REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

# INTELIGÊNCIA ARTIFICIAL E SENSORES MAGNÉTICOS NA GESTÃO DE MANUTENÇÃO PREDITIVA: UMA ABORDAGEM PARA A INDÚSTRIA 4.0

# ARTIFICIAL INTELLIGENCE AND MAGNETIC SENSORS IN PREDICTIVE MAINTENANCE MANAGEMENT: AN APPROACH FOR INDUSTRY 4.0

# INTELIGENCIA ARTIFICIAL Y SENSORES MAGNÉTICOS EN LA GESTIÓN DEL MANTENIMIENTO PREDICTIVO: UN ENFOQUE PARA LA INDUSTRIA 4.0

**Danilton Carlos da Silva**
Doutorado em Contabilidade, UEMG - Universidade Estado de Minas Gerais, Brasil
danilton.silva@uemg.br

**Daniela Freitas Borges**
Mestrado, UEMG - Universidade do Estado de Minas Gerais, Brasil
daniela.eng@hotmail.com

**Agaone Donizete Silva**
Mestrado, UEMG - Universidade do Estado de Minas Gerais, Brasil
Agaone.silva@uemg.br

**Vinícius de Barcelos Machado**
Mestrado, UEMG - Universidade do Estado de Minas Gerais, Brasil
vinicius. machado@uemg.br

**Rildo Afonso de Almeida**
Especialista, UEMG Universidade Estado de Minas Gerais, Brasil
rildo.almeida@uemg.br

## Resumo

A presente pesquisa tem como objetivo analisar como a integração entre sensores magnéticos e algoritmos de Inteligência Artificial pode contribuir para a gestão da manutenção preditiva em ambientes industriais, com foco na confiabilidade dos ativos, na redução de falhas e no apoio à tomada de decisão no contexto da Indústria 4.0. Metodologicamente, o estudo caracteriza-se como uma Revisão Sistemática da Literatura, de natureza qualitativa, exploratória e descritiva, complementada por análise descritiva/bibliométrica exploratória. Foram considerados estudos publicados entre 05/2015 e 05/2026, identificados nas bases Scopus, Web of Science, IEEE Xplore e ScienceDirect. A busca inicial resultou em 300 registros, dos quais 20 estudos compuseram a amostra final após aplicação dos critérios de inclusão, exclusão, remoção de duplicatas, triagem e avaliação da qualidade metodológica. Os dados foram organizados em matriz analítica, contemplando tipo de sensor, ativo monitorado, algoritmo utilizado, métrica reportada, aplicação, limitações e contribuição gerencial. Os resultados evidenciam que sensores magnéticos, como sensores de efeito Hall, sensores de campo magnético, medições de fluxo no entreferro e técnicas de fluxo magnético disperso, apresentam potencial relevante para o monitoramento de motores elétricos, máquinas rotativas e sistemas eletromecânicos. Quando associados a modelos de Machine Learning e Deep

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

Learning, esses sensores podem apoiar a detecção de anomalias, a classificação de falhas, o prognóstico, a estimativa de vida útil remanescente e a priorização de intervenções. Conclui-se que a integração entre sensores magnéticos e Inteligência Artificial fortalece a manutenção preditiva como prática estratégica de gestão de ativos, desde que acompanhada por qualidade dos dados, validação técnica, explicabilidade dos modelos, interoperabilidade e capacitação profissional.

**Palavras-chave:** Manutenção preditiva; Inteligência Artificial; Sensores magnéticos; Indústria 4.0; Gestão de ativos; Machine Learning; Internet das Coisas (IoT).

**Abstract**

This research aims to analyze how the integration of magnetic sensors and Artificial Intelligence algorithms can contribute to predictive maintenance management in industrial environments, focusing on asset reliability, failure reduction, and decision-making support in the context of Industry 4.0. Methodologically, the study is characterized as a Systematic Literature Review with a qualitative, exploratory, and descriptive approach, complemented by descriptive/exploratory bibliometric analysis. Studies published between 05/2015 and 05/2026 were considered and retrieved from Scopus, Web of Science, IEEE Xplore, and ScienceDirect. The initial search identified 300 records, of which 20 studies composed the final sample after applying inclusion and exclusion criteria, duplicate removal, screening, and methodological quality assessment. The data were organized into an analytical matrix, including type of sensor, monitored asset, algorithm used, reported metric, application, limitations, and managerial contribution. The results show that magnetic sensors, such as Hall-effect sensors, magnetic field sensors, air-gap flux measurements, and stray magnetic flux techniques, have relevant potential for monitoring electric motors, rotating machinery, and electromechanical systems. When combined with Machine Learning and Deep Learning models, these sensors can support anomaly detection, fault classification, prognosis, remaining useful life estimation, and intervention prioritization. It is concluded that the integration of magnetic sensors and Artificial Intelligence strengthens predictive maintenance as a strategic asset management practice, provided that it is supported by data quality, technical validation, model explainability, interoperability, and professional training.

**Keywords:** Predictive maintenance; Artificial Intelligence; Magnetic sensors; Industry 4.0; Asset management; Machine Learning; Internet of Things (IoT);

**Resumen**

La presente investigación tiene como objetivo analizar cómo la integración entre sensores magnéticos y algoritmos de Inteligencia Artificial puede contribuir a la gestión del mantenimiento predictivo en entornos industriales, con foco en la confiabilidad de los activos, la reducción de fallas y el apoyo a la toma de decisiones en el contexto de la Industria 4.0. Metodológicamente, el estudio se caracteriza como una Revisión Sistemática de la Literatura, de naturaleza cualitativa, exploratoria y descriptiva, complementada con un análisis descriptivo/bibliométrico exploratorio. Se consideraron estudios publicados entre 05/2015 y 05/2026, identificados en las bases Scopus, Web of Science, IEEE Xplore

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

y ScienceDirect. La búsqueda inicial resultó en 300 registros, de los cuales 20 estudios conformaron la muestra final después de aplicar criterios de inclusión, exclusión, eliminación de duplicados, cribado y evaluación de la calidad metodológica. Los datos fueron organizados en una matriz analítica, contemplando tipo de sensor, activo monitoreado, algoritmo utilizado, métrica reportada, aplicación, limitaciones y contribución gerencial. Los resultados evidencian que los sensores magnéticos, como sensores de efecto Hall, sensores de campo magnético, mediciones de flujo en el entrehierro y técnicas de flujo magnético disperso, presentan potencial relevante para el monitoreo de motores eléctricos, máquinas rotativas y sistemas electromecánicos. Cuando se asocian con modelos de Machine Learning y Deep Learning, estos sensores pueden apoyar la detección de anomalías, la clasificación de fallas, el pronóstico, la estimación de la vida útil remanente y la priorización de intervenciones. Se concluye que la integración entre sensores magnéticos e Inteligencia Artificial fortalece el mantenimiento predictivo como práctica estratégica de gestión de activos, siempre que esté acompañada por calidad de los datos, validación técnica, explicabilidad de los modelos, interoperabilidad y capacitación profesional.

**Palabras clave**: Mantenimiento predictivo; Inteligencia Artificial; Sensores magnéticos; Industria 4.0; Gestión de activos; Aprendizaje automático; Internet de las Cosas (IoT).

## 1. Introdução

A transformação digital dos sistemas produtivos tem redefinido a forma como as organizações industriais monitoram, controlam e gerenciam seus ativos. No contexto da Indústria 4.0, tecnologias como Internet das Coisas, sistemas ciberfísicos, computação em nuvem, sensores inteligentes e Inteligência Artificial passaram a integrar processos produtivos antes marcados por decisões predominantemente reativas ou baseadas em inspeções periódicas (Schwab, 2016; Lee et al., 2015). Essa mudança afeta diretamente a manutenção industrial, que deixa de ser compreendida apenas como uma atividade corretiva e passa a assumir função estratégica na confiabilidade operacional, na redução de custos, na segurança dos processos e na continuidade da produção.

A manutenção preditiva baseia-se no monitoramento contínuo ou periódico das condições reais de operação dos equipamentos, com o objetivo de identificar sinais de degradação antes da ocorrência de falhas funcionais. Diferentemente da manutenção corretiva, acionada após a falha, e da manutenção preventiva, baseada em intervalos fixos, a manutenção preditiva utiliza dados operacionais para estimar o estado de saúde dos ativos e orientar intervenções mais oportunas (Mobley, 2002;

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

Jardine et al., 2006). Em ambientes industriais digitalizados, essa abordagem tem sido fortalecida pelo uso de sensores, modelos estatísticos, Machine Learning e Deep Learning, capazes de identificar padrões complexos em grandes volumes de dados (Carvalho et al., 2019; Zonta et al., 2020).

Entre as tecnologias de monitoramento de condição, os sensores magnéticos apresentam relevância específica para máquinas elétricas, motores de indução, máquinas rotativas e sistemas eletromecânicos. Esses sensores permitem captar variações de campo magnético, fluxo no entreferro ou fluxo magnético disperso, associadas a alterações físicas e elétricas dos ativos. Tais sinais podem indicar falhas incipientes em rotores, estatores, rolamentos, desalinhamentos, excentricidades e outros modos de degradação que afetam o desempenho de equipamentos críticos. Quando combinados com algoritmos de IA, esses dados podem ser transformados em diagnósticos, classificações de falhas, estimativas de vida útil remanescente e informações gerenciais para apoio à tomada de decisão.

Apesar dos avanços recentes, a literatura ainda apresenta lacunas importantes. Parte dos estudos sobre manutenção preditiva concentra-se no desempenho dos algoritmos, sem discutir suficientemente os tipos de sensores utilizados, o contexto industrial de aplicação ou as implicações gerenciais dos resultados. Por outro lado, estudos específicos sobre sensores magnéticos frequentemente enfatizam o diagnóstico técnico de falhas, mas nem sempre demonstram como esses diagnósticos podem ser incorporados aos processos de planejamento, priorização e controle da manutenção. Assim, observa-se a necessidade de uma síntese que integre três dimensões: o sensoriamento magnético, os modelos de Inteligência Artificial e a gestão da manutenção preditiva.

Diante desse contexto, este artigo busca responder à seguinte questão de pesquisa: de que forma a integração entre sensores magnéticos e algoritmos de Inteligência Artificial pode contribuir para uma gestão de manutenção preditiva mais eficiente em ambientes industriais?

O objetivo geral do estudo é analisar como a integração de sensores magnéticos e algoritmos de Inteligência Artificial pode otimizar a gestão da manutenção preditiva em ambientes industriais, contribuindo para a confiabilidade

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

dos ativos, a redução de falhas e o apoio à tomada de decisão no contexto da Indústria 4.0.

Para alcançar esse objetivo, foram definidos os seguintes objetivos específicos:

I. identificar os principais tipos de sensores magnéticos utilizados no monitoramento preditivo de equipamentos industriais;

II. mapear os algoritmos de Inteligência Artificial aplicados à análise de dados de sensores na manutenção preditiva;

III. analisar como a integração entre sensores magnéticos e IA contribui para a eficiência da gestão da manutenção;

IV. sintetizar os benefícios, desafios e limitações dessa integração no contexto industrial.

A contribuição do estudo está em propor uma leitura integrada da manutenção preditiva, articulando evidências técnicas e gerenciais. Ao reunir estudos sobre sensores magnéticos, IA e gestão de ativos, a revisão busca demonstrar como sinais físicos captados nos equipamentos podem ser convertidos em informações úteis para diagnóstico, prognóstico, planejamento de intervenções, priorização de ativos críticos e melhoria da eficiência operacional.

## 2. Revisão da Literatura

Este referencial teórico foi reestruturado para sustentar a pergunta-problema do estudo: de que forma a combinação de sensores magnéticos e Inteligência Artificial pode contribuir para uma gestão de manutenção preditiva mais eficiente nas indústrias contemporâneas? Para isso, o capítulo articula seis eixos conceituais: Indústria 4.0, gestão da manutenção industrial, manutenção preditiva, sensores magnéticos, Inteligência Artificial aplicada à manutenção e integração entre sensoriamento e modelos inteligentes de decisão.

### 2.1 A Quarta Revolução Industrial e o paradigma da Indústria 4.0

O Paradigma da Indústria 4.0 e a Evolução Estratégica da Manutenção Industrial A Indústria 4.0 representa uma mudança de paradigma nos processos produtivos, impulsionada pela convergência de tecnologias como a Internet das Coisas (IoT), Inteligência Artificial (IA) e sistemas ciberfísicos (Moreira et al., 2025).

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

Nesse contexto, a manutenção deixou de ser uma função puramente operacional de reparo para se consolidar como um pilar estratégico que assegura a disponibilidade e a longevidade dos ativos produtivos (Alexandre et al., 2025; Lima et al., 2024). Essa transformação integra sistemas inteligentes capazes de tomar decisões autónomas, otimizando a confiabilidade operacional de forma proativa (Delecrodio et al., 2021).

Esta transição é marcada pela ascensão da manutenção prescritiva, que utiliza métodos de aprendizado de máquina e Big Data para não apenas antecipar falhas, mas recomendar ações corretivas precisas que maximizam a eficiência dos ativos (Machado et al., 2023). Essa evolução estrutural viabiliza a mudança de modelos reativos para estratégias preditivas, fundamentais para a redução de custos emergenciais e a minimização de interrupções não planejadas na cadeia de valor (D'Addario, 2024; Oliveira et al., 2025).

A implementação dessas tecnologias avançadas permite que os sistemas industriais desenvolvam capacidades de autoconsciência e autodiagnóstico, viabilizando o ajuste dinâmico de operações frente a comportamentos anômalos (Ruiz-Sarmiento et al., 2019; Subagja et al., 2024). Dessa forma, o gestor de manutenção redefine seu papel, distanciando-se da intervenção direta para concentrar-se na governança de sistemas sociotécnicos que convertem dados massivos em inteligência organizacional aplicada (Lima, 2025).

A incorporação de gêmeos digitais viabiliza a simulação contínua de cenários operacionais, fornecendo diagnósticos precisos que elevam a segurança de dados e a autonomia de robôs em toda a linha de produção (Carvalho, 2025; Neto et al., 2018). Em paralelo, a realidade aumentada oferece suporte visual detalhado aos técnicos em campo, reduzindo o tempo de inatividade e aumentando a precisão das intervenções humanas em equipamentos críticos (Crispim et al., 2025). Por meio dessa sinergia tecnológica, a gestão de ativos torna-se um valor intangível, capaz de converter a manutenção em uma vantagem competitiva sustentável que mitiga riscos operacionais (Cavalcanti, 2025; Gomaa, 2025).

Para sustentar esse ecossistema, a adoção de infraestruturas baseadas em processamento de borda (edge computing) torna-se indispensável para computar

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

volumes massivos de dados em tempo real, garantindo a baixa latência necessária para a tomada de decisão inteligente (Klieštik et al., 2023). Simultaneamente, a convergência entre essas ferramentas emergentes exige uma requalificação da força de trabalho, que passa a atuar de forma multidisciplinar na interface entre máquinas inteligentes e processos analíticos (Lisboa et al., 2024).

Contudo, o desafio central para muitas organizações reside no hiato entre a capacidade analítica de predição e a execução de recomendações prescritivas, o que exige processos estruturados para garantir que cada diagnóstico resulte em ações rastreáveis e justificáveis (Ben-Daya, 2026). A superação dessa barreira demanda não apenas investimentos em infraestrutura de TI, mas também a implementação de uma cultura organizacional que valorize o capital humano como elemento central na colaboração com sistemas autônomos (Roda & Macchi, 2021).

A transição para a Indústria 5.0 reforça essa sinergia ao priorizar a colaboração entre humanos e máquinas, visando potencializar a inovação e a produtividade através de uma integração mais resiliente e cooperativa (Kans & Campos, 2024). Nesse paradigma emergente, o setor evolui para um modelo focado na sustentabilidade e na resiliência, onde a robótica colaborativa e a realidade aumentada atuam como extensões das capacidades cognitivas e físicas do operador (Zafar et al., 2024). Essa colaboração homem-máquina permite que os técnicos se concentrem em tarefas complexas que exigem sensibilidade e pensamento crítico, enquanto sistemas autônomos assumem operações repetitivas ou de alto risco (Yitmen & Almusaed, 2024).

Paralelamente, a estruturação de frameworks de manutenção baseados em camadas permite que organizações integrem o monitoramento de condição e a inteligência artificial para otimizar o ciclo de vida dos ativos, garantindo maior eficiência operacional e sustentabilidade (Murtaza et al., 2024). Consequentemente, o desenvolvimento de estratégias para a Manutenção 5.0 exige o equilíbrio entre a automação analítica e a inteligência humana, promovendo um ambiente fabril onde a resiliência e a responsabilidade social sejam tão prioritárias quanto a performance técnica (Aktef et al., 2025; Psarommatis et al., 2023). Isso implica a captura

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

sistemática do conhecimento tácito e o fomento ao aprendizado contínuo para transpor lacunas geracionais de competências técnicas (Mahfoud, 2026).

