

Análise de falhas em motores diesel com aplicação de inteligência artificial e *business intelligence* para otimização da manutenção

Failure analysis in diesel engines using artificial intelligence and *business intelligence* for maintenance optimization

Arthur Gomes Rocha¹
Carlos Henrique Barbosa de Araújo²
Diego César Alves da Silva³
Diogo Henrique Dias Saraiva⁴
Lucas Alves de Oliveira⁵
Lucas Henrique de Abreu Martins⁶
Lucas Salles Souza⁷
Samuel Damacena⁸
Silvana Diniz⁹

RESUMO

Analisa-se a gestão de falhas em motores diesel de alta potência, com foco no motor Cummins QSK60, mediante a integração de técnicas de manutenção preditiva, metodologias de análise de falhas e ferramentas de Inteligência Artificial. O estudo tem como objetivo propor diretrizes práticas para a otimização da manutenção industrial, ampliar a confiabilidade operacional e reduzir custos decorrentes de paradas não programadas. Adota-se pesquisa bibliográfica sistematizada como procedimento metodológico, com corpus composto por 18 obras selecionadas em bases indexadas, complementado pela análise descritiva de 1.500 registros operacionais do motor QSK60 processados na plataforma Microsoft Power BI. Identificam-se os principais modos de falha, superaquecimento, lubrificação insuficiente, falhas em injetores e desgaste mecânico e demonstra-se que a aplicação integrada de RCM, FMEA e RCA, associada a modelos de aprendizado de máquina como SVR e GPR, potencializa o diagnóstico e a prevenção de falhas. Os resultados evidenciam predominância de custos corretivos e indicam que ferramentas de Business Intelligence viabilizam a identificação precoce de tendências de

¹ arthur.rochabh@hotmail.com

² carlos.7564.barbosa@gmail.com

³ diegocsilva04@icloud.com

⁴ diiogodias9@gmail.com

⁵ alvelucas@gmail.com

⁶ lucashenriquedeabreumartins@gmail.com

⁷ lucassallessouza@gmail.com

⁸ damacenasamuel7@gmail.com

⁹ Orientadora

degradação, constituindo caminho promissor para a evolução da manutenção industrial em direção aos conceitos da Indústria 4.0.

Palavras-chave: Motor diesel. Manutenção preditiva. Análise de falhas. Inteligência Artificial. Business Intelligence. Palavras-chave: Normalizar. Artigo científico. Referências. Publicação.

ABSTRACT

This study analyzes failure management in high-power diesel engines, focusing on the Cummins QSK60 engine through the integration of predictive maintenance techniques, failure analysis methodologies, and Artificial Intelligence tools. The study aims to propose practical guidelines for optimizing industrial maintenance, enhancing operational reliability, and reducing costs associated with unplanned downtime. A systematized bibliographic research approach was adopted as the methodological procedure, with a corpus comprising 18 works selected from indexed databases, complemented by the descriptive analysis of 1,500 operational records from the QSK60 engine processed using the Microsoft Power BI platform. The main failure modes identified include overheating, insufficient lubrication, injector failures, and mechanical wear. The findings demonstrate that the integrated application of Reliability-Centered Maintenance (RCM), Failure Mode and Effects Analysis (FMEA), and Root Cause Analysis (RCA), combined with machine learning models such as Support Vector Regression (SVR) and Gaussian Process Regression (GPR), enhances failure diagnosis and prevention. The results reveal a predominance of corrective maintenance costs and indicate that Business Intelligence tools enable the early identification of degradation trends, representing a promising pathway for the advancement of industrial maintenance toward Industry 4.0 concepts.

Keywords: Diesel engine; Predictive maintenance; Failure analysis; Artificial Intelligence; Business Intelligence.

1. INTRODUÇÃO

Os motores de combustão interna do ciclo Diesel desempenham papel fundamental em aplicações industriais, geração de energia e equipamentos de grande porte, sendo amplamente utilizados devido à sua elevada eficiência térmica, robustez e capacidade de operação em condições severas. Nesse contexto, motores de alta potência, como o Cummins QSK60, são empregados em sistemas críticos, nos quais a confiabilidade operacional é um fator determinante para a continuidade dos processos produtivos. Entretanto, devido às condições de operação envolvendo altas pressões, temperaturas elevadas, esforços mecânicos intensos e regimes variáveis de carga, esses equipamentos estão sujeitos a diferentes modos de falha, que podem comprometer seu desempenho, reduzir sua vida útil e gerar impactos significativos nos custos operacionais (HEYWOOD, 1988).

A complexidade crescente dos motores diesel modernos, associada à necessidade de aumento da disponibilidade operacional e redução de custos, torna a análise de falhas e o monitoramento das condições operacionais elementos essenciais para a gestão da manutenção. Métodos tradicionais, baseados em manutenção corretiva ou preventiva por tempo, apresentam limitações quanto à antecipação de falhas e à otimização dos intervalos de intervenção, resultando frequentemente em paradas não programadas e aumento dos custos operacionais. Nesse cenário, abordagens baseadas em manutenção preditiva, apoiadas por técnicas como análise de vibração, análise de óleo lubrificante e monitoramento de parâmetros de desempenho, vêm sendo amplamente utilizadas para diagnóstico e prognóstico de falhas em motores diesel (WANG, 2018).

Além disso, o avanço das tecnologias de aquisição e processamento de dados possibilitou a incorporação de ferramentas de Inteligência Artificial no diagnóstico de sistemas

mecânicos, permitindo a análise de grandes volumes de dados operacionais e a identificação de padrões associados a falhas. Modelos baseados em *machine learning*, como *Support Vector Regression (SVR)* e *Gaussian Process Regression (GPR)*, têm sido aplicados na estimativa da severidade de falhas e na previsão do comportamento de componentes ao longo do tempo, contribuindo para o aumento da confiabilidade e redução de custos operacionais (VIANA, 2025).

Apesar dos avanços nas técnicas de diagnóstico e manutenção, ainda existem lacunas na integração entre análise de falhas, previsão de comportamento e tomada de decisão aplicada à gestão da manutenção de motores diesel de grande porte. Dessa forma, estabelece-se como problema de pesquisa a seguinte questão: como a aplicação de técnicas de análise de falhas associadas à Inteligência Artificial pode contribuir para a otimização da manutenção, aumento da vida útil e redução de custos operacionais em motores diesel de alta potência?

Este estudo justifica-se pela necessidade crescente de maximizar a disponibilidade e confiabilidade de equipamentos industriais, reduzindo paradas não programadas e custos associados à manutenção corretiva. A aplicação de técnicas avançadas de diagnóstico e análise de dados em motores diesel representa uma oportunidade significativa de melhoria na gestão de ativos, permitindo maior eficiência operacional e suporte à tomada de decisão baseada em dados. Além disso, a integração entre engenharia mecânica e ferramentas de análise inteligente configura-se como uma tendência relevante no contexto industrial, contribuindo para o desenvolvimento de soluções mais eficientes e sustentáveis.

O objetivo geral deste trabalho é analisar falhas em motores diesel de alta potência, com foco no motor Cummins QSK60, utilizando técnicas de manutenção preditiva e Inteligência Artificial, visando à otimização da manutenção, aumento da vida útil dos componentes e redução dos custos operacionais. Como objetivos específicos, destacam-se: (a) identificar os principais modos de falha em motores diesel industriais; (b) analisar os parâmetros operacionais relevantes para o diagnóstico de falhas; (c) avaliar técnicas de monitoramento baseadas em vibração, análise de óleo e variáveis termodinâmicas; (d) aplicar modelos de Inteligência Artificial para predição de falhas e análise de severidade; e (e) propor diretrizes para melhoria da confiabilidade e eficiência na gestão da manutenção.

2. REFERENCIAL TEÓRICO

2.1 Motores Diesel de Alta Potência: Fundamentos e Contexto Industrial

Os motores de combustão interna do ciclo Diesel constituem uma das tecnologias de maior relevância para a produção de energia mecânica em aplicações industriais críticas. Seu princípio de funcionamento, descrito de forma seminal por Heywood (1988) na obra *Internal Combustion Engine Fundamentals*, baseia-se na compressão adiabática do ar até temperaturas suficientemente elevadas para provocar a auto-ignição do combustível injetado diretamente na câmara de combustão. Essa característica confere ao motor diesel eficiência térmica superior à dos motores de ignição por centelha, além de maior torque em baixas rotações e robustez estrutural, atributos que explicam sua ampla adoção em ambientes de alta demanda operacional.

