



APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL GENERATIVA (IA GEN) NA MANUTENÇÃO CENTRADA EM CONFIABILIDADE (MCC) PARA A MANUTENÇÃO PRESCRITIVA DE LOCOMOTIVAS FERROVIÁRIAS

PAULO BALACA¹; JOSÉ TORRES FARINHA²; GILBERTO MARTHA DE SOUZA¹

¹ Universidade de São Paulo (USP) — Brasil

² Instituto Superior de Engenharia de Coimbra (ISEC) — Portugal

RESUMO

Este trabalho apresenta uma revisão bibliográfica sobre a integração da Inteligência Artificial (IA) Generativa (GenAI) à Manutenção Centrada em Confiabilidade (MCC) para a viabilização da manutenção prescritiva em locomotivas ferroviárias. O objetivo é analisar como o uso de arquiteturas generativas, como Generative Adversarial Networks (GANs) e Variational AutoEncoders (VAEs), pode superar a escassez de dados de falhas raras por meio da geração de dados sintéticos e simulação de cenários operacionais complexos. A metodologia consistiu em uma análise sistemática de estudos da última década, com foco em modelos híbridos físico-dados e Digital Twins (DT). Os resultados indicam que avanços recentes em arquiteturas de autoatenção e modelos temporais aumentam a acurácia diagnóstica e a eficiência do agendamento de reparos. Entretanto, identificaram-se desafios críticos de interoperabilidade com sistemas legados e a necessidade de frameworks de certificação e validação técnica sob os padrões rigorosos das normas EN 50126/28/29. Conclui-se que, embora a IA Generativa atue como um catalisador disruptivo para a gestão de ativos, sua implementação sustentável depende da explicabilidade (XAI) para garantir confiança nas decisões prescritivas e segurança operacional em ambientes ferroviários distribuídos.

Palavras-chave: *Inteligência Artificial Generativa, Manutenção Centrada em Confiabilidade, Manutenção Prescritiva, Locomotivas Ferroviárias, Norma EN 50126*

1. INTRODUÇÃO

A indústria ferroviária enfrenta o desafio constante de maximizar a disponibilidade de ativos críticos, como as locomotivas, enquanto minimiza custos operacionais e riscos de segurança. Tradicionalmente, a Manutenção Centrada em Confiabilidade (MCC) tem sido a metodologia padrão para definir estratégias de manutenção baseadas em modos de falha e criticidade. Contudo, a transição para a Manutenção Prescritiva — que não apenas prevê falhas, mas recomenda ações específicas — esbarra na escassez de dados sobre falhas raras e na complexidade dos sistemas modernos.

Neste cenário, a Inteligência Artificial (IA) Generativa (GenAI, Generative AI) surge como uma tecnologia disruptiva. Diferente da IA preditiva convencional, as arquiteturas generativas permitem a criação de dados sintéticos para treinamento de modelos em cenários de baixa ocorrência e a simulação de múltiplos comportamentos operacionais através de Digital Twins (DT). O objetivo deste



trabalho é realizar uma revisão bibliográfica sobre como a integração da GenAI ao framework de RCM pode otimizar a manutenção de locomotivas, focando em arquiteturas avançadas, interoperabilidade e conformidade com as normas de segurança ferroviária EN 50126, EN 50128 e EN 50129.

2. DESENVOLVIMENTO

O estudo centra-se na aplicação da GenAI integrada com a MCC, com foco na manutenção prescritiva de locomotivas ferroviárias. Nesta seção são apresentados os conceitos genéricos da evolução da manutenção, os materiais, procedimentos metodológicos e análises estatísticas e bibliométrica realizadas, evidenciando a evolução das abordagens tradicionais de manutenção para soluções digitais avançadas. O objetivo é demonstrar como a combinação da MCC, Machine Learning (ML), DT e GenAI pode aprimorar diagnósticos, prognósticos e decisões prescritivas no setor ferroviário.

