



FRAMEWORK PARA PRIORIZAÇÃO DE MANUTENÇÃO DE ROLAMENTOS FERROVIÁRIOS BASEADO EM *HEALTH INDEX* E MONITORAMENTO *WAYSIDE*

Leandro Rocha Lopes¹; Lucas Fabrício Neves de Sousa¹; Daniele Coelho dos Anjos¹;
Roziane da Silva Almeida¹; Rafael Gonçalves¹

¹VALE EFC, MA - Brasil

RESUMO

A segurança operacional em ferrovias de carga pesada depende fortemente da confiabilidade dos rolamentos ferroviários, que operam sob elevadas cargas por eixo e ciclos térmicos severos. Nesse contexto, sistemas de monitoramento *wayside*, como os *Hot Box Detectors* (HBD), desempenham papel central na detecção de aquecimentos anômalos. Tradicionalmente, a atuação de manutenção baseia-se em alarmes reativos por limiares fixos ou, em estágios mais avançados, em regras preditivas simplificadas. Embora eficazes para falhas já manifestadas, tais abordagens apresentam limitações na priorização graduada do risco operacional. Este trabalho propõe um framework decisório para priorização de manutenção de rolamentos ferroviários, fundamentado em *Health Index* e monitoramento *wayside*, com foco na evolução dos critérios operacionais e na formalização matemática da tomada de decisão. São definidas variáveis térmicas representativas do comportamento dos rolamentos e analisadas por meio de Análise de Componentes Principais (PCA), empregada exclusivamente como ferramenta de caracterização e validação das *features*, evidenciando a organização do problema em duas dimensões latentes associadas à severidade térmica e à persistência dos eventos. O *Health Index* é introduzido como métrica sintética de apoio à decisão, sem caráter prognóstico, e utilizado para estruturar uma política de atuação baseada em faixas de severidade claramente interpretáveis. Estudos de caso ilustram a aplicação do framework e seus ganhos em termos de consistência, rastreabilidade e alinhamento com práticas de *Prognostics and Health Management* (PHM). Os resultados reforçam o potencial da abordagem para apoiar decisões de manutenção mais robustas em ambientes ferroviários *heavy haul*.

Palavras-chave: Rolamentos ferroviários, Priorização da Manutenção, Índice de Saúde (*Health Index*), Monitoramento *wayside*, *Hot Box Detectors* (HBD), Framework decisório

1. INTRODUÇÃO

A confiabilidade dos rolamentos ferroviários constitui um dos pilares da segurança operacional em ferrovias de carga pesada, especialmente em operações do tipo *heavy haul*, caracterizadas por altas cargas por eixo, ciclos térmicos intensos e condições ambientais severas. Nesse contexto, variações anômalas de temperatura tornam-se indicativas relevantes de processos de degradação, conforme evidenciado em estudos recentes sobre comportamento térmico em sistemas ferroviários de grande porte (Bosomworth et al., 2022; Wang et al., 2022). Em ferrovias de alta demanda logística, como a Estrada de Ferro Carajás (EFC), a antecipação de falhas térmicas é fundamental para reduzir paradas não programadas e mitigar riscos operacionais significativos (Binder et al., 2023).

No monitoramento de condição, sistemas *wayside* desempenham papel central ao fornecer medições não intrusivas durante a passagem das composições, destacando-se a temperatura de rolamentos como variável de maior sensibilidade diagnóstica (Yan et al., 2022). Entre esses sistemas, os *Hot Box Detectors* (HBDs) realizam medições por meio de sensores infravermelhos posicionados ao longo da via, associando os dados aos respectivos eixos e transmitindo-os a sistemas supervisórios centralizados (Lopes e Arruda, 2019; EN 15437-1+A1, 2023). A eficácia desses sistemas pode ser ampliada com o uso de análises de tendência, calibração periódica e ajustes dinâmicos de limiares, reduzindo erros de detecção e aumentando a sensibilidade a falhas incipientes (FRA, 2023; Tarawneh et al., 2020).

No contexto operacional da EFC, observou-se, ao longo do primeiro semestre de 2025, um aumento significativo de eventos associados a rolamentos, atingindo patamares cerca de 67% superiores aos registrados em 2024. Esse cenário evidenciou maior incidência em determinados modelos de rolamentos, além de crescimento nas intervenções emergenciais conduzidas pelo Centro de Monitoramento de Ativos (CMA). Entre os eventos críticos, destacaram-se vazamentos de lubrificante e aquecimentos severos detectados por HBD, indicando a necessidade de evolução nos critérios de priorização de manutenção.

Embora a temperatura seja reconhecida como uma das variáveis mais sensíveis para diagnóstico de degradação, conforme diretrizes da ISO 17359 (ISO, 2018), sua utilização isolada apresenta limitações. Métodos que integram níveis, dispersão e recorrência térmica tendem a proporcionar maior robustez diagnóstica, especialmente quando associados a abordagens multivariadas e modelos analíticos (Wang et al., 2022; Zhang et al., 2026).