Heywood (1988) destaca que as condições operacionais — altas pressões de combustão, temperaturas extremas dos gases, esforços mecânicos intensos e ciclos variáveis de carga — submetem os componentes a mecanismos de degradação complexos e interdependentes, como desgaste abrasivo, fadiga térmica e corrosão, tornando a gestão da manutenção uma variável crítica para a preservação do desempenho e da vida útil do equipamento. Wang et al. (2018) corroboraram esse entendimento ao sistematizar os principais modos de falha em motores diesel e demonstrar que a ausência de monitoramento adequado é o principal fator que eleva a frequência de paradas não programadas em operações industriais.

No contexto contemporâneo, Kardec e Nascif (2013) ressaltam que a indisponibilidade de equipamentos críticos pode gerar impactos financeiros que superam em múltiplas vezes o

custo de qualquer intervenção de manutenção planejada. Esse argumento é especialmente pertinente para motores de grande porte como o Cummins QSK60, amplamente empregados nos setores de mineração, petróleo e gás e geração de energia.

2.1.1 O Motor Cummins QSK60: Especificações Técnicas e Relevância Industrial

O Cummins QSK60 é um motor diesel de ciclo de quatro tempos, configuração V16, com deslocamento total de 60,2 litros. Conforme especificações publicadas pela Cummins Inc. (2016), o motor opera em faixas de potência de 1.668 kW a 2.238 kW (até 3.000 hp) e é equipado com o sistema de injeção Modular Common Rail (MCRS), que mantém alta pressão de injeção independentemente da rotação, assegurando desempenho consistente em toda a faixa operacional. O sistema eletrônico Quantum System embarcado realiza monitoramento contínuo de parâmetros cilindro a cilindro, habilitando funções avançadas de diagnóstico e prognóstico de falhas. A Tabela 1 apresenta as principais especificações técnicas do motor.

Tabela 1 – Especificações técnicas do motor Cummins QSK60

Parâmetro	Especificação
Configuração	V16 – 4 tempos
Deslocamento total	60,2 litros (3.672 in³)
Potência máxima	1.668 kW a 2.238 kW (até 3.000 hp)
Rotação nominal	1.800 rpm a 1.900 rpm
Sistema de injeção	Modular Common Rail (MCRS)
Turboalimentação	Turbocarga com aftercooler de baixa temperatura
Sistema eletrônico	Quantum System ECM
Lubrificação	Carter de alta capacidade (até 378 L); pré-lubrificação automática
Peso aproximado	7.990 kg (industrial) / 8.754 kg (naval)
Vida útil projetada	Até 30.000 horas sob manutenção adequada
Padrão de emissões	U.S. EPA Tier 2/4 – IMO Tier 2/3
Principais aplicações	Mineração, geração de energia, petróleo e gás, propulsão naval

Fonte: Adaptado de Cummins Inc. (2015, 2016).

O QSK60 encontra aplicação em escavadeiras hidráulicas de grande porte — como a Komatsu PC4000 e a Hitachi EX3600 — e em caminhões fora de estrada de mineração, como

os modelos BelAZ 75305 a 75310 e o Komatsu 830E-5. Nessas aplicações, o motor opera sob regimes severos de carga contínua, com exposição a contaminantes ambientais e variações térmicas extremas. Wang et al. (2018) observam que motores desse porte apresentam interdependências funcionais entre subsistemas que tornam o diagnóstico de falhas um problema multidimensional, evidenciando a necessidade de abordagens integradas de monitoramento e análise.

2.2 Evolução das Estratégias de Manutenção Industrial: Do Corretivo ao Preditivo

A compreensão das estratégias de manutenção exige uma perspectiva histórica que permita identificar os paradigmas que moldaram as práticas atuais. Moubray (2000), na obra de referência *RCM II — Manutenção Centrada na Confiabilidade*, sistematiza essa evolução em quatro gerações, cada uma marcada por uma concepção distinta sobre a relação entre falhas e tempo de operação dos equipamentos. Essa classificação, amplamente adotada por Kardec e Nascif (2013) e Siqueira (2009), constitui o principal marco interpretativo para o estudo das práticas de manutenção industrial. O Quadro 1 sintetiza essa evolução, relacionando cada geração às suas filosofias, técnicas e principais referências bibliográficas.

Quadro 1 – Evolução das gerações da manutenção industrial

Geração	Período	Filosofia Predominante	Técnicas Principais	Autores de Referência
1 ^a	Até 1945	Manutenção corretiva não planejada ("conserta quando quebra")	Reparo após falha; sem sistematização	Moubray (2000); Kardec e Nascif (2013)
2 ^a	1950–1970	Preventiva por tempo; "Curva da banheira" como modelo de falha	Revisões periódicas; Substituição programada por tempo	Nowlan e Heap (1978); Smith (1993)
3 ^a	1970–1990	Confiabilidade e monitoramento; RCM como paradigma central	RCM; FMEA; RCA; Manutenção preditiva baseada em condição	Nowlan e Heap (1978); Moubray (2000); Siqueira (2009)
4 ^a	1990–Atual	Gestão estratégica de ativos; Indústria 4.0 e manutenção inteligente	IA; IoT; Machine Learning; Gêmeos digitais; monitoramento contínuo	Kardec e Nascif (2013); Viana et al. (2023, 2025)

Fonte: Elaborado pelos autores com base em Nowlan e Heap (1978), Moubray (2000), Kardec e Nascif (2013) e Viana et al. (2023, 2025).

A primeira geração, predominante até a Segunda Guerra Mundial, caracterizava-se pela manutenção exclusivamente corretiva, com reparos realizados apenas após a manifestação das

falhas. A segunda geração introduziu a manutenção preventiva baseada em tempo, fundamentada na ideia de que a probabilidade de falha aumentava com a idade dos componentes — o chamado "modelo da curva da banheira". Kardec e Nascif (2013) ressaltam, contudo, que estudos posteriores demonstraram que apenas 11% dos componentes de sistemas complexos exibem esse padrão, revelando uma limitação estrutural dessa abordagem.

A terceira geração representou uma inflexão paradigmática com os trabalhos pioneiros de Nowlan e Heap (1978) que, a partir da análise de 12 anos de dados operacionais de frotas comerciais, demonstraram empiricamente que a manutenção preventiva por tempo não apenas não prevenia a maioria das falhas, como também introduzia novos riscos ao submeter componentes em bom estado a intervenções desnecessárias. Esse achado originou o conceito de Manutenção Centrada na Confiabilidade (RCM), aprimorado e difundido para o setor industrial por Moubray (2000). A quarta geração, impulsionada pela Indústria 4.0, integra sensores inteligentes, IoT e algoritmos de aprendizado de máquina, com Viana et al. (2023, 2025) e Bai et al. (2022) como marcos recentes.

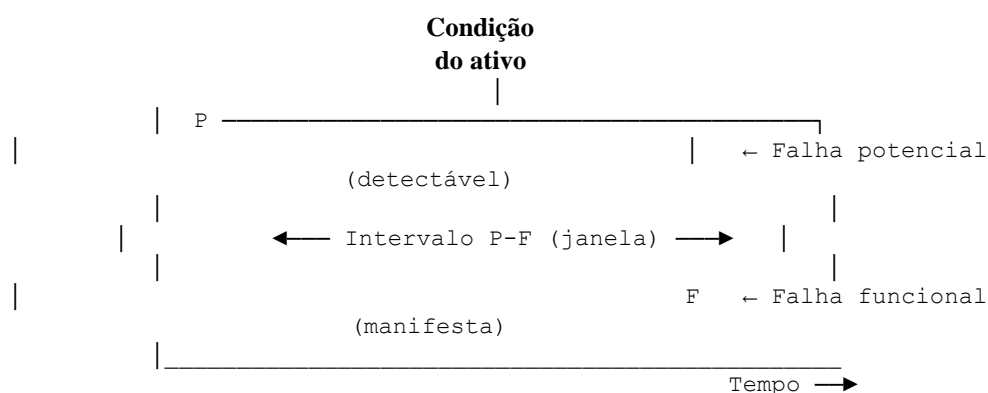
2.2.1 Manutenção Corretiva e Preventiva: Limites e Contextos de Aplicação

A manutenção corretiva não planejada é associada aos maiores custos de ciclo de vida dos equipamentos. Kardec e Nascif (2013) argumentam que estudos realizados em indústrias de processo indicam que o custo de uma parada não programada pode superar em até cinco vezes o custo de uma intervenção preventiva equivalente. A manutenção preventiva baseada em tempo avança ao introduzir a previsibilidade nas intervenções, mas Smith (1993) demonstrou que a substituição periódica de componentes pode paradoxalmente aumentar o risco de falhas, pois o processo de remontagem introduz oportunidades para erros humanos e perturba estados de equilíbrio em componentes desgastados — fenômeno que Moubray (2000) denomina "mortalidade infantil induzida".

