

**APLICAÇÃO DE BUSINESS INTELLIGENCE NA GESTÃO PREDITIVA DE
AMVS: UMA SOLUÇÃO PARA MONITORAMENTO E MANUTENÇÃO NA
ESTRADA DE FERRO**

***APPLICATION OF BUSINESS INTELLIGENCE IN THE PREDICTIVE
MANAGEMENT OF TURNOUTS: A SOLUTION FOR RAILWAY MONITORING AND
MAINTENANCE***

Matheus Sousa Barroso
Antonio Felipe Neves Santos
Jocikley da Silva Machado

RESUMO: A manutenção eficiente dos Aparelhos de Mudança de Via (AMVs) é essencial para garantir a segurança e a operação contínua das ferrovias. Este trabalho apresenta o desenvolvimento e a aplicação de uma solução de *Business Intelligence*, baseada no Power BI, para o monitoramento técnico e histórico dos AMVs da Estrada de Ferro Carajás. A solução integra dados operacionais oriundos de formulários técnicos preenchidos durante as manutenções preventivas, possibilitando a análise em tempo real do estado de cada AMV, sua evolução ao longo do tempo e a categorização de criticidades com base em parâmetros técnicos. Além disso, o sistema permite o acompanhamento do cumprimento de planos de manutenção via integração com o SAP, bem como a visualização georreferenciada dos ativos. A ferramenta inclui modelos de tendência para previsão de degradação, viabilizando ações corretivas com maior antecedência. Os resultados demonstram o impacto positivo da integração de dados e automação na gestão ferroviária, com ganhos em eficiência, assertividade e segurança operacional.

Palavras-chave: Aparelho de Mudança de Via, Power BI, Manutenção Preditiva, Business Intelligence, Ferrovia.

ABSTRACT: Efficient maintenance of Railway Turnouts (AMVs – Aparelhos de Mudança de Via) is essential to ensure the safety and continuous operation of railways. This paper presents the development and application of a Business Intelligence solution, based on Power BI, for the technical and historical monitoring of AMVs on the Carajás Railway. The solution integrates operational data from technical forms filled out during preventive maintenance, enabling real-time analysis of each AMV's condition, its evolution over time, and the categorization of criticalities based on technical parameters. In addition, the system allows tracking of

maintenance plan compliance through integration with SAP, as well as georeferenced visualization of the assets. The tool includes trend models for degradation forecasting, enabling corrective actions to be taken further in advance. The results demonstrate the positive impact of data integration and automation on railway management, with gains in efficiency, accuracy, and operational safety.

Keywords: Railway Turnout, Power BI, Predictive Maintenance, Business Intelligence, Railway.

SUMÁRIO

1 INTRODUÇÃO.....	4
2 FUNDAMENTAÇÃO TEÓRICA	5
2.1 Manutenção preditiva e gestão de ativos ferroviários	5
2.2 Uso de <i>business intelligence</i> na manutenção ferroviária.....	6
2.3 Aplicações analíticas em AMVs.....	7
3 METODOLOGIA.....	7
3.1 Coleta e preparação dos dados.....	7
3.2 Integração e modelagem de dados	8
3.3 Classificação de criticidade	9
3.4 Visualização georreferenciada e histórico	11
3.5 Análise preditiva e projeção de tendências.....	12
4 RESULTADOS E DISCUSSÕES.....	13
5 CONCLUSÃO.....	16
REFERÊNCIAS	16

1 INTRODUÇÃO

A gestão eficiente dos Aparelhos de Mudança de Via (AMVs) é fundamental para garantir a segurança e a continuidade operacional em sistemas ferroviários. A manutenção baseada em cronogramas predeterminados ou ações reativas tem se mostrado limitada, muitas vezes resultando em paradas não planejadas, custos elevados e riscos à segurança das operações férreas (IKUSI, [s.d.]; ADORTECH, 2024). Nesse contexto, a adoção de abordagens baseadas em análise de dados e inteligência operacional tem despontado como solução viável para enfrentar esses desafios de maneira mais assertiva.

A manutenção preditiva, sustentada por tecnologia de *Business Intelligence* (BI), permite monitorar em tempo real os parâmetros técnicos dos ativos, identificar anomalias e estimar o comprometimento futuro, antecipando ações corretivas (ESPOSITO, [s.d.]; ADORTECH, 2024). No setor ferroviário, esse modelo de manutenção tem se mostrado eficaz ao reduzir tempos de inatividade, otimizar custos e melhorar a confiabilidade dos ativos (GLOBAL RAILWAY REVIEW, 2019; IKUSI, [s.d.]). A aplicação de análises preditivas nas ferrovias, combinada com sistemas de BI, vem possibilitando a transformação dos dados operacionais brutos em decisões de manutenção mais estratégicas e embasadas (TRANSPORTATION RESEARCH PART C, 2019).