Diante desse contexto, torna-se necessário adotar metodologias capazes de não apenas identificar anomalias térmicas, mas estruturar a priorização de manutenção de forma graduada e consistente com o risco operacional. Neste trabalho, propõe-se um *framework* decisório baseado em *Health Index*, desenvolvido a partir de dados reais de HBD e orientado à integração multivariada de informações térmicas. Diferentemente de abordagens puramente reativas, o modelo permite apoiar decisões mesmo na ausência de alarmes críticos.

O conceito de *Health Index*, embora não normatizado, é amplamente utilizado em gestão de ativos como métrica consolidada de condição, alinhando-se aos princípios da ISO 17359 e a referências em PHM (Vogl, Weiss e Donmez, 2014; IEEE, 2017). Neste estudo, o índice é empregado como instrumento de síntese para classificação de risco, sem contemplar a estimativa direta de Vida Útil Remanescente (RUL).

Diante disso, este trabalho tem como objetivo principal propor e validar um *framework* para priorização de manutenção de rolamentos ferroviários baseado em *Health Index*, utilizando dados reais de monitoramento *wayside*. Especificamente, busca-se: (i) caracterizar o comportamento térmico de rolamentos por meio de abordagem multivariada; (ii) construir um índice sintético de saúde com propriedades interpretáveis; (iii) estruturar uma política de decisão baseada em severidade operacional; e (iv) avaliar, com dados reais, os ganhos em cobertura, sensibilidade e consistência na priorização da manutenção.

2. MONITORAMENTO DE ROLAMENTOS VIA *WAYSIDES*

O monitoramento *wayside* constitui a base do acompanhamento não intrusivo da condição de componentes críticos do material rodante em ferrovias de carga pesada. Em operações

heavy haul, caracterizadas por elevadas cargas por eixo, longos percursos e regimes térmicos severos, a confiabilidade dos rolamentos ferroviários está diretamente associada à capacidade de identificar aquecimentos anômalos de forma consistente e em tempo adequado. Esse arranjo viabiliza o monitoramento contínuo de grandes frotas sem a necessidade de instrumentação embarcada permanente, permitindo a gestão de ativos em escala operacional compatível com ferrovias de alta capacidade.

Na Estrada de Ferro Carajás (EFC), esse desafio é amplificado pelo porte da operação, que conta com aproximadamente 20 mil vagões de minério, totalizando cerca de 160 mil rolamentos em serviço. O monitoramento térmico desses componentes é realizado predominantemente por meio de *Hot Box Detectors* (HBDs) distribuídos ao longo da malha ferroviária. Atualmente, a EFC dispõe de 15 pontos de monitoramento HBD, estrategicamente posicionados ao longo dos 892 km de extensão da ferrovia, cobrindo os principais corredores operacionais entre mina, pátios intermediários e terminal marítimo. Os HBDs, conforme pode ser visto na Figura 1, realizam a medição da temperatura das caixas de rolamento por sensores infravermelhos orientados para o material rodante durante a passagem das composições. A cada passagem de uma composição, o sistema realiza a aquisição contínua da assinatura térmica de cada caixa de rolamento. Embora o output operacional seja tipicamente representado por um valor escalar por rolamento e por passagem, o processamento interno constrói um perfil térmico (*heat profile*) por meio da reamostragem e normalização do sinal, resultando em aproximadamente 24 pontos discretos que representam a distribuição térmica ao longo da passagem.

As medições são associadas aos respectivos eixos por sistemas de contagem de rodas, processadas localmente para validação básica e, posteriormente, transmitidas a sistemas supervisórios centralizados. A confiabilidade das leituras depende de fatores como alinhamento geométrico, calibração periódica, estabilidade do campo de visão e condições ambientais, o que impõe limitações práticas à interpretação direta de valores absolutos de temperatura, conforme discutido em diretrizes normativas e estudos aplicados ao monitoramento ferroviário (ISO, 2018; Tarawneh et al., 2020).




Figura 1. Medição de temperatura de rolamento via HBD monocal.

O espaçamento entre os pontos de monitoramento define a frequência com que cada rolamento é avaliado e, consequentemente, a janela temporal disponível para análise da evolução térmica entre passagens sucessivas. Falhas de evolução rápida tendem a ser identificadas apenas quando o aquecimento já atinge níveis elevados, enquanto processos de degradação progressiva manifestam-se como padrões térmicos recorrentes ao longo de

múltiplas leituras. Essa característica estrutural condiciona o tipo de critério operacional que pode ser aplicado de forma confiável aos dados *wayside*.

Historicamente, a atuação de manutenção baseada em HBDs fundamentou-se em critérios reativos, nos quais intervenções são acionadas quando a temperatura medida ultrapassa um limiar técnico previamente definido. Embora eficaz para conter falhas severas já manifestadas, essa abordagem não explora a informação temporal contida no histórico térmico do ativo. Como etapa intermediária à abordagem multivariada, foi previamente desenvolvido e implantado um critério preditivo baseado na temperatura diferencial (ΔT), definida como a diferença de temperatura entre as caixas de rolamento de um mesmo eixo, sendo utilizada como indicador de assimetria térmica e potencial degradação localizada. Esse conceito representou a primeira aplicação sistemática da temperatura diferencial como variável preditiva no monitoramento *wayside* de rolamentos ferroviários da EFC, permitindo maior sensibilidade à detecção de falhas incipientes quando comparado a abordagens baseadas exclusivamente em valores absolutos de temperatura (Rocha Lopes, 2024).