2.2.2 Manutenção Preditiva e Baseada em Condição: Fundamentos e Técnicas

A manutenção preditiva fundamenta-se no princípio de que a maioria das falhas é precedida por sinais detectáveis de degradação. Moubray (2000) introduziu o conceito de "intervalo P-F" para descrever o período entre o ponto onde uma falha potencial pode ser identificada (P) e o ponto onde ela se torna funcional (F). A Figura 1 ilustra esse intervalo e sua importância para o planejamento das intervenções de manutenção.

Figura 1 – Representação esquemática do intervalo P-F na manutenção preditiva



Fonte: Adaptado de Moubray (2000).

Wang et al. (2018) sistematizaram as principais técnicas de monitoramento de condição aplicadas a motores diesel em quatro categorias. Os autores concluem que a combinação dessas técnicas, denominada fusão de sensores, produz diagnósticos mais robustos do que qualquer

método individualmente. O Quadro 2 apresenta essas técnicas, os parâmetros monitorados, as falhas detectáveis e as respectivas referências bibliográficas.

Quadro 2 – Técnicas de manutenção aplicadas a motores diesel de alta potência

Técnica Preditiva	Parâmetro Monitorado	Falhas Detectáveis	Referência Bibliográfica
Análise de Vibração	Frequência, amplitude e fase de oscilação	Desbalanceamento, desalinhamento, desgaste de rolamentos, folgas mecânicas	Guterres (2025); Teixeira (2025); ABNT ISO/IEC 10816-3 (2009)
Análise de Óleo Lubrificante	Viscosidade, contaminantes e partículas de desgaste	Desgaste de cilindros e bronzinas, contaminação por água ou combustível	Wang et al. (2018)
Monitoramento de Desempenho	Pressão de combustão, temperatura dos gases, consumo de combustível	Perda de compressão, falhas no sistema de injeção	Viana et al. (2023); Wang et al. (2018)
Velocidade Instantânea do Eixo	Variação de rotação durante o ciclo de combustão	Irregularidades na combustão, falhas em válvulas e injetores	Wang et al. (2018)
Termografia Infravermelha	Distribuição de temperatura na superfície do motor	Pontos de superaquecimento, falhas no sistema de arrefecimento	Kardec e Nascif (2013)

Fonte: Elaborado pelos autores com base em Wang et al. (2018), Guterres (2025), Teixeira (2025) e Kardec e Nascif (2013).

Guterres (2025), em revisão bibliográfica sistemática, identificou que a análise de vibrações oferece a maior abrangência diagnóstica entre as ferramentas preditivas, sendo capaz de identificar prematuramente defeitos de desbalanceamento, desalinhamento, folga mecânica e desgaste de rolamentos. Teixeira (2025) acrescenta que os avanços em processamento de sinais digitais — especialmente a Transformada de Fourier e técnicas de análise tempofrequência — ampliaram significativamente a capacidade de interpretação dos dados vibracionais, com a norma ABNT ISO/IEC 10816-3:2009 estabelecendo os critérios de referência para avaliação da severidade de vibração em máquinas industriais com potência acima de 15 kW.

Wang et al. (2018) demonstram que a análise de óleo lubrificante complementa o diagnóstico vibracional ao fornecer informações diretas sobre o estado interno dos componentes sem necessidade de desmontagem. A análise espectroscópica e ferrográfica permite identificar a natureza e origem das partículas de desgaste, distinguindo desgaste abrasivo de adesivo,

conferindo especificidade diagnóstica superior à da análise vibracional isolada. 2.3 Metodologias de Análise e Gestão de Falhas

As metodologias de análise de falhas — RCM, FMEA e RCA — representam o núcleo conceitual da engenharia de manutenção moderna. Embora distintas em seus objetivos e momentos de aplicação, essas ferramentas são complementares e, quando integradas, formam um arcabouço metodológico robusto para a gestão proativa de falhas em equipamentos críticos.

2.3.1 Manutenção Centrada na Confiabilidade (RCM): Origens e Desenvolvimento

O conceito de RCM originou-se na aviação civil norte-americana nas décadas de 1960 e 1970. O marco fundador foi o relatório de Nowlan e Heap (1978), elaborado por encomenda do Departamento de Defesa dos Estados Unidos após 12 anos de análise de dados operacionais de frotas comerciais. Os autores demonstraram que apenas 11% dos componentes de sistemas aeronáuticos complexos apresentavam o padrão de falha relacionado à idade, enquanto 89% exibiam padrões aleatórios ou constantes, para os quais a substituição periódica por tempo era ineficaz ou contraproducente.

Moubray (2000) aprimorou e estruturou o processo em torno de sete perguntas fundamentais relativas a funções, falhas funcionais, modos de falha, efeitos, consequências, tarefas proativas e ações padrão. Segundo o autor, a implementação correta do RCM pode resultar em redução de 40% a 70% no volume de tarefas de manutenção rotineiras, com ganhos simultâneos em disponibilidade, confiabilidade e segurança operacional. No Brasil, Kardec e Nascif (2013) e Siqueira (2009) difundiram e adaptaram a metodologia ao contexto produtivo nacional, integrando-a ao Planejamento e Controle da Manutenção (PCM) e aos sistemas informatizados de gestão (CMMS).

2.3.2 Análise de Modos e Efeitos de Falha (FMEA): Fundamentos e Evolução

Palady (2007) define o FMEA como metodologia que opera sobre três dimensões para cada modo de falha: Severidade (S) — gravidade do efeito; Ocorrência (O) — probabilidade de manifestação; e Detecção (D) — capacidade dos controles em identificar a falha. Na versão clássica, essas notas eram combinadas no índice RPN ($S \times O \times D$). Contudo, Kardec e Nascif (2013) apontam que o RPN apresenta limitações reconhecidas: combinações distintas de notas podem produzir o mesmo índice com perfis de risco muito diferentes. Essa limitação motivou a revisão do manual FMEA pela AIAG e pela VDA em 2019, que substituiu o RPN pela Prioridade de Ação (PA), com peso maior à severidade como critério preponderante, convergindo com os princípios do RCM, conforme antecipara Moubray (2000).

2.3.3 Análise de Causa Raiz (RCA): Ferramentas e Aplicação

Segundo Moubray (2000), intervenções que não endereçam as causas raiz resultam invariavelmente na recorrência das falhas em intervalos cada vez menores. Kardec e Nascif (2013) complementam essa perspectiva ao afirmar que a RCA é o principal mecanismo de aprendizado organizacional disponível à função manutenção, transformando cada evento de falha em conhecimento aplicável à prevenção de ocorrências futuras. As ferramentas mais utilizadas incluem o Diagrama de Ishikawa, a técnica dos "5 Porquês" e a Análise de Árvore de Falhas (FTA). Siqueira (2009) ressalta que a combinação de múltiplas ferramentas produz resultados mais robustos do que o uso exclusivo de qualquer uma delas.

O Quadro 3 apresenta um comparativo sistematizado entre as três metodologias de análise de falhas, evidenciando suas distinções e complementaridades quanto ao objetivo, ao momento de aplicação, às ferramentas utilizadas, aos indicadores resultantes e às relações entre elas.

Quadro 3 – Comparativo entre as metodologias análise de falhas: RCM, FMEA e RCA

Critério de Análise	RCM	FMEA	RCA
Objetivo principal	Definir a estratégia de manutenção mais adequada para cada ativo e função	Identificar e priorizar modos de falha potenciais antes que ocorram	Investigar a causa fundamental de uma falha já ocorrida
Momento de aplicação	Planejamento proativo (antes da falha)	Projeto e planejamento (antes da falha)	Pós-falha (investigação reativa)
Principal ferramenta	Perguntas estruturadas + diagrama de decisão RCM	Tabela FMEA com critérios de Severidade (S), Ocorrência (O) e Detecção (D); Prioridade de Ação (PA)	Diagrama de Ishikawa; 5 Porquês; Árvore de Falhas (FTA)
Indicador-chave resultante	Disponibilidade (A) e MTBF	Prioridade de Ação (PA) — substituiu o RPN pela revisão AIAG/VDA (2019)	Taxa de recorrência de falhas; custo evitado
Relação com as demais metodologias	Usa o FMEA internamente; define o escopo da RCA para falhas prioritárias	Componente do RCM; orienta a RCA para as falhas de maior risco	Alimenta o FMEA com novos modos de falha identificados em campo
Principais referências	Nowlan e Heap (1978); Moubray (2000); Siqueira (2009)	Palady (2007); AIAG; VDA (2019); Kardec e Nascif (2013)	Moubray (2000); Kardec e Nascif (2013); Siqueira (2009)

Fonte: Elaborado pelos autores com base em Nowlan e Heap (1978), Moubray (2000), Palady (2007), AIAG; VDA (2019), Siqueira (2009) e Kardec e Nascif (2013).