A efetiva consolidação desse modelo requer a adoção de interfaces de suporte à decisão que incorporem o feedback dos operadores, refinando os modelos de IA através da colaboração e transformando o trabalhador em um participante ativo no ciclo de diagnóstico (Khanna et al., 2024; Lucantoni et al., 2026). Esta abordagem centrada no humano garante que a tecnologia auxilie na tomada de decisão, promovendo uma relação harmônica onde a inteligência artificial trabalha em conjunto com as habilidades cognitivas do colaborador (Priyadarshini et al., 2024; Rožanec et al., 2022). Essa integração reflete um compromisso direto com os Objetivos de Desenvolvimento Sustentável, ao fomentar uma industrialização que combina a eficiência tecnológica com a valorização do capital humano (Aheleroff et al., 2022; Costa, 2024).

Sob essa ótica, a manutenção baseada na resiliência emerge como um imperativo para a continuidade operacional, permitindo que os sistemas industriais desenvolvam tolerância a falhas e capacidade de recuperação autônoma perante incertezas (Bukowski & Werbińska-Wojciechowska, 2025). Neste contexto, a cooperação com sistemas de gêmeos digitais aprimora a precisão das intervenções em cenários de alta complexidade (Alimam et al., 2023), garantindo que o operador técnico atue como o mediador estratégico indispensável entre as sugestões algorítmicas e a execução física para assegurar a flexibilidade necessária diante de ambientes voláteis (Bukowski & Werbińska-Wojciechowska, 2025; Rodrigues, 2025). Portanto, a implementação de uma abordagem orientada pela resiliência não apenas otimiza o ciclo de vida dos ativos, mas também fortalece a sustentabilidade dos ecossistemas industriais perante as constantes mudanças do mercado global (Bukowski & Werbińska-Wojciechowska, 2025).

### 2.2 Fundamentos, Técnicas e Desafios da Manutenção Preditiva na Gestão de Ativos

A literatura contemporânea destaca que a transição para a Indústria 5.0 reconfigura o gerenciamento de ativos, deslocando o foco da automação pura para uma simbiose entre a criatividade do especialista humano e a precisão das máquinas

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

inteligentes (Pedrozo et al., 2025). Nesse contexto, a colaboração entre humanos e máquinas promove modelos de negócios flexíveis, capazes de reduzir desperdícios e alavancar a sustentabilidade dos processos fabris (Adel, 2022). Sob essa ótica, a integração de sistemas wearables e redes de sensores sem fio tem se consolidado como uma prática fundamental para elevar a produtividade, permitindo a manutenção de níveis operacionais robustos mesmo sob condições globais de incerteza (Cortés-Leal et al., 2022).

A implementação desses recursos tecnológicos possibilita a transição para sistemas produtivos adaptáveis, capazes de mitigar os impactos de eventos extremos ao integrar a resiliência como um pilar central da gestão de ativos (Chabane et al., 2023). Essa arquitetura de resiliência, sustentada pela coleta de dados em grande escala e pela análise automatizada de riscos, torna-se determinante para a continuidade dos negócios frente a rupturas globais (Wieczorek, 2024). Esta perspectiva alinha-se com a necessidade urgente de desenvolver estratégias robustas para gerir falhas, visando mitigar o risco de interrupções em cascata nos ambientes de produção modernos (Wachter et al., 2024).

Para que essa engrenagem funcione, a transição bem-sucedida para a Manutenção Prescritiva exige a superação de fragmentações conceituais e tecnológicas, permitindo que a integração vertical e horizontal transforme diagnósticos em recomendações operacionais autônomas (Orošnjak et al., 2025). Nesse sentido, a adoção de técnicas avançadas de Big Data e Inteligência Artificial é essencial para a efetivação dessa transição, possibilitando o desenvolvimento de frameworks de "Smart Maintenance" que elevam a resiliência sistêmica das plantas industriais (Mosca et al., 2025; Stachowiak, 2025).

Nesse cenário, a verdadeira centralidade humana na Indústria 5.0 só é alcançada quando o empoderamento técnico dos operadores é priorizado, capacitando-os a colaborar de forma eficaz com as tecnologias digitais em prol de sistemas mais sustentáveis (Alves et al., 2023). A aplicação dessas tecnologias emergentes não apenas impulsiona a eficiência produtiva, mas também permite que as organizações alcancem objetivos sociais e ambientais ao otimizar a interação

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

entre os sistemas cibernético-físicos e o capital humano (Hammad et al., 2025; Purnomo & Wedono, 2026).

**2.3 Manutenção preditiva: fundamentos, tecnologias e desafios**

A literatura enfatiza que a manutenção preditiva utiliza o monitoramento de condições e algoritmos de aprendizado de máquina para estimar o estado de saúde dos ativos, permitindo a predição precisa da Vida Útil Restante (RUL) de componentes críticos antes de sua falha funcional (Pinciroli et al., 2021). Dessa forma, a análise contínua de grandes volumes de dados operacionais provê suporte fundamental para a gestão proativa de anomalias, elevando significativamente a confiabilidade dos equipamentos (Borcari, 2026). A integração de modelos de Inteligência Artificial (IA) e técnicas de mineração de dados viabiliza a detecção precoce de sinais de advertência, mitigando paradas não planejadas e otimizando a disponibilidade dos sistemas de produção (Aldrini et al., 2023).

A abordagem proativa consolida essa estratégia ao investigar os mecanismos físicos subjacentes, buscando a erradicação das causas raízes em vez de apenas tratar sintomas recorrentes (Elahi et al., 2023). Sob esse prisma, a convergência entre ferramentas analíticas e a colaboração homem-IA promove a transição para métodos prescritivos, que não apenas antecipam falhas, mas recomendam ações corretivas otimizadas para a tomada de decisão (Alaoui et al., 2025; Ramzan & Recupero, 2025). Esse processo reforça a necessidade de transparência nos modelos estatísticos para garantir decisões tecnicamente embasadas e contextualmente conscientes (Kohli et al., 2025; Mateus et al., 2025).

Como extensão dessa arquitetura digital, a implementação de gêmeos digitais permite modelar sistemas físicos de forma abrangente, antecipando quebras potenciais antes que danos severos comprometam a integridade dos processos (Kalyon & Börklü, 2025). O uso dessas réplicas virtuais impulsionadas por IA Generativa destaca-se por simular cenários de falha raros e gerar conjuntos de dados sintéticos, superando as limitações históricas de escassez e desequilíbrio de informações no ambiente fabril (Mikołajewska et al., 2025).

Contudo, a adoção em larga escala destas soluções enfrenta a resistência dos operadores, visto que estruturas corporativas convencionais frequentemente

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

negligenciam a intuição humana e critérios de segurança essenciais (Sabuncu & Bilgehan, 2025). Somado a isso, a falta de interoperabilidade entre sistemas legados e plataformas modernas impõe barreiras significativas, demandando investimentos robustos em infraestrutura de rede e cibersegurança para sustentar a confiabilidade da Manutenção 4.0 (Achouch et al., 2022).

A superação desses obstáculos viabiliza a reconfiguração contínua dos algoritmos à medida que novos fluxos de informações são processados, garantindo que as predições mantenham a relevância e a precisão necessárias em ambientes dinâmicos (Wild et al., 2025). Logo, a transição para metodologias orientadas a dados exige estratégias abrangentes de integração, que contemplem desde a coleta sistemática no campo até o refinamento contínuo dos modelos de diagnóstico (Gawde et al., 2023; Jambol et al., 2024), fomentando o desenvolvimento de soluções personalizadas que atendam às especificidades técnicas e operacionais de cada setor industrial (Ohalete et al., 2023).

**2.4 Sensores magnéticos no monitoramento de equipamentos industriais**

Esses dispositivos oferecem alta sensibilidade na detecção de variações de campo magnético causadas por desgastes mecânicos ou desalinhamentos em motores e componentes rotativos. A integração de tais sensores em arquiteturas de IoT possibilita uma captura de dados mais granular e confiável, reduzindo os gargalos de qualidade de informação que frequentemente comprometem a eficácia de modelos preditivos (Baroud, 2024). Contudo, a viabilidade desses sistemas depende da mitigação de desafios técnicos como a heterogeneidade dos dados e a complexidade na fusão de múltiplas fontes de sensoriamento (Haque et al., 2024).

Outro fator crítico é que a dependência exclusiva de conectividade em nuvem introduz riscos significativos à segurança cibernética, levando muitas indústrias a explorar o Edge Computing para processar dados localmente e minimizar a exposição de informações sensíveis (Hamasha et al., 2025). A implementação de uma arquitetura distribuída, que combina de forma equilibrada o processamento na borda e na nuvem, garante tempos de resposta reduzidos para diagnósticos críticos e otimiza a infraestrutura de armazenamento necessária para o treinamento contínuo de modelos complexos de aprendizado de máquina (Allam, 2025). Essa

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

descentralização computacional mitiga problemas de latência e assegura a soberania dos dados ao limitar a necessidade de tráfego constante para servidores remotos (Bala et al., 2024).

Sob essa ótica, a utilização de algoritmos de Inteligência Artificial leve em dispositivos de borda permite a reconstrução de sinais relevantes e a análise de variações operacionais, mesmo em cenários com escassez de dados históricos (USA & Pothireddy, 2025). Em paralelo, os modelos híbridos e baseados em física emergem como soluções robustas para garantir a transparência e a conformidade com leis físicas em domínios críticos, assegurando que o suporte à decisão operacional seja alicerçado em fundamentos técnicos verificáveis (Nieminen et al., 2026).

Nesse cenário, a convergência entre sensores MEMS de baixo consumo e o processamento local viabiliza a implementação de estratégias de monitoramento de vibração altamente eficazes para a identificação precoce de falhas em máquinas rotativas (Romanssini, 2025). A adoção do tratamento local de sinais vibratórios, em detrimento da transmissão integral de dados brutos para a nuvem, permite reduções substanciais no consumo energético e na latência de execução (Romanssini et al., 2025). Ao delegar a extração de características e o diagnóstico de falhas para a periferia da rede, o sistema mitiga a sobrecarga das estruturas de comunicação e otimiza a eficiência do armazenamento em servidores remotos (Gao et al., 2025; Lu et al., 2023).

Essa abordagem descentralizada possibilita diagnósticos em tempo real, permitindo que sistemas críticos de controle intervenham autonomamente milissegundos após a detecção de anomalias operacionais (Kumar, 2025; Qian et al., 2019). Ao integrar o pré-processamento local com modelos de aprendizado profundo, essa arquitetura supera as limitações de latência e redundância de dados típicas das implementações puramente centralizadas (Chen et al., 2025). A aplicação de técnicas de TinyML diretamente em microcontroladores de borda viabiliza a análise espectral de sinais acústicos para a identificação de padrões de danos, eliminando a dependência de infraestruturas de rede críticas (Ech-Chadi et al., 2025; Shirly et al., 2025). Esta capacidade analítica local não apenas eleva a

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

confiabilidade da manutenção preditiva ao permitir diagnósticos contínuos em ambientes de conectividade instável, mas também otimiza a alocação de recursos computacionais para tarefas de monitoramento mais complexas (Walani & Doorsamy, 2025; Zhao & Wang, 2024).

Neste contexto, a implementação de arquiteturas com microcontroladores de baixo custo e alta eficiência energética, como o ESP32 ou o RP2040, demonstra que modelos de redes neurais convolucionais (CNNs) podem operar com precisão elevada mesmo sob restrições severas de memória e processamento (Gupta & Shivhare, 2025; Ūselis et al., 2025). A eficácia dessa estratégia é corroborada por resultados experimentais que demonstram a viabilidade de realizar diagnósticos em tempo real, atingindo índices de precisão superiores a 96% na detecção de falhas em mancais de motores (Arciniegas et al., 2025).

**2.5 Inteligência Artificial aplicada à manutenção industrial**

A Inteligência Artificial aplicada à manutenção industrial consiste no uso de métodos computacionais capazes de reconhecer padrões, classificar estados operacionais, detectar anomalias, estimar vida útil remanescente e apoiar decisões de intervenção.

A integração de sistemas de inteligência artificial na borda, conhecida como Edge-AI, permite a execução de algoritmos de aprendizado de máquina diretamente em dispositivos locais, identificando padrões operacionais e anomalias quase em tempo real sem a necessidade de infraestrutura de nuvem (Strantzalis et al., 2022). Essa descentralização minimiza a latência e reduz drasticamente a largura de banda necessária para a transmissão de dados, assegurando que diagnósticos críticos sejam realizados com total independência de conectividade externa (Annapareddy, 2025; Mennilli et al., 2025). Ademais, a implementação de redes de inferência hierárquicas viabiliza a adaptação dinâmica dos locais de processamento — seja no sensor, no gateway ou na nuvem —, otimizando o consumo energético e a autonomia conforme a criticidade e a complexidade da análise (Fuente et al., 2024, 2025).

A consolidação de frameworks baseados nessa tecnologia facilita a manutenção prognóstica ao antecipar padrões de degradação e reduzir o tempo de inatividade dos ativos industriais (Kumar et al., 2025). Estudos recentes demonstram

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

que essa estrutura distribuída é fundamental para diagnosticar precocemente falhas em máquinas complexas, gerando economia nos custos de reparo e aumentando a produtividade fabril de forma mensurável (Santos et al., 2024; Vermesan et al., 2022). Sob esse prisma, o modelo impulsiona a eficácia das rotinas preditivas ao permitir a inferência contínua sobre a saúde dos equipamentos, transformando dados brutos de sensores em insights acionáveis que mitigam paradas não planejadas (Anusha, 2024; Resende et al., 2021).

A incorporação de gêmeos digitais a essas arquiteturas locais fornece uma estimativa dinâmica da vida útil remanescente, proporcionando uma transição efetiva dos moldes reativos para uma gestão proativa e adaptativa dos sistemas industriais (Lu, 2025). Esse avanço é fortalecido pela capacidade de computar dados de alta frequência coletados em ambientes fabris, o que favorece a identificação precoce de assinaturas de falhas e a antecipação de riscos operacionais de forma automatizada (LAMDJAD & Chaiter, 2026). Logo, o processamento descentralizado não apenas assegura uma resposta mais célere diante de eventos críticos, mas também promove uma infraestrutura mais escalável e resiliente, apta para a integração em ecossistemas de manufatura inteligente (Joydeep, 2025; Thakkar & Kumar, 2024).

### 2.6 Integração de sensores magnéticos e IA na gestão de manutenção preditiva

A integração entre sensores magnéticos e Inteligência Artificial constitui uma arquitetura sociotécnica de manutenção preditiva. No nível físico, sensores captam variações de campo magnético associadas ao funcionamento do ativo. No nível informacional, esses sinais são filtrados, transformados e organizados em bases de dados. No nível analítico, modelos de IA detectam padrões de normalidade e anomalia.

A combinação de sensores de efeito Hall e algoritmos de aprendizado de máquina permite monitorar variações sutis no campo magnético de motores elétricos, viabilizando a identificação de falhas incipientes, como quebras de barras em rotores ou excentricidades, antes que resultem em paradas críticas (Henderson & Sanders, 2025). O processamento local dessas assinaturas eletromagnéticas reduz a dependência de largura de banda, enquanto a aplicação de modelos de

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

aprendizado profundo na borda garante a continuidade da supervisão em ambientes de alta carga, assegurando a confiabilidade operacional (Kovalev et al., 2026; Sathupadi et al., 2024). Essa dinâmica contrai significativamente os custos associados a intervenções corretivas e prolonga a vida útil dos ativos dentro de ecossistemas de manufatura avançada (Alomair, 2025; Sharanya et al., 2022).

A incorporação de redes neurais gráficas sobre esses fluxos de dados magnéticos aprimora a capacidade de reconhecimento de padrões complexos em sistemas interconectados, facilitando a detecção preditiva em tempo real (Patel & Patel, 2025; Prabu et al., 2025). Ao permitir que os dispositivos inteligentes realizem análises de vibração e diagnostiquem falhas localmente, essa convergência tecnológica viabiliza o envio de relatórios refinados para painéis de controle, otimizando a tomada de decisão das equipes de engenharia (Thelen et al., 2022). Sob esse prisma, a fusão estratégica de dados multimodais provenientes de sensores de vibração, pressão e temperatura permite que os algoritmos executem um monitoramento holístico da saúde dos ativos, superando as limitações do sensoriamento isolado (B, 2026). A implementação de grafos de conhecimento, ao integrar essas variáveis multissensoriais ao histórico de manutenção, possibilita diagnósticos preditivos robustos mesmo diante de conjuntos de dados desbalanceados (Wan et al., 2024). Ao articular essa camada de inteligência com protocolos de comunicação interoperáveis, a indústria pavimenta o caminho para a consolidação de sistemas autônomos que prescrevem intervenções otimizadas para maximizar a eficiência operacional (Souza & Silva, 2024).

A democratização dessas ferramentas por meio de plataformas de baixo custo, como o Arduino, torna a manutenção preditiva uma realidade acessível para pequenas e médias empresas (Morenas et al., 2023). Da mesma forma, o uso de microcontroladores como o ESP32 viabiliza a fusão eficiente de dados multimodais voltada à otimização energética e à redução de avarias catastróficas em diversos setores industriais (Rao et al., 2026). A convergência de modelos como Gradient Boosting e Regressão Logística em dispositivos periféricos permite uma classificação precisa de estados operacionais, minimizando falsos positivos durante a triagem contínua (Agarwal et al., 2025).

