando todos os componentes identificados durante a inspeção (FOX-IVEY *et al.*, 2020).

Na VLI Logística, o LRAIL foi instalado em veículo rodoferroviário híbrido, sendo capaz de trafegar e inspecionar nas bitolas métrica e larga. Essa configuração permitiu a otimização do uso de um único recurso tecnológico em toda a malha ferroviária sob concessão, ampliando a flexibilidade operacional do processo de inspeção. A Figura 1 ilustra a instalação do sistema no veículo de inspeção, bem como seus principais componentes embarcados.



Figura 1. Instalação do LRAIL em veículo rodoferroviário híbrido para a VLI Logística.

2.3. Desenvolvimento de Modelos de Inteligência Artificial

Embora o sistema de inspeção por imagem adquirido possuísse funcionalidades nativas para a identificação de determinadas falhas em componentes da via permanente, a especificação técnica definida para sua contratação contemplou, como requisito fundamental, o desenvolvimento de novos modelos de Inteligência Artificial aderentes às necessidades operacionais da VLI Logística.

Esses modelos foram concebidos com base nas características e critérios tradicionalmente avaliados na prospecção manual, de modo a garantir certa equivalência conceitual entre os métodos e viabilizar a transposição do conhecimento empírico acumulado pelos inspetores para um ambiente automatizado. Adicionalmente, foi realizado o aprimoramento de modelos previamente existentes, uma vez que a heterogeneidade dos componentes presentes na malha ferroviária demandou, em um primeiro momento, a capacitação do sistema para a correta identificação dos diferentes

elementos e, subsequentemente, sua classificação segundo atributos condicionais e modos de falha específicos.

No que se refere aos dormentes de madeira, foram aprimorados modelos destinados à detecção dos próprios dormentes, das placas de apoio e dos elementos de fixação. Além disso, foram desenvolvidos novos modelos específicos para a identificação de afundamento da placa de apoio, deslocamento lateral da placa, presença de trincas alinhadas aos tirefãos, trincas nas extremidades dos dormentes e apodrecimento do material, abrangendo os principais modos de falha considerados na avaliação da condição desses componentes.

2.4. Coleta e Seleção de Dados

Foram utilizados dados provenientes da inspeção realizada com o sistema LRAIL em 13 de fevereiro de 2025, no trecho ferroviário de bitola métrica entre Divinópolis – MG e Contagem – MG. Considerando esse escopo de coleta, tornou-se necessário qualificar a visibilidade dos dormentes como etapa prévia à seleção dos trechos passíveis de análise segundo o critério de cobertura superficial. Isso se justifica pelo fato de que a correta identificação das características de interesse está diretamente condicionada à visibilidade da superfície do dormente, a qual pode ser reduzida pela presença de lastro, terra ou vegetação sobre o componente.

Entre os parâmetros disponibilizados no relatório de inspeção por imagem, após o processamento dos dados em *software* proprietário do fornecedor, destaca-se o percentual da superfície do dormente obstruída. Para fins de interpretação da visibilidade das características avaliadas, considerou-se que faixas de cobertura entre 30% e 50% da superfície representam a condição ótima para a detecção automática, uma vez que as principais feições permanecem suficientemente expostas. Coberturas de até aproximadamente 65% passam a comprometer o processo de identificação, embora ainda permitam, de forma limitada, a detecção de determinadas características. Acima desse limiar, a visibilidade da superfície do dormente torna-se acentuadamente comprometida, restringindo de maneira significativa a avaliação confiável das condições do componente, conforme ilustrado na Figura 2.




Figura 2. Faixas percentuais de cobertura da superfície dos dormentes e interpretação operacional: 30-50% (faixa ótima de detecção), até ~65% (detecção comprometida, porém possível) e >65% (detecção fortemente comprometida).



Diante desse contexto, foram selecionados para as etapas subsequentes três trechos ferroviários (A, B e C), caracterizados por percentuais médios distintos de cobertura da superfície dos dormentes, porém com predominância de dormentes apresentando até 60% de cobertura superficial, assegurando condições mínimas de visibilidade compatíveis com os critérios estabelecidos para a aplicação dos modelos de detecção e classificação, conforme detalhado na Tabela 2.

Tabela 2. Características de cobertura da superfície dos dormentes para os trechos A, B e C.