2.4 Indicadores de Desempenho na Gestão da Manutenção

A gestão baseada em dados requer o estabelecimento de indicadores de desempenho que permitam avaliar a efetividade das estratégias adotadas. Os indicadores mais consolidados são o Tempo Médio Entre Falhas (MTBF — Mean Time Between Failures) e o Tempo Médio Para Reparo (MTTR — Mean Time To Repair), definidos pela norma ABNT NBR 5462:1994. O MTBF expressa a confiabilidade intrínseca do equipamento; o MTTR quantifica a manutenibilidade do sistema. A disponibilidade operacional ($A = \text{MTBF} / (\text{MTBF} + \text{MTTR})$) é o indicador mais diretamente relevante para operações críticas como mineração e geração de energia, onde cada hora de parada não programada do QSK60 representa perdas econômicas expressivas.

Kardec e Nascif (2013) argumentam que a função manutenção, para ser reconhecida como estratégica, precisa demonstrar seu valor por métricas objetivas que conectem as atividades de manutenção aos resultados do negócio — disponibilidade operacional, custos por unidade produzida e índice de falhas por equipamento. Siqueira (2009) ressalta que o monitoramento contínuo desses indicadores, aliado à análise das causas raiz de cada evento de falha, constitui a base do ciclo de melhoria contínua na gestão da manutenção.

2.5 Inteligência Artificial Aplicada ao Diagnóstico de Falhas em Motores Diesel

Wang et al. (2018) identificaram o aprendizado de máquina como a principal fronteira de inovação no diagnóstico de motores diesel, complementando as técnicas de monitoramento de condição estabelecidas. Viana et al. (2023) foram pioneiros na aplicação sistemática de algoritmos de regressão baseados em IA ao diagnóstico de falhas em motores diesel industriais, desenvolvendo uma base de dados com 3.500 cenários de falha simulados por modelo termodinâmico acoplado a modelo de vibração torcional do eixo de manivelas. Aplicando Random Forest (RF) e Redes Neurais Multicamadas (MLP), demonstraram que os algoritmos eram capazes de estimar a severidade das falhas com alta precisão, superando métodos baseados em regras fixas.

Em trabalho subsequente, Viana et al. (2025) avançaram essa investigação ao propor regressão por máquinas de kernel — SVR e GPR — com o GPR atingindo RMSE de $0,015 \pm 0,001\%$, o melhor resultado reportado até então na literatura. Bai et al. (2022) propuseram abordagem híbrida SSAE+SVM com acurácia superior a 98% na classificação de falhas em ambiente de bancada. O Quadro 4 apresenta o comparativo desses estudos, evidenciando os modelos utilizados, as bases de dados, os resultados e as limitações apontadas pelos próprios autores.

Quadro 4 – Comparativo de modelos de inteligência artificial para diagnóstico de falhas em motores diesel

Modelo de IA	Estudo de Referência	Base de Dados Utilizada	Resultados Principais	Limitação Apontada
Random Forest (RF) e Rede Neural MLP	Viana et al. (2023)	3.500 cenários simulados (modelo termodinâmico + vibração torsional do eixo)	Alta precisão na estimativa de severidade; MLP levemente superior ao RF	Dados simulados; generalização para condições reais não validada
Support Vector Regression (SVR) e Gaussian Process Regression (GPR)	Viana et al. (2025)	3.500 cenários simulados (mesma base de 2023)	GPR: RMSE $0,015 \pm 0,001\%$ — melhor resultado reportado; superior ao SVR e modelos anteriores	Variabilidade ambiental e qualidade do combustível não contempladas no simulador
Modelo de IA	Estudo de Referência	Base de Dados Utilizada	Resultados Principais	Limitação Apontada

SSAE + SVM (Autoencoder Esparso + Máquinas de Vetores de Suporte)	Bai et al. (2022)	Sinais de vibração multisensor em bancada com falhas préprogramadas	Acurácia superior a 98% na classificação; SSAE eficaz na redução de dimensionalidade	Validado somente em ambiente controlado de laboratório
Regras + Redes Bayesianas/Redes Neurais BP	Wang et al. (2018)	Dados operacionais reais em diferentes rotações de motor	Identificação correta de falhas em múltiplas condições de operação	Limitado a falhas conhecidas; sem estimativa quantitativa de severidade

Fonte: Elaborado pelos autores com base em Wang et al. (2018), Viana et al. (2023, 2025) e Bai et al. (2022).

Apesar dos avanços evidenciados, a literatura aponta limitações relevantes. Viana et al. (2025) reconhecem que seus modelos foram treinados e validados com dados simulados, e que a variabilidade ambiental, a qualidade do combustível e o histórico de manutenção — variáveis não contempladas nos simuladores — podem afetar o desempenho preditivo em condições reais de operação. Wang et al. (2018) destacam que a qualidade e a representatividade dos dados de treinamento são o fator crítico para a confiabilidade dos modelos de IA, argumento que reforça a importância da integração entre sistemas de monitoramento em campo e plataformas de análise de dados para a implementação efetiva dessas tecnologias no contexto do motor Cummins QSK60.

2.6 Síntese do Referencial Teórico e Lacunas Identificadas

O percurso teórico desenvolvido neste referencial revela a progressão do conhecimento em manutenção industrial a partir de quatro eixos interconectados: (i) os fundamentos dos motores diesel de alta potência, com Heywood (1988) como referência seminal; (ii) a evolução das estratégias de manutenção, demonstrada pela leitura conjugada de Nowlan e Heap (1978), Moubray (2000) e Kardec e Nascif (2013); (iii) as metodologias de análise de falhas — RCM, FMEA e RCA — com Siqueira (2009) e Palady (2007) como referências fundamentais para o contexto brasileiro; e (iv) a Inteligência Artificial aplicada ao diagnóstico, com os trabalhos de Viana et al. (2023, 2025) e Bai et al. (2022) como marcos recentes.

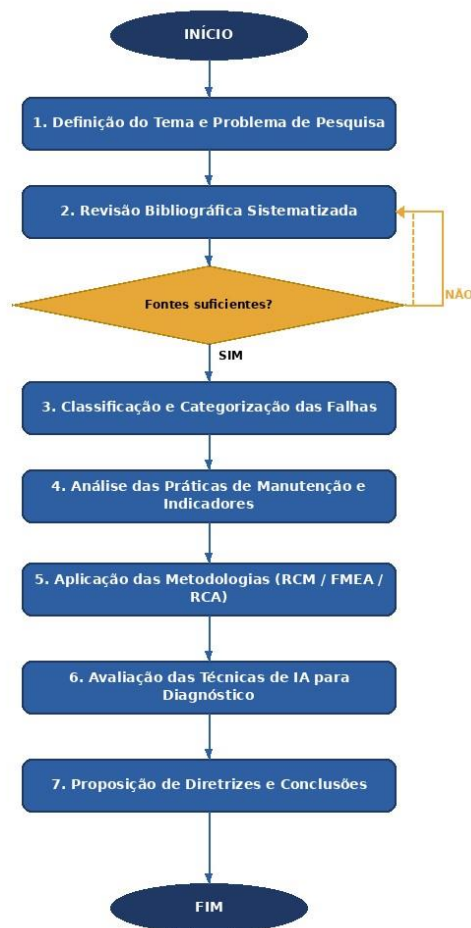
A análise desse conjunto de contribuições revela uma lacuna relevante: embora as técnicas de diagnóstico preditivo e os algoritmos de IA demonstrem desempenho promissor em ambientes controlados, sua integração com as metodologias de gestão de falhas (RCM e FMEA) e sua aplicação específica ao motor Cummins QSK60 em operações industriais nacionais carecem de investigação empírica estruturada. É nessa lacuna que o presente trabalho se insere, buscando contribuir com diretrizes práticas e fundamentadas para a melhoria da confiabilidade e da disponibilidade operacional desse equipamento.

3. METODOLOGIA

A metodologia de uma pesquisa científica compreende os procedimentos, técnicas e critérios que orientam a coleta, a análise e a interpretação dos dados, permitindo ao leitor compreender como o estudo foi conduzido e avaliar a confiabilidade de seus resultados (ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS, 2022).

A Figura 2 apresenta o fluxograma geral do percurso metodológico, sintetizando as etapas sequenciais da pesquisa desde a definição do tema até a proposição de diretrizes práticas. O losango de decisão indica o ponto de avaliação da suficiência do corpus bibliográfico: caso as fontes não sejam suficientes, o processo retorna à etapa de revisão para ampliar a cobertura temática.

Figura 2 – Fluxograma do percurso metodológico da pesquisa



Fonte: Elaborado pelos autores (2026).