Neste cenário, o presente artigo propõe-se a mostrar a construção e aplicação de um painel analítico em Power BI para gestão preditiva dos AMVs da Estrada de Ferro Carajás. A ferramenta integra dados capturados durante inspeções de manutenção preventiva — cadastrados via formulários técnicos — e fornece categorização automática de criticidade com base nos parâmetros medidos, além de exibir mapas de alertas, monitorar planos de manutenção via integração com SAP e desenhar tendências futuras de degradação dos componentes. Todo esse conjunto de funcionalidades busca promover uma abordagem mais eficiente, segura e orientada a dados na gestão de manutenção ferroviária.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Manutenção preditiva e gestão de ativos ferroviários

A gestão de ativos ferroviários consiste em um conjunto de práticas sistemáticas e coordenadas que visam maximizar o valor de um ativo ao longo de todo o seu ciclo de vida, desde sua concepção e aquisição até a desativação. Segundo o *Institute of Asset Management* (ABNT, 2014). No contexto ferroviário, onde a disponibilidade e a confiabilidade dos ativos estão diretamente ligadas à segurança operacional e ao desempenho logístico, a gestão de ativos desempenha um papel central na redução de falhas críticas, otimização de recursos e preservação da vida útil da infraestrutura.

Entre as abordagens modernas de gestão de ativos, a manutenção preditiva tem se destacado por oferecer um modelo proativo e baseado na condição real dos equipamentos. Diferentemente da manutenção corretiva, que ocorre após a falha, e da preventiva, que segue intervalos de tempo predefinidos, a manutenção preditiva utiliza dados históricos e em tempo real para antecipar falhas e programar intervenções no momento ideal (IBERDROLA, 2024). Esse método é sustentado por tecnologias como sensores IoT, análise de vibração, monitoramento térmico, visão computacional e algoritmos de *machine learning*, que identificam padrões anômalos e projetam o desgaste futuro dos componentes (REVISTA MANUTENÇÃO, 2024; MECALUX, 2023).

No setor ferroviário, essa abordagem ganha relevância devido à complexidade e à criticidade dos ativos, como trilhos, dormentes, lastro, sistemas de sinalização e Aparelhos de Mudança de Via (AMVs). Estudos indicam que a aplicação de manutenção preditiva em ferrovias pode reduzir significativamente o tempo de inatividade, melhorar a disponibilidade da malha e prevenir acidentes de grande impacto (DAVARI et al., 2021). Tecnologias como ultrassom, radar de penetração no solo (GPR), câmeras de alta resolução e sensores embarcados em veículos de inspeção têm permitido o monitoramento contínuo e não intrusivo dos ativos, alimentando sistemas analíticos capazes de correlacionar dados operacionais e históricos para priorização de intervenções (ALÉM DA INÉRCIA, 2025).

Além dos ganhos operacionais, a manutenção preditiva integrada à gestão de ativos proporciona benefícios econômicos relevantes, como a redução de custos com reparos emergenciais e otimização do estoque de peças, além de possibilitar um planejamento de longo prazo mais assertivo (SEMEQ, 2024). Essa integração de tecnologia, análise de dados e estratégia de manutenção se alinha às práticas recomendadas por frameworks internacionais como a ISO

55000, que enfatiza a importância da informação de qualidade e da tomada de decisão baseada em evidências para a sustentabilidade e competitividade do setor ferroviário.

2.2 Uso de *business intelligence* na manutenção ferroviária

A inteligência empresarial (ABNT, 2014). No contexto ferroviário, onde a manutenção envolve sistemas complexos e interdependentes, o uso de BI possibilita integrar dados operacionais e históricos para monitorar indicadores de desempenho, identificar padrões de degradação e antecipar falhas. De acordo com Kalathas, Papoutsidakis e Drosos (2021), a aplicação de sistemas de BI associados a métodos de machine learning em ferrovias gregas permitiu processar grandes volumes de dados de manutenção de forma eficiente, gerando conhecimento estratégico para otimizar a disponibilidade dos ativos e reduzir custos operacionais.

Embora parte da literatura trate de exemplos na gestão rodoviária, o paradigma é facilmente transferível para o ambiente ferroviário. No estudo desenvolvido por Barbosa (2020), sobre a BR-101/AL, a utilização de uma ferramenta de BI simplificou a visualização de dados complexos, transformando-os em painéis intuitivos que permitiam à gestão identificar gargalos e agir com maior assertividade. Em cenários ferroviários, recursos semelhantes podem viabilizar, por exemplo, o acompanhamento do cumprimento de planos de manutenção, a previsão de necessidade de peças e a priorização de ativos críticos.

