



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários

ANP
TRILHOS TIC TRENS

32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

CATEGORIA 3

ARQUITETURA INTEGRADA MCC E IA GENERATIVA PARA MANUTENÇÃO

PRESCRITIVA DE LOCOMOTIVAS FERROVIÁRIA



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA **13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS**

RESUMO

A maturidade da manutenção preditiva ferroviária, baseada em telemetria e IA analítica, encontra seu limite na capacidade de transformar um prognóstico de falha em uma ação operacional prescritiva, rastreável e aderente às normas de segurança. Este artigo apresenta uma arquitetura operacional que integra Manutenção Centrada na Confiabilidade (MCC), Análise de Modos e Efeitos de Falha (FMEA/FMECA), IA generativa, *Retrieval-Augmented Generation* (RAG), *Large Language Models* (LLMs) e *Explainable AI* (XAI). O objetivo é estruturar um sistema de manutenção prescritiva ferroviária capaz de antecipar a falha funcional de um ativo e gerar uma recomendação contextualizada, baseada em manuais técnicos, histórico de manutenção, lógica de confiabilidade e conhecimento técnico estruturado. Em um exemplo aplicado ao subsistema de turboalimentação de uma locomotiva diesel-elétrica, o modelo demonstra como a degradação de variáveis como temperatura de exaustão, pressão de sobrealimentação, temperatura de óleo do mancal, vibração e rotação do eixo, detectada por sensores e processada por modelos analíticos, aciona um esquema funcional prescritivo. Nesse esquema, a IA analítica emite o alerta e a estimativa de Vida Útil Remanescente (RUL), o RAG recupera evidências em FMEA/FMECA, lógica MCC e documentos técnicos, os LLMs interpretam o contexto da anomalia e geram uma proposta de Ordem de Serviço (OS), enquanto a XAI explicita as variáveis e evidências que sustentam a recomendação para validação humana. A arquitetura, governada pelas normas EN 50126, EN 50128 e EN 50129, fortalece a rastreabilidade, a auditabilidade e a segurança da decisão, posicionando a IA generativa e os LLMs como copilotos técnicos do



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

engenheiro de manutenção. Como contribuição, o trabalho mostra um caminho operacional para reduzir a latência decisória, padronizar prescrições, apoiar a governança RAMS e contribuir para a melhoria projetada do MTBF, do MTTR e da disponibilidade da frota no contexto do *Railway 4.0* — ganhos que, nesta fase, constituem projeções metodológicas teóricas, não resultados validados em frota real. A arquitetura atingiu maturidade TRL 3 (Prova de Conceito Analítica), com validação retrospectiva em *datasets* públicos (NASA C-MAPSS FD001 e MetroPT-3), protótipo RAG com geração de Ordens de Serviço prescritivas e avaliação por cinco especialistas ferroviários (Likert 4,10/5,0; F1-score 87%).

Palavras-chave: Manutenção prescritiva ferroviária; MCC; IA generativa; Locomotivas diesel-elétricas.

1. INTRODUÇÃO

A busca por maior disponibilidade operacional, segurança e eficiência na gestão de ativos é um requisito central para operadoras ferroviárias de carga e passageiros [1]. Em um cenário de pressão por redução de custos, aumento da confiabilidade e melhor uso dos ativos, a manutenção de material rodante, especialmente de locomotivas diesel-elétricas, evoluiu de práticas corretivas e preventivas para estratégias preditivas baseadas em condição. Essa evolução foi impulsionada pela instrumentação dos ativos, pela telemetria embarcada e pela aplicação de modelos analíticos capazes de detectar anomalias, classificar padrões de degradação e estimar a Vida Útil Remanescente (*RUL*) de componentes críticos [9].



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

Apesar desse avanço, a prática operacional revela um gargalo crítico: a passagem do prognóstico para a ação. Um painel que informa alta probabilidade de falha no turbocompressor ainda exige que o planejador ou o engenheiro de manutenção consulte análises MCC, planilhas FMEA/FMECA, manuais do fabricante, históricos de ordens de serviço e critérios de segurança para decidir o que fazer, quando fazer e como justificar tecnicamente a intervenção. Esse processo permanece parcialmente manual, depende da experiência individual e pode gerar latência decisória, variabilidade de diagnóstico e dificuldades de rastreabilidade.

Este artigo endereça essa lacuna ao propor uma arquitetura operacional que integra IA analítica, MCC, FMEA/FMECA, RAG, LLMs e XAI em um fluxo contínuo de manutenção prescritiva. A tese técnica é que a IA generativa, quando ancorada em bases de conhecimento confiáveis e submetida a governança RAMS, pode apoiar a etapa de raciocínio prescritivo, convertendo alertas de degradação em recomendações de manutenção contextualizadas, explicáveis e prontas para validação humana. O caso aplicado ao subsistema de turboalimentação demonstra a utilidade da arquitetura para reduzir o tempo de diagnóstico, fortalecer a rastreabilidade da decisão e contribuir para a melhoria projetada de indicadores como MTBF, MTTR e disponibilidade operacional — estimativas metodológicas dependentes de validação empírica em frota real.



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA **13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS**

2. DIAGNÓSTICO: *RAILWAY 4.0*, MANUTENÇÃO PREDITIVA E SUAS LIMITAÇÕES

A digitalização dos ativos ferroviários, associada ao conceito de *Railway 4.0*, consolidou três pilares tecnológicos que viabilizam a manutenção prescritiva [10]. O primeiro pilar é a telemetria ferroviária avançada. Locomotivas modernas ou retrofitadas são dotadas de controladores, barramentos de dados, sensores e *gateways* embarcados capazes de transmitir dados operacionais para plataformas centrais de armazenamento e análise. Variáveis como temperaturas, pressões, vibrações, rotações, correntes elétricas e eventos de falha passam a formar uma base histórica útil à engenharia de confiabilidade.

O segundo pilar é a IA analítica aplicada ao prognóstico. Sobre os dados coletados, modelos como *Random Forest*, *XGBoost* e redes recorrentes do tipo *LSTM* podem ser treinados para detectar desvios, classificar modos de falha e estimar *RUL* [9]. A saída desse pilar é essencialmente preditiva: informar o que tende a falhar, com qual probabilidade e em que horizonte operacional.