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

Nesse cenário, abordagens baseadas em Random Forest e redes Long Short-Term Memory (LSTM) têm demonstrado eficácia superior na análise de sequências temporais de vibração e telemetria, alcançando índices de precisão superiores a 94% (Saini et al., 2025). O emprego de classificadores baseados em XGBoost também tem se destacado na análise de telemetria, superando métodos tradicionais por oferecer maior interpretabilidade e acurácia na predição de falhas iminentes (Chinta et al., 2025; Reddy, 2026). Ao utilizar técnicas de otimização de funções objetivo e processamento paralelo, o algoritmo XGBoost garante uma modelagem robusta mesmo diante de volumes expressivos de dados incompletos ou ruidosos (IJERST, 2026; Klieštik et al., 2023).

A implementação de estratégias sensíveis ao custo mitiga o impacto de classes desbalanceadas nos modelos, priorizando a redução de falsos negativos em cenários onde a pane do ativo representa um risco crítico (Hrabovenskyi et al., 2025). A integração dessas técnicas de aprendizado conjunto, ao mesclar a capacidade de extração de características da Random Forest com o processamento de dependências temporais das redes LSTM, estabelece uma estrutura analítica abrangente que otimiza o agendamento de intervenções e a economia de recursos (Sharma et al., 2024). Esta metodologia híbrida antecipa padrões de degradação com exatidão superior ao capturar nuances complexas nos ciclos de vida dos componentes (Maheshwari et al., 2024; Muhammad et al., 2025).

A aplicação prática desses sistemas combinados pode proporcionar reduções de 70% a 85% em paradas não planejadas, aperfeiçoando simultaneamente o cronograma dos técnicos e a gestão de peças de reposição (Reddy, 2026). Essa sinergia entre inteligência computacional e monitoramento contínuo reflete a transição fundamental do paradigma reativo para um modelo de gestão proativa, alinhando a disponibilidade dos ativos às exigências de produtividade da Indústria 4.0 (Li & Ji, 2025; Mahesh et al., 2025).

## METODOLOGIA

### 3.1 Caracterização da pesquisa

Esta pesquisa caracteriza-se como uma Revisão Sistemática da Literatura, de natureza qualitativa, exploratória e descritiva, complementada por análise descritiva

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

e bibliométrica exploratória da produção científica selecionada. A escolha pela revisão sistemática justifica-se pela necessidade de identificar, selecionar, avaliar criticamente e sintetizar, de modo transparente e reprodutível, as evidências científicas relacionadas à integração entre sensores magnéticos, Inteligência Artificial e gestão da manutenção preditiva em ambientes industriais.

A condução da revisão foi orientada pelas recomendações do protocolo PRISMA 2020, que estabelece diretrizes para relatar de forma clara os processos de identificação, triagem, elegibilidade e inclusão dos estudos em revisões sistemáticas (Page et al., 2021). O PRISMA 2020 apresenta checklist de 27 itens e modelos de fluxograma para revisões sistemáticas, sendo adequado para aumentar a transparência e a rastreabilidade do processo de seleção dos estudos. Além disso, a organização metodológica apoia-se nas recomendações de Tranfield, Denyer e Smart (2003), que defendem revisões sistemáticas como estratégia para produção de conhecimento gerencial baseado em evidências, e em Kitchenham (2004), cuja proposta é amplamente utilizada em revisões sistemáticas nas áreas de engenharia, tecnologia e sistemas computacionais.

### 3.2 Protocolo da revisão e transparência metodológica

O protocolo da revisão foi estruturado previamente à etapa de seleção dos estudos e contemplou: definição da questão de pesquisa, escolha das bases de dados, elaboração das strings de busca, definição dos critérios de inclusão e exclusão, remoção de duplicatas, triagem por título e resumo, leitura integral dos textos elegíveis, avaliação da qualidade metodológica e extração dos dados para síntese qualitativa.

As etapas foram organizadas conforme o fluxo PRISMA 2020, compreendendo identificação, triagem, elegibilidade e inclusão dos estudos (Page et al., 2021). Não houve registro prévio do protocolo em plataforma pública específica, como OSF ou PROSPERO. Essa ausência foi reconhecida como limitação metodológica, sendo compensada pela descrição detalhada dos procedimentos adotados, de modo a permitir rastreabilidade e reprodutibilidade da revisão.

### 3.3 Bases de dados, período e data das buscas

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

As buscas foram realizadas nas bases Scopus, Web of Science, IEEE Xplore e ScienceDirect, selecionadas por sua abrangência nas áreas de engenharia, computação, automação, manutenção industrial, sensores, Inteligência Artificial, gestão de ativos e Indústria 4.0. As bases IEEE Xplore e ScienceDirect foram acessadas por meio do Portal de Periódicos CAPES/Café.As buscas foram realizadas entre os meses de maio e junho de 2026. O recorte temporal compreendeu publicações entre 05/2015 e 05/2026, período definido por abranger a consolidação da Indústria 4.0 e a ampliação das aplicações de sensores inteligentes, Internet das Coisas, Machine Learning e Deep Learning na manutenção preditiva. Estudos publicados em 2026 não compuseram a amostra sistemática, utilizados apenas como literatura contextual complementar, quando necessários à atualização conceitual, sem integrar a matriz analítica dos estudos selecionados.

### 3.4 Estratégias de busca e campos pesquisados

Foram utilizados descritores em inglês e português, combinados por operadores booleanos. As strings foram adaptadas às especificidades de cada base, considerando os campos disponíveis para busca em título, resumo, palavras-chave e metadados. A estratégia principal em inglês foi construída com os seguintes blocos conceituais: manutenção preditiva; sensores magnéticos; Inteligência Artificial; e contexto industrial/gestão de ativos.

**Quadro 1 – Estratégias de busca utilizadas nas bases selecionadas**

| Base | Campo pesquisado | String utilizada | Filtros aplicados |
|---|---|---|---|
| Scopus | TITLE-ABS-KEY | ("predictive maintenance" OR "condition-based maintenance" OR "condition monitoring" OR "fault diagnosis") AND ("magnetic sensor*" OR "magnetic field sensor*" OR "Hall effect sensor*" OR "stray flux" OR "magnetic flux leakage") AND ("artificial intelligence" OR "machine learning" OR "deep learning" OR "neural network*") AND ("Industry 4.0" OR "industrial management" OR "asset management" OR "manufacturing") | 05/2015–05/2026; artigos, revisões e conference papers; inglês, português ou espanhol; áreas de engenharia, computação, decisão, gestão e manufatura |
| Web of Science | Topic — TS | TS=("predictive maintenance" OR "condition-based maintenance" OR "condition monitoring" OR "fault diagnosis") AND TS=("magnetic sensor*" OR "magnetic field sensor*" OR "Hall effect sensor*" OR "stray flux" OR "magnetic flux leakage") AND | 05/2015–05/2026; article, review article e proceedings paper; inglês, português ou espanhol |

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

| Base | Campo pesquisado | String utilizada | Filtros aplicados |
|---|---|---|---|
| | | TS=("artificial intelligence" OR "machine learning" OR "deep learning" OR "neural network*") AND TS=("Industry 4.0" OR "industrial management" OR "asset management" OR "manufacturing") | |
| IEEE Xplore | All Metadata | ("predictive maintenance" OR "condition-based maintenance" OR "condition monitoring") AND ("magnetic sensor" OR "magnetic field sensor" OR "Hall effect sensor" OR "stray flux" OR "magnetic flux leakage") AND ("artificial intelligence" OR "machine learning" OR "deep learning") | 05/2015–05/2026; journals e conferences; engenharia elétrica, computação, sensores e sistemas industriais |
| ScienceDirect | Title, Abstract, Keywords | ("predictive maintenance" OR "condition-based maintenance") AND ("magnetic sensor" OR "magnetic field sensor" OR "Hall effect sensor" OR "stray flux" OR "magnetic flux leakage") AND ("artificial intelligence" OR "machine learning" OR "deep learning") AND ("Industry 4.0" OR "asset management") | 05/2015–05/2026; research articles e review articles; engenharia, computação, energia, manufatura e gestão industrial |

**Fonte:** elaborado pelos autores.

Também foi utilizada uma string complementar em português para ampliar a recuperação de estudos nacionais e ibero-americanos:

("manutenção preditiva" OR "manutenção baseada em condição" OR "monitoramento de condição") AND ("sensores magnéticos" OR "sensor de campo magnético" OR "sensor de efeito Hall" OR "fluxo disperso") AND ("inteligência artificial" OR "aprendizado de máquina" OR "machine learning" OR "deep learning") AND ("Indústria 4.0" OR "gestão industrial" OR "gestão de ativos").

### 3.5 Critérios de inclusão e exclusão

Os critérios de inclusão e exclusão foram definidos antes da triagem dos registros, com o objetivo de assegurar coerência entre a pergunta de pesquisa, o recorte temporal e o escopo temático da revisão.

**Quadro 2 – Critérios de inclusão**

| Código | Critério de inclusão |
|---|---|
| CI1 | Artigos publicados em periódicos científicos ou conferências revisadas por pares |
| CI2 | Publicações em português, inglês ou espanhol |
| CI3 | Estudos publicados entre 2015 e 2025 |
| CI4 | Estudos que abordam manutenção preditiva, manutenção baseada em condição, monitoramento de condição, diagnóstico de falhas ou prognóstico de falhas |

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

| Código | Critério de inclusão |
|---|---|
| CI5 | Estudos que utilizam sensores magnéticos, sensores de campo magnético, sensores de efeito Hall, fluxo disperso ou técnicas correlatas de medição magnética |
| CI6 | Estudos que empregam Inteligência Artificial, Machine Learning, Deep Learning ou modelos híbridos para análise preditiva |
| CI7 | Estudos aplicados ao contexto industrial, manufatura, motores elétricos, máquinas rotativas, sistemas eletromecânicos ou gestão de ativos |
| CI8 | Estudos com texto completo disponível e informações suficientes sobre método, aplicação ou resultados |

**Fonte:** elaborado pelos autores.

**Quadro 3 – Critérios de exclusão**

| Código | Critério de exclusão |
|---|---|
| CE1 | Artigos duplicados entre as bases |
| CE2 | Estudos fora do recorte temporal 2015–2025 |
| CE3 | Estudos sem relação direta com manutenção preditiva, diagnóstico de falhas ou monitoramento de condição |
| CE4 | Estudos focados exclusivamente em sensores não magnéticos, sem conexão com IA ou gestão da manutenção |
| CE5 | Editoriais, resumos expandidos, notas técnicas, textos opinativos, white papers corporativos e documentos sem revisão por pares |
| CE6 | Preprints, repositórios abertos e literatura cinzenta sem comprovação de revisão por pares, quando tratados como evidência sistemática |
| CE7 | Estudos sem acesso ao texto completo |
| CE8 | Estudos com baixa qualidade metodológica conforme a matriz de avaliação crítica adotada |

**Fonte:** elaborado pelos autores

### 3.6 Gerenciamento dos registros e remoção de duplicatas

Os resultados das buscas foram exportados das bases em formato RIS, BibTeX ou CSV e organizados em planilha de controle bibliográfico. A remoção de duplicatas foi realizada em duas etapas. Inicialmente, aplicou-se verificação automatizada por título, DOI e autores. Em seguida, foi feita conferência manual para identificar duplicidades não detectadas automaticamente, especialmente registros com pequenas variações no título, abreviação de periódicos, grafia de autores ou ausência de DOI.

A remoção de duplicatas considerou, prioritariamente, os seguintes campos: DOI, título, autores, ano de publicação e fonte. Esse procedimento segue recomendações metodológicas para revisões sistemáticas, nas quais a deduplicação deve combinar mecanismos automatizados e conferência manual para reduzir perdas ou duplicações indevidas de registros (Bramer et al., 2016).

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

### 3.7 Processo de seleção dos estudos

A busca inicial identificou 300 registros nas bases selecionadas. Após a remoção de 74 registros duplicados, permaneceram 226 registros para triagem por título, resumo e palavras-chave. Nessa etapa, foram excluídos 151 registros por baixa aderência ao tema, ausência de sensores magnéticos, ausência de aplicação em manutenção preditiva ou falta de relação com Inteligência Artificial.

Em seguida, 75 estudos foram avaliados em texto completo. Após a leitura integral, 55 estudos foram excluídos por não atenderem aos critérios de elegibilidade, especialmente por apresentarem foco exclusivo em sensores não magnéticos, ausência de aplicação industrial, ausência de IA aplicada à análise dos dados ou baixa qualidade metodológica. A amostra final foi composta por 20 estudos, incluídos na síntese qualitativa e na análise descritiva/bibliométrica exploratória.

A triagem foi realizada por três revisores independentes. Em caso de divergência entre os revisores, a decisão foi tomada por consenso. Quando o consenso não foi alcançado, um terceiro avaliador foi consultado para decisão final. Esse procedimento foi adotado para reduzir vieses individuais de seleção e aumentar a confiabilidade da elegibilidade dos estudos.

### 3.8 Avaliação da qualidade metodológica dos estudos incluídos

A qualidade metodológica dos estudos incluídos foi avaliada por meio de uma matriz crítica adaptada às características de revisões em tecnologia, engenharia e gestão. A matriz considerou critérios inspirados nas recomendações de revisões sistemáticas de Kitchenham (2004), Tranfield et al. (2003) e no uso de instrumentos de avaliação crítica para estudos com diferentes desenhos metodológicos, como o Mixed Methods Appraisal Tool — MMAT (Hong et al., 2018). O MMAT é utilizado para apreciação crítica de estudos qualitativos, quantitativos e mistos, sendo útil quando a amostra reúne diferentes tipos de desenho de pesquisa.

Cada estudo foi avaliado segundo oito critérios, com pontuação de 0 a 2: 0 = ausente; 1 = parcialmente atendido; 2 = plenamente atendido.

**Quadro 4 – Matriz de avaliação crítica dos estudos incluídos**

| Critério | Descrição |
|---|---|
| C1 | Aderência direta à pergunta de pesquisa |
| C2 | Clareza do objetivo e do desenho metodológico |

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

| Critério | Descrição |
|---|---|
| C3 | Presença de aplicação industrial ou contexto técnico claramente definido |
| C4 | Descrição do tipo de sensor utilizado ou da fonte de dados de monitoramento |
| C5 | Descrição do algoritmo de IA, Machine Learning ou Deep Learning empregado |
| C6 | Presença de validação experimental, base de dados, estudo empírico ou aplicação simulada consistente |
| C7 | Apresentação de métricas de desempenho ou evidências de resultado |
| C8 | Discussão de limitações técnicas, metodológicas ou gerenciais |

**Fonte:** elaborado pelos autores.

A pontuação máxima possível foi de 16 pontos. Os estudos foram classificados em três níveis: alta qualidade metodológica, quando obtiveram entre 13 e 16 pontos; qualidade moderada, entre 9 e 12 pontos; e baixa qualidade, com pontuação inferior a 9. Estudos classificados como de baixa qualidade foram excluídos da síntese sistemática ou utilizados apenas como apoio contextual, quando pertinente.

### 3.9 Extração e organização dos dados

Após a definição da amostra final, os dados dos estudos selecionados foram extraídos com base em um formulário padronizado. Foram registrados: autores, ano, título, base de origem, tipo de publicação, DOI, tipo de estudo, ativo industrial analisado, tipo de sensor magnético empregado, algoritmo de IA utilizado, tarefa realizada pelo modelo, métricas de desempenho, base de dados utilizada, principais resultados, limitações metodológicas e contribuição para a gestão da manutenção.

Essa etapa permitiu organizar a síntese dos estudos em uma matriz analítica, evitando que a discussão permanecesse apenas narrativa ou genérica. A matriz foi utilizada para comparar sensores magnéticos, aplicações industriais, algoritmos de IA, ativos monitorados, benefícios gerenciais e limitações técnicas.

A matriz analítica não foi utilizada apenas como instrumento de registro dos estudos, mas como base para a construção da análise comparativa apresentada nos resultados. A partir dela, foi possível relacionar cada estudo aos objetivos específicos da pesquisa, identificando quais evidências sustentavam a discussão sobre sensores magnéticos, algoritmos de Inteligência Artificial, ativos monitorados, métricas de desempenho, benefícios gerenciais e limitações técnicas. Assim, a matriz funcionou como elo metodológico entre a seleção dos estudos e a interpretação dos achados.

### 3.10 Procedimentos de análise dos dados

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

A análise dos dados foi realizada em três etapas complementares: caracterização descritiva da amostra, síntese qualitativa dos estudos e análise descritiva/bibliométrica exploratória dos metadados. Essas etapas foram conduzidas com base na matriz analítica dos 20 estudos incluídos na revisão sistemática, a qual funcionou como instrumento central de organização, comparação e interpretação das evidências. Dessa forma, buscou-se evitar que os resultados fossem apresentados apenas de maneira narrativa ou genérica, assegurando maior rastreabilidade entre a pergunta de pesquisa, os objetivos específicos, os estudos selecionados e os achados discutidos.