3.1 Classificação e Enquadramento da Pesquisa

O Quadro 5 apresenta o enquadramento metodológico do trabalho. Quanto à natureza, a pesquisa é **aplicada**, pois visa gerar conhecimentos para solução de problemas práticos (PRODANOV; FREITAS, 2013). Quanto ao tipo, é **exploratória-descritiva**: explora a lacuna de integração entre RCM, FMEA, RCA e IA aplicados ao Cummins QSK60; e descreve o estado atual das práticas de manutenção no campo. A abordagem é **qualitativa** e o procedimento técnico adotado é a **pesquisa bibliográfica sistematizada** — elaborada a partir de material publicado com critérios estruturados de busca e seleção (GIL, 2010).

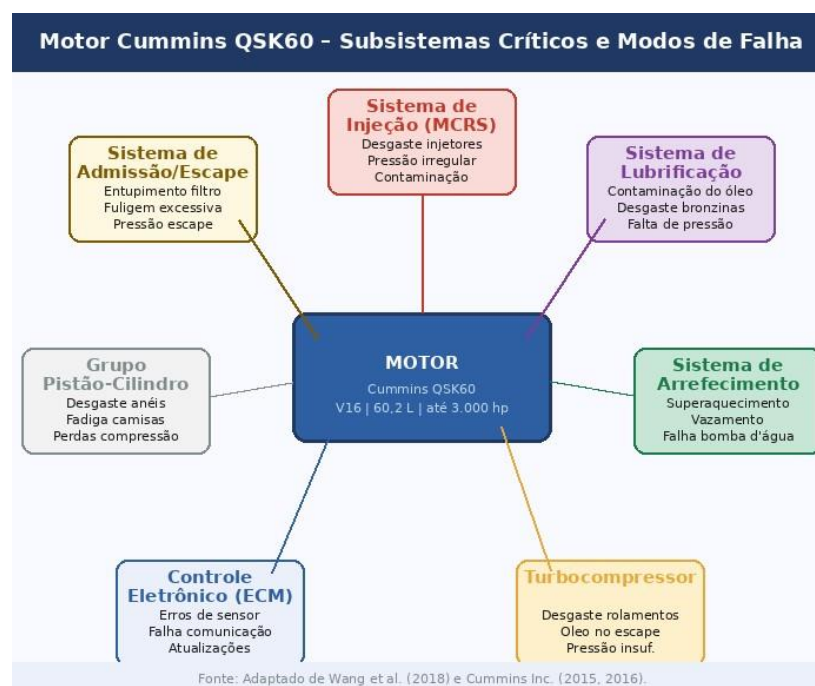
Quadro 5 – Enquadramento metodológico da pesquisa

Natureza	Tipo	Abordagem	Procedimento Técnico
Aplicada	Exploratória Descritiva	Qualitativa	Pesquisa bibliográfica sistematizada
Gerar conhecimento prático para melhoria da gestão da manutenção	Descreve práticas e explora lacunas de integração metodológica	Análise conceitual e interpretativa das metodologias e evidências	Revisão de literatura com critérios estruturados de busca e seleção

Fonte: Elaborado pelos autores com base em Gil (2010) e Prodanov e Freitas (2013).

A Figura 3 contextualiza o objeto de estudo ao apresentar os subsistemas críticos do motor Cummins QSK60 e seus principais modos de falha, delimitando o escopo de análise das etapas metodológicas subsequentes.

Figura 3 – Subsistemas críticos e principais modos de falha do motor Cummins QSK60



Fonte: Adaptado de Wang et al. (2018) e Cummins Inc. (2015, 2016).

3.2 Estratégia de Revisão Bibliográfica e Corpus

A revisão bibliográfica constitui o procedimento central deste trabalho, estruturado com protocolos explícitos de busca, critérios de inclusão e exclusão e procedimentos de análise que tornam o processo rastreável e replicável (BOTELHO; CUNHA; MACEDO, 2011).

A busca foi conduzida nas bases Scopus, Web of Science e Google Scholar, além do portal de periódicos da CAPES e documentos técnicos da ABNT/ISO, utilizando os termos "diesel engine fault diagnosis", "reliability-centered maintenance", "FMEA diesel engine",

"machine learning diesel" e "Cummins QSK60". O Quadro 6 detalha os critérios aplicados.

Quadro 6 – Critérios de inclusão e exclusão do corpus bibliográfico

Critério	Descrição	Exemplos
Inclusão	Artigos, livros e normas com aderência ao tema: motores diesel, manutenção industrial, diagnóstico de falhas, IA	Heywood (1988); Moubray (2000); Wang et al. (2018); Viana et al. (2023, 2025)
Exclusão	Sem relação com motores diesel de alta potência; anteriores a 1978 sem relevância histórica; sem autoria	Artigos sem aderência temática ou sem respaldo em periódicos de referência
Prioridade	Periódicos indexados (Scopus, Web of Science); obras clássicas; normas ABNT/ISO	Applied Intelligence; Electronics; Machines; Qualitymark; ABNT
Idioma / Recorte	Português e inglês; sem restrição para obras clássicas; prioridade pós-2018 para IA e diagnóstico preditivo	Viana et al. (2023, 2025) e Bai et al. (2022) como marcos recentes

Fonte: Elaborado pelos autores (2026).


A aplicação desses critérios resultou em 18 obras de referência. A Tabela 2 apresenta a composição quantitativa por categoria e a Figura 5 ilustra graficamente essa distribuição. A predominância de livros técnicos de referência (28%) reflete a relevância de obras como Heywood (1988) e Moubray (2000), enquanto artigos em periódicos indexados e normas técnicas (22% cada) asseguram incorporação do estado da arte recente e rigor normativo.

Tabela 2 – Composição do corpus bibliográfico por categoria de fonte

Categoria	Qtd.	%	Principais Obras
Livros e manuais técnicos	5	28%	Heywood (1988); Moubray (2000); Kardec e Nascif (2013); Siqueira (2009); Palady (2007)
Artigos em periódicos indexados	4	22%	Viana et al. (2023, 2025); Bai et al. (2022); Guterres (2025)
Normas técnicas (ABNT/ISO)	4	22%	ABNT NBR 5462; ABNT ISO/IEC 10816-3; ABNT NBR 6022; ABNT NBR 14724
Artigos em anais de congresso	2	11%	Wang et al. (2018); Teixeira (2025)
Documentos técnicos (fabricante)	2	11%	Cummins Inc. (2015); Cummins Inc. (2016)
Manuais de normalização	1	6%	AIAG; VDA (2019)

Fonte: Elaborado pelos autores (2026).

Figura 5 – Distribuição do corpus bibliográfico por categoria de fonte



Fonte: Elaborado pelos autores (2026).

3.3 Procedimento de Coleta e Tratamento de Dados

Para a validação prática dos conceitos de engenharia de manutenção, a pesquisa adota o delineamento de estudo de caso fundamentado em duas frentes. A primeira compreende o corpus bibliográfico sistematizado composto por 18 obras de referência. A segunda consiste em uma amostragem analítica de 1.500 registros operacionais e históricos de manutenção de um motor Cummins QSK60.


O levantamento de dados abrangeu seis variáveis físicas fundamentais (rotação, temperatura do óleo e do arrefecimento, vibração, consumo de combustível e carga operacional) e variáveis financeiras vinculadas aos custos e tipos de ordens de serviço executadas (corretiva, preventiva e preditiva).

A transposição dos dados brutos em informações interpretáveis foi realizada na plataforma Microsoft Power BI por meio do processo de *Extract, Transform and Load* (ETL). Os registros foram importados, depurados e consolidados em um modelo relacional único, vinculando a tabela de parâmetros do motor à tabela de histórico de manutenção. Por fim, para garantir o rigor metodológico, os indicadores calculados foram validados em estrita conformidade com os critérios técnicos das normas ABNT ISO/IEC 10816-3 e ABNT NBR 5462.

3.4 Integração Metodológica e Fundamentos Analíticos

A evolução das estratégias de manutenção — da corretiva à inteligente, conforme sintetizado na Figura 4 — contextualiza as escolhas analíticas deste trabalho. A representação em pirâmide evidencia que cada geração adicionou camadas de sofisticação ao repertório do gestor de manutenção, sendo as abordagens preditivas e baseadas em IA da quarta geração reservadas aos ativos de maior criticidade, como o motor QSK60 (KARDEC; NASCIF, 2013).