2.1. Evolução e Tipos de Manutenção

A gestão de ativos evoluiu através de paradigmas distintos: a Manutenção Corretiva (reativa), a Preventiva (baseada em tempo/uso), a Preditiva (monitoramento de condição) e a Detectiva (identificação de falhas ocultas). O estágio contemporâneo, a Manutenção Prescritiva, utiliza algoritmos avançados para prescrever a decisão ótima diante de um prognóstico de degradação. Conforme elucidado por SOUZA em *Organização e Gerência da Manutenção* e por MORTELARI et al. em *A MCC na Quarta Geração da Manutenção*, a tecnologia é o vetor dessa maturidade. É imperativo notar que os conceitos de "Detectiva" e "Manutenção Prescritiva" não integravam a obra seminal de MOUBRAY (1997). Embora o MCC de 3ª Geração tenha sido revolucionário, ele era limitado pelo poder de processamento computacional da década de 1990; a atual 4ª Geração exige o processamento massivo de dados e modelos cognitivos que o framework original não poderia prever.

2.2. Inteligência Artificial Generativa (GenAI)

A Inteligência Artificial Generativa (GenAI) surge como uma tecnologia disruptiva que se diferencia da IA preditiva convencional por sua capacidade de não apenas classificar ou prever, mas de criar novos dados e simular cenários complexos. No contexto da gestão de ativos ferroviários, ela atua como um catalisador para a Manutenção Prescritiva, permitindo que o sistema vá além do diagnóstico e recomende ações específicas baseadas em uma compreensão profunda do comportamento do ativo.

As principais características e aplicações da GenAI identificadas nas fontes são:

1. **Superação da Escassez de Dados:** Uma das maiores barreiras para a confiabilidade ferroviária é a falta de registros históricos sobre falhas raras. A GenAI, através de arquiteturas como Generative Adversarial Networks (GANs) e Variational AutoEncoders (VAEs), permite a geração de dados sintéticos para treinar modelos em cenários de baixa ocorrência, aumentando a acurácia diagnóstica;



2. Integração com Digital Twins (DT): A GenAI possibilita a simulação de múltiplos comportamentos operacionais por meio de Gêmeos Digitais, o que facilita a antecipação de falhas em ambientes altamente complexos e distribuídos;
3. Apoio à Decisão e Automação: No framework proposto para locomotivas, a GenAI desempenha funções críticas como a geração automática de relatórios técnicos, a simulação de cenários de falhas e a atualização dinâmica da matriz RCM; e
4. Explicabilidade e Segurança (XAI): Para que a Manutenção Prescritiva seja sustentável e segura, a GenAI deve ser integrada a mecanismos de Inteligência Artificial Explicável (XAI). Isso garante que as decisões prescritivas sejam compreensíveis para os mantenedores humanos, assegurando a confiança necessária para operar sob normas rigorosas, como a EN 50126/28/29.

2.3. Materiais

O estudo caracteriza-se como pesquisa aplicada, exploratória e quantitativa, fundamentada em revisão sistemática da literatura e análise bibliométrica.

Foram utilizadas as seguintes bases de dados:

- Scopus (base principal para análise bibliométrica);
- ScienceDirect (base complementar para aprofundamento técnico);
- Google Acadêmico (exploração inicial e identificação de literatura cinzenta).

A análise bibliométrica foi conduzida com o pacote Bibliometrix, executado no ambiente R (versão 4.x).

O período de coleta e análise compreendeu 2010–2026, considerando a consolidação da manutenção preditiva baseada em dados, o avanço do ML aplicado à engenharia e a emergência recente da GenAI.

2.4. Procedimentos Metodológicos

Fase 1 – Estratégia de Busca

Foram definidos descritores combinando os termos: 'Reliability Centered Maintenance' OR 'RCM' AND 'Predictive Maintenance' AND 'Railway' OR 'Locomotive' AND 'Artificial Intelligence' OR 'Machine Learning' OR 'Generative AI'.

Foram aplicados filtros de período (2010–2026), áreas (Engenharia e Ciência da Computação) e tipo de documento (artigos e revisões).

Fase 2 – Extração e Tratamento dos Dados

Os registros foram exportados em formato BibTeX e CSV contendo autores, ano, fonte, palavras-chave e número de citações. Realizou-se remoção de duplicidades, padronização de termos e exclusão de artigos fora do escopo ferroviário.