Trecho	Percentual Médio de Superfície Obstruída dos Dormentes (%)	Dormentes com Superfície Obstruída ≤ 60 (%)
A	49,2%	71%
B	53,8%	60%
C	59,7%	49%

2.5. Avaliação e Refinamento dos Modelos

De posse dos resultados da inspeção por imagem, a etapa subsequente consistiu na realização de atividades complementares em campo, com apoio do *software* QGIS. Para cada um dos trechos A, B e C, foi conduzida, pela Engenharia e pela Manutenção de Via Permanente, uma prospecção dormente a dormente, na qual se identificaram as características observadas em campo que não haviam sido corretamente reconhecidas pelo sistema, mas que deveriam contribuir para a classificação automática. Essas características foram devidamente registradas e sistematizadas no arquivo *shapefile*, conforme ilustrado na Figura 3.




Figura 3. Identificação dos dormentes e de características de interesse no aplicativo móvel do QGIS.



A partir dessa análise, foram estabelecidas regras de negócio destinadas ao aprimoramento do processo de classificação, com o objetivo de refinar o comportamento do sistema automatizado aos critérios tradicionalmente empregados na inspeção manual.

As regras desenvolvidas foram comparadas ao levantamento em campo e sua avaliação foi conduzida segundo métricas predefinidas: (i) diferença entre a taxa de dormentes inservíveis estimada pela prospecção de validação e a obtida pelo sistema de inspeção por imagem; (ii) falsos “dormentes bons” (casos classificados como “bom” pelo sistema e “inservível/ruim” na prospecção de validação); e (iii) falsos “dormentes ruins” (casos classificados como “inservível/ruim” pelo sistema e “bom” na prospecção de validação). A regra com maior aderência aos critérios definidos foi selecionada para continuidade do fluxo de trabalho nas etapas subsequentes.

2.6. Cálculo do Orçamento e Redistribuição de Dormentes

Com a regra de negócio que apresentou maior aderência aos critérios definidos devidamente implementada no fluxo de processamento de dados, procedeu-se ao processamento do conjunto completo de dados de inspeção da VLI Logística. Para a composição da necessidade final de dormentes nos segmentos de via, em consonância com o critério adotado no orçamento, foi formulada a Equação (1):

$$NF = NI + COBFALT + MS \quad (1)$$

em que NF corresponde à necessidade final de dormentes; NI refere-se à necessidade identificada, calculada a partir dos dormentes classificados pelo sistema de inspeção por imagem; COBFALT representa a parcela de dormentes não identificados pelo sistema, classificados como cobertos ou faltantes, estimada com base na diferença entre o número de dormentes previstos e os efetivamente registrados, considerando a extensão percorrida pelo veículo de inspeção; e MS corresponde à margem de segurança adotada.

A margem de segurança (MS) foi definida como 50% da diferença entre a taxa de dormentes inservíveis proveniente da prospecção corrigida de 2024 e a taxa de inservíveis identificada pelo sistema LRAIL, multiplicada pelo valor de NI, de modo a absorver incertezas associadas à visibilidade dos componentes e às limitações inerentes ao processo automatizado de inspeção.

Como resultado do cálculo da necessidade final de dormentes, realizou-se a realocação de dormentes entre trechos da via permanente que apresentavam quantitativo superior à necessidade estimada e aqueles cujas necessidades identificadas superavam os volumes originalmente previstos no orçamento. Esse procedimento possibilitou a redistribuição dos recursos disponíveis, sem alteração do quantitativo global de dormentes alocado.

Como métrica para avaliação da eficácia do processo proposto, adotou-se o grau de aderência à redistribuição dos quantitativos definidos, entendido como o nível de cumprimento da aplicação dos dormentes redistribuídos nos respectivos locais previstos pela metodologia, permitindo avaliar a efetiva incorporação dos resultados do trabalho no processo de planejamento e execução da manutenção da via permanente.

3. RESULTADOS E DISCUSSÕES

3.1. Modelos Desenvolvidos

Conforme exposto anteriormente, modelos pré-existent foram aprimorados e novos modelos foram desenvolvidos. A avaliação foi realizada com base nas seguintes métricas: recall (sensibilidade), entendido como a capacidade do sistema de identificar corretamente as ocorrências reais da característica-alvo; precisão, que indica a proporção de identificações corretas entre todas as sinalizações do sistema; e repetibilidade, definida como a consistência dos resultados em execuções ou coletas repetidas sob condições equivalentes. Os resultados obtidos para os modelos desenvolvidos e aprimorados encontram-se na Tabela 3.