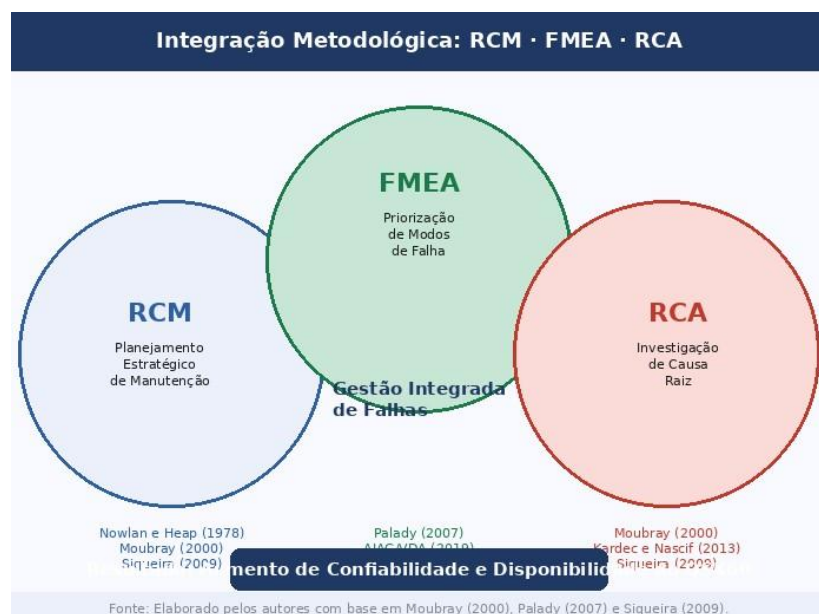
Figura 4 – Evolução das gerações das estratégias de manutenção industrial



Fonte: Elaborado pelos autores base Nowlan e Heap (1978), Moubray (2000) e Kardec e Nascif (2013).

A aplicação integrada de RCM, FMEA e RCA — conforme o diagrama de sobreposição da Figura 6 — constitui o núcleo analítico deste trabalho. Na zona de convergência denominada "Gestão Integrada de Falhas", o RCM define as estratégias de intervenção por subsistema, o FMEA prioriza os modos de falha por criticidade e o RCA investiga as causas fundamentais dos eventos ocorridos, retroalimentando o plano de manutenção. Essa integração é essencial para um motor da complexidade do QSK60, cujos subsistemas apresentam interdependências funcionais que amplificam o impacto de cada falha (WANG et al., 2018).

Figura 6 – Diagrama de integração metodológica: RCM, FMEA e RCA



Fonte: Elaborado pelos autores com base em Moubray (2000), Palady (2007) e Siqueira (2009).

O conceito de intervalo P-F (Figura 7) é o fundamento operacional da manutenção preditiva adotada neste estudo. A janela preditiva (âmbar) é o período em que técnicas de monitoramento de condição e modelos de IA devem detectar a falha potencial antes de sua manifestação funcional. Para o QSK60, a extensão desse intervalo varia entre subsistemas — curto no sistema de injeção, longo no grupo pistão-cilindro — reforçando a necessidade da abordagem integrada e multitécnica proposta (MOUBRAY, 2000; WANG et al., 2018).

Figura 7 – Intervalo P-F: janela de detecção na manutenção preditiva



Fonte: Adaptado de Moubray (2000).

3.5 Etapas e Protocolo de Análise

O percurso metodológico foi estruturado em cinco etapas analíticas, conforme o Quadro 7, que relaciona cada objetivo específico ao procedimento correspondente e às principais fontes utilizadas:

- Etapa 1 — Identificação e categorização dos modos de falha do QSK60 por subsistema, com base em Wang et al. (2018) e Cummins Inc. (2015, 2016);
- Etapa 2 — Análise comparativa das estratégias de manutenção e das técnicas de monitoramento de condição (vibração, óleo, termografia e desempenho);
- Etapa 3 — Revisão dos indicadores MTBF, MTTR e disponibilidade (ABNT NBR 5462:1994) e análise de sua aplicação em contextos industriais críticos;
- Etapa 4 — Aplicação descritiva de RCM, FMEA e RCA ao contexto do QSK60, com análise de convergências e priorização de falhas críticas;
- Etapa 5 — Avaliação dos modelos de IA (SVR, GPR, RF, MLP, SSAE+SVM) e síntese de diretrizes integradas para melhoria da confiabilidade e disponibilidade.

Quadro 7 – Protocolo de análise: objetivos específicos, procedimentos e fontes

Etapa	Objetivo Específico	Procedimento	Principais Fontes
1	Identificar as falhas recorrentes no motor Cummins QSK60	Categorização de modos de falha por subsistema	Wang et al. (2018); Heywood (1988); Cummins Inc. (2015, 2016)
2	Avaliar práticas de manutenção e métodos de diagnóstico aplicados	Análise comparativa: corretiva, preventiva e preditiva; técnicas de monitoramento de condição	Moubray (2000); Kardec e Nascif (2013); Guterres (2025)
3	Analisar indicadores de desempenho (MTBF, MTTR, disponibilidade)	Revisão dos indicadores e análise de sua aplicação em contextos industriais críticos	Siqueira (2009); Kardec e Nascif (2013); ABNT NBR 5462 (1994)
4	Aplicar RCM, FMEA e RCA ao contexto do QSK60	Análise de convergências e complementaridades; priorização de falhas críticas	Moubray (2000); Palady (2007); AIAG; VDA (2019)
5	Propor diretrizes de melhoria de confiabilidade e disponibilidade	Síntese de evidências; recomendações integrando manutenção preditiva e IA	Viana et al. (2023, 2025); Bai et al. (2022); Wang et al. (2018)

Fonte: Elaborado pelos autores (2026).

3.6 Limitações do Método

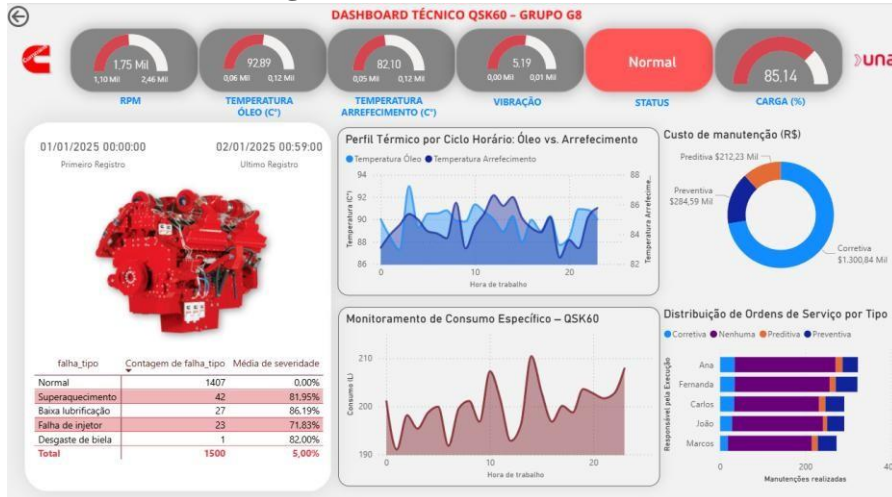
A principal limitação da pesquisa bibliográfica sistematizada adotada reside na ausência de dados empíricos primários coletados em campo — como registros reais de falhas e dados de sensores de motores QSK60 em operação — o que restringe a validação das diretrizes propostas em condições industriais reais. Viana et al. (2025) alertam que modelos de IA validados apenas com dados simulados podem apresentar desempenho inferior em condições reais, onde variáveis como qualidade do combustível e histórico de manutenção introduzem variabilidade não contemplada nos simuladores. As diretrizes deste trabalho devem, portanto, ser compreendidas como recomendações fundamentadas na literatura especializada, sujeitas à validação empírica em estudos futuros.

4. RESULTADOS E DISCUSSÕES

Com base no referencial teórico e nos objetivos propostos neste trabalho, foi desenvolvido um dashboard técnico em Business Intelligence (BI) voltado ao monitoramento operacional e à análise de falhas do motor diesel Cummins QSK60. A ferramenta foi elaborada utilizando a plataforma Microsoft Power BI, permitindo a integração e visualização dos

principais parâmetros operacionais, indicadores de manutenção e padrões de falha associados ao equipamento.

Figura 8 – Dashboard Técnico QSK60



Fonte: Captura de tela

A Figura 8 apresenta o dashboard desenvolvido para o monitoramento do motor QSK60, reunindo informações relacionadas à rotação do motor (RPM), temperatura do óleo lubrificante, temperatura do sistema de arrefecimento, vibração, carga operacional e status geral do equipamento. Além disso, o painel apresenta gráficos analíticos referentes ao comportamento térmico, distribuição das ordens de serviço, custos de manutenção e consumo específico ao longo do ciclo operacional.

O sistema desenvolvido possibilitou a consolidação visual dos dados operacionais em tempo real, favorecendo a identificação de tendências de degradação e possíveis falhas potenciais antes da ocorrência de falhas funcionais. Esse resultado está alinhado aos conceitos de manutenção preditiva discutidos por Moubray (2000) e Wang et al. (2018), que destacam a importância do monitoramento contínuo para ampliação da confiabilidade operacional.