A crescente complexidade operacional da EFC evidencia a necessidade de abordagens multivariadas, capazes de integrar diferentes características térmicas em critérios de decisão mais robustos. Essa evolução operacional motiva a transição de regras simples, baseadas exclusivamente em limiares ou contagens, para *frameworks* decisórios estruturados, nos quais múltiplas variáveis são consolidadas e interpretadas de forma coerente com o risco associado a cada rolamento monitorado.

3. CARACTERIZAÇÃO MULTIVARIADA

A caracterização multivariada do comportamento térmico dos rolamentos ferroviários foi conduzida a partir de dados históricos de temperatura diferencial (ΔT) provenientes dos *Hot Box Detectors* (HBDs), abrangendo todos os ativos monitorados ao longo da malha ferroviária. A metodologia foi estruturada em duas etapas distintas: (i) determinação prévia de um *threshold* térmico de relevância, aplicado globalmente ao banco de dados, e (ii) extração de variáveis térmicas em janelas móveis de 60 dias, condicionadas a esse limiar.

A definição do *threshold* térmico constitui a etapa inicial do processo de caracterização, antecedendo qualquer recorte temporal por janelas móveis. Para esse fim, foi conduzida uma análise estatística descritiva a partir de um conjunto histórico de rolamentos que apresentaram eventos térmicos confirmados, avaliando-se os valores máximos de temperatura diferencial (ΔT) observados em períodos anteriores à ocorrência desses eventos. A distribuição desses valores é apresentada na Figura 2.a, permitindo identificar faixas térmicas associadas a padrões anômalos de comportamento.

Além da análise da magnitude dos valores de ΔT , que captura a severidade térmica dos eventos, investigou-se a consistência das repetições ao longo do tempo, Figura 2.b, com o objetivo de diferenciar eventos isolados de padrões persistentes de degradação. Observou-se que limiares mais baixos tendem a apresentar maior número mínimo de repetições por ativo, enquanto limiares mais elevados reduzem a recorrência, mas aumentam a seletividade dos casos considerados. Em particular, verificou-se que a adoção de $\Delta T \geq 16^\circ\text{C}$, associada ao critério de pelo menos três ocorrências, permite abranger aproximadamente 96% dos ativos analisados, enquanto o limiar de $\Delta T \geq 20^\circ\text{C}$, sob o mesmo critério de recorrência, preserva cerca de 88% dos casos relevantes.




Figura 2.a. Distribuição maiores ΔT .




Figura 2.b. Repetições ≥ 3 .

Essa análise evidencia que, embora a redução do limiar aumente a abrangência estatística, valores mais conservadores mantêm elevada cobertura dos ativos com comportamento térmico persistente, ao mesmo tempo em que reduzem a inclusão de flutuações associadas ao regime normal de operação. Considerando-se o compromisso entre sensibilidade estatística, robustez diagnóstica e equilíbrio das demandas operacionais de manutenção, adotou-se $\Delta T \geq 20^\circ\text{C}$ como *threshold* de relevância térmica, associado ao requisito de no mínimo três medições acima desse limiar.

O *threshold* atua, nesta etapa, exclusivamente como filtro estatístico, separando variações térmicas compatíveis com o regime normal de operação de comportamentos potencialmente associados a processos de degradação. Sua função não é decisória, mas assegurar que apenas medições com significado físico e diagnóstico sejam consideradas na construção das variáveis térmicas utilizadas nas etapas subsequentes da análise multivariada.

Uma vez estabelecido o *threshold*, as variáveis térmicas passam a ser calculadas em janelas móveis de 60 dias, aplicadas individualmente a cada rolamento. Essa janela temporal foi definida de modo a proporcionar quantidade suficiente de observações para capturar padrões de progressão térmica e recorrência, respeitando as limitações impostas pelo espaçamento entre os pontos *wayside* e pela frequência de passagem das composições.

Dentro de cada janela, apenas as medições que excedem o *threshold* são utilizadas para o cálculo das variáveis, assegurando foco nos períodos de comportamento térmico anômalo. A partir dessas medições filtradas, são definidas quatro variáveis complementares:

- **Temperatura máxima** ($T_{\max}$): maior valor de ΔT registrado na janela, associada à severidade térmica extrema;
- **Temperatura média acima do limiar** ($T_{\text{méd}}$): média aritmética dos valores de ΔT que excedem o *threshold*, representando o nível térmico sustentado;
- **Desvio padrão** (σ): calculado a partir das medições acima do limiar, capturando a instabilidade e a variabilidade do sinal térmico;
- **Número de ocorrências** (N): contagem das medições com $\Delta T \geq 20^\circ\text{C}$ dentro da janela, expressando a persistência temporal do fenômeno.

Esse conjunto de variáveis integra informações de pico, tendência, dispersão e recorrência, mitigando a dependência de indicadores isolados e reduzindo a influência de eventos pontuais não representativos.