O uso de BI na manutenção ferroviária também se alinha à transformação digital do setor. Segundo Ferreira et al. (2024), ferramentas visuais de BI permitem consolidar dados de inspeções técnicas, prever demandas de estoque e apresentar a saúde dos ativos em tempo real, integrando informações operacionais e logísticas em um único ambiente analítico. Essa integração proporciona maior assertividade na tomada de decisões e reduz a dependência de análises manuais fragmentadas.

Além disso, estudos recentes destacam que a efetividade do BI na manutenção ferroviária depende de sua combinação com tecnologias emergentes, como Internet das Coisas (IoT), *Big Data* e Inteligência Artificial. Conforme destacado por Moloodpoor et al. (2024), o BI atua como facilitador da digitalização dos processos de manutenção, tornando possível transformar grandes volumes de dados provenientes de sensores e sistemas corporativos em ações estratégicas, alinhadas a frameworks de gestão de ativos, como a ISO 55000 e as diretrizes da União Internacional dos Caminhos-de-Ferro (UIC).

2.3 Aplicações analíticas em aparelhos de mudança de via

Os Aparelhos de Mudança de Via (AMVs) são componentes críticos da infraestrutura ferroviária, pois concentram esforços dinâmicos elevados e operam em condições que exigem alto nível de confiabilidade. A literatura aponta que a aplicação de métodos analíticos para o monitoramento desses ativos é fundamental para detectar falhas precoces e otimizar custos de manutenção. De acordo com Xie et al. (2020), “modelos baseados em dados permitem identificar irregularidades na geometria da via, defeitos na cabeça do trilho e ausência de componentes, possibilitando prever falhas com antecedência e planejar intervenções mais eficientes”.

Nesse sentido, Barkhordari, Galeazzi e Blanke (2021) desenvolveram uma ferramenta de monitoramento de longo prazo para *railpads* em AMVs utilizando distribuições extremas (*Generalized Extreme Value*), capaz de detectar alterações no comportamento estrutural ao longo do tempo. Os autores destacam que “a análise combinada de frequência e variáveis ambientais permite identificar tendências de degradação antes que ocorram falhas críticas”. Em outro estudo, Barkhordari et al. (2017) propuseram um modelo comportamental de baixa complexidade para AMVs, que representa a dinâmica dominante do sistema considerando lastro e railpad, por meio de identificação subespaço (*Eigensystem Realization Algorithm*). Segundo os autores, o método “é robusto, de baixo custo computacional e adequado para implementação em sistemas de diagnóstico e prognóstico”.

3 METODOLOGIA

3.1 Coleta e preparação dos dados

A base de qualquer sistema de manutenção preditiva confiável está na qualidade e consistência dos dados coletados. No caso da Estrada de Ferro Carajás, a primeira etapa da solução desenvolvida consistiu na criação e padronização de formulários técnicos para registrar, durante as manutenções preventivas, parâmetros essenciais ao monitoramento dos Aparelhos de Mudança de Via (AMVs). Esses formulários foram concebidos de forma a garantir que todos os inspetores, independentemente de sua experiência ou local de atuação, registrassem as informações seguindo o mesmo formato e utilizando as mesmas unidades de medida, evitando discrepâncias e aumentando a comparabilidade das informações ao longo do tempo.

A importância dessa padronização já foi amplamente destacada por Xie et al. (2020), que afirmam que “a coleta de dados estruturada e consistente é a base para que modelos de manutenção preditiva sejam confiáveis e escaláveis”. Da mesma forma, Barkhordari, Galeazzi

e Blanke (2021) ressaltam que, para AMVs, dados de campo precisos são indispensáveis, visto que pequenas variações nos parâmetros de medição podem indicar o início de um processo de degradação.

Os parâmetros técnicos monitorados nos AMVs da Estrada de Ferro Carajás foram definidos com base em critérios de engenharia, histórico de falhas e conformidade com normas internas. O processo de coleta ocorre diretamente em campo, no momento da manutenção preventiva, utilizando dispositivos móveis para o preenchimento dos formulários. Essa estratégia minimiza a defasagem temporal entre a medição e o registro, reduzindo erros de transcrição e permitindo a integração quase imediata das informações ao sistema de análise. Kalathas, Papoutsidakis e Drosos (2021) reforçam que “a redução do tempo entre a coleta e a disponibilização dos dados é crucial para que sistemas de apoio à decisão operem de forma eficaz e responsiva”.

Outro aspecto fundamental foi a definição de protocolos claros para a realização das medições. Esses protocolos incluem instruções detalhadas sobre a posição de medição, ferramentas utilizadas e tolerâncias aceitáveis para cada parâmetro. Essa prática, segundo Ferreira et al. (2024), “não apenas melhora a confiabilidade dos dados coletados, mas também facilita o treinamento e a uniformização das práticas das equipes de campo”.

Ao assegurar a padronização e a qualidade das informações, essa etapa inicial da metodologia garante que o sistema de *Business Intelligence* possa operar com dados consistentes, confiáveis e prontos para análises avançadas, possibilitando a geração de *insights* precisos para a manutenção preditiva e a gestão estratégica dos AMVs.