4.1 Monitoramento Operacional do Motor QSK60

Os indicadores superiores do dashboard foram projetados para representar os principais parâmetros críticos do motor. Observou-se que o motor operou com rotação média de aproximadamente 1.750 RPM, mantendo carga operacional próxima de 85%, condição compatível com aplicações industriais severas.

Figura 9 – Dashboard Técnico QSK60: Principais indicadores



Fonte: Captura de tela

As temperaturas do óleo lubrificante e do sistema de arrefecimento permaneceram dentro da faixa operacional esperada durante grande parte do ciclo analisado. Entretanto, pequenas oscilações térmicas foram identificadas em determinados períodos, indicando possíveis variações de carga ou eficiência no sistema de refrigeração.

O parâmetro de vibração apresentou média de 5,19 mm/s, valor que, embora dentro de limites aceitáveis para determinadas condições industriais, evidencia a necessidade de acompanhamento contínuo. Segundo a norma ABNT ISO/IEC 10816-3 (2009), níveis elevados

de vibração podem indicar desgaste mecânico, desalinhamento ou falhas em componentes rotativos.

A utilização de indicadores visuais do tipo gauge permitiu rápida interpretação das condições operacionais do equipamento, contribuindo para maior agilidade na tomada de decisão por parte das equipes de manutenção.

4.2 Análise de Perfil Térmico

O gráfico “Perfil Térmico por Ciclo Horário: Óleo vs. Arrefecimento” permitiu analisar o comportamento simultâneo da temperatura do óleo e da temperatura do sistema de arrefecimento ao longo do período operacional.

Figura 10 – Dashboard Técnico QSK60: Gráfico de linhas (Perfil térmico)



Fonte: Captura de tela

Observou-se comportamento relativamente estável entre ambas as variáveis, porém com momentos de divergência térmica em determinados horários. Essa diferença pode indicar redução da eficiência do sistema de troca térmica ou início de processos de incrustação e obstrução no sistema de arrefecimento.

Os resultados observados corroboram Wang et al. (2018), que apontam o monitoramento térmico como uma das principais ferramentas para identificação precoce de falhas em motores diesel de alta potência.

Além disso, a visualização temporal proporcionada pelo BI facilita a identificação de tendências operacionais que dificilmente seriam percebidas apenas por análises convencionais em planilhas ou registros manuais.

4.3 Distribuição dos Custos de Manutenção

O dashboard também apresentou a distribuição dos custos de manutenção por categoria: corretiva, preventiva e preditiva.

Figura 11 – Dashboard Técnico QSK60: Gráfico de rosca (Custo de manutenção)



Fonte: Captura de tela

Os resultados demonstraram predominância dos custos relacionados à manutenção corretiva, representando aproximadamente a maior parcela do custo total analisado. Esse comportamento evidencia que o equipamento ainda opera sob forte dependência de intervenções após falhas, cenário descrito por Kardec e Nascif (2013) como um dos principais fatores responsáveis pelo aumento dos custos operacionais e redução da disponibilidade dos ativos.

Em contrapartida, os custos relacionados à manutenção preditiva apresentaram menor representatividade, indicando potencial oportunidade de melhoria através da ampliação das estratégias baseadas em monitoramento de condição e análise inteligente de dados.

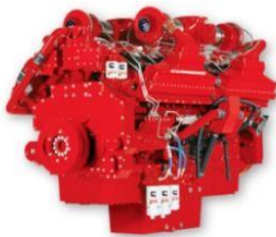
A visualização gráfica permitiu compreender de forma intuitiva o impacto financeiro das diferentes estratégias de manutenção, reforçando a importância da migração gradual de uma abordagem corretiva para uma manutenção preditiva orientada por dados.

4.4 Identificação de Modos de Falha

A tabela de falhas desenvolvida no painel permitiu identificar os principais modos de falha associados ao motor QSK60. Entre os eventos registrados, destacaram-se:

Superaquecimento - Baixa lubrificação -Falha de injetor -Desgaste de biela.

Figura 12 – Dashboard Técnico QSK60: Tabela (Falhas)



falha_tipo	Contagem de falha_tipo	Média de severidade
Normal	1407	0,00%
Superaquecimento	42	81,95%
Baixa lubrificação	27	86,19%
Falha de injetor	23	71,83%
Desgaste de biela	1	82,00%
Total	1500	5,00%

Fonte: Captura de tela

O superaquecimento apresentou maior número de ocorrências relevantes, acompanhado de elevada severidade média. Esse resultado demonstra forte relação entre parâmetros térmicos e criticidade operacional do motor.

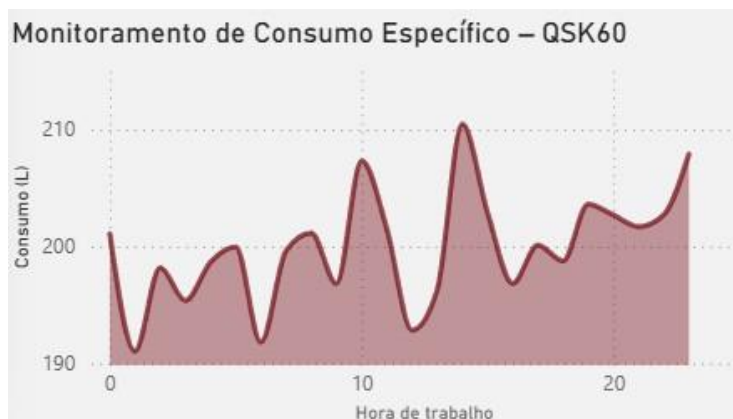
A baixa lubrificação também apresentou alta severidade, evidenciando a importância do monitoramento contínuo do sistema lubrificante, conforme discutido por Heywood (1988), que destaca o papel fundamental da lubrificação na redução do desgaste e preservação dos componentes internos do motor.

Os resultados encontrados demonstram coerência com os modos de falha descritos por Wang et al. (2018), validando a aderência do modelo analítico construído no dashboard em relação às falhas mais recorrentes em motores diesel industriais.

4.5 Monitoramento de Consumo Específico

O gráfico de consumo específico permitiu observar oscilações no comportamento do consumo ao longo do ciclo operacional do motor.

Figura 13 – Dashboard Técnico QSK60: Gráfico de linhas (Consumo)



Fonte: Captura de tela


Os picos identificados podem estar associados a alterações de carga, variações na eficiência de combustão ou possíveis irregularidades no sistema de injeção. Segundo Viana et al. (2023), padrões anormais de consumo representam variáveis relevantes para modelos preditivos baseados em inteligência artificial.

Nesse contexto, o dashboard demonstrou potencial para servir como ferramenta de apoio à aplicação futura de algoritmos de machine learning, permitindo integração entre monitoramento operacional e sistemas inteligentes de previsão de falhas.

4.6 Distribuição das Ordens de Serviço

A análise das ordens de serviço por responsável técnico demonstrou predominância de manutenções corretivas em relação às preventivas e preditivas.

Figura 14 – Dashboard Técnico QSK60: Gráfico de barras empilhadas (Ordem de serviço)



Fonte: Captura de tela

Esse comportamento evidencia um cenário ainda reativo na gestão da manutenção, reforçando a necessidade de implementação de práticas estruturadas de manutenção baseada em condição.

Além disso, a distribuição visual das ordens de serviço permitiu identificar diferenças operacionais entre os responsáveis técnicos, possibilitando futuras análises relacionadas à produtividade, recorrência de falhas e eficiência das intervenções realizadas.

4.7 Discussão dos Resultados

A análise realizada demonstra que a utilização de ferramentas de Business Intelligence aplicadas à manutenção industrial possui elevado potencial para apoiar a tomada de decisão e ampliar a confiabilidade operacional de motores diesel de alta potência.

A integração entre parâmetros operacionais, indicadores de manutenção e análise visual de falhas permitiu transformar grandes volumes de dados em informações interpretáveis, favorecendo ações preventivas e preditivas.

Os achados deste trabalho convergem com os estudos de Viana et al. (2023; 2025), que destacam a importância da análise de informações operacionais e da inteligência artificial para aumento da eficiência na gestão da manutenção industrial.

Além disso, os resultados reforçam os fundamentos de manutenção centrada na confiabilidade (RCM) apresentados por Moubray (2000), principalmente no que se refere à identificação de falhas potenciais antes da ocorrência de falhas funcionais.

Do ponto de vista prático, o dashboard desenvolvido apresenta potencial aplicação em ambientes industriais reais, podendo ser utilizado como ferramenta de apoio à gestão da manutenção, monitoramento de ativos críticos e planejamento de intervenções.

Apesar dos resultados satisfatórios, a aplicação prática da ferramenta depende da qualidade e atualização contínua dos dados operacionais, além da integração eficiente entre os sistemas de monitoramento e manutenção.