Fase 3 – Análise Bibliométrica

Foram realizadas análises de produção científica anual, índice H, citações, redes de coautoria, coocorrência de palavras-chave e mapeamento temático por clusterização (Louvain). Foram utilizadas as funções `biblioAnalysis()`, `summary()`, `networkPlot()` e `thematicMap()`.

A Figura 2, apresenta o fluxo metodológico da pesquisa, estruturado em quatro etapas sequenciais:

1. Definição da estratégia de busca, com seleção de descritores e filtros;
2. Coleta de dados, realizada nas bases Scopus, ScienceDirect e Google Acadêmico;
3. Tratamento dos dados, incluindo limpeza, padronização e exclusão de duplicidades;
4. Análise bibliométrica, com aplicação de técnicas estatísticas e mapeamento temático.



Figura 1. Fluxograma metodológico do estudo

3.EXECUÇÃO DA ANÁLISE BIBLIOMÉTRICA

3.1. Triagem dos Registos

O processo de seleção dos estudos foi conduzido de forma sistemática, conforme as diretrizes do protocolo PRISMA, assegurando transparência, rastreabilidade e reprodutibilidade metodológica. Inicialmente, foram identificados 87 registros por meio de buscas em bases de dados científicas (Scopus, ScienceDirect e Google Acadêmico), cobrindo o período de 1997 a 2026. Após a remoção de estudos não pertinentes com base na leitura dos títulos, 29 registros foram excluídos, resultando em 58 artigos para avaliação em texto completo.

Na etapa de elegibilidade, os artigos foram analisados integralmente à luz dos critérios de inclusão e exclusão previamente definidos. Dessa análise, 29 estudos foram excluídos, principalmente por não apresentarem aderência ao escopo da pesquisa, restando 29 artigos elegíveis.

Por fim, os 29 estudos remanescentes compuseram a amostra final da revisão, sendo submetidos à análise aprofundada nas análises estatísticas e bibliométricas.

Esse corpus consolidado permitiu identificar padrões de evolução temática, autores mais produtivos, redes de colaboração internacional e tendências emergentes relacionadas à integração de MCC, DT e GenAI na manutenção ferroviária.

A Figura 2, apresenta o fluxograma de triagem dos registros, detalhando visualmente o processo de filtragem desde a coleta inicial de 87 artigos até a seleção final dos 29 estudos válidos, explicitando os critérios de exclusão por duplicidade ou falta de aderência ao tema ferroviário.




Figura 2. Fluxograma da triagem dos registros utilizados no estudo

3.2. Análises Estatísticas

A análise estatística dos dados extraídos das bases de dados citadas no ponto 2.3, de (1997–2026) permitiram identificar padrões relevantes na evolução da pesquisa sobre manutenção ferroviária, MCC e integração com Inteligência Artificial (IA).

Produção científica anual: O conjunto de dados mostra publicações desde 1997, mas o crescimento significativo ocorre a partir de 2010. O período de 2023–2025 concentra o maior número de artigos, refletindo o avanço das tecnologias digitais, DT e GenAI aplicadas à manutenção prescritiva.

A Figura 3. Produção científica anual no período de 1997 a 2026, apresenta uma distinção entre artigos e revisões, bem como o número cumulativo de publicações. Observa-se crescimento acentuado da produção a partir da última década, indicando a consolidação e expansão do campo de pesquisa.




Figura 3. Produção científica anual no período de 1997 a 2026

Autores mais produtivos: Entre os 10 principais autores destacam-se Crespo Márquez, Adolfo, Kaewunruen, Sakdirat, além de pesquisadores como Zhang (Yujin, Yue, Chuntian), Chen (Siyuan, Zhiwen) e Mosca (Roberto, Marco), evidenciando grupos de pesquisa consolidados em torno da manutenção ferroviária e da IA, conforme mostra o quadro da figura 4.