3.2 Integração e modelagem de dados

Após a coleta e padronização, o passo seguinte foi garantir que as informações pudessem ser utilizadas de forma integrada e inteligente. Para isso, os formulários técnicos preenchidos em campo foram conectados diretamente ao ambiente de *Business Intelligence* no *Power BI*, criando um fluxo contínuo entre a entrada dos dados e sua análise. Esse processo elimina a necessidade de inserções manuais, reduzindo a probabilidade de erros e assegurando a atualização quase em tempo real dos indicadores de manutenção.

De acordo com Kalathas, Papoutsidakis e Drosos (2021), “a integração de múltiplas fontes de dados em um único ambiente de BI é um requisito fundamental para a eficiência de sistemas de manutenção preditiva”, pois possibilita uma visão completa do ativo, combinando informações de inspeção com dados administrativos e históricos. No caso da Estrada de Ferro Carajás, essa

integração envolve não apenas os dados dos formulários, mas também a conexão com o sistema SAP, que gerencia os planos de manutenção sistemática.

A integração com o SAP permite cruzar dados operacionais e de gestão, como prazos programados de manutenção, status de execução, existência de anomalias detectadas e abertura de notas corretivas para tratativa. Essa fusão de informações oferece uma camada adicional de contexto, possibilitando identificar situações em que a manutenção foi realizada, mas sem o devido registro técnico, ou em que parâmetros críticos foram detectados e ainda não receberam intervenção.

Para que essa conexão fosse eficiente, foi necessário realizar a modelagem dos dados no Power BI, estruturando tabelas relacionais que permitem análises dinâmicas e visualizações interativas. Conforme destaca Ferreira et al. (2024), “a modelagem adequada é um dos elementos centrais para garantir que as análises geradas por sistemas de BI sejam precisas, escaláveis e de fácil interpretação”. No projeto, a modelagem seguiu uma arquitetura de dados que facilita tanto o acesso rápido aos relatórios de status dos AMVs quanto o detalhamento técnico de cada medição realizada.

Outro aspecto importante dessa etapa foi o tratamento e normalização dos dados recebidos. Muitas vezes, campos preenchidos em inspeções manuais podem conter pequenas inconsistências de digitação, abreviações diferentes ou erros de formatação. Para corrigir esses problemas, foram implementadas rotinas de limpeza e padronização dentro do próprio Power Query, antes que as informações fossem carregadas no modelo analítico. Como ressaltam Barkhordari, Galeazzi e Blanke (2021), “dados limpos e consistentes são essenciais para que modelos analíticos tenham resultados confiáveis e mantenham sua utilidade ao longo do tempo”.

Ao final dessa etapa, o sistema já contava com uma base integrada e organizada, pronta para alimentar as análises de criticidade, gerar visualizações de alertas e executar modelos preditivos. Essa integração robusta é o que garante que o painel de controle dos AMVs seja capaz de refletir, de forma fiel e em tempo real, a situação operacional da via e a execução das manutenções planejadas.

3.3 Classificação de criticidade

A classificação de criticidade é a etapa responsável por transformar dados brutos coletados em campo em informações acionáveis para a tomada de decisão. No projeto desenvolvido para a Estrada de Ferro Carajás, cada parâmetro medido nos Aparelhos de Mudança de Via (AMVs)

é comparado a limites de tolerância previamente definidos pela equipe de engenharia, com base em normas técnicas internas, histórico de desempenho e análise de falhas anteriores.

Quando o valor registrado ultrapassa os limites aceitáveis, o sistema de *Business Intelligence* no *Power BI* atribui automaticamente uma das cinco categorias de prioridade: P2 (baixa criticidade), P1 (moderada), P1F (alta), P0 restrição (crítica com restrição operacional) e P0 interdição (crítica com necessidade imediata de retirada de operação). Essa classificação segue o princípio apontado por Barkhordari, Galeazzi e Blanke (2021), segundo o qual “a priorização baseada em categorias de risco é essencial para direcionar recursos de manutenção aos pontos com maior impacto na segurança e na disponibilidade da infraestrutura”.

O processo de categorização foi automatizado dentro do modelo de dados, permitindo que cada novo formulário de inspeção, assim que integrado ao sistema, gere instantaneamente a classificação do ativo inspecionado. Isso elimina a necessidade de avaliações manuais posteriores, reduzindo atrasos na tomada de decisão. Conforme afirmam Kalathas, Papoutsidakis e Drosos (2021), “a automação no tratamento e classificação de dados aumenta a responsividade das equipes e melhora a eficiência na execução das manutenções”.