As variáveis térmicas são organizadas em um vetor de estado térmico associado a cada rolamento, definido como:

$$\mathbf{x} = [T_{\max}, T_{\text{méd}}, \sigma, N]^T \in \mathbb{R}^4, \quad (1)$$

no qual cada componente corresponde a uma dimensão física específica do comportamento térmico observado. Essa representação vetorial permite tratar o monitoramento dos rolamentos como um problema multivariado, baseado na combinação simultânea de diferentes evidências térmicas.

Para caracterizar a estrutura estatística do conjunto de variáveis e avaliar redundâncias e complementaridades, aplicou-se a Análise de Componentes Principais (*Principal Component Analysis* – PCA) à matriz de correlação do vetor x . Neste trabalho, a PCA é utilizada exclusivamente como ferramenta de caracterização e validação das *features*, não desempenhando qualquer papel direto na priorização ou tomada de decisão.

Os resultados indicam que os dois primeiros componentes principais concentram aproximadamente 93,8% da variância total dos dados, permitindo uma redução dimensional significativa sem perda relevante de informação.

Tabela 1. Autovalores e variância explicada dos componentes principais

Componente	Autovalor	Variância (%)	Acumulada (%)
CP1	2,73	68,3	68,3
CP2	1,02	25,5	93,8
CP3	0,22	5,4	99,3
CP4	0,03	0,7	100

O primeiro componente (68,3% da variância) apresenta carregamentos elevados associados a $T_{\max}$, $T_{\text{méd}}$ e σ , sendo interpretado como uma dimensão relacionada à severidade e instabilidade térmica. O segundo componente (25,5% da variância) é fortemente dominado pela variável N , refletindo a persistência do comportamento anômalo ao longo do tempo. Na Figura 3 pode ser visualizado o gráfico de cargas fatoriais.




Figura 3. Gráfico de cargas fatoriais das variáveis térmicas nos dois primeiros componentes principais

Essa separação evidencia que o comportamento térmico dos rolamentos pode ser descrito em um espaço latente de baixa dimensionalidade, composto por dimensões fisicamente interpretáveis e estatisticamente independentes. A PCA, portanto, confirma a adequação das variáveis selecionadas e fornece suporte quantitativo à adoção de uma abordagem

multivariada, estabelecendo a base estatística sobre a qual se apoia o modelo decisório apresentado nas seções subsequentes.

4. HEALTH INDEX COMO MÉTRICA DE APOIO A DECISÃO

A multiplicidade de variáveis necessárias para descrever o comportamento térmico de rolamentos ferroviários, severidade, instabilidade e persistência, torna inviável, do ponto de vista operacional, a utilização direta dessas informações em processos de priorização de manutenção. Nesse contexto, o *Health Index* (HI) é introduzido como uma métrica sintética de apoio à decisão, capaz de consolidar múltiplas evidências térmicas em um único indicador escalar, preservando a informação relevante contida no espaço multivariado previamente caracterizado.

Do ponto de vista matemático, o *Health Index* pode ser definido como uma função de agregação multivariada que associa o vetor de estado térmico do rolamento, $\mathbf{x} \in \mathbb{R}^4$, a um escalar representativo de sua condição operacional:

$$HI = g(\mathbf{x}), \mathbf{x} = \begin{bmatrix} T_{\max} \\ T_{\text{méd}} \\ \sigma \\ N \end{bmatrix}. \quad (2)$$

No presente trabalho, o *Health Index* é construído de forma a representar condições saudáveis com valores próximos de 1 e condições críticas com valores próximos de 0, permitindo interpretação direta e alinhada à priorização operacional.

Antes do processo de agregação, as variáveis do vetor $\mathbf{x}$ são normalizadas, de forma a eliminar distorções decorrentes de diferenças de escala e permitir comparação direta entre termos heterogêneos. Denotando por HI_i os índices parciais normalizados de cada variável, tem-se:

$$HI = \begin{bmatrix} HI_{T_{\max}} \\ HI_{T_{\text{méd}}} \\ HI_{\sigma} \\ HI_N \end{bmatrix}, HI_i \in [0,1]. \quad (3)$$

As variáveis térmicas que compõem o vetor $\mathbf{x}$ apresentam escalas e domínios distintos, o que inviabiliza sua agregação direta. Assim, aplica-se uma etapa de normalização prévia, cujo objetivo é mapear todas as variáveis para um intervalo adimensional comum $[0, 1]$, assegurando comparabilidade, estabilidade estatística e coerência física.

Cada componente x_i é transformado em um índice parcial de saúde $HI_i \in [0,1]$, tal que valores elevados indicam condição saudável, enquanto valores próximos de zero representam maior severidade térmica.