O dashboard permitiu identificar padrões de comportamento operacional e tendências de falhas com maior rapidez em comparação às análises convencionais.

Por fim, observa-se que a utilização do Power BI contribuiu significativamente para a organização, interpretação e visualização dos dados operacionais do motor QSK60, demonstrando que soluções de Business Intelligence podem atuar como importantes aliadas na evolução da manutenção industrial em direção aos conceitos da Indústria 4.0.

5. CONCLUSÕES

A execução desta pesquisa possibilitou uma compreensão mais detalhada sobre como a combinação de análise de falhas, manutenção preditiva e ferramentas de inteligência artificial pode auxiliar na melhoria da gestão de motores diesel de alta potência. Mais do que validar conceitos já abordados na literatura, o estudo trouxe uma abordagem prática de como esses elementos podem ser integrados, destacando os benefícios na análise de dados e na assistência à decisão.

Um dos principais ensinamentos adquiridos diz respeito à relevância da organização e visualização das informações operacionais. A adoção de um painel em Business Intelligence mostrou que, quando bem-organizados, os dados não são apenas registros operacionais, mas se tornam ferramentas estratégicas que podem evidenciar padrões, identificar tendências e prever falhas potenciais. Constatou-se que variáveis como temperatura, vibração, consumo e carga operacional, quando avaliadas em conjunto, fornecem uma base robusta para o monitoramento contínuo e para a detecção de comportamentos atípicos.

Além do mais, a pesquisa deixou claro que os modos de falha mais frequentes, como superaquecimento, lubrificação insuficiente, falhas em injetores e desgaste mecânico, estão intimamente ligados às condições operacionais do motor. Essa descoberta reforça a ideia de que o monitoramento constante dessas variáveis é crucial para a prevenção de falhas e para a extensão da vida útil dos componentes. Outro aspecto importante foi a identificação da elevada dependência de manutenção corretiva, o que indica que ainda existe um espaço considerável para melhorar as práticas de manutenção em ambientes industriais.

Sob uma perspectiva científica, o trabalho se destaca ao mostrar que a combinação de metodologias estabelecidas, como RCM, FMEA e RCA, com ferramentas modernas de análise

de dados, amplia a capacidade de avaliação e gerenciamento de falhas. Percebeu-se que essa integração não apenas identifica problemas, mas também permite entender suas origens e priorizar ações de maneira mais eficaz, alinhando-se aos princípios da manutenção centrada na confiabilidade e às tendências da Indústria 4.0.

Outro conhecimento significativo gerado diz respeito à função da inteligência artificial como suporte à manutenção preditiva. Apesar de não ter sido aplicada diretamente com dados reais em larga escala, a estrutura formada no estudo indica que há um caminho viável para a futura implementação de modelos preditivos, utilizando os dados operacionais já monitorados. Isso reforça que o avanço tecnológico na manutenção industrial depende não apenas das ferramentas, mas também da qualidade e da organização das informações disponíveis.

Como um aporte prático, a pesquisa demonstra que soluções acessíveis, como a utilização do Power BI, já podem proporcionar melhorias substanciais na gestão da manutenção, aproximando o ambiente industrial de um modelo mais analítico, preventivo e baseado em dados. Esse aprendizado destaca que a evolução da manutenção não se baseia exclusivamente na realização de investimentos complexos, mas também na maneira como os dados existentes são aproveitados.

Por último, este estudo abre portas para novas investigações. Recomenda-se, como continuidade, a aplicação do modelo elaborado em um ambiente industrial real, com coleta contínua de dados e integração imediata com os sensores do equipamento. Além disso, pesquisas futuras poderão investigar a implementação prática de algoritmos de aprendizado de máquina para previsão de falhas, bem como realizar análises comparativas entre diferentes motores ou condições operacionais. Outra abordagem interessante seria examinar o impacto econômico da adoção de estratégias preditivas em vez da manutenção corretiva.

Dessa maneira, conclui-se que este estudo não só atendeu às suas metas, mas também contribuiu para expandir a compreensão sobre a aplicação prática de tecnologias digitais na manutenção industrial, evidenciando um caminho promissor para aumentar a confiabilidade, reduzir custos e aprimorar os processos de gestão de ativos.

REFERÊNCIAS BIBLIOGRÁFICAS

AIAG; VDA. *FMEA Handbook*. 1. ed. [S.l.]: Chrysler LLC; Ford Motor Company; General Motors; Volkswagen AG, 2019.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. *ABNT NBR 5462: Confiabilidade e Manutenibilidade*. Rio de Janeiro: ABNT, 1994.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. *ABNT ISO/IEC 10816-3: Vibração mecânica — Avaliação da vibração da máquina por medições em peças não rotativas Parte 3: Máquinas industriais com potência nominal acima de 15 kW*. Rio de Janeiro: ABNT, 2009.

BAI, H. et al. Research on Diesel Engine Fault Diagnosis Method Based on Stacked Sparse Autoencoder and Support Vector Machine. *Electronics*, Basel, v. 11, n. 14, art. 2249, 2022. DOI: <https://doi.org/10.3390/electronics11142249>.

BOTELHO, L. L. R.; CUNHA, C. C. A.; MACEDO, M. O método da revisão integrativa nos estudos organizacionais. *Gestão e Sociedade*, v. 5, n. 11, p. 121-136, 2011.

CUMMINS INC. *QSK60 Series: Engine Specification Sheet (QSK60-G4)*. Columbus: Cummins Inc., 2015. Disponível em:

<https://www.cummins.com/sites/default/files/201810/QSK60-G4.pdf>. Acesso em: 20 abr. 2026.

CUMMINS INC. *QSK60 Marine Propulsion and Auxiliary Engines*. Charleston: Cummins Inc., 2016. (Bulletin 4986143 Rev. 6/16). Disponível em: <https://mart.cummins.com/imagelibrary/data/assetfiles/0043523.pdf>. Acesso em: 20 abr. 2026.

GIL, A. C. *Como Elaborar Projetos de Pesquisa*. 5. ed. São Paulo: Atlas, 2010.

GUTERRES, A. M. Manutenção preditiva: uma revisão bibliográfica sobre a análise de vibração. *Revista Eletrônica Multidisciplinar de Investigação Científica*, v. 4, n. 22, 2025. DOI: <https://doi.org/10.47402/remici.v4n22303025>.

HEYWOOD, J. B. *Internal Combustion Engine Fundamentals*. New York: McGraw-Hill, 1988.

KARDEC, A.; NASCIF, J. *Manutenção: Função Estratégica*. 4. ed. Rio de Janeiro: Qualitymark, 2013.

MOUBRAY, J. *RCM II: Manutenção Centrada na Confiabilidade*. Tradução de Kleber Siqueira. Grã-Bretanha: Biddles Ltd., 2000.

NOWLAN, F. S.; HEAP, H. F. *Reliability-Centered Maintenance*. San Francisco: United Airlines / National Technical Information Service, 1978.

PALADY, P. *FMEA — Análise dos Modos de Falhas e Efeitos*. 4. ed. São Paulo: IMAN, 2007.

PRODANOV, C. C.; FREITAS, E. C. *Metodologia do Trabalho Científico*. 2. ed. Novo Hamburgo: Feevale, 2013.

SIQUEIRA, Y. P. D. S. *Manutenção Centrada na Confiabilidade: Manual de Implantação*. 1. ed. (reimpr.). Rio de Janeiro: Qualitymark, 2009.

SMITH, A. M. *Reliability-Centered Maintenance*. Boston: McGraw-Hill, 1993.

TEIXEIRA, M. F. H. B. I. Análise de vibrações como ferramenta de manutenção preditiva em equipamentos industriais: uma revisão. *RECIMA21 — Revista Científica Multidisciplinar*, v. 6, n. 5, e656424, 2025. DOI: <https://doi.org/10.47820/recima21.v6i5.6424>.

VIANA, D. P. et al. Predicting Faults in Diesel Engines with Kernel Machines Regression Techniques. *Applied Intelligence*, v. 55, art. 882, 2025. DOI: <https://doi.org/10.1007/s10489025-06643-7>.

VIANA, D. P. et al. Diesel Engine Fault Prediction Using Artificial Intelligence Regression Methods. *Machines*, Basel, v. 11, n. 5, art. 530, 2023. DOI: <https://doi.org/10.3390/machines11050530>.

WANG, Z. et al. The Common Fault Diagnosis Method of Diesel Engine. In: INTERNATIONAL CONFERENCE ON APPLIED MATHEMATICS, MODELLING AND STATISTICS APPLICATION (AMMSA), 2., 2018. *Proceedings...* [S.l.]: Atlantis Press, 2018. p. 390-392. DOI: <https://doi.org/10.2991/ammsa-18.2018.82>.