Na primeira etapa, procedeu-se à caracterização descritiva da amostra. Foram considerados ano de publicação, base de indexação, tipo de documento, área temática, tipo de estudo, ativo monitorado, tipo de sensor utilizado, algoritmo empregado e métrica de desempenho reportada. Essa etapa permitiu identificar o perfil geral dos estudos incluídos, bem como distinguir aqueles diretamente relacionados a sensores magnéticos daqueles que abordavam manutenção preditiva e Inteligência Artificial de forma mais ampla. Essa distinção foi necessária para que estudos contextuais não fossem interpretados com o mesmo peso analítico dos estudos diretamente vinculados ao foco central do artigo.

Na segunda etapa, realizou-se a síntese qualitativa dos estudos, agrupando os achados em quatro categorias analíticas: sensores magnéticos aplicados à manutenção preditiva; algoritmos de Inteligência Artificial utilizados; integração entre sensores e modelos inteligentes; e benefícios, desafios e limitações gerenciais. Essas categorias foram definidas a partir da pergunta de pesquisa e dos objetivos específicos do estudo. A matriz analítica permitiu comparar, em cada categoria, os tipos de sensores empregados, os ativos industriais monitorados, as tarefas realizadas pelos modelos de IA, as métricas apresentadas, as limitações metodológicas e as contribuições para a gestão da manutenção.

Na análise dos sensores magnéticos, foram observados os estudos que abordavam sensores de efeito Hall, sensores de campo magnético, medições de fluxo no entreferro e técnicas de fluxo magnético disperso. A comparação considerou o tipo de ativo monitorado, as falhas identificadas, as condições de aplicação e as

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

limitações técnicas descritas pelos autores. Na análise dos algoritmos de IA, foram examinadas as técnicas utilizadas, tais como Machine Learning, Deep Learning, redes neurais, modelos de classificação, detecção de anomalias, prognóstico e estimativa de vida útil remanescente. Essa organização permitiu relacionar cada algoritmo à sua finalidade na manutenção preditiva.

Ainda na segunda etapa, os estudos foram analisados quanto às implicações gerenciais da integração sensores–IA. Para isso, foram considerados os resultados relacionados ao apoio à tomada de decisão, priorização de ativos críticos, planejamento de intervenções, redução de paradas não programadas, gestão de peças, confiabilidade operacional e melhoria da disponibilidade dos equipamentos. Assim, a matriz dos 20 estudos foi utilizada não apenas para descrever tecnologias, mas para interpretar como os achados técnicos podem ser convertidos em decisões gerenciais no contexto da manutenção preditiva.

Na terceira etapa, foi realizada análise descritiva/bibliométrica exploratória dos metadados dos estudos incluídos, com foco em palavras-chave, recorrência temática e relações de coautoria. Considerando o tamanho reduzido da amostra final, composta por 20 estudos, os resultados bibliométricos foram interpretados de forma cautelosa e complementar, sem pretensão de representar a estrutura completa do campo científico. Essa etapa teve a finalidade de apoiar a visualização de padrões temáticos e agrupamentos de autoria, enquanto a síntese qualitativa constituiu a base principal da discussão dos resultados.

Além disso, a análise dos dados considerou a avaliação da qualidade metodológica dos estudos incluídos. Estudos com maior aderência à pergunta de pesquisa, descrição clara do sensor utilizado, explicitação do algoritmo de IA, presença de validação experimental ou aplicação simulada consistente, apresentação de métricas e discussão de limitações foram tratados como evidências mais robustas na síntese. Já estudos mais amplos, conceituais ou com menor detalhamento técnico foram utilizados com maior cautela, especialmente como apoio contextual ou complementar.

Dessa forma, os resultados apresentados no artigo derivaram diretamente do cruzamento das informações registradas na matriz analítica. A caracterização dos

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

estudos incluídos foi construída a partir das variáveis bibliográficas e metodológicas; a discussão sobre sensores magnéticos resultou da comparação entre sensores, ativos e falhas; a análise dos algoritmos de IA decorreu da relação entre modelos, tarefas e métricas; e a discussão sobre benefícios, desafios e limitações foi elaborada com base nas evidências técnicas, operacionais e gerenciais recorrentes nos estudos selecionados.

### 3.11 Fluxo PRISMA de seleção dos estudos

Na busca foram encontrados 300 registros nas bases selecionadas. Após a remoção de duplicidades, os registros foram avaliados em duas etapas: primeiro, leitura de título, resumo e palavras-chave; segundo, leitura integral dos estudos potencialmente elegíveis. A síntese final ficou composta pelos 20 estudos de maior aderência ao objetivo do artigo, considerando qualidade metodológica, centralidade temática, uso de sensores ou dados industriais, aplicação de IA e contribuição para a gestão da manutenção.

Quadro 01 - O processo de seleção seguiu o fluxo PRISMA, conforme descrito a seguir:

| **Etapa PRISMA** | **Procedimento** | **Quantidade** |
|---|---|---|
| Identificação | Registros identificados nas bases Web of Science, Scopus, IEEE Xplore e ScienceDirect | 300 |
| Triagem | Registros após remoção de duplicados | 226 |
| Triagem | Registros excluídos por título e resumo | 151 |
| Elegibilidade | Artigos avaliados em texto completo | 75 |
| Elegibilidade | Artigos excluídos por baixa aderência, ausência de aplicação industrial ou foco em sensores não magnéticos | 55 |
| Inclusão | Estudos incluídos na síntese qualitativa e bibliométrica | 20 |

**Fonte: elaborado pelos autores**

**Quadro 02 - As 20 publicações selecionadas/recomendadas para a síntese**

| Nº | Autor(es) | Ano | Título | Base/Fonte | Palavras-chave | DOI |
|---|---|---|---|---|---|---|
| 1 | Zonta, T.; da Costa, C. A.; Righi, R. R.; de Lima, M. J.; da | 2020 | Predictive maintenance in the Industry 4.0: A | Scopus / Web of Science / ScienceDirect | predictive maintenance; Industry 4.0; systematic literature review; | 10.1016/j.cie.2020.106889 |

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

| | | | | | | |
|---|---|---|---|---|---|---|
| | Trindade, E. S.; Li, G. P. | | systematic literature review | | condition monitoring; IoT | |
| 2 | Carvalho, T. P.; Soares, F. A. A. M. N.; Vita, R.; Francisco, R. P.; Basto, J. P.; Alcalá, S. G. S. | 2019 | A systematic literature review of machine learning methods applied to predictive maintenance | Scopus / Web of Science / ScienceDirect | predictive maintenance; machine learning; artificial intelligence; systematic literature review | 10.1016/j.cie.2019.106024 |
| 3 | Çınar, Z. M.; Nuhu, A. A.; Zeeshan, Q.; Korhan, O.; Asmael, M.; Safaei, B. | 2020 | Machine learning in predictive maintenance towards sustainable smart manufacturing in Industry 4.0 | Scopus / Web of Science | machine learning; predictive maintenance; smart manufacturing; Industry 4.0; sustainability | 10.3390/su12198211 |
| 4 | Achouch, M.; Dimitrova, M.; Ziane, K.; Sattarpanah Karganroudi, S.; Dhouib, R.; Ibrahim, H.; Adda, M. | 2022 | On predictive maintenance in Industry 4.0: Overview, models, and challenges | Scopus / Web of Science | predictive maintenance; Industry 4.0; CBM; PHM; RUL; challenges | 10.3390/app12168081 |
| 5 | Dalzochio, J.; Kunst, R.; Pignaton, E.; Binotto, A.; Sanyal, S.; Favilla, J.; Barbosa, J. | 2020 | Machine learning and reasoning for predictive maintenance in Industry 4.0: Current status and challenges | Scopus / Web of Science / ScienceDirect | machine learning; reasoning; predictive maintenance; Industry 4.0; challenges | 10.1016/j.compind.2020.103298 |
| 6 | Lei, Y.; Yang, B.; Jiang, X.; Jia, F.; Li, N.; Nandi, A. K. | 2020 | Applications of machine learning to machine fault diagnosis: A review and roadmap | Scopus / Web of Science / ScienceDirect | machine learning; fault diagnosis; deep learning; transfer learning; roadmap | 10.1016/j.ymssp.2019.106587 |
| 7 | Hector, I.; Panjanathan, R. | 2024 | Predictive maintenance in Industry 4.0: A | Scopus / PubMed / PeerJ | predictive maintenance; planning | 10.7717/peerj-cs.2016 |

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

| | | | | | | |
|---|---|---|---|---|---|---|
| | | | survey of planning models and machine learning techniques | | models; machine learning; Industry 4.0 | |
| 8 | Ruschel, E.; Santos, E. A. P.; Loures, E. F. R. | 2017 | Industrial maintenance decision-making: A systematic literature review | Scopus / Web of Science / ScienceDirect | industrial maintenance; decision-making; systematic literature review; maintenance management | 10.1016/j.jmsy.2017.09.003 |
| 9 | Mazaheri-Tehrani, E.; Faiz, J.; Sharifian, M. B. B. | 2022 | Airgap and stray magnetic flux monitoring techniques for fault diagnosis of electrical machines: An overview | Scopus / Web of Science / IET-Wiley | airgap flux; stray flux; magnetic flux; fault diagnosis; electrical machines | 10.1049/elp2.12157 |
| 10 | Zamudio-Ramírez, I.; Antonino-Daviu, J. A.; Osornio-Rios, R. A.; Quijano-Lopez, A.; Romero-Troncoso, R. J. | 2020 | Smart-sensor for the automatic detection of electromechanical faults in induction motors based on the transient stray flux analysis | Scopus / Web of Science | smart sensor; stray flux; induction motor; fault diagnosis; neural network | 10.3390/s20051477 |
| 11 | AlShorman, O.; Irfan, M.; Saad, N.; Zhen, D.; Haider, N.; Glowacz, A.; AlShorman, A. | 2020 | A review of artificial intelligence methods for condition monitoring and fault diagnosis of rolling element bearings for induction motors | Scopus / Web of Science | artificial intelligence; condition monitoring; fault diagnosis; bearings; induction motor | 10.1155/2020/8843759 |
| 12 | Kumar, R. R.; Andriollo, M.; Cirrincione, G.; Cirrincione, M.; Tortella, A. | 2022 | A comprehensive review of conventional and intelligence-based approaches for the fault diagnosis and condition monitoring of induction motors | Scopus / Web of Science | induction motors; fault diagnosis; condition monitoring; artificial intelligence | 10.3390/en15238938 |

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

| | | | | | | |
|---|---|---|---|---|---|---|
| 13 | Kibrete, F.; Woldemichael, D. E.; Gebremedhen, H. S. | 2024 | Multi-sensor data fusion in intelligent fault diagnosis of rotating machines: A comprehensive review | Scopus / Web of Science / ScienceDirect | multi-sensor data fusion; rotating machines; intelligent fault diagnosis; machine learning | 10.1016/j.measurement.2024.114658 |
| 14 | Hamani, K.; Kuchar, M.; Kubatko, M.; Kirschner, S. | 2025 | Advancements in induction motor fault diagnosis and condition monitoring: A comprehensive review | Scopus / Web of Science | induction motor; condition monitoring; fault diagnosis; sensors; artificial intelligence | 10.3390/s25195942 |
| 15 | Louzada, A. O.; et al. | 2025 | Detection of stator faults in three-phase induction motors using stray flux measurement and machine learning | Scopus / Web of Science | stator faults; induction motor; stray flux; machine learning; predictive maintenance | 10.3390/en18061516 |
| 16 | Ullah, N.; Abbas, M. F.; Kazmi, S. A. A.; et al. | 2023 | Machine learning based fault classification using stray flux and stator current in induction motor | IEEE Xplore | machine learning; stray flux; stator current; induction motor; fault classification | 10.1109/ICAI58407.2023.10136678 |
| 17 | Zhu, T.; Ran, Y.; Zhou, X.; Wen, Y.; Deng, G. | 2019 | A survey of predictive maintenance: Systems, purposes and approaches | arXiv / Google Scholar | predictive maintenance; systems; maintenance strategy; machine learning; condition-based maintenance | 10.48550/arXiv.1912.07383 |
| 18 | Krupitzer, C.; Wagenhals, T.; Züfle, M.; Lesch, V.; Schäfer, D.; Mozaffarin, A.; Edinger, J.; Becker, C.; Kounev, S. | 2020 | A survey on predictive maintenance for Industry 4.0 | arXiv / Google Scholar | predictive maintenance; Industry 4.0; industrial IoT; smart maintenance; survey | 10.48550/arXiv.2002.08224 |
| 19 | Chevtchenko, S. F.; dos Santos, M. | 2023 | Predictive maintenance model based on | arXiv / Google Scholar | anomaly detection; induction motors; IoT; machine learning; | 10.48550/arXiv.2310.14949 |

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

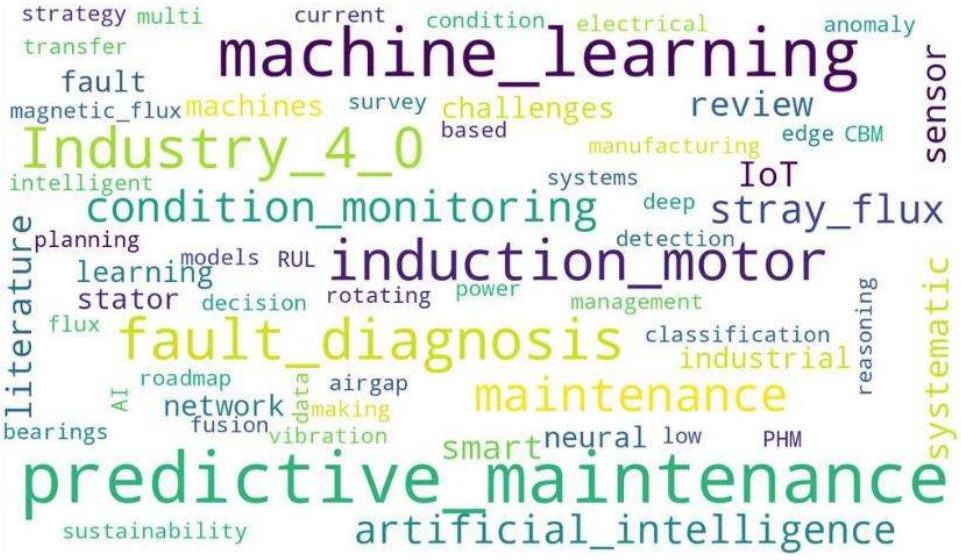
| | | | | | | |
|---|---|---|---|---|---|---|
| | C. M.; Vieira, D. M.; Mota, R. L.; Rocha, E.; Cruz, B. V.; Araújo, D.; Andrade, E. | | anomaly detection in induction motors: A machine learning approach using real-time IoT data | | predictive maintenance | |
| 20 | Vasilache, A.; Nitzsche, S.; Floegel, D.; Schuerman n, T.; von Dosky, S.; Bierweiler, T.; Mußler, M.; Kälber, F.; Hohmann, S.; Becker, J. | 202 4 | Low-power vibration-based predictive maintenance for Industry 4.0 using neural networks: A survey | arXiv / Google Scholar | low-power; vibration; predictive maintenance; neural networks; edge AI; Industry 4.0 | 10.48550/arXiv .2408.00516 |

**Fonte: elaborado pelos autores**

### 3.12 Nuvem de palavras-chave

A nuvem de palavras-chave foi desenvolvida a partir dos termos recorrentes no quadro de publicações. O resultado evidencia a centralidade de manutenção preditiva, machine learning, diagnóstico de falhas, monitoramento de condição, motores de indução e fluxo magnético/stray flux.

**Figura 01 – Nuvem de palavras**



REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

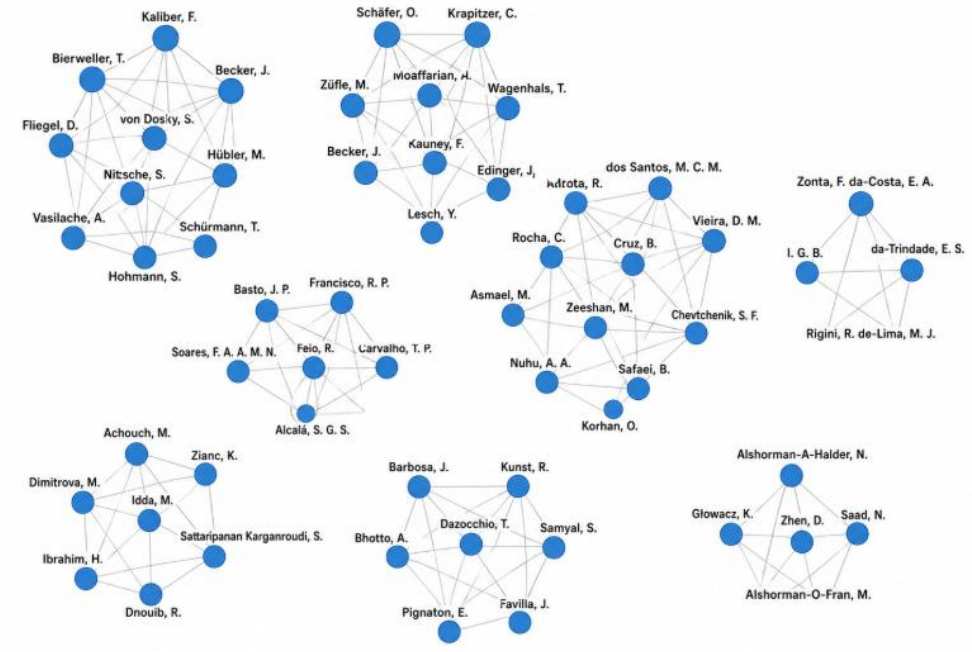
**Fonte: elaborado pelos autores**

### 3.13 Rede de coautoria

A rede de coautoria foi elaborada a partir dos autores identificados no quadro das 20 publicações selecionadas para a síntese da revisão sistemática e bibliométrica. Nessa representação, cada nó corresponde a um autor e cada aresta indica a existência de colaboração científica entre autores de uma mesma publicação. O tamanho dos nós reflete o número de conexões estabelecidas na rede, permitindo visualizar quais autores ocupam posições mais centrais dentro dos agrupamentos de colaboração.