Para a variável temperatura máxima ($T_{\max}$), a normalização é realizada em relação ao limite técnico absoluto de alarme térmico, definido operacionalmente como $T_{\text{lim}} = 50^\circ\text{C}$. Considerando que o aumento de $T_{\max}$ está associado à deterioração da condição do rolamento, adota-se uma normalização decrescente:

$$HI_{T_{\max}} = \max\left(0, 1 - \frac{T_{\max}}{T_{\text{lim}}}\right). \quad (4)$$

Dessa forma, valores próximos ao limite técnico absoluto resultam em $HI_{T_{\max}} \approx 0$, enquanto valores reduzidos de temperatura máxima preservam índices próximos de 1. As variáveis temperatura média acima do limiar ($T_{\text{méd}}$), desvio padrão (σ) e número de ocorrências (N) também possuem relação inversa com a saúde do rolamento. Para essas variáveis, a normalização é realizada por meio de uma transformação do tipo *min-max* invertida, com base nos valores máximo e mínimo observados no banco de dados, considerando exclusivamente medições acima do *threshold* térmico previamente definido:

$$HI_i = 1 - \frac{x_i - x_i^{\min}}{x_i^{\max} - x_i^{\min}}, i \in \{T_{\text{méd}}, \sigma, N\}. \quad (5)$$

No caso da variável de recorrência, estabelece-se $N_{\min} = 3$ como critério mínimo de inclusão do ativo no banco utilizado na construção do índice. Esse critério assegura que apenas comportamentos térmicos com persistência estatisticamente relevante sejam considerados, reduzindo a influência de registros esparsos ou eventos isolados.

O processo de normalização, portanto, não apenas equaliza as escalas das variáveis, mas também reforça a robustez do índice ao restringir sua construção a dados com significado físico e diagnóstico consistente, assegurando compatibilidade com o modelo de agregação adotado na sequência.

Para a agregação das variáveis normalizadas, adota-se um modelo interpolado entre a média ponderada e o pior caso, denominado *Health Index Weighted Worst-Average* (HI-WWA). O índice é definido como:

$$HI_{WWA} = (1 - \rho) \min(HI_i) + \rho \sum_{i=1}^4 \omega_i HI_i, \quad (6)$$

em que:

- HI_i são os índices normalizados das variáveis térmicas;
- ω_i são os pesos associados a cada variável, com $\sum_{i=1}^4 \omega_i = 1$;
- $\rho \in [0,1]$ é o parâmetro de interpolação entre as duas componentes.

O primeiro termo da Equação (6) representa o pior caso, garantindo sensibilidade a comportamentos extremos que possam indicar risco imediato. O segundo termo corresponde à média ponderada, que sintetiza o comportamento global do conjunto de variáveis, incorporando tendência, instabilidade e persistência de forma balanceada.

A interpolação controlada pelo parâmetro ρ permite ajustar o compromisso entre sensibilidade a extremos e robustez estatística, evitando tanto a subestimação de condições críticas quanto o excesso de alarmes motivados por flutuações pontuais.

A formulação do HI-WWA atende a propriedades fundamentais para uso em apoio à decisão operacional:

- **Monotonicidade:** Reduções nos índices parciais HI_i , associadas a agravamentos do comportamento térmico, conduzem a reduções monotônicas do valor de HI_{WWA} , refletindo de forma coerente a degradação da condição operacional do ativo.
- **Interpretabilidade:** o índice resultante pode ser diretamente associado a faixas de severidade operacional, permitindo sua utilização em processos de priorização e despacho de manutenção.
- **Aderência à priorização operacional:** ao incorporar simultaneamente severidade extrema e comportamento sustentado, o índice reflete de forma mais fiel o risco

associado ao rolamento monitorado, alinhando-se às restrições práticas de capacidade de intervenção.

A atribuição dos pesos baseia-se em três critérios principais: (i) sensibilidade ao risco operacional, (ii) capacidade de antecipação de falhas progressivas e (iii) robustez frente a ruído e variações operacionais.

Com base nesses critérios, os pesos foram definidos como:

$$\begin{aligned} \omega_{T_{\max}} &= 0,30, \\ \omega_{T_{\text{méd}}} &= 0,15, \\ \omega_{\sigma} &= 0,10, \\ \omega_N &= 0,45, \end{aligned} \quad \sum_{i=1}^4 \omega_i = 1. \quad (7)$$

O maior peso atribuído à variável N reflete a relevância da persistência do aquecimento como evidência robusta de degradação progressiva, conforme indicado pela análise multivariada. A variável $T_{\max}$ mantém peso elevado por sua associação a condições de severidade extrema, enquanto $T_{\text{méd}}$ e σ complementam a leitura de tendência sustentada e instabilidade térmica, respectivamente. As componentes e pesos pode ser visto na Figura 4.




Figura 4. Componentes do indicador HI-WWA e respectivos pesos, organizados segundo severidade instantânea e persistência/instabilidade térmica.

Neste trabalho, adota-se $\rho = 0,5$, valor que estabelece um compromisso equilibrado entre:

- sensibilidade a condições críticas extremas, assegurada pelo termo de pior caso;
- robustez estatística do comportamento global, refletida pela média ponderada.

Essa formulação evita tanto a subestimação de ativos que já apresentam condição crítica quanto a supervalorização de flutuações pontuais, resultando em um índice adequado ao suporte à decisão operacional.

É importante destacar que o HI-WWA, conforme formulado neste trabalho, não possui caráter prognóstico. O índice consolida informações observadas dentro de uma janela temporal finita, fornecendo uma classificação instantânea de risco, sem estimar explicitamente a taxa de degradação ou a Vida Útil Remanescente (*Remaining Useful Life* – RUL) do rolamento.