Figura 4. Os 10 principais Autores mais produtivos

Rede de países: A rede de colaboração entre países evidencia a predominância de polos científicos como Estados Unidos, China e Alemanha, caracterizados por elevada intensidade de conexões. Observa-se forte interação entre esses países,

formando o núcleo central da rede. Países como Reino Unido, França e Canadá também apresentam participação relevante, enquanto os demais atuam de forma periférica, com colaborações mais específicas. A estrutura geral indica um padrão concentrado de produção científica, com forte articulação internacional entre os principais centros de pesquisa. A Figura 5 apresenta a rede de colaboração internacional entre países no contexto da pesquisa sobre Manutenção Centrada em Confiabilidade (MCC) e Inteligência Artificial aplicada ao setor ferroviário.




Figura 5. Diagrama de cordas da colaboração internacional entre países

Clusters de palavras-chave: A análise de coocorrência revela quatro agrupamentos principais:

- GenAI e Deep Learning;
- DT e manutenção adaptativa;
- MCC e confiabilidade;
- Manutenção prescritiva e otimização de políticas.

A Figura 6, apresenta a rede de coocorrência de palavras-chave evidenciando quatro clusters temáticos distintos, identificados por cores. O cluster vermelho concentra termos relacionados à Inteligência Artificial, como GenAI, Deep Learning e Neural Networks, representando abordagens baseadas em dados. O cluster verde agrupa conceitos de Digital Twin e manutenção adaptativa, refletindo a digitalização dos sistemas. O cluster azul está associado à Manutenção Centrada na Confiabilidade (MCC), incluindo termos como RCM, Reliability e Failure Analysis, caracterizando abordagens tradicionais de engenharia. Por fim, o cluster laranja reúne conceitos de manutenção prescritiva e otimização, como Prescriptive Maintenance, Optimization e Decision Models, evidenciando a evolução para estratégias orientadas à decisão. As conexões entre os clusters indicam a crescente integração entre métodos clássicos de confiabilidade e técnicas avançadas de inteligência artificial.




Figura 6. Clusters de palavras-chave

Evolução temática: A linha temporal mostra uma transição clara:

- 1997–2010: foco em MCC tradicional e confiabilidade;
- 2011–2020: surgimento de ML;
- 2021–2026: consolidação de DT, GenAI e manutenção prescritiva como temas centrais.

A figura 7, mostra a evolução temática evidencia uma transição clara ao longo do período analisado. Entre 1997 e 2010, observa-se predominância de abordagens tradicionais baseadas em Manutenção Centrada na Confiabilidade (MCC) e análise de confiabilidade. No intervalo de 2011 a 2020, destaca-se o surgimento e crescimento de técnicas de Machine Learning, marcando a incorporação de métodos baseados em dados. A partir de 2021, verifica-se a consolidação de Digital Twin, Inteligência Artificial Generativa e manutenção prescritiva como temas centrais, refletindo a maturidade e transformação digital do campo.




Figura 7. Evolução temática (1997 - 2026)

A Tabela 1, fornece uma síntese quantitativa das análises estatísticas realizadas sobre a produção científica entre 1997 e 2026. Ela destaca indicadores cruciais, como o pico de publicações entre 2023–2025 e a transição temática da RCM tradicional para a IA Generativa e Gêmeos Digitais.

Tabela 1. Síntese das Análises Estatísticas da Produção Científica (1997–2026)

Indicador	Resultado
Produção científica anual	Crescimento significativo a partir de 2010; pico entre 2023–2025
Autores mais produtivos	Crespo Márquez, Kaewunruen, Zhang (Yujin, Yue, Chuntian), Chen, Mosca
Rede de países	China, EUA, Alemanha e Brasil; destaque para conexões China–EUA–Alemanha
Clusters de palavras-chave	IA generativa e deep learning; Digital twins; RCM; Prescriptive maintenance
Evolução temática	1997–2010: RCM tradicional; 2011–2020: ML e manutenção condicional; 2021–2026: digital twins e IA generativa



3.3. Análises Bibliométrica

A análise bibliométrica realizada sobre o conjunto de dados citados no ponto 2.3, evidenciam a evolução da pesquisa em **manutenção ferroviária, RCM e integração com IA**:

- **Distribuição temporal:** As publicações mais antigas datam de 1997, mas o crescimento significativo ocorre a partir de 2010. O período de **2023–2025 concentra o maior número de artigos**, refletindo o avanço das tecnologias digitais, DT e GenAI aplicadas à manutenção prescritiva.
- **Autores recorrentes:** Destacam-se nomes como **Crespo Márquez, Adolfo**, com contribuições em DT e otimização de políticas de manutenção, e **Kaewunruen, Sakdirat**, com trabalhos sobre manutenção ferroviária baseada em *Deep Reinforcement Learning*. Outros autores frequentes incluem **Zhang (Yujin, Yue, Chuntian)**, **Chen (Siyuan, Zhiwen)** e **Mosca (Roberto, Marco)**, evidenciando grupos de pesquisa consolidados.
- **Temas predominantes:**
 - **RCM clássico** em sistemas ferroviários e elétricos (1997–2010).
 - **DT e IA** (2022–2025), com frameworks como *RailTwin* e aplicações em manutenção adaptativa.
 - **GenAI e XAI** (2024–2026), com estudos sobre *GAN-based augmentation, explainable AI* e geração de dados sintéticos.
 - **Prescriptive Maintenance** consolidada em conferências recentes (2024–2025).
- **Impacto científico:** Alguns artigos apresentam elevado número de citações, como **D’Ariano et al. (2019)** com mais de **120 citações**, enquanto trabalhos mais recentes ainda acumulam poucas citações, mas refletem tendências emergentes.
- **Interpretação geral:** O campo mostra uma **linha evolutiva clara** — de MCC tradicional para manutenção baseada em condição, seguida pela integração com DT e, mais recentemente, pela aplicação de IA generativa e prescritiva, observa-se crescimento simultâneo das publicações e das citações, com aceleração significativa nas últimas décadas.

A Figura 8, evidencia a evolução conjunta da produção científica e do impacto acadêmico, demonstrando uma tendência de crescimento acelerado a partir da última década, particularmente associada à incorporação de tecnologias digitais e inteligência artificial.




Figura 8. Produção científica anual (artigos, revisões e citações)

4. RESULTADOS E DISCUSSÕES

A análise estatística e bibliométrica realizada entre 1997 e 2026 evidenciou a evolução da pesquisa em RCM, manutenção ferroviária e IA:

- Produção científica: crescimento contínuo a partir de 2010, com pico entre 2023–2025, impulsionado por DT e GenAI.
- Autores mais produtivos: destaque para Crespo Márquez, Adolfo e Kaewunruen, Sakdirat, além de Zhang, Chen e Mosca, indicando grupos consolidados.
- Colaboração internacional: pólos principais em China, EUA, Alemanha e Índia e Brasil, com forte interação China–EUA–Alemanha e o Brasil emergindo como parceiro estratégico, embora o Brasil não figure entre os países com maior volume absoluto de publicações no gráfico de colaboração, sua presença é identificada em conexões específicas relevantes, especialmente com os Estados Unidos e Índia, indicando um papel emergente na rede científica.
- Clusters temáticos: quatro agrupamentos principais — GenAI e DL; DTe manutenção adaptativa; RCM e confiabilidade; manutenção prescritiva e otimização de políticas.
- Evolução temática: transição de RCM tradicional (1997–2010) para ML e MCC (2011–2020), culminando em DT e GenAI (2021–2026).



5. CONCLUSÃO

A análise bibliométrica evidenciou o crescimento significativo da produção científica sobre manutenção ferroviária e sua integração com Inteligência Artificial, especialmente a partir de 2010, com pico recente entre 2023–2025. Observou-se uma clara evolução temática, partindo da Manutenção Centrada na Confiabilidade (MCC) tradicional para abordagens baseadas em Machine Learning, Digital Twins e, mais recentemente, Inteligência Artificial Generativa (GenAI) .

Os resultados indicam uma convergência entre confiabilidade, dados e modelos inteligentes, apontando a consolidação da manutenção prescritiva como novo paradigma. No entanto, foram identificadas lacunas importantes, incluindo a ausência de frameworks integrados MCC-IA, a limitação de estudos aplicados a locomotivas e desafios relacionados à explicabilidade (XAI), validação e conformidade com normas ferroviárias.