A análise evidencia que a produção científica sobre manutenção preditiva, Inteligência Artificial e sensores magnéticos apresenta uma estrutura fragmentada em diferentes clusters de pesquisa. Esses agrupamentos correspondem, em grande parte, às equipes responsáveis por estudos específicos sobre manutenção preditiva na Indústria 4.0, métodos de Machine Learning aplicados ao diagnóstico de falhas, monitoramento de condição em motores de indução, uso de fluxo magnético disperso e aplicações de sensores inteligentes em ambientes industriais.

**Figura 02 - Rede de coautoria**




**Fonte: elaborado pelos autores**

## 4. Resultados e Discussão

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

Esta seção apresenta os resultados da revisão sistemática a partir dos 20 estudos incluídos na amostra final. Diferentemente de uma discussão narrativa ampla sobre manutenção preditiva, os achados foram reorganizados com foco na relação específica entre sensores magnéticos, algoritmos de Inteligência Artificial e gestão da manutenção preditiva. A análise foi estruturada em seis eixos: caracterização dos estudos incluídos; sensores magnéticos aplicados à manutenção preditiva; algoritmos de IA identificados; integração sensores–IA e implicações gerenciais; benefícios, desafios e limitações; e proposição de framework integrador.

Essa reorganização responde diretamente à necessidade de demonstrar, de forma mais clara, quais evidências sustentam cada achado, evitando afirmações genéricas do tipo “a literatura mostra que” sem explicitar a base empírica, técnica ou metodológica dos estudos analisados.

### 4.1 Caracterização dos estudos incluídos

A amostra final foi composta por 20 publicações selecionadas a partir das bases Scopus, Web of Science, IEEE Xplore e ScienceDirect. Os estudos incluídos apresentam três perfis principais: revisões sistemáticas e surveys sobre manutenção preditiva na Indústria 4.0; estudos sobre algoritmos de Machine Learning e Deep Learning aplicados ao diagnóstico de falhas; e estudos específicos sobre sensores magnéticos, fluxo disperso, fluxo no entreferro e monitoramento de máquinas elétricas.

O Quadro 04 do artigo já apresenta autores, ano, título, base/fonte, palavras-chave e DOI dos estudos incluídos, com destaque para trabalhos como Zonta et al. (2020), Carvalho et al. (2019), Çınar et al. (2020), Achouch et al. (2022), Dalzochio et al. (2020), Lei et al. (2020), Ruschel et al. (2017), Mazaheri-Tehrani et al. (2022), Zamudio-Ramírez et al. (2020), AlShorman et al. (2020), Kumar et al. (2022) e Kibrete et al. (2024). Esses estudos formam a base principal para a síntese qualitativa e técnica da revisão.

A análise da amostra evidencia que parte significativa dos estudos possui caráter de revisão ou levantamento do estado da arte, abordando manutenção preditiva, diagnóstico de falhas e modelos de IA de forma abrangente. Por outro lado, os estudos mais diretamente associados ao título do artigo são aqueles que tratam

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

de fluxo magnético disperso, fluxo no entreferro, sensores inteligentes, motores de indução e máquinas rotativas. Essa distinção é relevante porque nem todos os estudos incluídos tratam especificamente de sensores magnéticos; alguns abordam manutenção preditiva e IA de modo mais amplo, servindo como base contextual e metodológica.

**Quadro 03 – Organização analítica dos estudos incluídos**

| Eixo de análise | Estudos associados | Contribuição para o artigo | Limitação observada |
|---|---|---|---|
| Revisões sobre manutenção preditiva e Indústria 4.0 | Zonta et al. (2020); Achouch et al. (2022); Çınar et al. (2020) | Fundamentam o papel da manutenção preditiva em ambientes digitais e conectados | Nem sempre aprofundam sensores magnéticos |
| Machine Learning aplicado à manutenção | Carvalho et al. (2019); Lei et al. (2020); Dalzochio et al. (2020) | Organizam algoritmos, tarefas preditivas e desafios de aprendizagem de máquina | Forte foco algorítmico, com menor discussão gerencial |
| Decisão e gestão da manutenção | Ruschel et al. (2017); Hector e Panjanathan (2024) | Conectam manutenção preditiva à tomada de decisão, planejamento e gestão industrial | Pouca especificidade sobre sensores magnéticos |
| Sensoriamento magnético e máquinas elétricas | Mazaheri-Tehrani et al. (2022); Zamudio-Ramírez et al. (2020) | Sustentam o eixo distintivo do artigo: fluxo disperso, fluxo no entreferro e motores de indução | Aplicações concentradas em máquinas elétricas |
| Diagnóstico de falhas em motores e rolamentos | AlShorman et al. (2020); Kumar et al. (2022); Kibrete et al. (2024) | Relacionam sensores, fusão de dados e diagnóstico inteligente de falhas | Heterogeneidade de sensores e métricas |

**Fonte:** elaborado pelos autores

Essa caracterização permite afirmar que a contribuição do artigo não está apenas em revisar manutenção preditiva com IA, mas em evidenciar como sinais eletromagnéticos capturados por sensores magnéticos podem alimentar modelos inteligentes de diagnóstico, prognóstico e suporte à decisão gerencial.

### 4.2 Sensores magnéticos aplicados à manutenção preditiva

Os estudos analisados indicam que os sensores magnéticos são particularmente relevantes no monitoramento de motores elétricos, motores de indução, máquinas rotativas e sistemas eletromecânicos. Esses sensores captam variações no campo magnético associadas a alterações no comportamento físico e elétrico dos ativos, permitindo identificar indícios de falhas antes que elas evoluam para paradas críticas.

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

A revisão permitiu organizar os sensores e técnicas magnéticas em quatro grupos principais: sensores de efeito Hall, sensores de campo magnético, medições de fluxo no entreferro e técnicas de fluxo magnético disperso. Essa classificação atende à recomendação dos avaliadores de tornar os sensores magnéticos o eixo distintivo do artigo, evitando que a discussão se torne uma revisão genérica sobre IA e manutenção preditiva.

**Quadro 04 – Sensores magnéticos identificados e aplicações na manutenção preditiva**

| Tipo de sensor ou técnica | Aplicação predominante | Falhas associadas | Potencial para gestão da manutenção |
|---|---|---|---|
| Sensor de efeito Hall | Medição de variações de campo magnético em motores e sistemas eletromecânicos | Alterações de campo, variações de corrente, falhas elétricas incipientes | Monitoramento contínuo e geração de alertas de anomalia |
| Sensor de campo magnético | Captura de assinaturas eletromagnéticas em ativos rotativos | Desbalanceamento eletromagnético, degradação de componentes e assimetrias | Apoio à priorização de inspeções e intervenções |
| Fluxo magnético no entreferro | Monitoramento de máquinas elétricas e motores de indução | Falhas no rotor, estator, excentricidade e irregularidades eletromecânicas | Diagnóstico técnico mais refinado de ativos críticos |
| Fluxo magnético disperso | Detecção de alterações externas no campo magnético da máquina | Barras quebradas, excentricidade, falhas eletromecânicas e degradação progressiva | Planejamento antecipado de manutenção e redução de paradas não programadas |
| Sensores inteligentes integrados | Dispositivos com aquisição, pré-processamento e comunicação de dados | Anomalias multivariadas e falhas combinadas | Integração com sistemas de gestão, painéis e ordens de serviço |

**Fonte:** elaborado pelos autores.

Os estudos específicos sobre fluxo no entreferro e fluxo magnético disperso são centrais porque demonstram que sensores magnéticos podem detectar assinaturas eletromagnéticas de falhas que, em muitos casos, antecedem manifestações mecânicas mais evidentes. Mazaheri-Tehrani et al. (2022) contribuem ao sistematizar técnicas de monitoramento por fluxo no entreferro e fluxo disperso em máquinas elétricas, enquanto Zamudio-Ramírez et al. (2020) apresentam

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

aplicação de sensor inteligente para detecção automática de falhas eletromecânicas em motores de indução com base na análise de fluxo disperso.

Entretanto, os sensores magnéticos também apresentam limitações. Sua efetividade depende da posição de instalação, da sensibilidade do sensor, das condições de carga do equipamento, da qualidade do sinal captado, do ruído eletromagnético do ambiente e da capacidade de pré-processamento dos dados. Além disso, em alguns contextos, o sensoriamento magnético deve ser combinado com vibração, corrente, temperatura ou acústica para aumentar a robustez diagnóstica. Assim, os sensores magnéticos não substituem necessariamente outras modalidades sensoriais, mas podem complementar arquiteturas de monitoramento preditivo em ativos eletromecânicos.

### 4.3 Algoritmos de IA identificados

Os algoritmos de Inteligência Artificial identificados nos estudos incluídos foram organizados segundo sua finalidade analítica. Essa taxonomia atende diretamente à recomendação da avaliação, que apontou que o manuscrito apenas listava algoritmos como Random Forest, SVM, KNN, XGBoost, CNN e LSTM, sem classificá-los por função no processo de manutenção preditiva.

**Quadro 05 – Taxonomia dos algoritmos de IA aplicados à manutenção preditiva**

| Finalidade analítica | Algoritmos identificados | Função na manutenção preditiva | Contribuição gerencial |
|---|---|---|---|
| Classificação de falhas | SVM, Random Forest, KNN, Decision Trees, XGBoost, redes neurais | Classificar estados operacionais como normal, alerta ou falha | Apoiar decisões sobre urgência da intervenção |
| Detecção de anomalias | Modelos não supervisionados, redes neurais, métodos baseados em padrões | Identificar desvios em relação ao comportamento normal do ativo | Reduzir atrasos na identificação de falhas incipientes |
| Predição temporal | LSTM, redes recorrentes, modelos de séries temporais | Antecipar tendência de degradação e evolução da falha | Planejar janelas de parada e alocação de equipes |

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

| Finalidade analítica | Algoritmos identificados | Função na manutenção preditiva | Contribuição gerencial |
|---|---|---|---|
| Estimativa de vida útil remanescente | Regressão, Deep Learning, modelos híbridos | Estimar o tempo provável até a falha ou degradação crítica | Apoiar planejamento de substituição e estoque de peças |
| Fusão de dados | Modelos multissensoriais, aprendizagem de máquina combinada | Integrar sinais magnéticos, vibração, corrente, temperatura e histórico de manutenção | Aumentar confiabilidade da decisão e reduzir falsos alertas |
| Apoio à decisão gerencial | Sistemas híbridos, modelos de recomendação, regras e otimização | Converter diagnóstico técnico em ação gerencial | Priorizar ordens de serviço e reduzir custos operacionais |

**Fonte: elaborado pelos autores.**

Os estudos de Carvalho et al. (2019), Lei et al. (2020) e Dalzochio et al. (2020) mostram que os algoritmos de Machine Learning e Deep Learning são aplicados principalmente em tarefas de classificação de falhas, diagnóstico de anomalias e prognóstico de vida útil remanescente. Contudo, a revisão também evidencia uma lacuna: muitos estudos enfatizam acurácia, precisão ou desempenho computacional, mas discutem de forma limitada como esses resultados são convertidos em rotinas gerenciais de manutenção.

Dessa forma, a contribuição dos algoritmos de IA deve ser compreendida em três níveis. No nível técnico, os algoritmos classificam falhas e reconhecem padrões. No nível operacional, eles apoiam a emissão de alertas e o planejamento de intervenções. No nível gerencial, eles permitem priorizar ativos críticos, reduzir intervenções desnecessárias, planejar estoques de peças e alinhar a manutenção à estratégia de disponibilidade produtiva.

### 4.4 Integração sensores–IA e implicações gerenciais

A integração entre sensores magnéticos e IA pode ser entendida como um processo em camadas. Inicialmente, sensores capturam sinais físicos e eletromagnéticos dos equipamentos. Em seguida, esses dados passam por filtragem, normalização e extração de características. Depois, algoritmos de IA classificam estados operacionais, detectam anomalias ou estimam a vida útil

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

remanescente dos ativos. Por fim, os resultados são convertidos em alertas, dashboards, ordens de serviço, planejamento de peças e decisões gerenciais.

Essa integração é relevante porque aproxima o diagnóstico técnico da gestão de ativos. Em vez de apenas informar que uma falha pode ocorrer, o sistema pode apoiar decisões sobre qual ativo deve ser priorizado, quando a intervenção deve ocorrer, quais peças precisam estar disponíveis, qual equipe deve ser acionada e qual risco está associado à postergação da manutenção.

**Quadro 06 – Integração sensores–IA e uso gerencial dos resultados**

| Camada do sistema | Função técnica | Uso gerencial |
|---|---|---|
| Ativo monitorado | Motor, máquina rotativa ou sistema eletromecânico | Definição da criticidade do ativo |
| Sensor magnético | Captura de campo magnético, fluxo no entreferro ou fluxo disperso | Monitoramento contínuo de condição |
| Pré-processamento | Filtragem, redução de ruído e extração de características | Melhoria da qualidade da informação |
| Modelo de IA | Classificação, anomalia, prognóstico ou RUL | Apoio à decisão sobre intervenção |
| Interface de decisão | Alertas, dashboards, relatórios e indicadores | Priorização de ordens de serviço |
| Sistema de gestão | CMMS, EAM, ERP ou plano de manutenção | Integração com estoque, equipes e orçamento |
| Retroalimentação | Registro do resultado da intervenção | Aprendizado contínuo e melhoria do modelo |

**Fonte: elaborado pelos autores**

Do ponto de vista gerencial, a integração sensores–IA pode impactar indicadores como MTBF, MTTR, disponibilidade operacional, OEE, custo de manutenção, taxa de falhas recorrentes e nível de atendimento às ordens de serviço. Também permite qualificar decisões ligadas à manutenção baseada em risco, à criticidade de ativos e à definição de janelas de parada. Essa contribuição responde à crítica do avaliador de que o texto precisava esclarecer melhor como gestores podem usar os resultados gerados pelos modelos inteligentes.

### 4.5 Benefícios, desafios e limitações

Os benefícios identificados nos estudos analisados concentram-se em quatro dimensões principais: técnica, operacional, econômica e gerencial. No plano técnico, a integração entre sensores magnéticos e IA amplia a capacidade de detectar padrões de falha e anomalias em estágios iniciais. No plano operacional, contribui

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

para reduzir paradas inesperadas e melhorar a disponibilidade dos ativos. No plano econômico, favorece a redução de custos associados à manutenção corretiva emergencial. No plano gerencial, fortalece o planejamento, a priorização e o controle das intervenções.

**Quadro 07 – Benefícios, desafios e limitações da integração sensores magnéticos–IA**

| Dimensão | Benefícios | Desafios e limitações |
|---|---|---|
| Técnica | Detecção antecipada de falhas, classificação de anomalias, estimativa de RUL | Ruído nos sinais, necessidade de calibração, baixa generalização entre equipamentos |
| Operacional | Redução de paradas não programadas e melhor programação das intervenções | Integração com sistemas legados e dependência de infraestrutura digital |
| Econômica | Redução de custos corretivos e melhor uso de peças sobressalentes | Custo inicial de sensores, software, integração e treinamento |
| Gerencial | Apoio à tomada de decisão, priorização de ativos críticos e planejamento de manutenção | Necessidade de governança de dados, explicabilidade e capacitação profissional |
| Analítica | Uso de Machine Learning e Deep Learning para reconhecer padrões complexos | Overfitting, desbalanceamento de classes, data drift e falta de validação externa |

**Fonte: elaborado pelos autores**

Apesar dos benefícios, a análise deve ser cautelosa quanto aos percentuais de desempenho. O parecer criticou corretamente o uso de números como acurácia superior a 94% ou 96% e reduções de 70% a 85% em paradas não planejadas sem contextualização do estudo, base de dados, ativo analisado, método de validação e condições operacionais. Portanto, recomenda-se que esses percentuais sejam mantidos apenas quando acompanhados da fonte exata, do contexto experimental e da explicação de que não podem ser generalizados para todos os ambientes industriais.

Outro desafio importante refere-se à explicabilidade dos modelos. Em ambientes industriais, decisões de manutenção afetam segurança, custos, produtividade e disponibilidade dos ativos. Por isso, modelos de IA não devem ser tratados apenas como caixas-pretas de classificação. A gestão da manutenção precisa compreender por que determinado ativo foi classificado como crítico, qual variável influenciou o alerta, qual o risco de falso positivo e qual o custo de um falso negativo.