Tabela 3. Resultados obtidos para os modelos aprimorados e desenvolvidos.

Item	Característica	Recall (%)	Precisão (%)	Repetibilidade (%)
Dormente	Identificação do Material	98,61	99,20	99,71
	Trincas Alinhadas com Trefão	96,87	71,59	95
	Trincas nas Extremidades	100	100	95
	Apodrecimento	84,58	88,93	N/A
Placa de Apoio	Deteção	99,76	99,92	99,71
	Afundamento	75	75	N/A
	Deslocamento Lateral	30	30	N/A
Fixações	Deenik – Deteção	99,97	99,59	99,69
	E-clip – Deteção	99,95	99,96	98,62
	Fastclips – Deteção	99,82	100	98,62
Trefãos	Deteção	99,72	99,54	99,89

Ressalta-se que o valor mínimo, definido em especificação técnica, para precisão e repetibilidade dos modelos era de 95%, com exceção do deslocamento lateral, cujo requisito mínimo era de 70%. Dessa forma, os únicos modelos com desempenho abaixo do esperado foram os de afundamento de placa, deslocamento lateral de placa e apodrecimento. Em geral, o desempenho inferior dos dois primeiros decorre da alta complexidade de medição e identificação desses modos de falha, em razão do acúmulo de lastro na região das fixações, como pode ser identificado na Figura 4. Quanto ao apodrecimento, embora o desempenho tenha ficado em torno de 90%, o conjunto de dados de treinamento foi limitado e não contemplou toda a diversidade de casos da malha da VLI, permanecendo espaço para aprimoramentos.




Figura 4. Identificação comprometida de afundamento e deslocamento de placa em função do excesso de lastro na região de fixação.

3.2. Comparativo de Características

Com base nos modelos pré-existentes aprimorados e nos novos modelos desenvolvidos, buscou-se identificar as limitações da tecnologia ao comparar com os critérios utilizados na prospecção, o que pode ser visualizado na Tabela 4.

Tabela 4. Comparativo entre características observadas na prospecção manual e identificadas pelo LRAIL

Categoria	Característica	Identificado pelo LRAIL
Condição	Bom; inservível	Sim
	Faltante; soterrado	Não
Posição	Sequenciamento	Sim
	Sob solda	Não
	Sob junta metálica	Sim
Som à Percussão	Oco; grave	Não
Fissuras	Trincas alinhadas à fixação	Sim
	Trincas transversais e/ou longitudinais totais	Não
	Trincas nas extremidades do dormente	Sim
	Esmagamento na extremidade do dormente	Sim
Placa de Apoio	Deslocamento lateral	Sim
	Afundamento;	Sim
	Apodrecimento e/ou formação de furos sob a placa	Não
Fixações	Furo ovalizado	Não
	Fixação solta e/ou alta	Sim

Dessa forma, observa-se que, com os modelos implementados, o sistema LRAIL é capaz de contemplar aproximadamente 60% das características essenciais tradicionalmente observadas durante a prospecção manual.

3.3. Aplicação e Avaliação das Regras de Negócio

Como as características identificadas pelo sistema não contemplavam todas as avaliadas na prospecção a pé e os modelos ainda avaliam cada item de forma



individualizada, a classificação foi refinada em pós-processamento por meio de regras de negócio testadas em múltiplas simulações, que combinam atributos dos relatórios com limiares dimensionais obtidos em campo.

As regras de negócio foram avaliadas nos trechos A, B e C. A variação no percentual de cobertura superficial entre os trechos possibilitou avaliar a assertividade em diferentes cenários, embora, na VLI, a média e a mediana do fenômeno sejam de 51%, valor compatível com a utilização do LRAIL, como ilustra a Figura 5.




Figura 5. Distribuição da taxa de cobertura da superfície do dormente na VLI.

Como referência para a avaliação, a prospecção manual realizada nos três trechos, com apoio do software QGIS, resultou nas taxas apresentadas na Tabela 5.

Tabela 5. Resultados obtidos na prospecção em campo pela Engenharia.

Trecho A		Trecho B		Trecho C	
Aceitáveis	Inservíveis	Aceitáveis	Inservíveis	Aceitáveis	Inservíveis
40%	60%	34%	66%	53%	47%

Os resultados comparativos das regras de negócio — obtidos a partir das simulações aplicadas nos trechos A, B e C — são apresentados na Tabela 6, reportando, para cada configuração, a diferença entre a taxa de dormentes inservíveis (validação vs. LRAIL), bem como a ocorrência de “falsos dormentes bons” e “falsos dormentes ruins”, discriminadas por trecho.

