Revista Ibero-Americana de Humanidades, Ciências e Educação — REASE

doi.org/10.51891/rease.v12i11.32825

APLICAÇÕES E LIMITAÇÕES DA INTELIGÊNCIA ARTIFICIAL NA MANUTENÇÃO PREDITIVA INDUSTRIAL: UMA REVISÃO BIBLIOGRÁFICA

APPLICATIONS AND LIMITATIONS OF ARTIFICIAL INTELLIGENCE IN INDUSTRIAL PREDICTIVE MAINTENANCE: A LITERATURE REVIEW

Ezequiel Alexandre dos Santos Silva Rodrigues[1]
Rafael da Silva Oliveira Grilo[2]
Gustavo Henrique de Oliveira Rodrigues[3]
Evellyn Huani Signori[4]
Sheila Leal Oliveira Loureiro[5]
Guilherme Augusto Vilas Boas Vasconcelos[6]

RESUMO: Este estudo analisa a aplicação da Inteligência Artificial na manutenção preditiva e sua relação com o desempenho de equipamentos industriais. O objetivo foi identificar as principais aplicações da IA em tarefas de monitoramento, detecção de anomalias, diagnóstico, prognóstico de falhas e estimativa da vida útil remanescente, bem como examinar seus possíveis reflexos sobre disponibilidade, ocorrência de falhas e tempo de parada. A pesquisa consiste em uma revisão narrativa da literatura com busca estruturada, de abordagem qualitativa e caráter descritivo, realizada no Google Scholar, SciELO e ScienceDirect, contemplando publicações entre 2019 e 15 de outubro de 2026. Após a aplicação dos critérios de inclusão e exclusão, oito estudos compuseram o conjunto principal da análise, sendo seis revisões e dois estudos de aplicação experimental ou industrial. Os resultados indicaram que a IA tem sido utilizada principalmente no processamento de dados operacionais, identificação de condições anormais, diagnóstico de falhas, prognóstico da degradação e estimativa de RUL. Entretanto, os estudos apresentaram heterogeneidade quanto aos equipamentos, métodos, conjuntos de dados, formas de validação e indicadores analisados. As evidências foram mais consistentes para o apoio ao monitoramento, diagnóstico e prognóstico do que para demonstrar melhorias operacionais diretamente comparáveis. Conclui-se que a IA pode contribuir para a manutenção preditiva, mas seus efeitos dependem da qualidade dos dados, das condições de aplicação, da validação dos modelos e da integração das informações ao processo de tomada de decisão.

Palavras-chave: Inteligência Artificial. Manutenção preditiva. Confiabilidade. Aprendizado de Máquina. Monitoramento de condições.

ABSTRACT: This study analyzes the application of Artificial Intelligence in predictive maintenance and its relationship with the performance of industrial equipment. The objective was to identify the main applications of AI in monitoring, anomaly detection, fault diagnosis, fault prognosis, and remaining useful life estimation, as well as to examine their potential effects on availability, failure occurrence, and downtime. The research consists of a narrative literature review with a structured search strategy, adopting a qualitative and descriptive approach. Searches were conducted in Google Scholar, SciELO, and ScienceDirect, covering publications from 2019 to October 15, 2026. After applying the inclusion and exclusion criteria, eight studies were included in the main analysis, comprising six literature reviews and two experimental or industrial application studies. The results indicated that AI has been primarily used for processing operational data, identifying abnormal conditions, diagnosing faults, predicting degradation, and estimating remaining useful life (RUL). However, the studies showed heterogeneity regarding equipment, methods, datasets, validation procedures, and performance indicators. The evidence was more consistent in supporting monitoring, diagnosis, and prognosis than in demonstrating directly comparable operational improvements. It is concluded that AI can contribute to predictive maintenance, but its effects depend on data quality, application conditions, model validation, and the integration of information into decision-making processes.

Keywords: Artificial Intelligence. Predictive Maintenance. Reliability. Machine Learning. Condition Monitoring.

[1] Graduando em Engenharia Mecânica. Centro Universitário UNA – Pouso Alegre.
[2] Graduando em Engenharia Mecânica. Centro Universitário UNA – Pouso Alegre.
[3] Graduando em Engenharia Mecânica. Centro Universitário UNA – Pouso Alegre.
[4] Graduanda em Engenharia Mecânica. Centro Universitário UNA – Pouso Alegre.
[5] Mestra em Engenharia Civil. Ânima Educação.
[6] Doutor em Engenharia Mecânica. Centro Universitário UNA – Pouso Alegre.

1 INTRODUÇÃO

A manutenção industrial desempenha papel relevante na continuidade dos processos produtivos, uma vez que falhas inesperadas podem provocar interrupções, aumento de custos e perdas operacionais. Entre as estratégias utilizadas para acompanhar o desempenho dos ativos, destaca-se a manutenção preditiva, baseada no monitoramento das condições de funcionamento dos equipamentos e na utilização dessas informações para apoiar decisões de manutenção (CARVALHO et al., 2019; SURUCU; GADSDEN; YAWNEY, 2023).

Com o avanço da digitalização industrial, técnicas de Inteligência Artificial passaram a ser incorporadas ao processamento dos dados provenientes do monitoramento de máquinas e equipamentos. Neste estudo, a Inteligência Artificial é considerada como conceito abrangente, enquanto o Aprendizado de Máquina e o Aprendizado Profundo representam abordagens utilizadas no desenvolvimento de modelos capazes de reconhecer padrões nos dados operacionais. Essas técnicas têm sido empregadas em aplicações de manutenção preditiva associadas ao monitoramento de condições, à detecção de anomalias, ao diagnóstico de falhas e ao prognóstico da degradação (LANZARIN; CECCONELLO, 2026; SILVA et al., 2026).