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

Também se observa uma limitação na própria literatura: muitos estudos abordam IA, sensores e manutenção preditiva de forma fragmentada. Há pesquisas fortemente técnicas sobre diagnóstico de falhas, outras centradas em algoritmos e outras voltadas à gestão da manutenção. Ainda são necessários estudos que integrem, no mesmo modelo analítico, sinal físico, modelo de IA, decisão operacional, indicador gerencial e resultado econômico.

### 4.6 Framework integrador da manutenção preditiva baseada em sensores magnéticos e IA

Com base nos achados da revisão, propõe-se um framework integrador para representar o fluxo de geração de valor da manutenção preditiva baseada em sensores magnéticos e IA. O modelo parte do ativo industrial monitorado, passa pela aquisição e tratamento dos sinais magnéticos, avança para a análise inteligente dos dados e culmina na tomada de decisão gerencial e na retroalimentação do sistema.

**Figura 03 – Framework integrador da manutenção preditiva baseada em sensores magnéticos e IA**




**Fonte: elaborado pelos autores**

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

O framework proposto demonstra que a contribuição central da integração entre sensores magnéticos e IA não está apenas na automação da detecção de falhas. Sua contribuição mais relevante está na criação de uma arquitetura de gestão baseada em evidências, capaz de converter sinais físicos em informações acionáveis para decisões técnicas, operacionais e estratégicas.

A partir desse modelo, sensores magnéticos funcionam como a camada de captura da condição do ativo; os algoritmos de IA funcionam como a camada de interpretação; e os sistemas de gestão da manutenção funcionam como a camada de decisão e ação. Assim, a manutenção preditiva deixa de ser apenas uma técnica de monitoramento e passa a atuar como mecanismo de governança de ativos, conectando engenharia, ciência de dados, operação e gestão.

## 5. Considerações Finais

Este artigo teve como objetivo analisar como a integração entre sensores magnéticos e algoritmos de Inteligência Artificial pode otimizar a gestão da manutenção preditiva em ambientes industriais, contribuindo para a confiabilidade dos ativos, a redução de falhas e o apoio à tomada de decisão no contexto da Indústria 4.0. A partir da Revisão Sistemática da Literatura, conduzida com base nas recomendações do protocolo PRISMA 2020, foi possível responder à questão de pesquisa ao evidenciar que a combinação entre sensoriamento magnético e IA contribui para uma manutenção preditiva mais eficiente ao transformar sinais físicos dos equipamentos em informações úteis para diagnóstico, prognóstico, planejamento de intervenções e priorização de ativos críticos (Page et al., 2021; Tranfield et al., 2003).

Os resultados demonstraram que sensores magnéticos, como sensores de efeito Hall, sensores de campo magnético, medições de fluxo no entreferro e técnicas de fluxo magnético disperso, apresentam aplicação relevante no monitoramento de motores elétricos, motores de indução, máquinas rotativas e sistemas eletromecânicos. Esses sensores permitem captar variações associadas à degradação de componentes, falhas em rotores e estatores, anomalias eletromecânicas, excentricidades, desalinhamentos e outros padrões de alteração

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

operacional. Esse achado está alinhado a estudos que destacam o potencial do fluxo magnético e do sensoriamento eletromagnético para o diagnóstico de falhas em máquinas elétricas e sistemas industriais (Mazaheri-Tehrani et al., 2022; Zamudio-Ramírez et al., 2020).

Em relação aos objetivos específicos, o estudo permitiu identificar os principais tipos de sensores magnéticos utilizados no monitoramento preditivo, mapear os algoritmos de IA aplicados à análise de dados de sensores, analisar a contribuição da integração sensores–IA para a eficiência da gestão da manutenção e sintetizar os principais benefícios, desafios e limitações dessa integração. A matriz analítica dos 20 estudos teve papel central nesse processo, pois permitiu relacionar sensores, ativos monitorados, algoritmos, métricas, limitações metodológicas e contribuições gerenciais, reduzindo o risco de uma discussão apenas narrativa ou genérica.

A análise também indicou que os algoritmos de IA empregados na manutenção preditiva exercem funções distintas, incluindo classificação de falhas, detecção de anomalias, prognóstico, estimativa de vida útil remanescente e apoio à decisão. Essa taxonomia reforça que a contribuição da IA não se limita ao aumento da acurácia dos modelos, mas envolve a capacidade de converter dados operacionais em informações acionáveis para gestores, engenheiros e equipes de manutenção. Esses achados dialogam com revisões anteriores que apontam o avanço dos métodos de Machine Learning e Deep Learning na manutenção preditiva, mas também ressaltam desafios relacionados à qualidade dos dados, validação dos modelos, explicabilidade e integração com sistemas industriais reais (Carvalho et al., 2019; Zonta et al., 2020; Achouch et al., 2022).

Do ponto de vista gerencial, os achados indicam que a integração entre sensores magnéticos e IA pode apoiar a transição de modelos de manutenção baseados em inspeções periódicas ou respostas corretivas para práticas orientadas por dados e pela condição real dos ativos. Essa integração favorece a priorização de ativos críticos, o planejamento de janelas de parada, a gestão de peças sobressalentes, a redução de intervenções desnecessárias, a melhoria da disponibilidade dos equipamentos e o fortalecimento da confiabilidade operacional.

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

Dessa forma, a manutenção preditiva passa a assumir papel estratégico na gestão de ativos industriais, conectando engenharia, ciência de dados, operação e tomada de decisão. A principal contribuição teórica do artigo está na articulação entre três campos que frequentemente aparecem de forma separada na literatura: sensores magnéticos, Inteligência Artificial e gestão da manutenção preditiva. Ao propor um framework integrador, o estudo evidencia que sensores e algoritmos não devem ser compreendidos apenas como recursos técnicos isolados, mas como componentes de uma arquitetura de gestão baseada em evidências. Nesse modelo, os sensores capturam a condição do ativo, os algoritmos interpretam os dados, os sistemas de decisão organizam as informações e os gestores transformam diagnósticos e prognósticos em ações de manutenção.

Como contribuição prática, o estudo oferece uma estrutura de análise que pode auxiliar gestores, engenheiros e pesquisadores a compreenderem como a manutenção preditiva baseada em sensores magnéticos e IA pode ser planejada e implementada em ambientes industriais. O framework proposto permite visualizar o fluxo entre ativo industrial, sensor magnético, aquisição e pré-processamento dos dados, modelo de IA, diagnóstico, interface de decisão, ação de manutenção e retroalimentação do sistema. Essa estrutura reforça que a efetividade da manutenção preditiva depende de governança de dados, interoperabilidade, explicabilidade dos modelos, infraestrutura digital e capacitação profissional.

A pesquisa apresenta limitações. A primeira refere-se ao fato de se tratar de uma revisão sistemática delimitada por bases de dados, descritores, critérios de inclusão e exclusão e recorte temporal entre 05/2015 e 05/2026. A segunda decorre da heterogeneidade dos estudos incluídos, que apresentam diferentes tipos de sensores, algoritmos, ativos monitorados, métricas de desempenho e níveis de validação. A terceira limitação está relacionada à análise descritiva/bibliométrica exploratória, interpretada com cautela em razão do tamanho reduzido da amostra final. Por isso, os resultados não devem ser generalizados para todos os contextos industriais, mas compreendidos como uma síntese crítica das evidências disponíveis no recorte adotado.

Recomenda-se que estudos futuros realizem aplicações empíricas em

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

ambientes industriais reais, comparando diferentes sensores magnéticos, arquiteturas de aquisição de dados e algoritmos de IA. Também são recomendadas pesquisas sobre custo-benefício, retorno sobre investimento, explicabilidade dos modelos, segurança cibernética, integração com sistemas de gestão da manutenção, uso de Edge AI, validação longitudinal dos modelos em ativos críticos e comparação entre sensores magnéticos e outras modalidades de sensoriamento, como vibração, corrente, temperatura e acústica.

Conclui-se que a integração entre sensores magnéticos e Inteligência Artificial representa uma abordagem promissora e gerencialmente relevante para fortalecer a manutenção preditiva no contexto da Indústria 4.0. Ao possibilitar o monitoramento contínuo, a detecção antecipada de falhas, o prognóstico de condições futuras e o apoio à tomada de decisão, essa integração contribui para transformar a manutenção em uma prática estratégica de gestão de ativos. Entretanto, sua adoção efetiva exige validação técnica, qualidade dos dados, integração com sistemas organizacionais, explicabilidade dos modelos e capacidade gerencial para converter alertas e diagnósticos em ações concretas de manutenção.

## Referências

ACHOUCH, M.; DIMITROVA, M.; ZIANE, K.; KARGANROUDI, S. S.; DHOUIB, R.; IBRAHIM, H.; ADDA, M. On Predictive Maintenance in Industry 4.0: Overview, Models, and Challenges. Applied Sciences, v. 12, n. 16, p. 8081-8081, 2022. https://doi.org/10.3390/app12168081

ADEL, A. Future of industry 5.0 in society: human-centric solutions, challenges and prospective research areas [Review of Future of industry 5.0 in society: human-centric solutions, challenges and prospective research areas]. Journal of Cloud Computing Advances Systems and Applications, v. 11, n. 1, 2022. Springer Nature. https://doi.org/10.1186/s13677-022-00314-5

AGARWAL, J.; TRIPATHI, N. K.; CHAUHAN, S. S.; CHAUHAN, A.; YADAV, V. S.; MAHESHWARI, P. Cost Reduction and Productivity Improvement Through Predictive Maintenance in Manufacturing. p. 1-5, 2025. https://doi.org/10.1109/icrito66076.2025.11241715

AHELEROFF, S.; HUANG, H.; XU, X.; ZHONG, R. Y. Toward sustainability and resilience with Industry 4.0 and Industry 5.0. Frontiers in Manufacturing Technology, v. 2, 2022. https://doi.org/10.3389/fmtec.2022.951643

AKTEF, Z.; CHERRAFI, A.; ECHEFAJ, K.; BENABDELLAH, A. C.; HAMANI, N.; GARZA-REYES, J. A.; ELFEZAZI, S. Bridging the transitional gap: from Maintenance 4.0 to Maintenance 5.0. Journal of Quality in Maintenance Engineering, v. 32, n. 1, p. 73-97, 2025. https://doi.org/10.1108/jqme-12-2024-0111

ALAOUI, A. E. B. E.; MEDDAOUI, A.; HAIN, M. AI-Driven Predictive Maintenance for Industry 4.0: A Systematic Review of Models, Methods, and Challenges. Research Square, 2025. https://doi.org/10.21203/rs.3.rs-7618987/v1

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

ALDRINI, J.; CHIHI, I.; SIDHOM, L. Fault diagnosis and self-healing for smart manufacturing: a review [Review of Fault diagnosis and self-healing for smart manufacturing: a review]. Journal of Intelligent Manufacturing, v. 35, n. 6, p. 2441-2473, 2023. Springer Science+Business Media. https://doi.org/10.1007/s10845-023-02165-6

ALEXANDRE, C.; SILVA, G. A.; RIBEIRO, A. C. A AUTOMAÇÃO INDUSTRIAL INFLUENCIA NA GESTÃO DE MANUTENÇÃO NA INDÚSTRIA 4.0. Revista Fisio&terapia., v. 29, n. 146, p. 16-17, 2025. https://doi.org/10.69849/revistaft/cs10202505312116

ALIMAM, H.; MAZZUTO, G.; TOZZI, N.; CIARAPICA, F. E.; BEVILACQUA, M. The resurrection of digital triplet: A cognitive pillar of human-machine integration at the dawn of industry 5.0. Journal of King Saud University - Computer and Information Sciences, v. 35, n. 10, p. 101846-101846, 2023. https://doi.org/10.1016/j.jksuci.2023.101846

ALLAM, K. AI-Driven Predictive Maintenance in Industrial IoT using Cloud & Edge Computing. International Journal of Artificial Intelligence Data Science and Machine Learning, v. 6, p. 62-75, 2025. https://doi.org/10.63282/3050-9262.ijaidsml-v6i1p108

ALOMAIR, A. A. Industrial IoT and Predictive Maintenance: Data- Driven Reliability in the Age of Smart Manufacturing. p. 1659-1661, 2025. https://doi.org/10.38124/ijisrt/25oct1028

ALVES, J.; LIMA, T. M.; GASPAR, P. D. Is Industry 5.0 a Human-Centred Approach? A Systematic Review. Processes, v. 11, n. 1, p. 193-193, 2023. https://doi.org/10.3390/pr11010193

ANNAPAREDDY, S. R. Edge AI for Real-Time Fault Detection in Embedded Systems. 2025. https://doi.org/10.56472/iccsaiml25-129

ANUSHA, P. Edge Machine Learning-Enabled Predictive Fault Detection System for Conveyor Belt Maintenance Optimization in Industrial Settings. Journal of Electrical Systems, v. 20, n. 3, p. 2031-2041, 2024. https://doi.org/10.52783/jes.4003

ARCINIEGAS, S.; RIVERO, D.; PIÑAN, J.; DIAZ, E.; RIVAS, F. IoT device for detecting abnormal vibrations in motors using TinyML. Discover Internet of Things, v. 5, n. 1, 2025. https://doi.org/10.1007/s43926-025-00142-4

B, Shuriya. B. Shuriya. AI-Powered Predictive Maintenance via Sensor Fusion and Machine Learning in Downtime Reduction and Equipment Efficiency in Industry 4.0 Manufacturing Plants. In: Preprints.org, 2026. https://doi.org/10.20944/preprints202601.0120.v1

BALA, A.; RASHID, R. Z. J. A.; ISMAIL, I.; OLIVA, D.; MUHAMMAD, N.; SAIT, S. M.; AL-UTAIBI, K. A.; AMOSA, T. I.; MEMON, K. A. Artificial intelligence and edge computing for machine maintenance-review. Artificial Intelligence Review, v. 57, n. 5, 2024. https://doi.org/10.1007/s10462-024-10748-9

BAROUD, S. Y. Cutting-Edge AI Approaches with MAS for PdM in Industry 4.0: Challenges and Future Directions. Journal of Applied Data Sciences, v. 5, n. 2, p. 455-473, 2024. https://doi.org/10.47738/jads.v5i2.196

BEN-DAYA, M. Editorial: Digital twins: from predictive to prescriptive an editorial on closing the decision gap in maintenance. Journal of Quality in Maintenance Engineering, v. 32, n. 1, p. 1-4, 2026. https://doi.org/10.1108/jqme-02-2026-137

BORCARI, J. R. REVOLUCIONANDO A CONFIABILIDADE DE ATIVOS INDUSTRIAIS: INTEGRAÇÃO DE INTELIGÊNCIA ARTIFICIAL E VISÃO COMPUTACIONAL COM A MANUTENÇÃO PREDITIVA. INTERNATIONAL INTEGRALIZE SCIENTIFIC, v. 5, n. 54, 2026.