Tabela 6. Resultados obtidos no conjunto de dados após a aplicação de 5 regras de negócio distintas.

Trecho	Regra	Aceitáveis	Inservíveis	Falsos Bons	Falsos Ruins	Precisão
A	V1	41%	60%	7%	6%	87%
	V2	49%	51%	12%	3%	85%
	V3	52%	48%	15%	3%	82%
	V4	46%	54%	10%	3%	87%
	V5	46%	54%	10%	3%	87%
B	V1	39%	61%	7%	18%	76%
	V2	52%	48%	10%	7%	83%
	V3	58%	42%	13%	5%	82%
	V4	58%	42%	13%	5%	82%
	V5	58%	42%	13%	5%	82%
C	V1	26%	74%	4%	31%	64%
	V2	34%	66%	4%	23%	72%
	V3	69%	31%	19%	3%	77%
	V4	67%	33%	18%	4%	79%
	V5	67%	33%	17%	4%	78%

Durante a concepção e a avaliação das regras de negócio, observou-se a recorrência de precisões mais elevadas em trechos com menor percentual de superfície do dormente obstruída, conforme esperado. Ressalta-se que a métrica de precisão não reflete a proximidade entre a taxa de inservíveis após a aplicação da regra e a taxa de dormentes inservíveis medida em campo, apresentada na Tabela 5, mas sim a ocorrência de falsos “dormentes bons” e falsos “dormentes ruins”. Essa abordagem considera o posicionamento exato de cada dormente ao longo da via, de modo que, mais importante do que obter valores globais de taxa de inservíveis próximos aos observados em campo, é assegurar a correta sequência espacial de classificação.

Verificou-se, ainda, que a definição dos limites e das combinações lógicas implica um *trade-off* entre a redução de falsos dormentes bons e o controle de falsos dormentes ruins, de modo que avanços em um indicador resultam, invariavelmente, em penalizações no outro.

Diante dos resultados apresentados, escolheu-se o conjunto de regras V5 para dar sequência ao cálculo da necessidade de dormentes para toda malha ferroviária da VLI, por apresentar precisão média de 82%, com desempenho ótimo para trechos na faixa de cobertura $< 50\%$ e aceitável para valores superiores.

3.4. Aderência ao Remanejamento de Recursos

Após o cálculo da necessidade de dormentes, com base na inspeção por imagem e no refino proporcionado pelas regras de negócio, procedeu-se à realocação de dormentes em 286 ativos, sem alteração do quantitativo global, apenas com redistribuição entre trechos. A principal métrica de avaliação da assertividade do processo implantado é a



aderência ao remanejamento de recursos, entendida como o nível de cumprimento da aplicação dos dormentes redistribuídos nos respectivos locais previstos pela metodologia.

Todavia, os dados de remanejamento disponíveis para análise contemplaram apenas 71 ativos, cujas ordens de serviço de aplicação encontravam-se baixadas no sistema, o que delimita o universo avaliado nesta etapa.

Considerou-se aderente o ativo que apresentou aplicação inferior ou até 120% do quantitativo proposto pelo Sistema de Imagem, similar ao critério avaliado para cumprimento do mapa de dormentes. Os resultados de aderência por ativo/trecho são apresentados a seguir na Tabela 7.

Tabela 7. Aderência da aplicação ao remanejamento de dormentes.

Supervisão	Quantidade de Ativos com Remanejamento	Quantidade de Ativos Aderentes	Percentual de Aderência (%)
1	7	1	14%
2	3	3	100%
3	7	4	57%
4	23	20	87%
5	31	13	42%

Nota: a amostra de 71 ativos condiciona a interpretação da aderência reportada, recomendando-se a ampliação do conjunto de ordens de serviço baixadas em ciclos subsequentes para maior robustez estatística. Observa-se, ainda, que as supervisões 2 e 4, com maiores níveis de aderência, contemplaram trechos utilizados no treinamento dos modelos e no refino das regras de negócio.