Para analisar os possíveis efeitos da Inteligência Artificial, foram considerados indicadores como disponibilidade, ocorrência de falhas, tempo de parada, MTBF e MTTR, além da estimativa de vida útil remanescente (RUL). Esses indicadores permitem distinguir o desempenho dos modelos computacionais dos resultados operacionais relatados na literatura.

Entretanto, o bom desempenho computacional de um modelo não implica necessariamente melhoria equivalente no desempenho operacional. Métricas utilizadas para avaliar algoritmos, como acurácia, precisão, recall e F1-score, descrevem a capacidade do modelo de identificar ou classificar determinadas condições, enquanto indicadores como disponibilidade, ocorrência de falhas e tempo de parada representam resultados relacionados à operação e à manutenção dos ativos. Além disso, fatores como qualidade dos dados, condições de operação e integração das informações aos processos de manutenção podem influenciar os resultados obtidos.

Nesse contexto, permanece relevante compreender que tipo de evidência a literatura apresenta sobre a relação entre o desempenho dos modelos de Inteligência Artificial e os resultados observados nos equipamentos. Parte dos estudos concentra-se na avaliação do desempenho computacional, enquanto outros apresentam aplicações experimentais ou industriais e discutem seus possíveis reflexos sobre a manutenção. Dessa forma, torna-se

necessário distinguir quais estudos demonstram apenas desempenho do modelo e quais apresentam evidências relacionadas a indicadores operacionais, bem como identificar limitações, resultados nulos e lacunas existentes.

Diante desse contexto, o presente trabalho busca responder à seguinte questão de pesquisa: quais efeitos, limitações e lacunas são relatados na literatura sobre a aplicação da Inteligência Artificial à manutenção preditiva, e que evidências os sustentam em relação aos indicadores de manutenção, desempenho operacional e estimativas prognósticas selecionados?

O objetivo geral deste estudo é analisar criticamente as evidências disponíveis na literatura sobre as aplicações da Inteligência Artificial na manutenção preditiva e sua relação com o desempenho de equipamentos industriais. Especificamente, busca-se identificar as aplicações e tarefas de IA avaliadas nos estudos; caracterizar os métodos empregados e as formas de validação utilizadas; analisar quais indicadores operacionais ou prognósticos foram efetivamente mensurados e quais permaneceram sem avaliação direta; e discutir as limitações técnicas, metodológicas e operacionais relatadas.

Esta revisão justifica-se pela necessidade de distinguir o desempenho computacional dos modelos de IA dos resultados efetivamente observados na manutenção industrial. Sua contribuição consiste em classificar as evidências como resultados medidos, estimados ou potenciais, identificando lacunas de mensuração e comparabilidade nos indicadores operacionais.

2 REFERENCIAL TEÓRICO

2.1 Manutenção industrial e manutenção preditiva

A manutenção industrial compreende atividades destinadas a conservar ou restabelecer as condições necessárias ao funcionamento dos equipamentos. Entre as principais estratégias encontram-se a manutenção corretiva, realizada após a ocorrência da falha; a preventiva, baseada em intervenções previamente estabelecidas; e a preditiva, orientada pelo acompanhamento das condições do equipamento. Essas estratégias não são necessariamente substitutas entre si, pois sua aplicação depende da função do ativo, das consequências da falha, da possibilidade de monitoramento e dos recursos disponíveis (SELLITTO, 2005).

A manutenção preditiva utiliza informações obtidas sobre a condição do equipamento para apoiar o planejamento das intervenções. Variáveis como vibração, temperatura, pressão, corrente elétrica e ruído podem ser monitoradas para identificar alterações no comportamento

do ativo. Esse acompanhamento caracteriza o monitoramento de condição e pode ser realizado independentemente do uso de Inteligência Artificial (SURUCU; GADSDEN; YAWNEY, 2023).

A Inteligência Artificial permite processar os dados dos sensores, reconhecer padrões, classificar condições e produzir estimativas. Contudo, a aquisição de sinais depende do sensoriamento e a decisão de manutenção permanece vinculada à análise técnica e à gestão dos ativos. Souza e Silva (2024) ilustram essa integração no setor de mineração.

2.2 Inteligência artificial e sensoriamento aplicados à manutenção preditiva

A digitalização dos processos industriais ampliou a disponibilidade de dados provenientes de máquinas e equipamentos, favorecendo o uso de métodos computacionais na manutenção preditiva. Nesse contexto, a Inteligência Artificial constitui uma área abrangente, enquanto o Aprendizado de Máquina corresponde a um conjunto de métodos capazes de aprender padrões a partir de dados e o Aprendizado Profundo representa uma classe desses métodos baseada em arquiteturas de múltiplas camadas. A escolha da técnica depende do tipo de dado disponível, da tarefa pretendida e da forma de validação utilizada (CARVALHO et al., 2019; SURUCU; GADSDEN; YAWNEY, 2023).

As aplicações podem desempenhar tarefas distintas. A detecção de anomalias busca reconhecer comportamentos diferentes do padrão esperado. O diagnóstico pode envolver a classificação do tipo de falha, mas essa classificação não demonstra necessariamente sua causa física, que pode exigir análise técnica adicional. O prognóstico busca estimar a evolução futura da degradação, podendo incluir a estimativa da vida útil remanescente (Remaining Useful Life – RUL). Nem todos os sistemas executam simultaneamente detecção, diagnóstico e prognóstico, razão pela qual essas tarefas são analisadas separadamente neste trabalho.