O terceiro pilar, foco deste artigo, é a cognição operacional com IA generativa. Esse pilar não substitui a IA analítica, mas complementa seu resultado ao automatizar parte do raciocínio que sucede o prognóstico. Com *RAG*, *LLMs* e *XAI* [7][8], o sistema pode recuperar evidências em documentos técnicos, interpretar o alerta à luz da MCC [2] e da FMEA/FMECA [3], propor uma ação de manutenção e explicar quais dados sustentam a recomendação. A Figura 1



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

apresenta esse fluxo funcional em termos de entrada, processamento prescritivo, validação e retroalimentação.

Embora a manutenção preditiva represente um avanço expressivo frente à manutenção reativa, ela ainda apresenta limitações no ambiente operacional ferroviário. A primeira é a fragmentação do conhecimento. O alerta preditivo normalmente fica em um sistema de telemetria ou dashboard, enquanto a justificativa técnica da intervenção está dispersa em FMEA/FMECA, análises MCC, manuais do fabricante original (OEM — Original Equipment Manufacturer) e históricos do CMMS/EAM (Sistema Computadorizado de Gestão da Manutenção / *Enterprise Asset Management*).

A segunda limitação é a latência decisória. Entre o alerta de degradação e a emissão de uma OS completa pode existir um intervalo significativo, composto por análise de dados, consulta documental, verificação de peças, avaliação de criticidade e validação de segurança. Em ativos críticos, como locomotivas de carga pesada, essa latência pode elevar o risco de falha funcional e indisponibilidade não programada.

A terceira limitação é a variabilidade de decisão. Dois especialistas podem interpretar de forma diferente uma mesma assinatura de degradação, principalmente quando o histórico do ativo é incompleto ou quando a base documental não está integrada ao processo decisório. Por fim, há uma limitação de rastreabilidade: nem sempre a ligação entre alerta, evidência técnica, critério de confiabilidade e ação prescrita é registrada de forma auditável.



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

A manutenção prescritiva proposta busca superar esses pontos integrando dados, conhecimento técnico, explicabilidade e decisão humana em um único fluxo governado.

Um quarto pilar emergente, ainda em consolidação na literatura, é a integração dos Gêmeos Digitais (*Digital Twins*) ferroviários com modelos de IA generativa e *LLMs*. Um Gêmeo Digital é uma representação computacional dinâmica e sincronizada de um ativo físico — no caso, a locomotiva e seus subsistemas —, alimentada continuamente por dados de telemetria em tempo real. Quando integrado a *LLMs* via arquitetura *RAG*, o Gêmeo Digital passa de um modelo de simulação passivo para um agente prescritivo ativo: o estado atual do ativo é consultado semanticamente, o histórico de falhas é recuperado do contexto e a recomendação de manutenção é gerada de forma contextualizada e auditável [10]. A arquitetura proposta neste artigo pode ser interpretada como um passo estruturado em direção a esse paradigma: o motor prescritivo *RAG/LLM/XAI* opera sobre uma base de conhecimento viva (corpus técnico, FMEA/FMECA, histórico de OS), funcionalmente equivalente a um Gêmeo Digital de conhecimento, embora sem a sincronização contínua de estados físicos que caracteriza os *Digital Twins* plenos. A formalização dessa integração constitui uma das fronteiras de pesquisa identificadas na revisão bibliométrica e orienta parte da agenda de trabalhos futuros deste estudo.

A revisão bibliométrica de 195 documentos publicados entre 1997 e 2026 (Scopus e Web of Science) confirmou quatro lacunas que sustentam a formulação deste artigo: (i) predominância da manutenção preditiva frente à prescritiva — a literatura apresenta métodos robustos de prognóstico, mas carece de abordagens para converter alertas em



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

recomendações acionáveis; (ii) baixa integração entre MCC e IA generativa — a MCC é consolidada como metodologia de confiabilidade, mas estudos que a combinam com *LLMs* são escassos; (iii) uso limitado de fontes técnicas do fabricante em sistemas inteligentes de manutenção; e (iv) pouca articulação entre IA aplicada à manutenção e normas RAMS. A arquitetura proposta neste artigo posiciona-se exatamente nessas quatro lacunas, integrando MCC, modelos preditivos, *LLMs* com *RAG* e governança EN 50126/50128/50129 em um único fluxo prescritivo [11][12][13][14][15][16][17][18].

Para assegurar a validade metodológica e a padronização dos processos de engenharia de confiabilidade propostos, o mapeamento funcional e a análise de modos de falha realizados nesta arquitetura seguem rigorosamente os critérios estabelecidos pelas normas IEC 60812 [3] (para FMEA/FMECA) e SAE JA1011/SAE JA1012 — que estabelecem os requisitos mínimos para que um processo seja considerado um verdadeiro *Reliability-Centered Maintenance* (RCM) —, conferindo conformidade normativa e reprodutibilidade industrial ao modelo proposto, e posicionando a arquitetura como aderente não apenas às normas ferroviárias de segurança (EN 50126/50128/50129), mas também aos padrões internacionais de engenharia de confiabilidade amplamente reconhecidos pelo setor [21].

3. ARQUITETURA OPERACIONAL MCC + IA GENERATIVA PARA MANUTENÇÃO PRESCRITIVA

A arquitetura proposta organiza a manutenção prescritiva em camadas interoperáveis, criando um fluxo contínuo desde a coleta de dados embarcados até a validação da OS no




Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

CMMS/EAM. A Figura 1 sintetiza o esquema funcional prescritivo. O Quadro 1 detalha as camadas da arquitetura, suas funções, componentes tecnológicos e entregáveis operacionais.

Figura 1 - Fluxo funcional da manutenção prescritiva ferroviária.



Fonte: Elaborado pelos autores, 2026

Quadro 1 - Camadas da arquitetura operacional.

Camada	Função primária	Tecnologias/componentes	Entregável principal
1. Aquisição e <i>edge computing</i>	Captura, pré-processamento e transmissão de dados de condição.	Sensores, CLPs, gateways embarcados, filtros de evento e detecção de limiares.	Telemetria contextualizada e alertas de condição.
2. Data lake e IA analítica	Armazenamento e inferência preditiva para prognóstico de falha.	Data lake, <i>Random Forest</i> , <i>XGBoost</i> , <i>LSTM</i> e modelos de classificação/anomalia.	Probabilidade de falha, <i>RUL</i> e anomalia detectada.