Além da classificação individual, o sistema também gera um panorama agregado, exibindo a quantidade e a localização dos AMVs por nível de criticidade. Esse recurso facilita a análise estratégica, permitindo que gestores visualizem áreas da malha com concentração de ativos em condição crítica e priorizem ações de forma regionalizada. Ferreira et al. (2024) destacam que “o mapeamento georreferenciado associado à classificação de criticidade amplia a capacidade de planejamento e reduz deslocamentos desnecessários das equipes de manutenção”.

Outro benefício dessa abordagem é a rastreabilidade. Cada classificação fica registrada junto com os valores originais medidos, a data da inspeção e o responsável pela coleta. Isso cria um histórico auditável que pode ser consultado para investigações de incidentes ou revisões técnicas, conforme preconizado por Xie et al. (2020), que recomendam “a manutenção de registros completos e auditáveis para análise de tendências e validação de processos de manutenção preditiva”.

Assim, a classificação de criticidade implementada no projeto não apenas agiliza a tomada de decisão operacional, mas também cria um sistema de gestão da informação robusto, que serve de base para análises históricas, modelagem preditiva e auditorias técnicas, fortalecendo a governança da manutenção ferroviária.

3.4 Visualização de alertas e histórico

A visualização de alertas é um dos recursos mais relevantes do painel de *Business Intelligence* desenvolvido para a Estrada de Ferro Carajás, pois transforma dados técnicos em representações espaciais que facilitam a interpretação e a priorização das ações de manutenção. No sistema, cada Aparelho de Mudança de Via (AMV) é exibido em um mapa interativo, posicionado de acordo com sua localização real na malha ferroviária e identificado pela sua classificação de criticidade.

Essa abordagem segue o que Ferreira et al. (2024) apontam como uma tendência no uso de BI para manutenção de ativos: “a integração de dados georreferenciados com indicadores técnicos amplia a capacidade de planejamento, otimiza deslocamentos e permite a visualização de padrões regionais de degradação”. No caso do projeto, isso significa que gestores podem, em poucos segundos, identificar áreas da ferrovia onde há concentração de AMVs em estado crítico e planejar intervenções de forma agrupada, reduzindo custos operacionais e tempo de resposta.

Além da visualização de alertas, o painel também disponibiliza o histórico completo de medições para cada AMV, armazenando informações desde o primeiro registro coletado via formulário técnico. Esse histórico inclui valores medidos, data e hora da inspeção, responsável pelo registro e classificações atribuídas ao longo do tempo. Xie et al. (2020) reforçam que “a manutenção de séries históricas detalhadas é essencial para a análise de tendências, o diagnóstico de problemas recorrentes e a validação de modelos preditivos”.

Para melhorar a usabilidade, a visualização no Power BI foi configurada para permitir filtros dinâmicos, como seleção por trecho da ferrovia, intervalo de tempo, nível de criticidade ou status do plano de manutenção. Kalathas, Papoutsidakis e Drosos (2021) destacam que “o poder das ferramentas de BI está na capacidade de fornecer visualizações interativas, que não apenas apresentam dados, mas permitem ao usuário explorá-los sob diferentes perspectivas”.

Outro ponto importante é que, ao clicar em um AMV no mapa, o usuário tem acesso imediato a um painel detalhado com seu histórico, os parâmetros medidos, a evolução dos valores e o status das ações corretivas. Isso garante rastreabilidade total e suporte para auditorias técnicas, conforme defendido por Barkhordari, Galeazzi e Blanke (2021), que recomendam “a rastreabilidade integral dos eventos de manutenção para fortalecer a governança e a confiabilidade operacional”.

Com essa integração entre localização física e histórico operacional, a ferramenta fornece não apenas um retrato estático da condição atual dos AMVs, mas também uma visão temporal e

espacial da sua evolução, permitindo análises estratégicas mais profundas e suporte robusto para decisões operacionais e de investimento.

3.5 Análise preditiva e projeção de tendências

A etapa de análise preditiva é responsável por transformar o histórico de medições dos Aparelhos de Mudança de Via (AMVs) em projeções quantitativas sobre o seu comportamento futuro. No projeto desenvolvido para a Estrada de Ferro Carajás, essa funcionalidade foi incorporada diretamente ao painel do Power BI, permitindo que, a partir das séries temporais de inspeções, sejam geradas curvas de tendência que estimam a evolução de seis parâmetros técnicos prioritários para a troca de trilho nos próximos três meses.

Essas previsões são calculadas considerando o ritmo de degradação observado, de forma que cada nova medição atualiza automaticamente o model. Barkhordari et al. (2017) destacam que “o uso de prognósticos quantitativos na manutenção ferroviária possibilita a identificação de falhas antes que elas ocorram, reduzindo custos com reparos emergenciais e aumentando a disponibilidade dos ativos”.