A RUL corresponde a uma estimativa do tempo de operação restante até que seja atingida determinada condição limite. Sua interpretação depende da definição dessa condição, da unidade temporal utilizada e do regime de funcionamento do equipamento. Portanto, melhorar a precisão de uma estimativa de RUL não significa necessariamente aumentar a vida física do componente; significa obter uma previsão mais adequada de quanto tempo ele poderá permanecer em operação dentro das condições consideradas.

Lanzarin e Cecconello (2026), em revisão de 25 estudos sobre elevadores, identificaram aplicações de Aprendizado de Máquina, Aprendizado Profundo, Internet das Coisas,

computação em nuvem, gêmeos digitais e modelos informados pela física. Entre as técnicas destacam-se CNN, LSTM e XGBoost. Esses 25 trabalhos integram a revisão citada e não foram examinados individualmente nesta pesquisa.

Por se tratar de uma revisão específica de elevadores, suas conclusões não são generalizadas automaticamente para outros ativos industriais.

Silva et al. (2026) analisaram sensores magnéticos associados à IA principalmente em motores elétricos, máquinas rotativas e sistemas eletromecânicos, relatando detecção de anomalias, classificação de falhas, prognóstico e estimativa de RUL. Os achados não representam todas as modalidades de sensoriamento industrial.

2.3 Indicadores de confiabilidade associados à manutenção preditiva

Confiabilidade é a capacidade de um item desempenhar a função requerida, sob condições estabelecidas, por determinado intervalo de tempo. Não equivale à disponibilidade ou ao desempenho da manutenção, dimensões tratadas separadamente nesta revisão.

A disponibilidade indica a aptidão de um equipamento para executar sua função quando requerido. Sua comparação exige definições e bases temporais compatíveis, inclusive quanto ao tratamento de manutenção programada, atrasos e indisponibilidades.

A ocorrência de falhas é a contagem de eventos registrados, enquanto sua frequência considera um período ou exposição. A taxa de falhas possui definição própria na análise de confiabilidade; portanto, essas medidas não são consideradas intercambiáveis.

O tempo de parada pode envolver diagnóstico, espera por peças, mobilização e reparo. É necessário distinguir paradas planejadas das não planejadas, pois uma intervenção programada pode prevenir uma interrupção posterior mais longa.

O MTBF indica o tempo médio entre falhas de itens reparáveis, e o MTTR corresponde ao tempo médio de reparo conforme a definição da fonte. O MTTR não equivale necessariamente ao tempo total de parada, que pode incluir atrasos logísticos e administrativos.

A RUL é uma saída prognóstica distinta das métricas que avaliam sua precisão, como erro de previsão, horizonte e incerteza. Seu uso efetivo na decisão de manutenção também deve ser identificado quando relatado.

Por isso, a análise distingue saída do modelo, métrica de validação e resultado operacional observado, evitando interpretar desempenho computacional como comprovação de melhoria da manutenção.

2.4 Limitações e desafios da inteligência artificial na manutenção preditiva

A avaliação de modelos de Inteligência Artificial aplicados à manutenção depende da qualidade e da representatividade dos dados utilizados. Falhas raras podem produzir conjuntos desbalanceados, enquanto alterações de carga, velocidade, ambiente e regime de operação podem modificar os padrões registrados pelos sensores. Também devem ser consideradas diferenças entre dados obtidos em laboratório e dados coletados em condições reais de campo, pois um modelo validado em ambiente controlado pode apresentar desempenho diferente quando aplicado industrialmente (LANZARIN; CECCONELLO, 2026; SILVA et al., 2026).

Além da qualidade dos dados, são relevantes a forma de validação utilizada, a explicabilidade dos modelos, a interoperabilidade com sistemas existentes e a capacidade de integrar as informações produzidas ao processo de manutenção. Assim, neste trabalho, as limitações relatadas são classificadas principalmente segundo três dimensões: qualidade e representatividade dos dados; validação e desempenho do modelo; e integração operacional das informações produzidas.

Scaife (2024) aponta limitações de disponibilidade de dados em operações de instalações. Como esse contexto não corresponde necessariamente a processos industriais, seus resultados são considerados com cautela.

3 METODOLOGIA

Trata-se de revisão narrativa da literatura com busca estruturada, abordagem qualitativa e caráter descritivo, destinada a comparar aplicações, evidências e limitações da IA na manutenção preditiva. A revisão narrativa permite integrar pesquisas com diferentes métodos e contextos, sem adotar protocolo formal de revisão sistemática (ROTHER, 2007).

Foram consultados Google Scholar, SciELO e ScienceDirect, com combinações de termos em português e inglês referentes a IA, manutenção preditiva, Aprendizado de Máquina, confiabilidade, falhas, disponibilidade, paradas e vida útil remanescente.

Para padronização da estratégia de busca, foram consideradas combinações como: “manutenção preditiva” AND “inteligência artificial” AND “confiabilidade”; “predictive maintenance” AND “artificial intelligence” AND reliability; “predictive maintenance” AND “machine learning” AND “failure prediction”; e “predictive maintenance” AND (“artificial intelligence” OR “machine learning”) AND (reliability OR availability OR “remaining useful

life"). As buscas foram encerradas em 15 de outubro de 2026, de modo que o recorte temporal não pressupõe a cobertura integral do ano de 2026.

O recorte incluiu trabalhos publicados de 2019 até 15 de outubro de 2026, concentrando a análise em aplicações contemporâneas de IA na manutenção preditiva. Esse período diz respeito às oito publicações selecionadas e não necessariamente aos estudos primários citados dentro das revisões.

Foram considerados elegíveis estudos publicados em português ou inglês, disponíveis em texto integral e relacionados à aplicação de Inteligência Artificial na manutenção preditiva de ativos físicos. Para inclusão, os trabalhos deveriam apresentar pelo menos um dos seguintes elementos: monitoramento de condição associado a modelos computacionais, detecção de anomalias, classificação ou diagnóstico de falhas, prognóstico, estimativa de vida útil remanescente, avaliação do desempenho de modelos ou resultados relacionados à manutenção e ao desempenho operacional dos equipamentos.