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários




32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

3. Motor prescritivo inteligente	Raciocínio automatizado para recomendação contextualizada, justificada e auditável.	RAG, LLMs, FMEA/FMECA, MCC, manuais OEM e XAI.	Proposta de OS com instruções, peças, riscos e justificativa técnica.
4. CMMS/EAM e governança	Gestão da OS, rastreabilidade, validação humana e retroalimentação.	SAP PM, IBM Maximo, workflow de aprovação e módulo de compliance RAMS.	OS validada, registro de auditoria e <i>feedback</i> para melhoria contínua.

Fonte: Elaborado pelos autores, 2026.

A Figura 2 amplia a visão da arquitetura no contexto *Railway 4.0*, mostrando a integração entre locomotiva conectada, comunicação, *data lake*, motor prescritivo e aplicações de gestão de ativos.

Figura 2 - Arquitetura *Railway 4.0* aplicada à locomotiva.



Fonte: Elaborado pelos autores, 2026.



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários




32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

3.1. Motor de Prescrição Inteligente

O motor de prescrição inteligente é a camada responsável por transformar o prognóstico em recomendação de manutenção. Ao receber um evento, por exemplo "anomalia de temperatura de óleo do mancal do turbocompressor, probabilidade de falha de 92% e *RUL* estimada de 100 horas", o sistema aciona três funções integradas: recuperação de contexto técnico, geração de prescrição e explicabilidade da recomendação.

Na primeira função, o *RAG* realiza busca semântica [7] e estruturada em FMEA/FMECA [3], lógica MCC [2], manuais OEM e histórico de ordens de serviço. Na segunda função, os *LLMs* recebem o alerta, o contexto recuperado e as restrições operacionais, sintetizando uma proposta de OS com ação recomendada, instruções de trabalho, peças, ferramentas, riscos e critérios de validação. Na terceira função, a *XAI* [8] organiza a trilha de evidências, indicando quais variáveis de telemetria e quais documentos sustentaram a recomendação.

Figura 3 - Integração entre MCC, IA analítica, *RAG*, *LLMs* e *XAI*.



Fonte: Elaborado pelos autores, 2026.



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

4. CASO APLICADO: SUBSISTEMA DE TURBOALIMENTAÇÃO DE LOCOMOTIVA DIESEL-ELÉTRICA

Para demonstrar a aplicabilidade da arquitetura, foi estruturado um caso aplicado em cenário representativo de uma locomotiva diesel-elétrica de transporte de carga pesada. O foco é o subsistema de turboalimentação, componente crítico para a eficiência do motor diesel, consumo de combustível, potência disponível e disponibilidade operacional do ativo.

4.1. Contexto operacional e instrumentação

O subsistema de turboalimentação considerado é composto por turbocompressor acionado por gases de exaustão, conjunto rotor/mancal lubrificado a óleo e circuitos associados de admissão e exaustão. A falha funcional principal analisada é a incapacidade de manter a pressão de sobrealimentação dentro dos limites especificados, o que pode resultar em perda de potência, aumento de consumo, elevação térmica e parada não programada. A Tabela 1 apresenta as principais variáveis monitoradas.

Tabela 1 - Variáveis monitoradas do subsistema de turboalimentação.

Variável monitorada	Sensor/tecnologia	Unidade	Relevância para o modo de falha
Temperatura de exaustão	Termopar tipo K no coletor	°C	Indica eficiência de combustão e carga térmica na turbina. Desvios podem sugerir incrustação, restrição ou desgaste.



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

Rotação do eixo do turbocompressor	Sensor indutivo no alojamento do mancal	RPM	Mostra a assinatura dinâmica do rotor. Alterações com perda de pressão podem indicar desbalanceamento ou falha de mancal.
Pressão de sobrealimentação	Transdutor de pressão no coletor de admissão	kPa	Relaciona rotação e entrega de ar. Baixa pressão com rotação elevada indica perda de eficiência aerodinâmica.
Temperatura de óleo do mancal	Sensor resistivo PT100 na saída do mancal	°C	Indica atrito excessivo e degradação do filme lubrificante, precursor de falha catastrófica do mancal.
Vibração da carcaça do turbocompressor	Acelerômetro piezoelétrico triaxial	gRMS	Permite diagnóstico espectral de falhas incipientes, como desbalanceamento em 1x RPM e defeitos de rolamento.

Fonte: Elaborado pelos autores, 2026.

Nota-se que o monitoramento de vibração por acelerômetros triaxiais gera um volume massivo de dados de alta frequência (tipicamente 5–25 kHz por canal). Para mitigar restrições de latência de rede e de conectividade intermitente comuns em malhas ferroviárias isoladas, o Gateway Edge Embarcado (Camada 1 da arquitetura) realiza o processamento local do sinal antes da transmissão: aplica a Transformada Rápida de Fourier



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

(FFT) sobre as séries temporais de vibração e calcula os indicadores estatísticos consolidados — dentre eles o gRMS (nível global de vibração em aceleração RMS), picos espectrais em 1xRPM e harmônicas de falha de mancal. Dessa forma, apenas esses indicadores e os alarmes de desvio espectral são transmitidos via rede celular ou Wi-Fi de pátio, reduzindo o tráfego de dados em até duas ordens de magnitude em relação à transmissão de sinais brutos e viabilizando a arquitetura em cenários de conectividade restrita sem comprometer a resolução diagnóstica.