Para viabilizar essa funcionalidade, foi necessário aplicar técnicas de análise de séries temporais, utilizando como base a sequência cronológica de valores coletados em campo. Conforme apontam Xie et al. (2020), “a análise preditiva baseada em séries temporais é uma das abordagens mais eficazes para modelar o desgaste de componentes ferroviários, pois considera o histórico de medições e o contexto operacional do ativo”.

O painel também apresenta a projeção graficamente, permitindo que o usuário visualize a tendência de cada parâmetro e identifique, de forma intuitiva, quais AMVs estão se aproximando de níveis críticos. Essa representação visual é fundamental para a rápida interpretação por parte das equipes de manutenção, corroborando o que Kalathas, Papoutsidakis e Drosos (2021) descrevem como “a capacidade do BI de transformar grandes volumes de dados em informações compreensíveis e acionáveis”.

Outro aspecto importante dessa etapa é sua integração com a classificação de criticidade. Quando a projeção indica que um parâmetro ultrapassará o limite aceitável dentro do período analisado, o sistema pode gerar alertas visuais nos gráficos. Ferreira et al. (2024) observam que “a conexão entre análises preditivas e sistemas de gestão de manutenção potencializa o uso dos dados e cria um ciclo contínuo de melhoria operacional”.

Assim, a análise preditiva implementada no projeto não se limita a prever a degradação dos componentes, mas atua como uma camada estratégica que antecipa necessidades, otimiza recursos e reforça a segurança operacional, consolidando o uso de Business Intelligence como ferramenta central na manutenção ferroviária.

4 RESULTADOS E DISCUSSÕES

A solução *Analytics AMV* foi desenvolvida para centralizar, em um único painel no *Power BI*, o monitoramento dos Aparelhos de Mudança de Via (AMVs) da Estrada de Ferro Carajás, transformando dados técnicos de campo em decisões operacionais estratégicas. Como ressaltam Rodríguez-Hernández (2025), a digitalização e integração de dados de ativos ferroviários com sistemas de gestão permitem ganhos expressivos em eficiência, rastreabilidade e segurança operacional. A interface inicial da ferramenta, apresentada na Figura 1, deixa claro o escopo da solução: analisar e monitorar todos os parâmetros de cada AMV, oferecendo visões rápidas (“Apropriações”) e análises detalhadas (“Análise completa”).

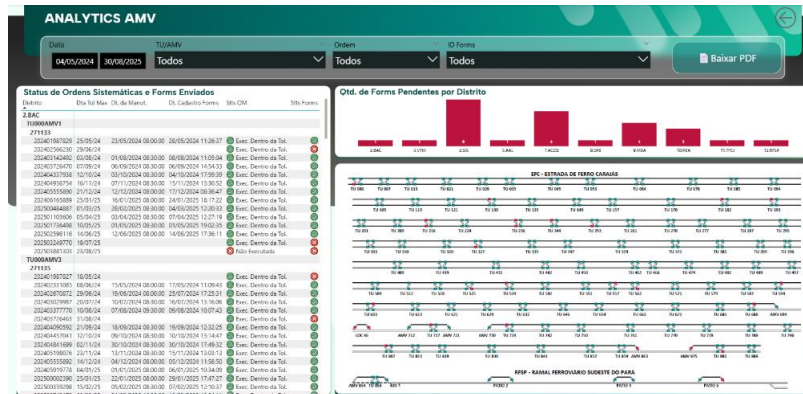
Figura 1 - Capa de apresentação do *Analytics AMV*



Fonte: Imagem gerada pelo autor (2025)

A plataforma possibilita acompanhar, em tempo quase real, a execução das ordens de manutenção sistemática e o envio dos formulários técnicos, cruzando essas informações com dados do SAP. Essa integração é apontada como prática recomendada por Esri UK (2023), que destaca o valor do cruzamento entre dados operacionais e georreferenciados para otimizar o planejamento de manutenção. A Figura 2 ilustra esse processo, apresentando o status das execuções, a quantidade de formulários pendentes por distrito e a visualização da malha ferroviária com os AMVs inspecionados.

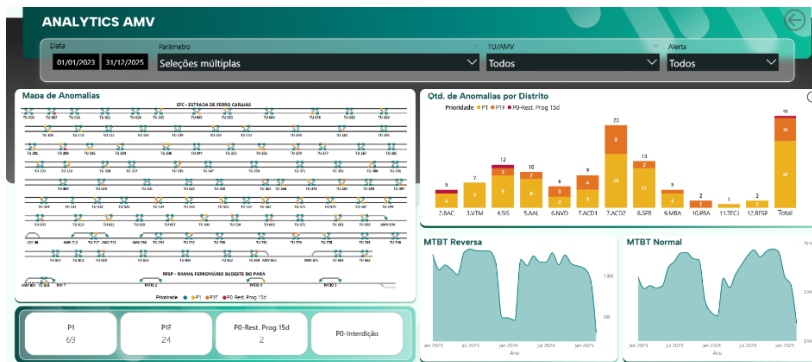
Figura 2 - Status de Ordens e Formulários Enviados



Fonte: Imagem gerada pelo autor (2025)

O mapa de alertas também se mostra essencial para priorizar intervenções de acordo com a criticidade dos problemas. A Figura 3 traz o mapa de anomalias, no qual cada ocorrência é classificada segundo sua prioridade (P1, P1F, P0 restrição e P0 interdição) e apresentada em conjunto com um gráfico que mostra sua distribuição por distrito. Conforme Davari et al. (2021), a visualização espacial associada a dados de criticidade aumenta a capacidade de resposta e eficiência na alocação de recursos para manutenção.