Foram incluídos estudos primários e revisões: os primeiros forneceram resultados experimentais ou industriais específicos, enquanto as revisões permitiram mapear métodos e limitações. Os dois tipos de evidência foram analisados de acordo com suas diferenças metodológicas.

Foram excluídos trabalhos duplicados, estudos sem relação com a manutenção de ativos físicos, publicações sobre Inteligência Artificial sem aplicação à manutenção, trabalhos sem acesso ao texto integral e materiais que não apresentassem informações suficientes sobre aplicação, metodologia, validação ou resultados. Quando identificadas, duplicatas foram verificadas por meio da comparação entre título, autoria, ano de publicação e DOI.

Após a aplicação dos critérios de elegibilidade, oito estudos compuseram o conjunto principal da análise: Carvalho et al. (2019); Leukel, González e Riekert (2021); Achouch et al. (2023); Surucu, Gadsden e Yawney (2023); Souza e Silva (2024); Scaife (2024); Lanzarin e Cecconello (2026); e Silva et al. (2026). Referências utilizadas exclusivamente para fundamentação conceitual, como a ABNT NBR 5462 e Sellitto (2005), não foram consideradas integrantes da amostra analítica.

Os registros quantitativos das etapas iniciais de busca e triagem não foram preservados; portanto, não foi possível determinar com precisão o total de resultados recuperados, duplicatas e exclusões. Como se trata de revisão narrativa com busca estruturada, e não de revisão

sistemática sob protocolo PRISMA, esses números não foram reconstruídos retrospectivamente. Tal ausência constitui uma limitação metodológica.

Os oito estudos foram organizados em matriz com autoria, tipo e contexto do estudo, sensores e dados, tarefa e técnica de IA, validação, métricas, saídas, indicadores, comparação, resultados e limitações. Também se registrou a localização das informações nas fontes.

A avaliação crítica considerou, nos estudos primários, contexto, dados, comparadores, validação e resultados mensurados; nas revisões, estratégia de busca, seleção e limitações. Assim, estudos experimentais, aplicações industriais e revisões não receberam peso equivalente.

A análise distinguiu as saídas produzidas pelos modelos, as métricas utilizadas para validá-las e os resultados operacionais observados nos equipamentos. As evidências foram classificadas como medidas, quando acompanhadas de valores observados ou calculados; estimadas, quando provenientes de previsões; potenciais, quando os benefícios foram apenas discutidos; e não informadas, quando os estudos não apresentaram resultados correspondentes. Essa classificação permitiu avaliar criticamente a relação entre o desempenho computacional e os efeitos operacionais relatados.

Os valores quantitativos relatados foram preservados quando relevantes. A abordagem qualitativa diz respeito à integração e interpretação das evidências, e não à exclusão de resultados numéricos.

Não foram realizados experimentos nem testes de causalidade. A análise distinguiu resultados mensurados, estimados, potenciais e não informados, examinando a força e as limitações das evidências.

A Figura 1 sintetiza a questão de pesquisa, busca, elegibilidade, seleção dos oito estudos, extração de informações, classificação, avaliação crítica e síntese dos resultados.

Figura 1 – Etapas metodológicas da revisão bibliográfica



Fonte: Elaboração própria (2026).

4 RESULTADOS E DISCUSSÕES

O conjunto incluiu seis revisões (CARVALHO et al., 2019; LEUKEL; GONZÁLEZ; RIEKERT, 2021; SURUCU; GADSDEN; YAWNEY, 2023; SCAIFE, 2024; LANZARIN; CECCONELLO, 2026; SILVA et al., 2026) e dois estudos de aplicação experimental ou industrial (ACHOUCH et al., 2023; SOUZA; SILVA, 2024).

As evidências encontradas não possuem a mesma natureza. Parte dos trabalhos avalia principalmente desempenho computacional dos modelos, enquanto outros apresentam resultados relacionados ao monitoramento, prognóstico ou planejamento das intervenções. Os desfechos operacionais, como disponibilidade, ocorrência de falhas e tempo de parada, não foram mensurados de maneira padronizada entre os estudos, o que limita comparações quantitativas diretas.

As seis revisões podem incluir estudos primários sobrepostos; portanto, sua concordância foi interpretada como convergência da literatura, e não como seis conjuntos independentes de demonstrações experimentais.

A síntese das principais características dos trabalhos utilizados nesta análise é apresentada na Tabela 1.

Tabela 1 – Síntese dos estudos selecionados sobre a aplicação de inteligência artificial na manutenção preditiva

Tabela 1 – Síntese dos estudos selecionados sobre a aplicação da Inteligência Artificial na manutenção preditiva.