Enquanto modelos de prognóstico requerem observações contínuas e modelagem explícita da evolução temporal da falha, o HI-WWA atua como instrumento de priorização operacional, adequado ao contexto *wayside*, no qual as medições são discretas no tempo e condicionadas ao espaçamento entre equipamentos. Dessa forma, o índice

estabelece uma ponte quantitativa entre a caracterização multivariada das variáveis térmicas e o modelo decisório de atuação em manutenção apresentado na seção seguinte.

5. POLÍTICA DE DECISÃO BASEADA EM SEVERIDADE

A consolidação das variáveis térmicas caracterizadas por meio do *Health Index* permite estruturar um modelo decisório formal para priorização de manutenção de rolamentos ferroviários, transformando informações multivariadas em ações operacionais rastreáveis. Do ponto de vista matemático, a decisão de manutenção pode ser expressa como uma função discreta do índice agregado,

$$a = f(HI), \quad (8)$$

em que a representa a ação operacional recomendada. A função de decisão é definida por meio de um conjunto ordenado de limiares $\{\tau_0, \tau_1, \tau_2\}$, que particionam o domínio do *Health Index* em faixas de severidade operacional:

$$a(HI) = \begin{cases} C0, & HI \leq \tau_0, \\ C1, & \tau_0 < HI \leq \tau_1, \\ C2, & \tau_1 < HI \leq \tau_2, \\ C3, & HI > \tau_2. \end{cases} \quad (9)$$

Esses limiares não são definidos como valores absolutos fixos, mas determinados a partir da distribuição empírica do *Health Index* no banco de dados operacional, utilizando estatísticas de ordem. Seja $\mathcal{H} = \{HI_1, \dots, HI_n\}$ o conjunto de índices calculados para os ativos monitorados, definem-se o primeiro quartil Q_1 , a mediana Q_2 e o intervalo interquartil $IQR = Q_3 - Q_1$. A fronteira inferior de severidade extrema é estabelecida por $\tau_0 = Q_1 - \alpha \cdot IQR$, com $\alpha \in (0,1]$, permitindo identificar condições significativamente mais degradadas que a massa principal da distribuição. Os limiares intermediários são definidos como $\tau_1 = Q_1$ e $\tau_2 = Q_2$, assegurando uma transição gradual entre estados de severidade elevada, moderada e baixa.

Sob essa formulação, cada classe C_k representa uma região relativa de risco, e não uma previsão determinística de falha. À medida que o *Health Index* se desloca no domínio contínuo, a decisão evolui de forma consistente com a deterioração progressiva do comportamento térmico. A essa classificação associa-se uma janela operacional de atuação, definida de acordo com o risco observado: atuação imediata para C0, curto prazo para C1, programação em médio prazo para C2 e monitoramento contínuo para C3. Esses prazos não devem ser interpretados como estimativas de tempo até falha, mas como horizontes máximos recomendados de intervenção compatíveis com a criticidade relativa do ativo.

A Figura 5 apresenta um exemplo de ativo classificado com severidade C1, no qual se observa elevação sustentada da temperatura diferencial no rodeiro 1, aumento da variabilidade térmica e incremento do número de ocorrências acima do *threshold*. Esses fatores resultaram na redução progressiva dos índices parciais normalizados e, consequentemente, do valor agregado do *Health Index*. Em caráter experimental, o rolamento foi priorizado para manutenção e posteriormente substituído. Os registros térmicos subsequentes evidenciam a eliminação do comportamento anômalo após a intervenção, com recuperação dos índices parciais e do *Health Index*, confirmando a coerência entre variáveis físicas, índice consolidado e decisão operacional.




Figura 5. Ativo classificado com severidade C1.

A aplicação do modelo ao conjunto de dados operacionais permitiu avaliar quantitativamente os ganhos da nova abordagem. No período analisado, o modelo baseado no HI-WWA classificou 205 rolamentos com algum nível de severidade, identificando dois casos críticos (C0) e um caso de curto prazo (C1), inexistentes na metodologia anterior baseada exclusivamente em regras escalares de repetição térmica. Aproximadamente 80% dos eventos históricos conhecidos foram associados a alguma faixa de severidade pelo novo critério, sendo cerca de 40% enquadrados nas classes C0 ou C1, o que evidencia aumento significativo da sensibilidade à identificação de condições de risco elevado. Em comparação, a abordagem anterior apresentava menor abrangência e ausência de diferenciação entre severidades críticas imediatas e de curto prazo. A comparação conceitual entre o modelo tradicional (reativo) e a proposta HI-WWA pode ser vista na Figura 6.




Figura 6. Comparação conceitual entre o sistema de alarme tradicional e o indicador HI-WWA ao longo da curva de degradação física do rolamento.

A operacionalização do modelo decisório é viabilizada por sua integração a um ambiente de *Business Intelligence* (BI) desenvolvido pelo Centro de Monitoramento de Ativos. Nesse ambiente, os valores do *Health Index*, as classes de severidade e as janelas de atuação são atualizados automaticamente a partir dos dados *wayside*, permitindo visualizações estruturadas por frota, localização e horizonte temporal.