Conclui-se que, apesar do avanço acelerado da área, a integração efetiva entre MCC e IA ainda requer maior maturidade metodológica e validação prática. Como perspectivas futuras, destacam-se o desenvolvimento de modelos híbridos estruturados, a aplicação em ambientes reais e o alinhamento com requisitos normativos, visando garantir confiabilidade e segurança operacional.

AGRADECIMENTOS

Os autores agradecem à UNIVERSIDADE DE SÃO PAULO (USP) e ao INSTITUTO SUPERIOR DE ENGENHARIA DE COIMBRA (ISEC) pelo apoio e suporte ao desenvolvimento desta pesquisa.

REFERÊNCIAS

1. ALONSO-GONZÁLEZ, Miguel; GARCÍA-DÍAZ, Vicente; LÓPEZ PÉREZ, Benjamín. Designing an Agentic AI-Driven Framework for Decision-Making in Industrial Maintenance. **Communications in Computer and Information Science**, v. 2729, p. 118–130, 2026.
2. AMALIAH, Nuuraan Risqi; TJAHJONO, Benny; PALADE, Vasile. Human-in-the-Loop XAI for Predictive Maintenance: A Systematic Review. **Electronics (Switzerland)**, v. 14, n. 17, art. 3384, 2025.
3. BARBARESCHI, Mario *et al.* Harnessing Explainable AI in Railway: A Decision Tree-Based Approach. **Proceedings – 2025 20th European Dependable Computing Conference Companion Proceedings**, p. 119–124, 2025.
4. BOBADILLA, Héctor A. Fernández; MARTIN, Ullrich. GAN-based Data Augmentation of Railway Track Irregularities for Fault Diagnosis. **Proceedings of the International Joint Conference on Neural Networks**, 2024.



5. BRIS-PEÑALVER, Francisco Javier; VERDECIA-PEÑA, Randy; ALONSO, José I. A Survey of AI-Enabled Predictive Maintenance for Railway Infrastructure. **Sensors**, v. 26, n. 3, art. 906, 2026.
6. BROTHERTON, Tom *et al.* A testbed for data fusion for engine diagnostics and prognostics. **IEEE Aerospace Conference Proceedings**, v. 6, p. 3029–3042, 2002.
7. CHAKRAVORTY, Deep *et al.* Application of Reliability Centered Maintenance for Electric Locomotive Right from Design Phase. **Lecture Notes in Mechanical Engineering**, p. 535–543, 2024.
8. CHENG, Yu *et al.* Review of the Applied Research on Multimodal Deep Learning in Rail Top Surface Defect Detection. **China Railway Science**, v. 46, n. 1, p. 70–86, 2025.
9. CRESPO MÁRQUEZ, Adolfo; PÉREZ OLIVER, Diego. Leveraging Generative AI for Modelling and Optimization of Maintenance Policies in Industrial Systems. **Information (Switzerland)**, v. 16, n. 3, art. 217, 2025.
10. D’ARIANO, Andrea *et al.* Integrated stochastic optimization approaches for tactical scheduling of trains and railway infrastructure maintenance. **Computers and Industrial Engineering**, v. 127, p. 1315–1335, 2019.
11. DIRNFELD, Ruth *et al.* Railway Digital Twins and Artificial Intelligence: Challenges and Design Guidelines. **Communications in Computer and Information Science**, v. 1656, p. 102–113, 2022.
12. FARINHA, José Manuel Torres. **Asset Maintenance Engineering Methodologies**. 1. ed. Boca Raton: CRC Press, 2020.
13. HADJ-MABROUK, Habib. Contributions and limitations of AI and machine learning in railway operations, maintenance, and safety: A literature review. **Journal of Risk and Reliability**, v. 240, n. 1, p. 3–36, 2026.
14. JI, Hangyu *et al.* Optimization of train schedule with uncertain maintenance plans in high-speed railways. **Omega (United Kingdom)**, v. 124, art. 102999, 2024.
15. KHAJEHDEZFULY, Amin; AZIZIPOUR, Hadi; KAEWUNRUEN, Sakdirat. A review of applications of AI in monitoring, inspection, and maintenance of railway tracks. **Journal of Industrial Information Integration**, v. 48, art. 101005, 2025.
16. MORTELARI, Denis; SIQUEIRA, Kleber; PIZZATO, Nei. **O RCM na Quarta Geração da Manutenção – A Moderna Gestão de Ativos**. São Paulo: Editora RG, 2022.
17. MOUBRAY, John. **Reliability-Centered Maintenance**. Oxford: Butterworth-Heinemann, 1997.
18. NIEMINEN, Walter *et al.* Synthetic Data for Predictive Maintenance: A Systematic Review. **Journal of Intelligent Manufacturing**, 2026.
19. NUNES, José. **Gestão da Manutenção Industrial**. Lisboa: Lidel, 2015.