Figura 3 - Mapa de Anomalias e Distribuição por Distrito



Fonte: Imagem gerada pelo autor (2025)

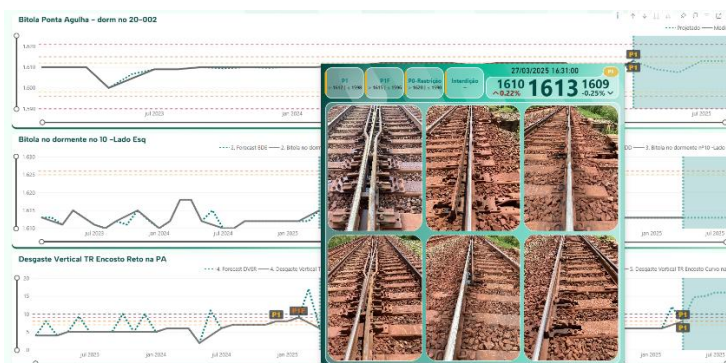
O histórico completo das medições aparece em forma tabular na Figura 4, com registros mensais para cada parâmetro monitorado e destaque automático para valores fora da tolerância. Kalathas, Papoutsidakis e Drosos (2021) afirmam que a análise de séries temporais é fundamental para detectar padrões de degradação e identificar falhas recorrentes antes que causem indisponibilidade.

Figura 4 - Histórico de Medições por Parâmetro

Fonte: Imagem gerada pelo autor (2025)

Complementando as funcionalidades, a ferramenta incorpora análises preditivas para parâmetros críticos, projetando tendências de degradação com base nos dados históricos. A Figura 5 exemplifica esse recurso, apresentando curvas de tendência para os próximos três meses associadas a imagens de campo que registram a condição física do AMV. Essa combinação de dados quantitativos e evidências visuais é apontada por Rodríguez-Hernández (2025) como fator determinante para a assertividade na manutenção preditiva, pois permite validar previsões com inspeções reais e agir antes que os níveis críticos sejam atingidos.

Figura 5 - Projeção de Tendências e Imagens de Campo



Fonte: Imagem gerada pelo autor (2025)

Com a implementação do *Analytics* AMV, foi possível reduzir significativamente o tempo de análise, aumentar a precisão na priorização das intervenções e aprimorar o controle sobre os planos de manutenção, prevenindo falhas que poderiam comprometer a disponibilidade da via. Esses resultados alinham-se às conclusões de Davari et al. (2021), que identificam a manutenção preditiva baseada em dados como uma das abordagens mais eficazes para elevar a confiabilidade de sistemas ferroviários complexos.

5 CONCLUSÃO

A implementação do *Analytics* AMV na Estrada de Ferro Carajás demonstrou como a integração de dados técnicos, ferramentas de *Business Intelligence* e metodologias preditivas pode transformar a gestão de manutenção ferroviária. Ao centralizar informações de inspeção, execução de ordens de serviço, histórico de parâmetros e projeções de tendência em um único ambiente, a solução permitiu uma visão ampla e detalhada do estado dos Aparelhos de Mudança de Via, viabilizando decisões mais rápidas, assertivas e baseadas em evidências.

A combinação de mapas de alertas, classificação automática de criticidade e previsão de degradação proporcionou ganhos significativos em eficiência operacional e segurança. Esse resultado confirma o que Davari et al. (2021) destacam ao afirmar que a manutenção preditiva orientada por dados é uma das abordagens mais eficazes para elevar a confiabilidade de ativos complexos, reduzindo custos e evitando falhas catastróficas.

Além dos benefícios imediatos, a solução desenvolvida está alinhada às tendências globais de digitalização do setor ferroviário, apontadas por Rodríguez-Hernández (2025), nas quais a integração de sistemas corporativos, inteligência analítica e dados de campo cria um ciclo contínuo de melhoria. A utilização de imagens de inspeção associadas às projeções numéricas, por exemplo, reforça a confiabilidade das previsões e facilita a comunicação técnica entre equipes, conforme preconizado por Kalathas, Papoutsidakis e Drosos (2021).