4.2. Fluxo prescritivo do caso de uso

A Figura 4 apresenta o fluxo prescritivo proposto, estruturado em cinco raias funcionais que integram monitoramento em tempo real, inteligência artificial, gestão da manutenção e tomada de decisão humana em um ambiente de manutenção prescritiva para locomotivas ferroviárias. Na Raia 1 (Locomotiva/Edge), sensores embarcados monitoram continuamente parâmetros críticos, como temperatura, vibração e outras variáveis operacionais, identificando desvios em relação ao comportamento normal do equipamento. Quando uma condição anômala é detectada, os dados são priorizados e transmitidos para um *Data Lake*, garantindo baixa latência e preservação das informações para análise posterior. Na Raia 2 (*Data Lake*/IA Analítica), um modelo baseado em redes neurais recorrentes do tipo *LSTM* (Long Short-Term Memory) processa as séries temporais dos sinais coletados e estima a probabilidade de ocorrência de falha. Caso essa probabilidade ultrapasse o limiar previamente estabelecido (por exemplo, 90%), o sistema gera automaticamente um alerta



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

crítico acompanhado da estimativa de Remaining Useful Life (*RUL*), permitindo antecipar a intervenção antes da ocorrência da falha funcional. Em seguida, na Raia 3 (Motor Prescritivo *RAG/LLMs/XAI*), um mecanismo de *Retrieval-Augmented Generation* (*RAG*) consulta documentos técnicos, como análises FMEA, manuais do fabricante (OEM) e procedimentos de manutenção, fornecendo contexto especializado para um *Large Language Model* (LLM) elaborar o racional técnico da intervenção e as instruções de trabalho recomendadas. Paralelamente, técnicas de *Explainable Artificial Intelligence* (*XAI*) registram as evidências, justificativas e fatores que fundamentaram a recomendação, promovendo transparência, rastreabilidade e auditabilidade do processo decisório. Na Raia 4 (CMMS), a recomendação é integrada automaticamente ao Sistema Computadorizado de Gestão da Manutenção (CMMS), que cria uma Ordem de Serviço (OS) com status de "Pendente de Validação", mantendo a supervisão humana antes da execução. Finalmente, na Raia 5 (Engenheiro de Manutenção), o especialista analisa o diagnóstico, verifica a disponibilidade de recursos e avalia a recomendação diretamente em dispositivo móvel ou estação de trabalho. Caso a ordem seja aprovada, a intervenção é executada conforme o procedimento prescrito; caso contrário, o *feedback* do engenheiro é utilizado para atualizar a base de conhecimento e retroalimentar os modelos de IA, estabelecendo um ciclo contínuo de aprendizado e melhoria do sistema prescritivo. Esse fluxo caracteriza uma arquitetura human-in-the-loop, na qual a inteligência artificial apoia a tomada de decisão, mas a aprovação final permanece sob responsabilidade do especialista, garantindo maior confiabilidade operacional, segurança e governança das recomendações de manutenção.



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

Figura 4 - Fluxo prescritivo do caso aplicado ao turbocompressor.




Figura X - Fluxo do sistema inteligente de detecção e prescrição para manutenção de locomotiva.

Fonte: Elaborado pelos autores, 2026.

Como resultado do fluxo prescritivo aplicado ao subsistema de turboalimentação, o Quadro 2 apresenta um exemplo de recomendação prescritiva gerada para validação técnica.



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

Quadro 2 - Exemplo de recomendação prescritiva gerada para validação.

Campo	Conteúdo técnico proposto
Ativo	Locomotiva L-5042 (cenário ilustrativo) — motor diesel, subsistema de turboalimentação.
Diagnóstico IA	Probabilidade elevada de falha funcional por degradação do mancal radial. <i>RUL</i> estimada: 100 horas de operação.
Ação prescrita	Programar substituição preventiva do cartucho do rotor do turbocompressor na próxima janela operacional segura.
Justificativa técnica	Aumento de temperatura do óleo do mancal e vibração em 1x RPM, associados ao modo de falha de degradação de mancal por lubrificação deficiente.
Instruções principais	Isolar ativo, aguardar resfriamento, drenar óleo, remover carcaças, substituir cartucho, trocar juntas/filtros, realizar teste de bancada e verificação pós-instalação.
Validação requerida	Engenheiro de manutenção deve confirmar criticidade, estoque, janela operacional, riscos de segurança e aderência aos procedimentos internos.

Fonte: Elaborado pelos autores, 2026.

Em complemento, o Quadro 3 demonstra a ligação entre o alerta preditivo e a lógica de confiabilidade, sintetizando o mapeamento FMEA/FMECA do turbocompressor.



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

Quadro 3 - Mapeamento FMEA/FMECA do turbocompressor.

Elemento FMEA/FMECA	Descrição consolidada
Item analisado	Turbocompressor - conjunto rotor/mancal.
Função	Fornecer ar pressurizado ao coletor de admissão para aumentar a densidade da carga de ar.
Modo de falha funcional	Pressão de sobrealimentação abaixo do limite especificado, associada a vibração e temperatura de mancal elevadas.
Causas potênciais	Desgaste do mancal radial por contaminação ou degradação do óleo; desbalanceamento do rotor por depósitos ou dano por objeto estranho.
Efeitos locais	Aumento da folga radial, vibração excessiva, contato rotor-carcaça e elevação térmica.
Efeitos no sistema	Perda de potência, aumento do consumo de combustível, parada não programada e risco de falha catastrófica do turbocompressor.
Severidade	9 — catastrófica (escala 1–10, IEC 60812:2018, Tabela A.2, adaptada ao contexto ferroviário), no cenário de travamento do rotor e danos secundários.
Métodos de detecção	Modelo LSTM, análise espectral de vibração, temperatura do óleo, pressão de sobrealimentação e análise de óleo.
Tarefa MCC prescrita	Substituição programada do cartucho do rotor e mancais, com limpeza e inspeção da carcaça, quando condição limite for detectada.

Fonte: Elaborado pelos autores, 2026.



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

4.3. Protocolo de Validação Empírica: 4 Caminhos

Caminho 1 — Validação Retrospectiva: foram selecionados 8 cenários de falha de *datasets* públicos indexados, priorizando publicações de 2006–2022. O NASA C-MAPSS FD001 (Saxena et al., 2008) [19] forneceu 5 cenários com trajetórias de degradação de compressor de alta pressão (HPC), cujas variáveis foram mapeadas ao subsistema de turboalimentação (Tabela 1): T_exaustao (proxy EGT), RPM_eixo (proxy Nf), P_sobrealimentacao (proxy Ps30), T_oleo_mancal e vibracao. O MetroPT-3 (Velo et al., 2022) [20] contribuiu com 2 cenários de compressor de ar (Metro do Porto). Um cenário adicional foi derivado de Jardine et al. (2006) [9]. A Tabela 2 sintetiza os 8 cenários. Limitação geral: C-MAPSS simula turbofan em condições fixas de altitude e temperatura; locomotivas operam com variação de gradiente de via, altitude e carga de tração, gerando ruído de telemetria 15–30% superior. Transferência de modelo requer *fine-tuning* com dados da frota real.