4. CONCLUSÃO

Este trabalho moderniza a prospecção de dormentes de madeira ao integrar um sistema automatizado de inspeção por imagem (LRAIL), modelos de visão computacional (DCNN) e um pós-processamento baseado em regras de negócio, reduzindo a subjetividade da inspeção a pé, aumentando a repetibilidade e oferecendo dados 2D/3D georreferenciados para subsidiar o planejamento de manutenção. A definição explícita de critérios de visibilidade (cobertura superficial) mostrou-se determinante para selecionar trechos analisáveis e interpretar o desempenho dos modelos, que foram alinhados aos critérios tradicionais da prospecção por meio de regras em pós-processamento.

Na aplicação, os resultados foram incorporados ao cálculo da necessidade final de dormentes e a um processo que permitiu redistribuir recursos sem aumentar o quantitativo global, utilizando a aderência à aplicação como métrica prática para aferir a incorporação do método ao planejamento e à execução. As limitações observadas concentram-se na dependência da visibilidade (lastro/terra/vegetação), no desempenho inferior em classes mais desafiadoras (p. ex., afundamento/deslocamento de placa e apodrecimento) e na amostra restrita para avaliação de aderência, apontando frentes claras de melhoria.



Como próximos passos, espera-se dar continuidade ao treinamento dos modelos com dados mais amplos e diversos; realizar *feature selection* para priorizar variáveis mais informativas e simplificar o *pipeline*; e conduzir validação cruzada de novas regras de negócio implementadas como modelos de classificação, de modo a quantificar generalização, calibrar limiares e reduzir o *trade-off* entre falsos “bons” e falsos “ruins” em diferentes faixas de cobertura. Essas ações tendem a elevar a robustez do diagnóstico e a consolidar a manutenção baseada em condição como prática corrente.

5. REFERÊNCIAS

FOX-IVEY, Richard; NGUYEN, Thanh; LAURENT, John. **Extended Field Trials of LRAIL for Automated Track Change Detection**. *U.S. Department of Transportation, Federal Railroad Administration, DOT/FRA/ORD-20/14*, 2020. Disponível em: <<https://railroads.dot.gov/sites/fra.dot.gov/files/2020-04/Pavemetrics%20Phase%202.pdf>>. Acesso em: 22 mar. 2026.

KRAUS, Sascha et al. **Digital Transformation: An Overview of the Current State of the Art of Research**. *SAGE Open*, July–Sept. 2021. Disponível em: <<https://journals.sagepub.com/doi/pdf/10.1177/21582440211047576>>. Acesso em: 22 mar. 2026.

MCKINSEY & COMPANY. **The rail sector’s changing maintenance game**. 2018. Disponível em: <<https://www.mckinsey.com/~media/McKinsey/Industries/Public%20and%20Social%20Sector/Our%20Insights/The%20rail%20sectors%20changing%20maintenance%20game/The-rail-sectors-changing-maintenance-game.pdf>>. Acesso em: 22 mar. 2026.

ZHAO, Xia et al. **A review of convolutional neural networks in computer vision**. *Artificial Intelligence Review*, v. 57, art. 99, 2024. Disponível em: <<https://link.springer.com/article/10.1007/s10462-024-10721-6>>. Acesso em: 22 mar. 2026.



AI-BASED WOODEN TIE INSPECTION

ABSTRACT

This paper presents the modernization of wooden sleeper inspection through the integration of an automated image-based inspection system (LRAIL), computer vision techniques based on Deep Convolutional Neural Networks (DCNN), and post-processing using business rules. The objective is to reduce the subjectivity inherent to walking inspections and to provide consistent, repeatable, and georeferenced 2D/3D data to support budgeting and maintenance prioritization. Methodologically, the criteria of the manual inspection were characterized; the data acquisition system was described (2D images and 3D profiles with high-precision GNSS); operational visibility ranges (surface coverage) were defined as prerequisites for model application; component identification and fault classification models were developed and refined; and combinations of business rules were tested through multiple simulations and compared with validation inspections. The results indicate that the models capture a substantial portion of the essential characteristics observed in the field and that performance is sensitive to visibility conditions; the selected rule showed the highest adherence to the defined criteria and was adopted to determine the final sleeper demand and to guide redistribution among track segments, without increasing the overall quantity, whose effectiveness was assessed through application adherence. It is concluded that the proposed approach improves information quality and process traceability, while highlighting limitations related to surface coverage and more challenging defect classes, indicating next steps involving continuous model training, feature selection, and cross-validation of new business rules implemented as classification models.

Keywords: *Artificial Intelligence, Sleeper Inspection, Railway Maintenance, Automated Inspection, Track Infrastructure.*