Autor (ano)	Tipo de estudo	Contexto / ativo principal	Principais tarefas de IA	Técnicas / algoritmos	Principais resultados (da fonte)
Carvalho et al. (2019)	Revisão sistemática	Diversos setores industriais	Detecção, diagnóstico, prognóstico e classificação de falhas	Machine Learning (diversos)	Mapeamento das aplicações, métodos e tendências de ML na manutenção preditiva.
Leukel, González e Riekert (2021)	Revisão sistemática	Manufatura e sistemas industriais	Detecção, diagnóstico e prognóstico	Machine Learning (diversos)	Síntese de aplicações de ML para previsão de falhas e direções para implementação.
Surucu, Gadsden e Yawney (2023)	Revisão de literatura (review)	Diversos setores industriais	Monitoramento de condições, detecção, diagnóstico e prognóstico	Machine Learning (diversos)	Discussão das aplicações de ML no monitoramento de condições, processamento de dados e seleção de modelos.
Achouch et al. (2023)	Estudo experimental	Compressor centrífugo TA-48	Detecção, diagnóstico e prognóstico (RUL)	LSTM (Deep Learning)	Proposta e validação de modelo LSTM para estimativa da vida útil remanescente (RUL) do compressor.
Souza e Silva (2024)	Estudo de caso	Mineração (equipamentos industriais)	Monitoramento de condições e detecção de anomalias	Plataforma DYNAPREDICT (algoritmo não informado)	Aplicação de sensores triaxiais sem fio (vibração e temperatura) com plataforma de IA. Redução da parada planejada para 1,9 dia (vs. 20 dias no cenário corretivo).
Scaife (2024)	Revisão sistemática	Operações de instalações industriais	Detecção, diagnóstico e prognóstico	Machine Learning (diversos)	Síntese de aplicações, benefícios potenciais e barreiras para implementação.
Lanzarin e Cecconello (2026)	Revisão sistemática	Elevadores	Detecção, diagnóstico e prognóstico	Machine Learning, Deep Learning, CNN, LSTM, XGBoost (entre outros)	Análise de 25 estudos sobre aplicações de IA e sensoriamento na manutenção preditiva de elevadores.
Silva et al. (2026)	Revisão sistemática	Motores elétricos, máquinas rotativas e sistemas eletromecânicos	Detecção, diagnóstico e prognóstico (RUL)	Machine Learning e Deep Learning (diversos) (com sensores magnéticos)	Síntese de aplicações de sensores magnéticos com IA, incluindo detecção, classificação de falhas, prognóstico e estimativa de RUL.

Fonte: Elaboração própria (2026), com base na literatura analisada.

4.1 Monitoramento de condição, detecção e diagnóstico de falhas

Os estudos abordam monitoramento de condição, detecção de anomalias e diagnóstico de falhas. O monitoramento acompanha variáveis operacionais; a detecção reconhece desvios; e o diagnóstico classifica falhas, sem necessariamente estabelecer sua causa física.

No estudo de Souza e Silva (2024), sensores triaxiais sem fio foram utilizados para monitorar vibração e temperatura de equipamentos críticos no setor de mineração. Os dados foram processados por uma plataforma de monitoramento baseada em Inteligência Artificial, denominada DYNAPREDICT, responsável pela geração de alertas relacionados a condições anormais. Como o trabalho consultado não identifica de forma verificável o algoritmo específico empregado pela plataforma, essa informação deve ser registrada como "algoritmo não informado", evitando atribuir técnicas como SVM ou CNN sem suporte explícito da fonte.

Lanzarin e Cecconello (2026), em revisão específica sobre manutenção preditiva de elevadores, identificaram aplicações de Aprendizado de Máquina e Aprendizado Profundo em

tarefas relacionadas ao reconhecimento de padrões e ao diagnóstico de falhas em subsistemas críticos. Os 25 estudos mencionados pertencem à revisão desses autores e não correspondem a 25 estudos primários examinados diretamente no presente TCC. Assim, seus resultados são utilizados como síntese de literatura e não como 25 evidências independentes.

Silva et al. (2026) identificaram aplicações de sensores magnéticos associados a métodos de Machine Learning e Deep Learning em motores elétricos, máquinas rotativas e sistemas eletromecânicos. Entre as tarefas relatadas encontram-se detecção de anomalias, classificação de falhas e prognóstico. Esse recorte foi preservado na análise, evitando generalizar os resultados para qualquer tipo de sensoriamento industrial.

Carvalho et al. (2019) e Surucu, Gadsden e Yawney (2023) também descrevem aplicações de Aprendizado de Máquina no monitoramento de condições e identificação de padrões associados à degradação dos ativos. Entretanto, a presença recorrente dessas aplicações em revisões não demonstra, isoladamente, redução de falhas ou melhoria operacional. Ela evidencia principalmente que detecção e classificação constituem tarefas frequentes na literatura analisada.

Assim, embora monitoramento e classificação apareçam em diferentes trabalhos, detectar uma condição anormal não equivale a prever uma falha futura ou comprovar melhoria nos indicadores operacionais.

4.2 Disponibilidade e tempo de parada

A análise dos estudos mostrou menor disponibilidade de evidências diretamente comparáveis sobre disponibilidade e tempo de parada do que sobre o desempenho dos modelos. Em vários trabalhos, esses indicadores aparecem como benefícios potenciais ou como consequências esperadas de uma intervenção antecipada, sem mensuração operacional padronizada.

Souza e Silva (2024) apresentam uma comparação relevante entre cenários de manutenção. O estudo indica aproximadamente 1,9 dia de parada planejada, em comparação com 20 dias no cenário corretivo. Esse resultado oferece uma referência quantitativa para a discussão do tempo de parada, porém deve ser interpretado com cautela. A comparação apresentada não corresponde necessariamente a um experimento controlado antes e depois da implementação da IA, mas a cenários de manutenção distintos. Portanto, não permite atribuir automaticamente à Inteligência Artificial toda a diferença observada.

Os alertas de Souza e Silva (2024) apoiaram intervenções antecipadas, demonstrando uso prático das informações, mas sem permitir atribuir à IA todos os benefícios sugeridos.

Lanzarin e Cecconello (2026) relacionam as tecnologias analisadas ao potencial de aumento da segurança e da disponibilidade operacional em elevadores. Entretanto, essa expressão deve ser preservada como potencial, pois a presença de técnicas de IA nos estudos revisados não significa que todos tenham demonstrado aumento mensurado de disponibilidade.

Alertas antecipados podem apoiar o planejamento de mão de obra, peças e recursos. Contudo, essa relação não constitui demonstração causal uniforme.