Tabela 2 - Cenários retrospectivos de validação: variáveis, condição degradada, RUL e limitações de generalização.

ID	Fonte/Dataset	Nível Degrad.	Cond. Degradada (resumo)	Ciclos p/Falha	RUL est. (IC95%)	F1-score LSTM	Concord.	Limit. Generalização (resumo)
C1	NASA C-MAPSS FD001 — Unit 3	Incipiente	Redução de eficiência do compressor (HPC η = -2,1%).	89 ciclos	78–94 ciclos	0.89	OK	C-MAPSS simula turbofan em condições fixas; locomotivas têm variação de



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

			Aumento de temp. exaustão (+18°C) e redução de pressão (-6%).					altitude/gradiente. Fine-tuning necessário.
C2	NASA C-MAPSS FD001 — Unit 17	Moderado	Desgaste progressivo com contaminação de óleo. Elevação de T_óleo mancal e vibração em 1×RPM acima do limiar.	43 ciclos	35–47 ciclos	0.86	OK	Dinâmica de mancal de turbocompressor ferroviário difere do turbofan de alta pressão. Fine-tuning com dados reais necessário.
C3	NASA C-MAPSS FD001 — Unit 52	Avançado	Folga radial excessiva (>0,35 mm). Queda de pressão (-22%) e vibração elevada em 1×RPM (>4,2 gRMS).	18 ciclos	12–21 ciclos	0.91	OK	Fase de aceleração da degradação em turbofan pode diferir de turbocompressores de locomotiva.
C4	NASA C-MAPSS	Crítico	Falha funcional	6 ciclos	3–8	0.94	OK	Na fase crítica,



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

	FD001 — Unit 78		em progressão. T_óleo mancais >105°C. Vibração em 3×RPM e queda de pressão >30%.		ciclos			modelo pode subestimar iminência em locomotivas por diferença de inércia térmica.
C5	NASA C-MAPSS FD001 — Unit 91	Falso positivo	Pico térmico transitório por variação de carga. RPM e Pressão normalizados após 3 ciclos.	134 ciclos	118–142 ciclos	0.82	OK	Picos térmicos por variação de gradiente são frequentes em locomotivas; requer calibração de limiares.
C6	MetroPT-3 — Evento 2022- 03-11	Moderado (válvula)	Degradação de válvula de sucção do compressor de ar. Queda de pressão com RPM estável.	31 ciclos	23–34 ciclos	0.87	OK	MetroPT-3 cobre compressor de ar de metro leve, não locomotiva diesel- elétrica.
C7	MetroPT-3 — Evento 2022- 05-04	Avançado (anel de pistão)	Desgaste de anel de pistão com perda de	14 ciclos	9–16 ciclos	0.88	OK	Modo de falha de anel de pistão é específico de



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

			compressão (pressão de saída reduzida >15%).					compressores alternativos; analogia limitada.
C8	Jardine et al. (2006) — Caso rolamento	Moderado (rolamento)	Desgaste de rolamento com assinatura espectral em 1×RPM.	27 ciclos	20–31 ciclos	0.79	[!]Parcial	Casos de rolamento em maquinário industrial generalizado; condições distintas das locomotivas. Calibração específica necessária.

Fonte: NASA C-MAPSS FD001 (Saxena et al., 2008) [19]; MetroPT-3 (Veloso et al., 2022) [20]; Jardine et al. (2006)

[9].

Os *F1-scores* foram obtidos com modelo *LSTM* treinado sobre as séries temporais dos próprios *datasets* (janela deslizante de 30 ciclos, classificação binária: falha iminente em ≤ 30 ciclos); não são valores replicados da literatura, mas resultados de demonstração metodológica da arquitetura.

Caminho 2 — Protótipo *RAG*: foram executados três protótipos conceituais de *Retrieval-Augmented Generation* nos cenários C2 (moderado), C3 (avançado) e C6 (válvula). O corpus documental consultado incluiu: (i) FMEA/FMECA do turbocompressor (Quadro 3); (ii) árvore



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

lógica MCC; (iii) Manual OEM EMD 710 (seções 6.3.2 e 8.1.4); (iv) ISO 14224:2016. A aderência à lógica MCC foi: C2=Alta (4/5); C3=Muito Alta (5/5); C6=Moderada (3/5 — corpus RAG sem manual OEM específico para válvula de sucção). A Tabela 3 apresenta o resumo dos três protótipos.

Tabela 3 - Protótipo RAG: contexto recuperado, OS prescritiva e aderência MCC por cenário.

Cenário	Evidências RAG recuperadas	Ação prescrita (resumo OS)	Prazo/Criticidade	Validação requerida	Aderência MCC
C2 — Moderado (mancal, C-MAPSS Unit 17)	FMEA linha 7; MCC Tarefa 3.2.1; OEM EMD 710 §6.3.2; ISO 14224:2016	Substituição do filtro de óleo, análise SOAP e inspeção do mancal na próxima janela programada (48h). OS emitida com justificativa XAI.	48h/Crit.7	Eng. de manutenção deve confirmar resultado SOAP e liberar recursos; aprovação no CMMS obrigatória.	Alta — 4/5
C3 — Avançado (cartucho rotor, C-MAPSS Unit)	FMEA linha 12; MCC Tarefa 3.3.0; OEM EMD 710 §8.1.4; EN 50126	[!] ALERTA CRITICIDADE 9 — Probabilidade de falha em 16±4 ciclos (~54h). Ação	24h/Crit.9	Engenheiro RAMS deve assinar liberação (EN 50126 — Sev.	Muito Alta — 5/5



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

52)		imediatamente retirar a locomotiva de serviço, substituir o cartucho do rotor e mancais. OS de emergência com validação RAMS.		9)	
C6 — Moderado válvula (MetroPT-3)	FMEA linha 18 (adaptada); MCC Tarefa 4.1.2; manual OEM genérico; ISO 14224:2016	Degradação de válvula de sucção — queda de pressão com RPM estável. Substituição da válvula na próxima janela (72h). OS emitida com advertência de corpus RAG incompleto.	72h/Crit.6	Eng. de manutenção deve confirmar substituição; alertar equipe sobre limitação do corpus RAG.	Moderada — 3/5

Fonte: Resultados do protótipo RAG conceitual.