Como perspectivas futuras, o sistema pode evoluir para incorporar algoritmos de aprendizado de máquina mais sofisticados, capazes de identificar padrões complexos de degradação, além de expandir a integração com sensores IoT para coleta automática e contínua de dados. Tais avanços ampliariam a capacidade de antecipar falhas e tornariam a manutenção ainda mais proativa, alinhando-se às melhores práticas internacionais.

Em síntese, o *Analytics* AMV não apenas aprimorou a gestão de manutenção da Estrada de Ferro Carajás, mas também se apresenta como um modelo replicável para outras operações ferroviárias que buscam combinar inteligência de dados, automação e análise preditiva para atingir níveis superiores de confiabilidade e desempenho.

REFERÊNCIAS

ABNT. ABNT NBR ISO 55000:2014 — Gestão de ativos — Visão geral, princípios e terminologia. Rio de Janeiro: ABNT, 2014.

ABNT. ABNT NBR ISO 55001:2014 — Gestão de ativos — Sistemas de gestão de ativos — Requisitos. Rio de Janeiro: ABNT, 2014.

ABNT. ABNT NBR ISO 55002:2018 — Gestão de ativos — Sistemas de gestão de ativos — Diretrizes para a aplicação da ABNT NBR ISO 55001. Rio de Janeiro: ABNT, 2018.

BARKHORDARI, P.; GALEAZZI, R.; BLANKE, M. Monitoring of Railpad Long-term Condition in Turnouts Using Extreme Value Distributions. *ArXiv*, 2021. Disponível em: <https://arxiv.org/abs/2101.02567>. Acesso em: 10 ago. 2025.

BARKHORDARI, P.; GALEAZZI, R.; TEJADA, A. de M.; SANTOS, I. F. Low-complexity Behavioral Model for Predictive Maintenance of Railway Turnouts. *Annual Conference of the PHM Society*, v. 9, n. 1, 2017. Disponível em: <https://papers.phmsociety.org/index.php/phmconf/article/view/2399>. Acesso em: 10 ago. 2025.

BARBOSA, R. F. Utilização de ferramenta de Business Intelligence para a gestão da manutenção e conservação de rodovias (BR-101/AL). 2020. Dissertação (Mestrado em Engenharia Civil) – Universidade Federal de Alagoas, Maceió, 2020. Disponível em: <https://www.repositorio.ufal.br/handle/123456789/11595>. Acesso em: 10 ago. 2025.

DAVARI, N. et al. A Survey on Data-Driven Predictive Maintenance for the Railway Industry. *Sensors*, v. 21, n. 17, p. 5739, 2021. DOI: <https://doi.org/10.3390/s21175739>.

ESRI UK. Asset Management & Maintenance – Rail. Disponível em: <https://www.esriuk.com/en-gb/industries/rail/business-areas/asset-management-maintenance>. Acesso em: 10 ago. 2025.

FERREIRA, A. P. et al. Integração de ferramentas de Business Intelligence para gestão de manutenção ferroviária. *Anais do Congresso Nacional de Engenharia Ferroviária*, 2024.

IBERDROLA. Manutenção preditiva: a técnica baseada em dados-chave para se antecipar aos erros. Disponível em: <https://www.iberdrola.com/inovacao/manutencao-preditiva>. Acesso em: 10 ago. 2025.

KALATHAS, I.; PAPOUTSIDAKIS, M.; DROSOS, C. Business Intelligence and Machine Learning Methods for Predictive Maintenance in Greek Railways. *Open Journal of Applied Sciences*, v. 11, p. 20-35, 2021. DOI: <https://doi.org/10.4236/ojapps.2021.112003>.

MECALUX. Manutenção preditiva: técnicas e vantagens. Disponível em: <https://www.mecalux.com.br/blog/manutencao-preditiva>. Acesso em: 10 ago. 2025.

REVISTA MANUTENÇÃO. Conceitos e vantagens da manutenção preditiva. Disponível em: <https://revistamanutencao.com.br/literatura/tecnica/manutencao/conceitos-e-vantagens-da-manutencao-preditiva.html>. Acesso em: 10 ago. 2025.

RODRÍGUEZ-HERNÁNDEZ, M. Digitalization as an Enabler in Railway Maintenance: A Review. *Infrastructures*, v. 10, n. 4, 2025. DOI: <https://doi.org/10.3390/infrastructures10040096>.

SEMEQ. Manutenção preditiva: o que é e quais são os benefícios. Disponível em: <https://semeq.com/pt/blog/manutencao-preditiva/>. Acesso em: 10 ago. 2025.

XIE, J. et al. Systematic Literature Review on Data-Driven Models for Predictive Maintenance of Railway Track: Implications in Geotechnical Engineering. *Engineering Failure Analysis*, v. 115, 2020. Disponível em: <https://pdfs.semanticscholar.org/ff8f/9a1b320415fbc0bcf3c460fc6615e3d66189.pdf>. Acesso em: 10 ago. 2025.