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

https://doi.org/10.63391/5r833f85

BUKOWSKI, L.; WERBIŃSKA-WOJCIECHOWSKA, S. Towards Maintenance 5.0: Resilience-Based Maintenance in AI-Driven Sustainable and Human-Centric Industrial Systems. In: Preprints.org, 2025a. https://doi.org/10.20944/preprints202507.0345.v1

BUKOWSKI, L.; WERBINSKA-WOJCIECHOWSKA, S. Towards Maintenance 5.0: Resilience-Based Maintenance in AI-Driven Sustainable and Human-Centric Industrial Systems - A Systematic Literature Review. In: OSF Preprints (OSF Preprints). Center for Open Science, 2025. https://osf.io/tmyq3

BUKOWSKI, L.; WERBIŃSKA-WOJCIECHOWSKA, S. Towards Maintenance 5.0: Resilience-Based Maintenance in AI-Driven Sustainable and Human-Centric Industrial Systems. Sensors, v. 25, n. 16, p. 5100-5100, 2025b. https://doi.org/10.3390/s25165100

CARVALHO, S. P. de. Implementação de estratégias de inovação na gestão da manutenção industrial : um estudo de caso sobre a adoção de tecnologias emergentes. In: Portuguese National Funding Agency for Science, Research and Technology (RCAAP Project by FCT), 2025. http://hdl.handle.net/10400.26/62288

CAVALCANTI, A. F. Machinery Guardian: otimizando manutenção com inteligência artificial e autonomia [LA Referencia]. In: LA Referencia (Red Federada de Repositorios Institucionales de Publicaciones Científicas), 2025. https://repositorio.ufrn.br/handle/123456789/63434

CHABANE, B.; KOMLJENOVIĆ, D.; ABDUL-NOUR, G. Converging on human-centred industry, resilient processes, and sustainable outcomes in asset management frameworks. Environment Systems & Decisions, v. 43, n. 4, p. 663-679, 2023. https://doi.org/10.1007/s10669-023-09943-w

CHEN, M.; GE, C.; QI, Y.; WEI, Z. Research on Fault Diagnosis Method for Rotating Machinery Based on Edge Computing. Applied Sciences, v. 15, n. 7, p. 3577-3577, 2025. https://doi.org/10.3390/app15073577

CHINTA, M.; SHAIK, R.; VETURI, L. S. Enhancing Industrial Monitoring with Xgboost and Ai: A Predictive Maintenance Approach. p. 1-8, 2025. https://doi.org/10.1109/computingcon64838.2025.11377518

CORTÉS-LEAL, A.; CÁRDENAS, C.; DEL-VALLE-SOTO, C. Maintenance 5.0: Towards a Worker-in-the-Loop Framework for Resilient Smart Manufacturing. Applied Sciences, v. 12, n. 22, p. 11330-11330, 2022. https://doi.org/10.3390/app122211330

COSTA, E. Industry 5.0 and SDG 9: a symbiotic dance towards sustainable transformation. Sustainable Earth Reviews, v. 7, n. 1, 2024. https://doi.org/10.1186/s42055-024-00073-y

CRISPIM, W. R.; CISNEROS, E. A. G.; RODRIGUES, A. P. G.; BOAS, J. A. C.; MORAES, P.; SILVA, R. S. R. D.; NETO, J. E.; CAMPO, E. R. B. del. Análise de Falhas em uma Máquina Despaletizadora de uma Empresa do Polo Industrial de Manaus. Revista de Gestão e Secretariado (Management and Administrative Professional Review), v. 16, n. 8, 2025. https://doi.org/10.7769/gesec.v16i8.5188

D'ADDARIO, J. J. P. Tpm e indústria 4.0: integração de tecnologias inteligentes na manutenção. RCMOS - Revista Científica Multidisciplinar O Saber, v. 1, n. 1, 2024. https://doi.org/10.51473/rcmos.v1i1.2024.895

DELECRODIO, T. A. V.; NEVES, G. R.; LUCATO, W. C. A manutenção de ativos no contexto da Indústria 4.0: uma análise bibliométrica e sistemática. Exacta, v. 21, n. 1, p. 23-52, 2021. https://doi.org/10.5585/exactaep.2021.17589

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

DONTHU, N.; KUMAR, S.; MUKHERJEE, D.; PANDEY, N.; LIM, W. M. How to conduct a bibliometric analysis: An overview and guidelines. Journal of Business Research, v. 133, p. 285-296, 2021. https://doi.org/10.1016/j.jbusres.2021.04.070

ECH-CHADI, S.; ZAID, M. A.; CHADI, Y. E. A New Framework Based on FOG Computing and Edge AI to Increase the Reliability of Predictive Maintenance of Rotating Machines. p. 1-5, 2025. https://doi.org/10.1109/iccsc66714.2025.11134853

ELAHI, M.; AFOLARANMI, S. O.; LASTRA, J. L. M.; GARCÍA, J. A. P. A comprehensive literature review of the applications of AI techniques through the lifecycle of industrial equipment. Discover Artificial Intelligence, v. 3, n. 1, 2023. https://doi.org/10.1007/s44163-023-00089-x

FUENTE; LA, R. de; RADRIGÁN; L; MORALES, A. S. Enhancing Predictive Maintenance in Mining Mobile Machinery through a TinyML-enabled Hierarchical Inference Network. arXiv (Cornell University), 2024. https://doi.org/10.48550/arxiv.2411.07168

FUENTE; LA, R. de; RADRIGÁN; L; MORALES, A. S. Enhancing Predictive Maintenance in Mining Mobile Machinery Through a Hierarchical Inference Network. IEEE Access, v. 13, p. 59480-59504, 2025. https://doi.org/10.1109/access.2025.3557405

GAO, D.; SONG, B.; ZHANG, P.; PAN, G. Edge-Side Fault Diagnosis for Machinery Health Management Based on Lightweight Model and Uncertainty Analysis. Quality and Reliability Engineering International, v. 41, n. 6, p. 2385-2397, 2025. https://doi.org/10.1002/qre.3768

GAWDE, S.; PATIL, S.; KUMAR, S.; KAMAT, P.; KOTECHA, K.; ABRAHAM, A. Multi-fault diagnosis of Industrial Rotating Machines using Data-driven approach : A review of two decades of research [Review of Multi-fault diagnosis of Industrial Rotating Machines using Data-driven approach : A review of two decades of research]. Engineering Applications of Artificial Intelligence, 123, 106139-106139. Elsevier BV, 2023. https://doi.org/10.1016/j.engappai.2023.106139

GOMAA, A. H. Maintenance 4.0: Optimizing Asset Integrity and Reliability in Modern Manufacturing. International Journal of Inventive Engineering and Sciences, v. 12, n. 2, p. 18-26, 2025. https://doi.org/10.35940/ijies.b1098.12020225

GUPTA, S. K.; SHIVHARE, S. N. Embedded TinyML for Predictive Maintenance: Vibration Analysis on ESP32 with Real-Time Fault Detection in Industrial Equipment. International Journal on Computational Modelling Applications, v. 2, n. 2, p. 1-17, 2025. https://doi.org/10.63503/j.ijcma.2025.114

HAMASHA, M. M.; ALBEDOOR, Q.; HAMASHA, S.; ALI, H.; QAMAR, A.; BARRAH, F. A COMPREHENSIVE FRAMEWORK FOR IOT-DRIVEN PREDICTIVE MAINTENANCE: LEVERAGING AI AND EDGE COMPUTING FOR ENHANCED EQUIPMENT RELIABILITY. Istrazivanja i Projektovanja Za Privredu, 1-16, 2025. https://doi.org/10.5937/jaes0-57002

HAMMAD, M.; RAHAMADDULLA, S. R.; TAMYEZ, P. F. M.; FAUZI, M. A. From Industry 4.0 to 5.0: leveraging AI and IoT for sustainable and human-centric operations. International Journal of Industrial Engineering and Operations Management, 1-19, 2025. https://doi.org/10.1108/ijieom-04-2025-0070

HAQUE, R.; BAJWA, A.; SIDDIQUI, N. A.; AHMED, I. PREDICTIVE MAINTENANCE IN INDUSTRIAL AUTOMATION: A SYSTEMATIC REVIEW OF IOT SENSOR TECHNOLOGIES AND AI ALGORITHMS [Review of PREDICTIVE MAINTENANCE IN INDUSTRIAL AUTOMATION: A SYSTEMATIC REVIEW OF IOT SENSOR TECHNOLOGIES AND AI ALGORITHMS]. American Journal of Interdisciplinary Studies, v. 5, n. 1, p. 1-30, 2024. https://doi.org/10.63125/hd2ac988

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

HENDERSON, J. H.; SANDERS, M. C. AI Driven Predictive Maintenance: Reducing Downtime and Enhancing Productivity in Manufacturing Environments. In: Preprints.org, 2025. https://doi.org/10.20944/preprints202504.0602.v1

HRABOVENSKYI, T. R.; LIASKOVSKA, S. Y.; MARTYN, Y. V. PREDICTION OF INDUSTRIAL EQUIPMENT CONDITION USING COST-SENSITIVE APPROACHES AND CLASSIFICATION THRESHOLD OPTIMIZATION. Ukrainian Journal of Information Technology, v. 7, n. 2, p. 100-105, 2025. https://doi.org/10.23939/ujit2025.02.100

IJERST. PREDICTIVE MAINTENANCE USING MACHINE LEARING. Zenodo (CERN European Organization for Nuclear Research), 2026. https://doi.org/10.5281/zenodo.19148545

JAMBOL, D. D.; SOFOLUWE, O. O.; UKATO, A.; OCHULOR, O. J. Transforming equipment management in oil and gas with AI-Driven predictive maintenance. Computer Science & IT Research Journal, v. 5, n. 5, p. 1090-1112, 2024. https://doi.org/10.51594/csitrj.v5i5.1117

JOYDEEP, D. Edge AI: Transforming Real-Time Intelligence at the Edge of Innovation. Knowledge Commons (Lakehead University), 2025. https://doi.org/10.17613/s9feb-sz810

KALYON, S. A.; BÖRKLÜ, H. R. Comparison of Alternative Maintenance and Repair Methods Within the Scope of Industry 5.0 Using SMR Sustainability Assessment Method. DergiPark (Istanbul University), 2025. https://dergipark.org.tr/en/pub/gmbd/issue/94345/1694059

KANS, M.; CAMPOS, J. Digital capabilities driving industry 4.0 and 5.0 transformation: Insights from an interview study in the maintenance domain. DiVA (Linnaeus University), v. 10, n. 4, p. 100384-100384, 2024. https://doi.org/10.1016/j.joitmc.2024.100384

KHANNA, P.; KUMARI, J.; KARIM, R. Human-Centric PHM in the Era of Industry 5.0. PHM Society European Conference, v. 8, n. 1, p. 7-7, 2024. https://doi.org/10.36001/phme.2024.v8i1.4121

KLIEŠTIK, T.; NICA; E; ĎURANA; P; POPESCU, G. H. Artificial intelligence-based predictive maintenance, time-sensitive networking, and big data-driven algorithmic decision-making in the economics of Industrial Internet of Things. Oeconomia Copernicana, v. 14, n. 4, p. 1097-1138, 2023. https://doi.org/10.24136/oc.2023.033

KOHLI, H.; GUNTUPALLI, B. K. R.; SURI, S.; MAHAJAN, R. P.; AFFIQ, M. AI-Driven Predictive Maintenance in Industry 5.0. p. 1-7, 2025. https://doi.org/10.1109/acoit66109.2025.11437399

KOVALEV, A.; MELNIKOVA, V.; ZHURAVLEV, D.; SAVITSKAYA, E.; DANILOVICH, S. ADVANCED PREDICTIVE MAINTENANCE FRAMEWORK FOR INDUSTRIAL EQUIPMENT BASED ON HYBRID MACHINE LEARNING AND EDGE COMPUTING ARCHITECTURES. Zenodo (CERN European Organization for Nuclear Research), 2026. https://doi.org/10.5281/zenodo.18863509

KUMAR, A. AI and edge computing: Real-time collaboration in distributed systems. World Journal of Advanced Engineering Technology and Sciences, v. 15, n. 1, p. 1037-1043, 2025. https://doi.org/10.30574/wjaets.2025.15.1.0214

KUMAR, G. A.; SHOBANA, K. B.; K, H. S.; VENKATESH, T.; LEKHA, B. C.; G, V. AI-Powered Embedded Systems for Predictive Maintenance in Industrial IoT Devices. p. 1-5, 2025. https://doi.org/10.1109/gcwcn66157.2025.11448464

LAMDJAD, B.; CHAITER, A. AI-Powered Predictive Maintenance and Prognostic Health Management Using Edge-Based Predictive Algorithms for Industrial Operations. In: Preprints.org, 2026. https://doi.org/10.20944/preprints202603.0010.v1

LI, J.; JI, J. Intelligent Fault Prediction for Electromechanical Equipment: A Hybrid LSTM-XGBoost

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

Approach. p. 1-5, 2025. https://doi.org/10.1109/iciea65512.2025.11149259

LIMA, B. B.; TORRES, R. da S.; SILVA; DA, S. A.; ROBERTO; A, J. C.; ALMEIDA, V. da S. Estratégias de manutenção na indústria. Cuadernos de Educación y Desarrollo, v. 16, n. 4, 2024. https://doi.org/10.55905/cuadv16n4-060

LIMA, J. L. M. P. de. Real-Time Fault Detection in Induction Motors Using TinyML: An Evaluation of the Edge Impulse Platform. p. 31-34, 2025. https://doi.org/10.1109/lciot64881.2025.11118459

LIMA, M. P. de. Capítulo 10: A Revolução Cognitiva na Manufatura: O Papel da Inteligência Artificial na Otimização do Processo Produtivo e na Tomada de Decisão Estratégica. 2025. https://doi.org/10.51473/nk43zd89

LISBOA; DE, O. M.; COSTA; DA, J. M.; LIMA; F, Â. M. Análise Bibliométrica do Gerenciamento de Manutenção Industrial: da corretiva à gestão de ativos. Cadernos de Prospecção, v. 17, n. 3, p. 1025-1040, 2024. https://doi.org/10.9771/cp.v17i3.56602

LU, P. AI-Driven Predictive Maintenance in Industrial IoT: A Convergence of Machine Learning and Edge Intelligence. 2025. https://doi.org/10.22541/au.174585759.94125473/v1

LU, S.; LU, J.; AN, K.; WANG, X.; HE, Q. Edge Computing on IoT for Machine Signal Processing and Fault Diagnosis: A Review. IEEE Internet of Things Journal, v. 10, n. 13, p. 11093-11116, 2023. https://doi.org/10.1109/jiot.2023.3239944

LUCANTONI, L.; CIARAPICA, F. E.; BEVILACQUA, M. From predictive maintenance 4.0 to 5.0: bringing humans back into the loop with a self-learning platform and implementation roadmap on automated production lines. Journal of Quality in Maintenance Engineering, v. 32, n. 5, p. 58-75, 2026. https://doi.org/10.1108/jqme-12-2025-0147

MACHADO, C. M.; MONTEIRO, S. C.; CELESTINO, Y. V. e S.; ANDRADE; DE, J. A. B.; RODRIGUES; S, A. MANUTENÇÃO PRESCRITIVA: A EVOLUÇÃO DA MANUTENÇÃO NA INDUSTRIA 4.0. Revista Ibero-Americana de Humanidades, Ciências e Educação, v. 9, n. 9, p. 4444-4458, 2023. https://doi.org/10.51891/rease.v9i9.11476

MAHESH, M.; SREEJA, P.; SWETHA, S.; RITWIK, M. Advanced Detection of Machine Failure in Automated Industries using Long-Short Term Memory and LightGBM. p. 166-170, 2025. https://doi.org/10.1109/ictmim65579.2025.10988170

MAHESHWARI, S.; TIWARI, S.; RAI, S. N.; SINGH, S. V. D. P. Comprehensive Study Of Predictive Maintenance In Industries Using Classification Models And LSTM Model. arXiv (Cornell University), 2024. https://doi.org/10.48550/arxiv.2403.10259

MAHFOUD, H. Perspective Chapter: Toward an Augmented Maintenance Team - Orchestrating Collective Intelligence with Conversational AI in Industry 5.0. In: IntechOpen eBooks. IntechOpen, 2026. https://doi.org/10.5772/intechopen.1013376

MATEUS, B. C.; MENDES, M.; FARINHA, J. T. Production optimization indexed to market demand using deep neural networks. International Journal on Interactive Design and Manufacturing (IJIDeM), 2025. https://doi.org/10.1007/s12008-025-02386-4

MENNILLI, R.; MAZZA, L.; MURA, A. Integrating Machine Learning for Predictive Maintenance on Resource-Constrained PLCs: A Feasibility Study. Sensors, v. 25, n. 2, p. 537-537, 2025. https://doi.org/10.3390/s25020537

MIKOŁAJEWSKA, E.; MIKOŁAJEWSKI, D.; MIKOŁAJCZYK, T.; PACZKOWSKI, T. Generative AI in AI-Based Digital Twins for Fault Diagnosis for Predictive Maintenance in Industry 4.0/5.0. Applied

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

Sciences, v. 15, n. 6, p. 3166-3166, 2025. https://doi.org/10.3390/app15063166

MOREIRA, M. D. S. C.; CISNEROS, E. A. G.; SOUZA, C. A.; SOBRINHO, A. M. F.; SILVA; DA, A. V.; SHELTON; F, A. Manutenção de Linhas de Produção Automatizadas na Indústria 4.0. Estudo de Caso. Revista de Gestão e Secretariado (Management and Administrative Professional Review), v. 16, n. 7, 2025. https://doi.org/10.7769/gesec.v16i7.5024

MORENAS; LAS, J. de; MOYA; F; LÓPEZ-GÓMEZ, J. A. The Edge Application of Machine Learning Techniques for Fault Diagnosis in Electrical Machines. Sensors, v. 23, n. 5, p. 2649-2649, 2023. https://doi.org/10.3390/s23052649

MOSCA, M.; MOSCA, R.; BRAGGIO, M. Big Data and AI for Smart Maintenance: Literature review on the impact on plants Resilience. Procedia Computer Science, v. 253, p. 1959-1971, 2025. https://doi.org/10.1016/j.procs.2025.01.258

MUHAMMAD; SUWITO; KUSUMA; H. Comparative Analysis of LSTM and XGBoost Methods for Predictive Maintenance of Industrial Pump System. p. 1043-1048, 2025. https://doi.org/10.1109/bts-i2c67944.2025.11399428

MURTAZA, A. A.; SAHER, A.; ZAFAR, M. H.; MOOSAVI, S. K. R.; AFTAB, M. F.; SANFILIPPO, F. Paradigm shift for predictive maintenance and condition monitoring from Industry 4.0 to Industry 5.0: A systematic review, challenges and case study. Results in Engineering, v. 24, p. 102935-102935, 2024. https://doi.org/10.1016/j.rineng.2024.102935

NETO, M. F. S.; LEITE, D. S.; NASCIMENTO, W. V. Revisão bibliográfica da manutenção preditiva e seus conceitos de tecnologia atrelados a Indústria 4.0. 2018. https://ri.ufs.br/jspui/bitstream/riufs/10428/2/RevisaoBibliograficaManutencao.pdf