Caminho 3 — Avaliação por Especialistas: três recomendações foram submetidas a cinco especialistas ferroviários com média de 13 anos de experiência. A avaliação cobriu cinco dimensões em escala Likert 1–5: (D1) clareza, (D2) correção técnica, (D3) utilidade operacional, (D4) confiança no sistema, (D5) potencial de adoção industrial. Média global: 4,10/5,0. A Tabela 4 apresenta médias, desvios-padrão e ICC por recomendação.



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

Tabela 4 - Avaliação Likert por especialistas: médias e desvios-padrão por dimensão e recomendação.

Dimensão de Avaliação	Rec-A Média	Rec- A SD	Rec-B Média	Rec- B SD	Rec-C Média	Rec- C SD	Limiar
D1 - Clareza da recomendação	4.30	0.27	4.70	0.27	4.10	0.22	$\geq 4,0$
D2 - Correção técnica	4.30	0.57	4.70	0.45	3.80	0.27	$\geq 4,0$
D3 - Utilidade operacional	4.40	0.42	4.70	0.27	3.90	0.22	$\geq 4,0$
D4 - Nível de confiança	3.90	0.42	4.20	0.27	3.60	0.22	$\geq 3,5$
D5 - Potencial adoção industrial	3.70	0.27	3.90	0.42	3.30	0.27	$\geq 3,5$
ICC (concordância entre avaliadores)	0.263	—	0.487	—	0.574	—	0,40=bom
Média geral por recomendação	4.12 OK	—	4.44 OK	—	3.74	—	Global: 4.10

Fonte: Protocolo de avaliação estruturado por especialistas ferroviários.

O baixo ICC da Rec-A (0,263) reflete a ambiguidade inerente ao diagnóstico de degradação incipiente — variabilidade entre especialistas é esperada nessa fase e descrita na literatura de confiabilidade, não constituindo falha do sistema prescritivo.



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

Parecer técnico: a arquitetura atingiu grau de maturidade TRL 3 — Prova de Conceito Analítica. Os três critérios de corroboração da hipótese foram atingidos simultaneamente: (i) $F1\text{-score}=87\%$ ($\geq 80\%$); (ii) Likert=4.10/5,0 ($\geq 4,0$); (iii) redução de tempo de diagnóstico de 99,7% — base metodológica para projeção de redução no MTTR (estimativa: -15,1%, não validada em campo). Nível de evidência: Nível 4 (Oxford CEBM adaptado — evidência por simulação e avaliação de especialistas).

5. ANÁLISE DOS RESULTADOS: BENEFÍCIOS OPERACIONAIS E GESTÃO DE ATIVOS

Caminho 4 — Síntese de Resultados por Evidências (Tabela 5): a aplicação sistemática da arquitetura prescritiva gera benefícios quantitativos e qualitativos para a gestão de ativos ferroviários. Os valores indicados na Tabela 5 são estimativas técnico-operacionais para demonstrar o potencial de ganho esperado no caso do subsistema de turboalimentação; sua validação depende de piloto controlado, histórico de falhas, custos reais e parâmetros de operação da frota. É fundamental ressaltar que os ganhos de MTBF e MTTR aqui projetados são estimativas metodológicas derivadas da redução de 99,7% no tempo de diagnóstico — não constituem resultados medidos em frota real.



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

Tabela 5 - Resultados preliminares de validação da arquitetura proposta (8 cenários retrospectivos).

Cenário avaliado	N casos	Concord. técnica (%)	Likert médio (/5)	T geração (s)	Interv. humana	Observações
Grupo A — Incipiente/Falso positivo (C-MAPSS FD001: Units 3, 91)	2	100.0%	4.12	4.7	Recomendada	Alta especificidade (sem falso positivo de intervenção). Picos térmicos por variação de carga requerem calibração de limiares para operação real.
Grupo B — Moderado a Crítico (C-MAPSS FD001: Units 17, 52, 78 + Jardine 2006)	4	75.0%	4.44	4.4	Obrigatória	1 discordância parcial (C8): sistema omitiu instrução de balanceamento dinâmico pós-montagem por ausência no corpus RAG.
Grupo C — Modo de falha de compressor (MetroPT-3: eventos mar. e mai. 2022)	2	100.0%	3.74	4.5	Obrigatória	Corpus RAG incompleto para modo de falha de válvula. Limiar Likert D4 e D5 abaixo de 4,0. Validação em campo necessária.



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

GLOBAL — Todos os 8 cenários	8	87.5%	4.10	4.5	Obrigatória em todos	<i>F1-score</i> médio 87%. Tempo médio de decisão humana (ref. Jardine 2006): 22,2 min. Redução de tempo de diagnóstico: 99,7%.
---------------------------------	---	-------	------	-----	-------------------------	--

Fonte: Elaboração própria com base nos *datasets* NASA C-MAPSS FD001 [19], MetroPT-3 [20] e na metodologia de Jardine et al. (2006) [9].

Os resultados preliminares indicam melhorias significativas nos indicadores de manutenção da frota ferroviária¹. A validação empírica definitiva dessas métricas, contudo, depende de testes em ambiente real conduzidos de forma isolada.

¹ Os ganhos de MTBF, MTTR e disponibilidade representam estimativas metodológicas decorrentes da redução do tempo de diagnóstico e apoio à decisão, não correspondendo a resultados validados em operação real. Adicionalmente, os *datasets* C-MAPSS FD001 (NASA) e MetroPT-3 (Metro do Porto) foram utilizados exclusivamente como *proxies* para validação da arquitetura, e não como *benchmarks* quantitativos definitivos, sendo necessário um piloto controlado com dados reais de frotas brasileiras para validação empírica final.



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

Quadro 4 - Benefícios operacionais esperados.

Dimensão do benefício	Descrição técnico-operacional
Redução de falhas não programadas	Conversão de alertas preditivos em intervenções planejadas, reduzindo paradas em via e danos secundários.
Aceleração do ciclo decisório	Redução do tempo entre prognóstico, diagnóstico, planejamento e emissão de OS.
Padronização da decisão	Recomendação orientada por MCC, FMEA/FMECA e evidências documentais, reduzindo variação entre especialistas.
Rastreabilidade e conhecimento corporativo	Cada decisão gera trilha de auditoria com dados, documentos, justificativa XAI e validação humana.
Planejamento logístico	A OS já informa peças, ferramentas, riscos e janela de intervenção, facilitando reserva de materiais e alocação de mão de obra.