Diferenças entre equipamentos, períodos e formas de cálculo impedem agregar os valores de disponibilidade e tempo de parada em uma porcentagem geral de melhoria.

4.3 Prognóstico e estimativa da vida útil remanescente

O prognóstico de falhas incorpora a dimensão temporal, permitindo estimar a evolução da degradação dos equipamentos e sua vida útil remanescente (RUL). Nesse contexto, Achouch et al. (2023) apresentam um estudo experimental com o compressor centrífugo multiestágio TA-48, no qual diferentes técnicas de Aprendizado de Máquina foram avaliadas, incluindo redes Long Short-Term Memory (LSTM) para a previsão de RUL. O estudo destaca a importância dos modelos prognósticos, além das aplicações voltadas à classificação de falhas. Para a análise das evidências, foram considerados, quando disponíveis, a variável prevista, a unidade de medida da RUL, os métodos de validação e as métricas de erro, sendo as informações ausentes classificadas como “não informado”.

Silva et al. (2026) também identificaram aplicações de prognóstico e estimativa de RUL em estudos associados a sensores magnéticos. Nesse caso, a revisão oferece evidência de que a tarefa aparece na literatura, mas não substitui a análise das métricas e resultados do estudo primário de Achouch et al.

A vida útil remanescente (RUL) corresponde à estimativa do tempo de operação restante de um componente até atingir determinada condição limite. Dessa forma, maior precisão na previsão não implica necessariamente o prolongamento de sua vida útil física. Além disso, a estimativa de RUL deve ser diferenciada das métricas utilizadas para avaliar a qualidade do prognóstico, como erro de previsão, horizonte temporal e incerteza associada.

A Tabela 2 relaciona as tarefas da IA aos indicadores e à natureza das evidências encontradas.

Tabela 2 – Matriz de evidências dos estudos analisados sobre técnicas de inteligência artificial e resultados reportados

Tabela 2 – Matriz de evidências dos estudos analisados sobre técnicas de Inteligência Artificial e resultados reportados.

Estudo (ano)	Tarefa de IA avaliada	Técnica / modelo principal	Validação / métrica computacional	Indicador, desfecho ou saída analisada	Resultado reportado (da fonte)	Natureza da evidência
Carvalho et al. (2019)	Detecção, diagnóstico e prognóstico	Machine Learning (diversos)	Síntese de estudos da literatura	Disponibilidade, taxa de falhas, MTBF, MTTR	Mapeamento de aplicações, métodos e tendências de ML na manutenção preditiva.	Potencial (revisão)
Leukel, González e Riekert (2021)	Detecção, diagnóstico e prognóstico	Machine Learning (diversos)	Síntese de estudos da literatura	Disponibilidade, tempo de parada, MTBF, MTTR	Síntese de aplicações de ML para previsão de falhas e direções para implementação.	Potencial (revisão)
Surucu, Gadsden e Yawney (2023)	Monitoramento de condição, detecção, diagnóstico e prognóstico	Machine Learning (diversos)	Discussão conceitual e síntese de aplicações	Disponibilidade, taxa de falhas, tempo de parada, RUL (discutidos)	Discussão das aplicações de ML no monitoramento de condições, processamento de dados e seleção de modelos.	Potencial (revisão)
Achouch et al. (2023)	Detecção, diagnóstico e prognóstico (RUL)	LSTM (Deep Learning)	Validação experimental com dados do compressor TA-48	RUL (estimativa de vida útil remanescente)	Proposta e validação de modelo LSTM para estimativa da vida útil remanescente do compressor.	Estimada (RUL), com validação experimental
Souza e Silva (2024)	Monitoramento de condição e detecção de anomalias	Plataforma DYNAPREDICT (algoritmo não informado)	Aplicação industrial, validação em ambiente operacional	Tempo de parada (comparação de cenários)	Redução da parada planejada para 1,9 dia (vs. 20 dias no cenário corretivo).	Medida (estudo de caso)
Scaife (2024)	Detecção, diagnóstico e prognóstico	Machine Learning (diversos)	Síntese de estudos da literatura	Disponibilidade, taxa de falhas, tempo de parada	Síntese de aplicações, benefícios potenciais e barreiras para implementação.	Potencial (revisão)
Lanzarin e Cecconello (2026)	Detecção, diagnóstico e prognóstico	Machine Learning, Deep Learning, CNN, LSTM, XGBoost (entre outros)	Síntese de 25 estudos da literatura	Disponibilidade, taxa de falhas, tempo de parada	Análise de 25 estudos sobre aplicações de IA e sensoriamento na manutenção preditiva de elevadores.	Potencial (revisão)
Silva et al. (2026)	Detecção, diagnóstico e prognóstico (RUL)	Machine Learning e Deep Learning (diversos, com sensores magnéticos)	Síntese de estudos da literatura	Disponibilidade, taxa de falhas, tempo de parada, RUL	Síntese de aplicações de sensores magnéticos com IA, incluindo detecção, classificação de falhas, prognóstico e estimativa de RUL.	Potencial (revisão)

Fonte: Elaborada pelos autores (2026), a partir dos estudos analisados.

Fonte: Elaboração própria (2026), com base na literatura analisada.

4.4 Limitações observadas nos estudos

As limitações foram agrupadas em qualidade dos dados, validação dos modelos e integração operacional.

No primeiro grupo, destacam-se escassez de registros reais de falhas, ocorrência de falhas raras, possível desbalanceamento das classes e variações nas condições de carga e operação. Esses fatores podem comprometer a capacidade de generalização dos modelos para situações diferentes daquelas utilizadas no treinamento.