O processo completo de transformação dos dados térmicos em decisão operacional é sintetizado no fluxo metodológico do critério HI-WWA, apresentado na Figura 7. O fluxo inicia-se com a aquisição dos dados *wayside*, seguida pela aplicação do *threshold* térmico, extração das variáveis na janela móvel, normalização, agregação pelo HI-WWA e, por

fim, classificação por faixas de severidade e definição da ação de manutenção. Esse encadeamento consolida o HI-WWA como elemento central de integração entre análise estatística e decisão operacional, transformando dados térmicos discretos em ações priorizadas de forma sistemática, transparente e alinhada às restrições reais da operação ferroviária.



Figura 7. Fluxo metodológico pelo critério HI-WWA.

6. CONCLUSÃO

Este trabalho apresentou um framework decisório para priorização de manutenção de rolamentos ferroviários, fundamentado na integração de dados térmicos *wayside*, caracterização estatística multivariada e formalização matemática do processo de decisão. A abordagem foi desenvolvida a partir de dados reais de *Hot Box Detectors* (HBDs) da Estrada de Ferro Carajás, considerando as restrições operacionais e a natureza discreta das medições em ambientes *heavy haul*.

A caracterização multivariada evidenciou que o comportamento térmico dos rolamentos pode ser representado de forma consistente em um espaço de baixa dimensionalidade, organizado principalmente em duas dimensões latentes associadas à severidade térmica e à persistência dos eventos. A aplicação da Análise de Componentes Principais (PCA), utilizada exclusivamente como ferramenta de caracterização e validação das features, forneceu suporte estatístico à seleção das variáveis e à adoção de uma abordagem multivariada.

Com base nessa estrutura, foi formulado o *Health Index* Interpolado com Média Ponderada e Pior Caso (HI-WWA) como métrica sintética de apoio à decisão, permitindo consolidar múltiplas evidências térmicas em um indicador único, interpretável e aderente à priorização operacional. A normalização das variáveis, a definição dos pesos e a interpolação entre comportamento médio e severidade extrema asseguram monotonicidade, robustez estatística e coerência física do índice, sem atribuir caráter prognóstico ao modelo.

A política decisória associada ao HI-WWA foi estruturada por meio de limiares de severidade τ_k fundamentados na distribuição empírica do índice, permitindo converter o monitoramento contínuo em uma classificação por regiões de risco operacional. Os estudos de caso e simulações conceituais demonstraram coerência entre variáveis térmicas, valor do índice e decisões adotadas, incluindo a identificação de condições críticas e de curto prazo não capturadas por metodologias escalares anteriores.

A aplicação prática do framework resultou em ganhos quantitativos relevantes, com aumento da cobertura de ativos monitorados, maior sensibilidade à identificação de condições de risco elevado e introdução de granularidade decisória inexistente na abordagem anterior.

Do ponto de vista quantitativo, o modelo permitiu classificar 205 rolamentos com algum nível de severidade, identificando casos críticos (C0) e de curto prazo (C1) inexistentes

na abordagem anterior. Aproximadamente 80% dos eventos históricos foram associados a alguma faixa de severidade, sendo cerca de 40% enquadrados como risco elevado (classes C0 e C1), evidenciando aumento significativo da sensibilidade do critério proposto.

A integração do modelo a um ambiente de *Business Intelligence* viabilizou sua operacionalização de forma transparente, com rastreabilidade completa das decisões e suporte efetivo à gestão da manutenção.

Por fim, destaca-se que o *framework* proposto não substitui abordagens prognósticas nem sistemas complementares de monitoramento. Sua principal contribuição reside na estruturação objetiva da priorização operacional, baseada em evidências térmicas observadas, respeitando as limitações impostas pela infraestrutura *wayside*. Extensões futuras podem explorar a integração do HI-WWA com outras modalidades de monitoramento e sua evolução para modelos prognósticos mais avançados.

7. REFERÊNCIAS

- Binder, M., Mezhuyev, V. and Tschandl, M., 2023. "Predictive maintenance for the railway domain: a systematic literature review". IEEE Xplore / ResearchGate, 1–20
- Bosomworth, C., Spiryagin, M., Alahakoon, S., Cole, C., Sneath, B. and Makin, B., 2022. "Rail temperature variation under heavy haul operations". Railway Engineering Science, Vol. 30, pp. 148–161.
- Dumoulin, J., Merainani, B. and Toullier, T., 2024. "Study of hot box detection on moving targets using wayside thermal infrared cameras and image processing methods". In Communications in a Conference (Inria HAL), pp. 1–8.
- EN 15437-1+A1, 2023. Railway applications – Axlebox condition monitoring – Part 1: Trackside equipment. European Standard.
- FRA – Federal Railroad Administration, 2023. "Safety Advisory 2023-01; Evaluation of Policies and Procedures Related to the Use and Maintenance of Hot Bearing Wayside Detectors". Federal Register, 1–6.
- Foltz, H., Tarawneh, C., Amaro, M., Thomas, S. and Avila, D., 2023. "Thermoelectric energy harvesting for wireless onboard rail condition monitoring". International Journal of Rail Transportation, 1–15.
- Goebel, K., 2008. "Prognostics in battery health management / prognostics in engineering systems". IEEE (magazine/conference).
- IEEE, 2017. IEEE Std. 1856-2017 – Standard Framework for Prognostics and Health Management of Electronic Systems. IEEE Standards Association.
- ISO, 2018. ISO 17359:2018 – Condition Monitoring and Diagnostics of Machines – General Guidelines. International Organization for Standardization.
- Jardine, A.K.S., Lin, D. and Banjevic, D., 2006. "A review on machinery diagnostics and prognostics implementing condition-based maintenance". Mechanical Systems and Signal Processing, Vol. 20, pp. 1483–1510.
- K. Liu, N. Z. Gebraeel and J. Shi, "A Data-Level Fusion Model for Developing Composite Health Indices for Degradation Modeling and Prognostic Analysis," in IEEE Transactions on Automation Science and Engineering, vol. 10, no. 3, pp. 652-664, July 2013, doi: 10.1109/TASE.2013.2250282.