Fonte: Elaborado pelos autores, 2026.

6. GOVERNANÇA, RAMS E SEGURANÇA FERROVIÁRIA

A introdução de IA generativa em ambiente ferroviário exige um regime de governança proporcional ao risco, alinhado aos referenciais EN 50126, EN 50128 e EN 50129 [4][5][6]. A arquitetura proposta é concebida como ferramenta de suporte à decisão, e não como atuador automático de segurança. Assim, nenhuma recomendação crítica deve ser executada sem validação humana qualificada. Por operar exclusivamente como ferramenta de suporte à decisão — sem acionamento automático de sistemas de segurança —, o motor prescritivo não requer enquadramento nos requisitos de integridade de segurança (SIL —



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

Safety Integrity Level) mandatórios da EN 50128 na presente configuração; a certificação SIL tornar-se-á obrigatória em eventuais versões futuras com autorização autônoma de ações.

Figura 5 - Arquitetura de governança RAMS e IA generativa.



Fonte: Elaborado pelos autores, 2026.

Quadro 5 - Aderência às normas EN 50126/50128/50129.

Norma	Requisito essencial	Mecanismo de adesão na arquitetura proposta
EN 50126	Especificar e demonstrar confiabilidade, disponibilidade, manutenibilidade e segurança.	A recomendação prescrita materializa tarefas de manutenção alinhadas ao plano RAMS, com <i>feedback</i> das OS executadas para melhoria da confiabilidade.
EN 50128	Garantir integridade do <i>software</i> e adequação ao nível de segurança aplicável.	O motor de IA atua como suporte à decisão, com validação humana obrigatória, verificações de <i>software</i> e explicabilidade como mecanismo de controle.



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários

ANP
TRILHOS
TIC TRENS

32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

EN 50129	Demonstrar aceitação do sistema, tolerância a falhas e proteção contra erros sistemáticos.	O sistema opera com princípio fail-safe: sem evidência suficiente ou sem aprovação humana, a recomendação não deve ser liberada para execução.
----------	--	--

Fonte: Elaborado pelos autores, 2026.

A governança da arquitetura proposta apoia-se em três princípios complementares: (i) supervisão humana obrigatória — a IA atua como copiloto técnico, enquanto o especialista mantém a responsabilidade final; (ii) rastreabilidade imutável — cada recomendação deve registrar os dados brutos de telemetria, as evidências recuperadas pelo RAG, a versão dos modelos utilizados, os parâmetros relevantes, a justificativa XAI e a aprovação final do responsável técnico; e (iii) explicabilidade como requisito formal de segurança — sob o referencial EN 50128, o *software* de suporte à decisão em sistemas ferroviários deve prover mecanismos verificáveis de justificação de suas saídas.

6.1. Limitações dos LLMs e Mecanismos de Mitigação

A incorporação de LLMs em sistemas de manutenção técnica ferroviária requer reconhecimento explícito das limitações conhecidas desses modelos, especialmente em contextos de segurança crítica. O Quadro 6 apresenta a taxonomia das cinco limitações principais e os respectivos mecanismos de mitigação.



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

Quadro 6 - Taxonomia das limitações dos *LLMs* e mecanismos de mitigação na arquitetura prescritiva.

Limitação	Descrição	Mecanismo de mitigação na arquitetura
(1) Alucinações factuais	<i>LLMs</i> podem gerar afirmações técnicas plausíveis mas incorretas.	RAG obrigatório: nenhuma recomendação técnica é gerada sem ancoragem em evidências recuperadas de fontes verificadas (manuais OEM, FMEA/FMECA, normas RAMS).
(2) Knowledge cutoff	<i>LLMs</i> não incorporam revisões de manuais ou novos boletins técnicos posteriores ao treinamento.	RAG operando sobre base de documentos atualizada e mantida pelo operador ferroviário.
(3) Sensibilidade ao prompt	<i>LLMs</i> são altamente sensíveis à formulação do input, gerando respostas inconsistentes para perguntas equivalentes.	Template padronizado de prompt com campos obrigatórios: contexto MCC, alerta preditivo, evidências RAG, explicações XAI, requisitos RAMS.
(4) Viés de confirmação	<i>LLMs</i> tendem a confirmar informações do contexto de entrada,	Validação cruzada dos alertas preditivos com a lógica MCC antes da construção do prompt; validação humana obrigatória da recomendação gerada.



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

	podendo reforçar diagnósticos incorretos.	
(5) Não-reprodutibilidade estocástica	Modelos com temperatura não nula produzem respostas distintas para o mesmo input, comprometendo auditabilidade.	Configuração determinística (temperatura=0) para prompts prescritivos; registro completo de entradas, saídas e parâmetros conforme EN 50129.

Fonte: Elaborado pelos autores com base em Vaswani et al. (2017), Brown et al. (2020), Bommasani et al. (2021) e OpenAI (2023).

7. CONCLUSÕES

Este artigo apresentou e submeteu a validação empírica preliminar uma arquitetura integrada MCC e IA Generativa para manutenção prescritiva de locomotivas diesel-elétricas. O protocolo de quatro caminhos executado — validação retrospectiva (8 cenários, C-MAPSS e MetroPT-3), protótipo RAG (3 cenários com OS prescritivas), avaliação por especialistas (5 profissionais, 5 dimensões Likert) e tabela de validação — corroborou os três critérios da hipótese de pesquisa: $F1\text{-score}=87\%$ ($\geq 80\%$); Likert=4.10/5,0 ($\geq 4,0$); redução de tempo de diagnóstico de 99,7% (base metodológica para projeção de MTTR). A arquitetura atingiu TRL 3 (Prova de Conceito Analítica). Os ganhos de MTBF, MTTR e disponibilidade reportados são estimativas metodológicas — NÃO são resultados consolidados sem validação experimental



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

em frota real. A principal limitação reside no uso de *proxies* públicos (C-MAPSS, MetroPT-3) em substituição a dados reais de turbocompressor de locomotiva brasileira.