No segundo grupo estão as limitações relacionadas à validação. Um modelo pode apresentar bom desempenho em um conjunto de dados específico e ainda assim ter comportamento diferente em campo. Por isso, resultados obtidos em laboratório, conjuntos de dados históricos ou ambientes controlados devem ser distinguidos de validações realizadas em condições industriais reais.

Também devem ser considerados falsos alarmes e falhas não detectadas. Um sistema com elevado desempenho médio ainda pode produzir alertas desnecessários ou deixar de identificar eventos relevantes. Quando essas informações não são apresentadas nos estudos, sua

ausência deve ser registrada como uma lacuna da evidência, e não substituída pela suposição de benefício.

No terceiro grupo encontram-se fatores relacionados à aplicação operacional, como interoperabilidade, integração com sistemas existentes, interpretação dos alertas, capacitação profissional e transformação das previsões em ações de manutenção. Lanzarin e Cecconello (2026) destacam escassez de dados reais, variabilidade operacional e integração com sistemas legados, enquanto Silva et al. (2026) acrescentam questões relacionadas à validação técnica, explicabilidade e capacitação profissional.

Scaife (2024) também relata insuficiência de dados em operações de instalações, contexto cujas conclusões não foram generalizadas a todos os ativos industriais.

A repetição de limitações entre revisões não representa necessariamente evidências independentes, devido à possível sobreposição de estudos primários.

O Quadro 1 sintetiza benefícios potenciais e limitações identificados na literatura.

Quadro 1 – Benefícios potenciais e limitações da inteligência artificial na manutenção preditiva

Quadro 1 – Benefícios potenciais e limitações da Inteligência Artificial na manutenção preditiva.

Classificação	Item sintetizado	Interpretação / cautela
Benefício potencial	Identificação antecipada de condições anormais.	Relatado em diferentes estudos; não implica, por si só, redução de falhas.
Benefício potencial	Apoio ao diagnóstico de falhas.	Relacionado à classificação e interpretação de padrões; causa física pode exigir análise adicional.
Benefício potencial	Apoio ao prognóstico e à estimativa de RUL.	Presente em estudos com tarefas prognósticas; RUL estimada não equivale a aumento da vida física.
Benefício potencial	Planejamento antecipado das intervenções.	Depende da interpretação dos alertas e da execução das ações de manutenção.
Benefício potencial	Possível redução de paradas não planejadas.	Deve ser tratada como potencial quando não houver mensuração operacional direta.
Limitação	Qualidade e representatividade dos dados.	Falhas raras, classes desbalanceadas e mudanças de condição podem reduzir a generalização.
Limitação	Escassez de dados reais de falhas.	Limita treinamento, validação e comparação entre aplicações.
Limitação	Validação e generalização dos modelos.	Bom desempenho computacional não garante o mesmo resultado em campo.
Limitação	Integração com sistemas e processos de manutenção.	Alertas só produzem efeito operacional quando incorporados à decisão e à intervenção.
Limitação	Explicabilidade e capacitação profissional.	A interpretação dos resultados e a tomada de decisão permanecem dependentes de análise técnica.

Fonte: Elaborada pelos autores (2026), a partir da literatura analisada.
Nota: os benefícios são apresentados conforme a força da evidência disponível e não representam efeitos garantidos da IA.

Fonte: Elaboração própria (2026), com base na literatura analisada.

4.5 Discussão integrada das evidências

A análise conjunta mostrou que os oito trabalhos não apresentam o mesmo nível de evidência sobre os benefícios atribuídos à Inteligência Artificial. Parte dos resultados está

concentrada no desempenho computacional dos modelos, no reconhecimento de padrões e nas saídas de diagnóstico ou prognóstico, enquanto os efeitos diretamente mensurados sobre disponibilidade, ocorrência de falhas e tempo de parada são menos uniformes.

Essa diferença reforça a necessidade de separar desempenho do modelo de desempenho do equipamento. Métricas como acurácia, precisão, recall e F1-score avaliam tarefas de classificação ou detecção, enquanto métricas de erro de RUL avaliam previsões prognósticas. Já disponibilidade, taxa ou ocorrência de falhas, MTBF, MTTR e tempo de parada pertencem ao desempenho operacional e à manutenção do ativo. Um bom resultado no primeiro grupo não implica automaticamente melhoria equivalente no segundo.

A matriz registra tarefas, técnicas, validação, indicadores e natureza das evidências, distinguindo resultados medidos, estimados e potenciais.

Os resultados oferecem suporte mais consistente para afirmar que a IA pode auxiliar no processamento de dados, na identificação de condições anormais, no diagnóstico e no prognóstico do que para determinar uma magnitude geral de melhoria operacional. O estudo de Souza e Silva (2024), por exemplo, oferece um comparativo relacionado ao tempo de parada, enquanto Achouch et al. (2023) oferece evidência experimental pertinente ao prognóstico de RUL. Nos demais casos, diferentes benefícios aparecem frequentemente como potenciais ou são sintetizados por trabalhos de revisão.

Equipamentos, sensores, algoritmos, métodos, validação e indicadores heterogêneos dificultam agregar resultados, mas permitem comparação crítica.

Como seis trabalhos são revisões potencialmente sobrepostas, sua concordância indica recorrência na literatura, não demonstrações independentes de eficácia.

A principal contribuição desta revisão é diferenciar evidências de desempenho computacional dos resultados operacionais mensurados, estimados ou apenas potenciais, identificando lacunas de informação.

A Figura 2 apresenta o modelo conceitual que relaciona aquisição de dados, análise por IA, validação, tomada de decisão e possíveis indicadores operacionais. Trata-se de síntese da literatura, não de relação causal testada.

Figura 2 – Modelo conceitual da aplicação da inteligência artificial na manutenção preditiva



Fonte: Elaboração própria (2026).