- Lee, J., Kao, H.A. and Yang, S., 2014. "Service Innovation and Smart Analytics for Industry 4.0 and Big Data Environment". *Procedia CIRP*, Vol. 16, pp. 3–8.
- Liu, D., Liu, K., Xu, X., Cai, Y. and Wang, Q., 2024. "Research and application on PHM technology for high-speed train traction systems". In *Proceedings of EITRT 2023, Lecture Notes in Electrical Engineering*, Springer, pp. 316–321.
- Lopes, L.R. and Arruda, G.B., 2019. "Implantação de manutenção preditiva para aumento de confiabilidade de equipamentos HotBox/HotWheel na EFC". In *Anais do Congresso ABRISCO*, pp. 1–14.
- Lopes, L.R., 2024. "Predictive maintenance strategy for railway wagon bearings through temperature history". Poster presented at the South Africa Heavy Haul Association (SAHHA) Conference, South Africa.
- MxV Rail and University of Illinois at Urbana-Champaign, 2023. "Spacing study of Hot Bearing Detectors (HBD)". *Technology Digest TD17-034*, 1–6.
- Vogl, G.W., Weiss, B.A. and Donmez, M.A., 2014. "Standards related to prognostics and health management (PHM) for manufacturing". NISTIR 8012, National Institute of Standards and Technology, 45 p. doi:10.6028/NIST.IR.8012.
- Tarawneh, C., Aranda, J., Hernandez, V., Crown, S. and Montalvo, J., 2020. "An investigation into wayside hot-box detector efficacy and optimization". *International Journal of Rail Transportation*, Vol. 8, No. 3, pp. 264–284. .
- Wang, B., Liu, Y., Zhang, B. and Huai, W., 2022. "Analysis of the temperature characteristics of high-speed train bearings based on a dynamics model and thermal network method". *Chinese Journal of Mechanical Engineering*, Vol. 35, Article 104, pp. 1–14.
- Yan, G., Chen, J., Bai, Y., Yu, C. and Yu, C., 2022. "A survey on fault diagnosis approaches for rolling bearings of railway vehicles". *Processes*, Vol. 10, No. 4, Article 724, pp. 1–28.
- Zhang, X., Ma, Z., Zhao, D., Yuan, W. and Dai, X., 2026. "Prediction of high-speed train bearing temperature based on a hybrid physics-informed and data-driven model". *Measurement Science and Technology*, Vol. 37, 026204, pp. 1–17.

DECISION-MAKING FRAMEWORK FOR RAILWAY BEARING MAINTENANCE PRIORITIZATION BASED ON HEALTH INDEX AND WAYSIDE MONITORING

ABSTRACT

Operational safety in heavy-haul railways strongly depends on the reliability of railway bearings, which operate under high axle loads and severe thermal cycles. In this context, wayside monitoring systems such as Hot Box Detectors (HBDs) play a central role in detecting abnormal bearing heating. Traditionally, maintenance actions have been driven by reactive alarm thresholds or, at more advanced stages, by simplified predictive rules. Although effective for already manifested failures, these approaches present limitations when supporting graded prioritization of operational risk. This work proposes a decision-making framework for railway bearing maintenance prioritization, grounded in Health Index concepts and wayside monitoring data, with emphasis on the evolution of operational criteria and the mathematical structuring of the decision process. Representative thermal variables describing bearing behavior are defined and analyzed through Principal Component Analysis (PCA), which is employed exclusively as a tool for feature characterization and validation. The analysis reveals that the decision problem can be organized into two latent dimensions associated with thermal severity and event persistence. The Health Index is introduced as a synthetic, non-prognostic metric to support maintenance decision-making and to structure an operational policy based on clearly interpretable severity ranges. Case studies illustrate the application of the proposed framework and demonstrate gains in terms of consistency, traceability, and alignment with Prognostics and Health Management (PHM) practices. The results highlight the potential of the approach to support more robust and transparent maintenance decisions in heavy-haul railway environments.

Keywords: *Railway bearings; Maintenance prioritization; Health Index; Wayside Monitoring; Hot Box Detectors; Decision-Making Framework*