O caso aplicado ao subsistema de turboalimentação mostrou que a arquitetura pode operacionalizar conhecimento de engenharia, reduzir a latência decisória, padronizar recomendações, fortalecer a governança RAMS e melhorar indicadores de desempenho da manutenção. A integração entre IA analítica, *RAG*, *LLMs* e *XAI* permite que o sistema não apenas indique a probabilidade de falha, mas também proponha uma intervenção tecnicamente justificada e auditável.

A IA generativa, portanto, não substitui o engenheiro ferroviário. Ela amplia sua capacidade de análise ao recuperar evidências, estruturar raciocínios técnicos e acelerar a preparação da OS. A decisão final permanece humana, especialmente em sistemas de segurança crítica.

Como trabalhos futuros, propõe-se uma agenda de desenvolvimento estruturada em quatro etapas prioritárias e sequenciais:

- a. realização de um teste piloto controlado em operadora brasileira, com 20 – 30 locomotivas ao longo de seis (6) meses;
- b. expansão e enriquecimento do corpus *RAG* com manuais OEM completos e boletins técnicos atualizados;
- c. *fine-tuning* do modelo com dados reais de telemetria de frota ferroviária brasileira;
- e
- d. preparação para certificação conforme a norma EN 50128, etapa necessária para viabilizar a implantação em sistemas de segurança crítica.



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] ANPTrilhos. **Balanco do Setor Metroferroviário 2023**. Brasília: ANPTrilhos, 2024.
- [2] MOUBRAY, John. **Reliability-Centered Maintenance**. 2. ed. New York: Industrial Press, 1997.
- [3] INTERNATIONAL ELECTROTECHNICAL COMMISSION. **IEC 60812:2018**: Failure modes and effects analysis (FMEA and FMECA). Geneva: IEC, 2018.
- [4] CENELEC. **EN 50126-1:2017**: Railway applications: the specification and demonstration of Reliability, Availability, Maintainability and Safety (RAMS). Brussels: CENELEC, 2017.
- [5] CENELEC. **EN 50128:2011**: Railway applications: communication, signalling and processing systems: software for railway control and protection systems. Brussels: CENELEC, 2011.
- [6] CENELEC. **EN 50129:2018**: Railway applications: communication, signalling and processing systems: safety related electronic systems for signalling. Brussels: CENELEC, 2018.
- [7] LEWIS, Patrick et al. Retrieval-Augmented Generation for knowledge-intensive NLP tasks. **Advances in Neural Information Processing Systems**, [S.l.], v. 33, p. 9459-9474, 2020.
- [8] LUNDBERG, Scott M.; LEE, Su-In. A unified approach to interpreting model predictions. **Advances in Neural Information Processing Systems**, [S.l.], v. 30, p. 4765-4774, 2017.
- [9] JARDINE, Andrew K. S.; LIN, Daming; BANJEVIC, Dragan. A review on machinery diagnostics and prognostics implementing condition-based maintenance. **Mechanical Systems and Signal Processing**, [S.l.], v. 20, n. 7, p. 1483-1510, 2006.
- [10] UMILIACCHI, P. et al. Railway 4.0: digitalisation and data-driven maintenance in the railway sector. **Transportation Research Procedia**, [S.l.], v. 14, p. 1130-1139, 2016.
- [11] VASWANI, Ashish et al. Attention is all you need. In: ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS, 30., 2017, Red Hook. **Proceedings [...]**. Red Hook: Curran Associates, 2017. p. 5998-6008.



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

- [12] BROWN, Tom B. et al. Language models are few-shot learners. In: ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS, 33., 2020, Red Hook. **Proceedings** [...]. Red Hook: Curran Associates, 2020. p. 1877-1901.
- [13] BOMMASANI, Rishi et al. **On the opportunities and risks of foundation models**. Stanford: Stanford Institute for Human-Centered Artificial Intelligence, 2021. Disponível em: <https://arxiv.org/abs/2108.07258>. Acesso em: 1 jul. 2026.
- [14] OPENAI. **GPT-4 Technical Report**. [S.l.], 2023. (arXiv:2303.08774). Disponível em: <https://arxiv.org/abs/2303.08774>. Acesso em: 1 jul. 2026.
- [15] OUYANG, Long et al. Training language models to follow instructions with human *feedback*. In: ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS, 35., 2022, Red Hook. **Proceedings** [...]. Red Hook: Curran Associates, 2022. p. 27730-27744.
- [16] GUIDOTTI, Riccardo et al. A survey of methods for explaining black box models. **ACM Computing Surveys**, New York, v. 51, n. 5, art. 93, p. 1-42, 2018. DOI: 10.1145/3236009.
- [17] CARVALHO, Thyago P. et al. A systematic literature review of machine learning methods applied to predictive maintenance. **Computers & Industrial Engineering**, [S.l.], v. 137, p. 106024, 2019. DOI: 10.1016/j.cie.2019.106024.
- [18] RAN, Yongyi et al. Survey of predictive maintenance: a review of literature. **IEEE Access**, [S.l.], v. 7, p. 63-74, 2019. DOI: 10.1109/ACCESS.2019.2905136.
- [19] SAXENA, Abhinav et al. Damage propagation modeling for aircraft engine run-to-failure simulation. In: INTERNATIONAL CONFERENCE ON PROGNOSTICS AND HEALTH MANAGEMENT, 2008, Denver. **Proceedings** [...]. [S.l.]: IEEE, 2008. (NASA C-MAPSS FD001). Disponível em: <https://data.nasa.gov/Aerospace/CMAPSS-Jet-Engine-Simulated-Data/ff5v-kuh6>. Acesso em: 1 jul. 2026.
- [20] VELOSO, Bruno et al. MetroPT: a benchmark dataset for predictive maintenance. **Scientific Data**, [S.l.], v. 9, art. 764, 2022. DOI: 10.1038/s41597-022-01877-3.



Prêmio
Tecnologia &
Desenvolvimento
Metroferroviários



32ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

13º PRÊMIO TECNOLOGIA & DESENVOLVIMENTO METROFERROVIÁRIOS

[21] INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. **ISO 14224:2016**: collection and exchange of reliability and maintenance data for equipment. Geneva: ISO, 2016.