5 CONCLUSÕES

Este estudo teve como objetivo analisar as aplicações e limitações da Inteligência Artificial na manutenção preditiva e sua relação com o desempenho de equipamentos industriais. A revisão de oito trabalhos, composta por seis estudos de revisão e dois de aplicação experimental ou industrial, identificou aplicações principalmente no monitoramento de condições, detecção de anomalias, diagnóstico de falhas, prognóstico da degradação e estimativa da vida útil remanescente (RUL).

Os resultados demonstraram que a Inteligência Artificial pode contribuir para o processamento de dados operacionais e a identificação antecipada de condições anormais, fornecendo informações relevantes ao planejamento da manutenção. Entretanto, as evidências analisadas foram mais consistentes quanto ao desempenho computacional dos modelos do que à demonstração de melhorias operacionais diretamente comparáveis. Dessa forma, métricas como acurácia, precisão e erro de previsão não devem ser interpretadas isoladamente como comprovação de aumento da disponibilidade ou redução de falhas e paradas.

A análise também identificou limitações relacionadas à qualidade e representatividade dos dados, à escassez de registros reais de falhas, à variabilidade das condições operacionais, à

validação dos modelos e à integração das informações aos processos de manutenção. Esses fatores evidenciam que os resultados operacionais dependem não apenas da capacidade dos algoritmos, mas também da interpretação técnica e da execução das intervenções.

Entre as limitações desta revisão, destacam-se o número reduzido de estudos primários, a predominância de revisões bibliográficas, a heterogeneidade dos métodos e indicadores e a possibilidade de sobreposição de estudos entre as revisões selecionadas. Essas características impediram a determinação de um efeito quantitativo geral da Inteligência Artificial sobre os indicadores operacionais considerados.

Conclui-se que a Inteligência Artificial constitui uma ferramenta de apoio ao monitoramento, diagnóstico, prognóstico e tomada de decisão na manutenção preditiva, embora seus benefícios operacionais não sejam automáticos. Recomenda-se que pesquisas futuras priorizem aplicações industriais em condições reais de operação, com indicadores padronizados, comparadores definidos e avaliações que relacionem o desempenho dos modelos aos resultados efetivamente observados nos equipamentos.

REFERÊNCIAS

ACHOUCH, Mounia; DIMITROVA, Mariya; DHOUIB, Rizck; IBRAHIM, Hussein; ADDA, Mehdi; SATTARPANAH KARGANROUDI, Sasan; ZIANE, Khaled; AMINZADEH, Ahmad. Predictive Maintenance and Fault Monitoring Enabled by Machine Learning: Experimental Analysis of a TA-48 Multistage Centrifugal Plant Compressor. Applied Sciences, v. 13, n. 3, 1790, 2023. DOI: https://doi.org/10.3390/app13031790

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. NBR 5462: confiabilidade e mantenabilidade — terminologia. Rio de Janeiro: ABNT, 1994.

CARVALHO, Thyago P.; SOARES, Fabrízzio A. A. M. N.; VITA, Roberto; FRANCISCO, Roberto da P.; BASTO, João P.; ALCALÁ, Symone G. S. A systematic literature review of machine learning methods applied to predictive maintenance. Computers & Industrial Engineering, v. 137, 106024, 2019. DOI: https://doi.org/10.1016/j.cie.2019.106024

LANZARIN, Leonardo de Lima; CECCONELLO, Ivandro. Aplicação de Inteligência Artificial e tecnologias de sensoriamento na manutenção preditiva de elevadores: uma revisão sistemática no contexto da Indústria 4.0. *Exacta*, v. 24, e30304, p. 1-25, 2026. DOI: https://doi.org/10.5585/2026.30304

LEUKEL, Joerg; GONZÁLEZ, Julian; RIEKERT, Martin. Adoption of machine learning technology for failure prediction in industrial maintenance: a systematic review. Journal of Manufacturing Systems, v. 61, p. 87-96, 2021. DOI: https://doi.org/10.1016/j.jmsy.2021.08.012

ROTHER, Edna Terezinha. Revisão sistemática X revisão narrativa. Acta Paulista de Enfermagem, São Paulo, v. 20, n. 2, p. v-vi, 2007. DOI: https://doi.org/10.1590/S0103-21002007000200001

SCAIFE, Anthony D. Improve predictive maintenance through the application of artificial intelligence: a systematic review. Results in Engineering, v. 21, 101645, 2024. DOI: https://doi.org/10.1016/j.rineng.2023.101645

SELLITTO, Miguel Afonso. Formulação estratégica da manutenção industrial com base na confiabilidade dos equipamentos. Produção, v. 15, n. 1, p. 44-59, 2005. DOI: https://doi.org/10.1590/S0103-65132005000100005

SILVA, Danilton Carlos da; BORGES, Daniela Freitas; SILVA, Agaone Donizete; MACHADO, Vinícius de Barcelos; ALMEIDA, Rildo Afonso de. Inteligência Artificial e sensores magnéticos na gestão de manutenção preditiva: uma abordagem para a Indústria 4.0. Revista Multidisciplinar do Nordeste Mineiro, v. 13, n. 15, p. 1-52, 14 jul. 2026. DOI: https://doi.org/10.66104/pvsnve05

SOUZA, Alan Christian Almeida; SILVA, Paula Renatha Nunes da. 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. DOI: https://doi.org/10.51891/rease.v10i10.16252

SURUCU, Onur; GADSDEN, Stephen Andrew; YAWNEY, John. Condition Monitoring using Machine Learning: A Review of Theory, Applications, and Recent Advances. Expert Systems with Applications, v. 221, 119738, 2023. DOI: https://doi.org/10.1016/j.eswa.2023.119738