20. PEREIRA, Carlos. **Manutenção Centrada na Confiabilidade: Aplicações Industriais**. São Paulo: Blucher, 2018.
21. RODRÍGUEZ, Mauricio *et al.* Application of Degradation and Optimization Models for digitization of Maintenance Management in Railway Infrastructures. **IFAC-PapersOnLine**, v. 58, n. 8, p. 115–120, 2024.
22. SALIERNO, Giulio; LEONARDI, Letizia; CABRI, Giacomo. Generative AI and Large Language Models in Industry 5.0: Shaping Smarter Sustainable Cities. **Encyclopedia**, v. 5, n. 1, art. 30, 2025.
23. SEYEDAN OSKOU EI, Seyed Farboud; ABAPOUR, Mehdi; BEIRAGHI, Mojtaba. Identifying critical components for railways rolling stock reliability: a case study for Iran. **Scientific Reports**, v. 14, art. 12080, 2024.
24. SOUZA, Valdir Cardoso de. **Organização e Gerência da Manutenção**. 5. ed. São Paulo: All Print, 2010.
25. SRESAKOOLCHAI, Jessada; KAEWUNRUEN, Sakdirat. Railway infrastructure maintenance efficiency improvement using deep reinforcement learning integrated with digital twin based on track geometry and component defects. **Scientific Reports**, v. 13, n. 1, art. 2439, 2023.
26. THOMPSON, Emmanuel Anu *et al.* Revolutionizing railway systems: A systematic review of digital twin technologies. **High-speed Railway**, v. 3, n. 3, p. 238–250, 2025.
27. YAO, Yujin; LI, Qi; LI, Zhuoran. Design and Key Technology Research of Intelligent Operation and Maintenance System for Suspended Monorail Turnouts. **Railway Standard Design**, v. 67, n. 10, p. 101–107, 2023.
28. ZHANG, Yue; WANG, Boyi; WANG. **Application of Artificial Intelligence (AI) in Reliability-Centered Maintenance (RCM) for Prescriptive Maintenance of Railway Locomotives**. 2026. Manuscrito não publicado.



ABSTRACT

This study presents a literature review on the integration of Generative Artificial Intelligence (AI) with Reliability-Centered Maintenance (RCM) to enable prescriptive maintenance in railway locomotives. The objective is to analyze how generative architectures, such as GANs and VAEs, can overcome the scarcity of rare failure data through synthetic data generation and the simulation of complex operational scenarios. The methodology consisted of a systematic analysis of studies from the last decade, focusing on hybrid physics-data models and digital twins. Results indicate that recent advances in self-attention architectures and temporal models increase diagnostic accuracy and repair scheduling efficiency. However, critical challenges regarding interoperability with legacy systems and the need for technical certification and validation frameworks under the rigorous EN 50126/28/29 standards were identified. It is concluded that, while Generative AI acts as a disruptive catalyst for asset management, its sustainable implementation depends on explainability (XAI) to ensure confidence in prescriptive decisions and operational safety in distributed railway systems.

Keywords: *Generative Artificial Intelligence; Reliability-Centered Maintenance; Prescriptive Maintenance; Railway Locomotives; EN 50126 Standard.*