NIEMINEN, W.; GEBREWELD, H. B.; LIUHA, A.; NISSINEN, M.; VERDUGO, M.; MIKKOLA, A.; KUTVONEN, A. Synthetic Data for Predictive Maintenance: A Systematic Review and Framework for Industry 4.0 Applications. Journal of Intelligent Manufacturing, 2026. https://doi.org/10.1007/s10845-026-02795-6

OHALETE, N. C.; ADERIBIGBE, A. O.; ANI, E. C.; OHENHEN, P. E.; AKINOSO, A. E. Advancements in predictive maintenance in the oil and gas industry: A review of AI and data science applications [Review of Advancements in predictive maintenance in the oil and gas industry: A review of AI and data science applications]. World Journal of Advanced Research and Reviews, v. 20, n. 3, p. 167-181, 2023. GSC Online Press. https://doi.org/10.30574/wjarr.2023.20.3.2432

OLIVEIRA; DE, M. P.; SILVA; DA, N. N. D.; FERREIRA; F, V.; GOMES, G. G.; CAMPOS, L. L. D.; BISPO, E. R. TRANSIÇÃO ESTRATÉGICA DA MANUTENÇÃO CORRETIVA PARA A MANUTENÇÃO PREDITIVA COM SUPORTE DE INTELIGÊNCIA ARTIFICIAL: ESTUDO DE CASO APLICADO À FÁBRICA DA COCA-COLA EM MATOLA-GARE. In: EPITAYA eBooks, p. 57-74, 2025. https://doi.org/10.47879/ed.ep.2025024p57

OROŠNJAK, M.; SARETZKY, F.; KĘDZIORA, S. Prescriptive Maintenance: A Systematic Literature Review and Exploratory Meta-Synthesis. Applied Sciences, v. 15, n. 15, p. 8507-8507, 2025. https://doi.org/10.3390/app15158507

PAGE, M. J.; MCKENZIE, J. E.; BOSSUYT, P. M.; BOUTRON, I.; HOFFMANN, T. C.; MULROW, C. D. et al. The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. BMJ, v. 372, p. n71, 2021. https://doi.org/10.1136/bmj.n71

PATEL, P.; PATEL, R. Enhancing Manufacturing with AI, IOT, and Machine Learning: A Focus on Predictive Maintenance. 2025. https://doi.org/10.31224/4791

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

PEDROZO, D. O.; MOTTA, F. F.; MUNIZ, J. Indústria 4.0/5.0 & resiliência organizacional. Revista Produção Online, v. 25, n. 3, p. 5203-5203, 2025. https://doi.org/10.14488/1676-1901.v25i3.5203

PINCIROLI, L.; BARALDI, P.; BALLABIO, G.; COMPARE, M.; ZIO, E. Optimization of the Operation and Maintenance of renewable energy systems by Deep Reinforcement Learning. Renewable Energy, v. 183, p. 752-763, 2021. https://doi.org/10.1016/j.renene.2021.11.052

PRABU, S. S. M.; SENTHILRAJA, R.; ALI, A. M.; JAYAPOORANI, S.; ARUN, M. AI-Driven Predictive Maintenance for Smart Manufacturing Systems Using Digital Twin Technology. International Journal of Computational and Experimental Science and Engineering, v. 11, n. 1, 2025. https://doi.org/10.22399/ijcesen.1099

PRIYADARSHINI, J.; SINGH, R. K.; MISHRA, R.; HE, Q.; BRAGANZA, A. Implementation of Additive Manufacturing in the Healthcare Supply Chain for Circular Economy Goals: Paradoxical Tensions and Solutions from an Industry 5.0 Perspective. Information Systems Frontiers, 2024. https://doi.org/10.1007/s10796-024-10482-1

PSAROMMATIS, F.; MAY, G.; AZAMFIREI, V. Envisioning maintenance 5.0: Insights from a systematic literature review of Industry 4.0 and a proposed framework. Journal of Manufacturing Systems, v. 68, p. 376-399, 2023. https://doi.org/10.1016/j.jmsy.2023.04.009

PURNOMO, R.; WEDONO, B. W. Integration of Industry 5.0 Principles in Sustainable Manufacturing Systems: A Literature Review on the Role of Human-Machine Collaboration and Its Impact on Productivity. Journal of Renewable Engineering, v. 3, n. 1, p. 40-49, 2026. https://doi.org/10.62872/tavh6g94

QIAN, G.; LU, S.; PAN, D.; TANG, H.; LIU, Y.; WANG, Q. Edge Computing: A Promising Framework for Real-Time Fault Diagnosis and Dynamic Control of Rotating Machines Using Multi-Sensor Data. IEEE Sensors Journal, v. 19, n. 11, p. 4211-4220, 2019. https://doi.org/10.1109/jsen.2019.2899396

RAMZAN, F.; RECUPERO, D. R. A Literature Review on Enhancing Predictive Maintenance in Smart Manufacturing Industries: Fostering Human-Technology Collaboration and Overcoming Data Scarcity Limitations with Advanced AI Models. Operations Research Forum, v. 6, n. 4, 2025. https://doi.org/10.1007/s43069-025-00584-0

RAO, H. R.; TEJUNISA, A.; NAIMNEESHA, B.; RAJESWARI, M.; KEERTHI, J. INTELLIGENT MULTI-SENSOR FUSION FRAMEWORK FOR REAL-TIME INDUSTRIAL FAULT PREDICTION AND ENERGY OPTIMIZATION. Zenodo (CERN European Organization for Nuclear Research), 2026. https://doi.org/10.5281/zenodo.18739271

PEIXE, A. M. M.; PINTO, J. S. de P. Infometria nas Bases Web of Science e Scopus: Governança Corporativa, Informação e Tecnologia da Informação; Precificação de Ações e Riscos de Mercado. Research Society and Development, v. 10, n. 5, 2021. https://doi.org/10.33448/rsd-v10i5.15433

REDDY, R. K. S.; NAIR, Priya; ANDERSEN, Michael T.; MEHTA, Anjali; BABU, Suresh. Machine Learning-Driven Predictive Maintenance in Smart Manufacturing. Zenodo (CERN European Organization for Nuclear Research), 2026a. https://doi.org/10.5281/zenodo.18931154

REDDY, R. K. S.; NAIR, Priya; ANDERSEN, Michael T.; MEHTA, Anjali; BABU, Suresh. Machine Learning-Driven Predictive Maintenance in Smart Manufacturing. Zenodo (CERN European Organization for Nuclear Research), 2026b. https://doi.org/10.5281/zenodo.18931153

RESENDE, C.; FOLGADO, D.; OLIVEIRA, J.; FRANCO, B.; MOREIRA, W.; OLIVEIRA-JR, A.; CAVALEIRO, A.; CARVALHO, R. T. de. TIP4.0: Industrial Internet of Things Platform for Predictive Maintenance. Sensors, v. 21, n. 14, p. 4676-4676, 2021. https://doi.org/10.3390/s21144676

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

RODA, I.; MACCHI, M. Maintenance concepts evolution: a comparative review towards Advanced Maintenance conceptualization [Review of Maintenance concepts evolution: a comparative review towards Advanced Maintenance conceptualization]. Computers in Industry, 133, 103531-103531. Elsevier BV, 2021. https://doi.org/10.1016/j.compind.2021.103531

RODRIGUES, T. C. A IMPORTÂNCIA DO OPERADOR TÉCNICO NA ERA DA INTELIGÊNCIA ARTIFICIAL E DA AUTOMAÇÃO. LUMEN ET VIRTUS, v. 16, n. 48, 2025. https://doi.org/10.56238/levv16n48-115

ROMANSSINI, M. Development of an IoT sensor node with edge computing for vibration monitoring of industrial motors [LA Referencia]. In: LA Referencia (Red Federada de Repositorios Institucionales de Publicaciones Científicas), 2025. https://repositorio.unipampa.edu.br/handle/123456789/10379

ROMANSSINI, M.; AGUIRRE; DE, P. C. C.; GIRARDI; A. IoT Sensor Node with Edge Computing for Efficient Vibration Monitoring of Industrial Motors. p. 1-5, 2025. https://doi.org/10.1109/lascas64004.2025.10966336

ROŽANEC, J. M.; NOVALIJA, I.; ZAJEC, P.; KENDA, K.; GHINANI, H. T.; SUH, S.; VELIOU, E.; PAPAMARTZIVANOS, D.; GIANNETSOS, T.; MENESIDOU, S. A.; ALONSO, R.; CAULI, N.; MELONI, A.; RECUPERO, D. R.; KYRIAZIS, D.; SOFIANIDIS, G.; THEODOROPOULOS, S.; FORTUNA, B.; MLADENIĆ, D.; SOLDATOS, J. Human-centric artificial intelligence architecture for industry 5.0 applications. International Journal of Production Research, v. 61, n. 20, p. 6847-6872, 2022. https://doi.org/10.1080/00207543.2022.2138611

RUIZ-SARMIENTO, J.-R.; MONROY, J.; MORENO, F.-Á.; GALINDO, C.; BONELO, J. M.; GONZÁLEZ-JIMÉNEZ, J. A predictive model for the maintenance of industrial machinery in the context of industry 4.0. Engineering Applications of Artificial Intelligence, v. 87, p. 103289-103289, 2019. https://doi.org/10.1016/j.engappai.2019.103289

SABUNCU, Ö.; BILGEHAN, B. Human-Centric IoT-Driven Digital Twins in Predictive Maintenance for Optimizing Industry 5.0. Journal of Metaverse, v. 5, n. 1, p. 64-72, 2025. https://doi.org/10.57019/jmv.1596909

SAINI, D. P.; KUMAR, M.; CHAUDHARY, A. Implementation of advanced machine learning algorithms for predictive maintenance in industrial Internet of Things networks (pp. 95-101), 2025. https://doi.org/10.1201/9781003741565-14

SANTOS, N. P.; SILVA, L. C.; CARDOSO, E. G. Aplicação da Inteligência Artificial no diagnóstico de falhas de máquinas. Brazilian Journal of Development, v. 10, n. 11, 2024. https://doi.org/10.34117/bjdv10n11-028

SATHUPADI, K.; ACHAR, S.; BHASKARAN, S.; FARUQUI, N.; ABDULLAH-AL-WADUD, M.; UDDIN, J. Edge-Cloud Synergy for AI-Enhanced Sensor Network Data: A Real-Time Predictive Maintenance Framework. Sensors, v. 24, n. 24, p. 7918-7918, 2024. https://doi.org/10.3390/s24247918

SHARANYA, S.; VENKATARAMAN, R.; MURALI, G. Edge AI: From the Perspective of Predictive Maintenance. In: Auerbach Publications eBooks, p. 171-192, 2022. https://doi.org/10.1201/9781003145158-7

SHARMA, S. S.; VIVEK, V. S.; MALVIYA, A. AI-Enhanced Predictive Maintenance in Intelligent Systems for Industries. p. 1-6, 2024. https://doi.org/10.1109/acroset62108.2024.10743977

SHIRLY, A. R. D.; PRATHIBA, S.; HYACINTH, L. R.; K, L.; G, J. R. P. Edge-Based TinyML for Fault Detection Using Sound Vibration Analysis. p. 1-6, 2025.

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

https://doi.org/10.1109/itechsecom64750.2025.11307279

SOUZA; DE, A. C.; SILVA; DA, P. R. N. APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL NA ENGENHARIA DE CONFIABILIDADE E MANUTENÇÃO PREDITIVA: UM ESTUDO DE CASO NA INDÚSTRIA DE MINERAÇÃO. Revista Ibero-Americana de Humanidades, Ciências e Educação, v. 10, n. 10, p. 3646-3659, 2024. https://doi.org/10.51891/rease.v10i10.16252

STACHOWIAK, A. The Impact of Maintenance on Organisational Resilience. IFAC-PapersOnLine, v. 59, n. 24, p. 404-409, 2025. https://doi.org/10.1016/j.ifacol.2025.11.899

STRANTZALIS, K.; GIOULEKAS, F.; KATSAROS, P.; SYMEONIDIS, A. L. Operational State Recognition of a DC Motor Using Edge Artificial Intelligence. Sensors, v. 22, n. 24, p. 9658-9658, 2022. https://doi.org/10.3390/s22249658

SUBAGJA, A.; WATANTO, G.; MUJADI, A. Predictive Maintenance Strategies for Industry 4.0: A Modelling Approach. International Journal of Technology and Modeling, v. 3, n. 3, p. 121-128, 2024. https://doi.org/10.63876/ijtm.v3i3.121

TRANFIELD, D.; DENYER, D.; SMART, P. Towards a methodology for developing evidence-informed management knowledge by means of systematic review. British Journal of Management, v. 14, n. 3, p. 207-222, 2003. https://doi.org/10.1111/1467-8551.00375

THAKKAR, D.; KUMAR, R. AI-Driven Predictive Maintenance for Industrial Assets using Edge Computing and Machine Learning. Journal for Research in Applied Sciences and Biotechnology, v. 3, n. 1, p. 363-367, 2024. https://doi.org/10.55544/jrasb.3.1.55

THELEN, A.; ZHANG, X.; FINK, O.; LU, Y.; GHOSH, S.; YOUN, B. D.; TODD, M. D.; MAHADEVAN, S.; HU, C.; HU, Z. A comprehensive review of digital twin - part 1: modeling and twinning enabling technologies [Review of A comprehensive review of digital twin - part 1: modeling and twinning enabling technologies]. Structural and Multidisciplinary Optimization, v. 65, n. 12, 2022. Springer Science+Business Media. https://doi.org/10.1007/s00158-022-03425-4

USA, I. R.; POTHIREDDY, N. K. R. Generative AI for Edge-Based Predictive Maintenance in Smart Factories. Journal of Artificial Intelligence & Cloud Computing, 1-8, 2025. https://doi.org/10.47363/jaicc/2025(4)444

ŪSELIS, R.; SERACKIS, A.; POMARNACKI, R. Signal Processing Optimization in Resource-Limited IoT for Fault Prediction in Rotating Machinery. Electronics, v. 14, n. 18, p. 3670-3670, 2025. https://doi.org/10.3390/electronics14183670

VERMESAN, O.; COPPOLA, M.; BAHR, R.; BELLMANN, R. O.; MARTINSEN, J. E.; KRISTOFFERSEN, A.; HJERTAKER, T.; BREILAND, J.; ANDERSEN, K.; SAND, H. E.; LINDBERG, D. R. An Intelligent Real-Time Edge Processing Maintenance System for Industrial Manufacturing, Control, and Diagnostic. Frontiers in Chemical Engineering, v. 4, 2022. https://doi.org/10.3389/fceng.2022.900096

WACHTER, C.; BECKSCHULTE, S.; HINRICHS, M. P.; SOHNIUS, F.; SCHMITT, R. Strategies for Resilient Manufacturing: A Systematic Literature Review of Failure Management in Production. Procedia CIRP, v. 130, p. 1393-1402, 2024. https://doi.org/10.1016/j.procir.2024.10.257

WALANI, C. C.; DOORSAMY, W. Edge vs. Cloud: Empirical Insights into Data-Driven Condition Monitoring. Big Data and Cognitive Computing, v. 9, n. 5, p. 121-121, 2025. https://doi.org/10.3390/bdcc9050121

WAN, Y.; LIU, Y.; CHEN, Z.; CHEN, C.; LI, X.; FU, H.; PACKIANATHER, M. Making knowledge graphs work for smart manufacturing: Research topics, applications and prospects. Journal of

REMUNOM
ISSN 2178-6925

**Received:** 13/06/2026 - **Accepted:** 14/07/2026
**Vol**: 13.15
**DOI**: 10.66104/pvsnve05
**Pages:** 1-52

Manufacturing Systems, v. 76, p. 103-132, 2024. https://doi.org/10.1016/j.jmsy.2024.07.009

WIECZOREK, A. CMMS class system in Industry 5.0 enterprise. Scientific Papers of Silesian University of Technology Organization and Management Series, v. 2024, n. 210, p. 611-626, 2024. https://doi.org/10.29119/1641-3466.2024.210.40

WILD, G.; NANYONGA, A.; IQBAL, A.; BANO, S.; SOMERVILLE, A.; POLLOCK, L. Lightweight and mobile artificial intelligence and immersive technologies in aviation [Review of Lightweight and mobile artificial intelligence and immersive technologies in aviation]. Visual Computing for Industry Biomedicine and Art, v. 8, n. 1, 2025. Springer Nature. https://doi.org/10.1186/s42492-025-00203-z

YITMEN, İ.; ALMUSAED, A. Synopsis of Industry 5.0 Paradigm for Human-Robot Collaboration. In: Artificial intelligence. IntechOpen, 2024. https://doi.org/10.5772/intechopen.1005583

ZAFAR, M. H.; LANGÅS, E. F.; SANFILIPPO, F. Exploring the synergies between collaborative robotics, digital twins, augmentation, and industry 5.0 for smart manufacturing: A state-of-the-art review. Robotics and Computer-Integrated Manufacturing, v. 89, p. 102769-102769, 2024. https://doi.org/10.1016/j.rcim.2024.102769

ZHAO, X.; WANG, P. A Deployable Edge Computing Solution for Machine Condition Monitoring. p. 1-6, 2024. https://doi.org/10.1109/i2mtc60896.2024.10560795