

**OTIMIZAÇÃO DA MANUTENÇÃO INDUSTRIAL: Uso do Machine Learning em
manutenções preditivas eficazes**

***OPTIMIZATION OF INDUSTRIAL MAINTENANCE: Use of Machine Learning in
effective predictive maintenance***

Francisco Emmanuel Da Silva – francisco.silva121@fatec.sp.gov.br
Faculdade de Tecnologia de Taquaritinga (Fatec) – Taquaritinga – São Paulo – Brasil

Prof. Me João de Lucca Filho – joaodelucca@terra.com.br
Faculdade de Tecnologia de Taquaritinga (Fatec) – Taquaritinga – SP – Brasil

DOI: 10.31510/infa.v22i2.2269

Data de submissão: 23/09/2025

Data do aceite: 03/12/2025

Data da publicação: 20/12/2025

RESUMO

Este artigo tem como objetivo analisar, por meio de uma revisão bibliográfica, como o Machine Learning (ML) otimiza a manutenção preditiva industrial, impactando indicadores tradicionais (OEE, MTTR, MTBF) e custos operacionais (OPEX). A fundamentação teórica explora conceitos de manutenção preditiva, evolução dos indicadores e aplicações de algoritmos de aprendizado de máquina. Estudos de caso e aplicações no setor industrial evidenciam a eficácia da integração entre sensores IoT e algoritmos de Machine Learning na antecipação de falhas e otimização de recursos. A pesquisa adota abordagem mista, unindo análise qualitativa e quantitativa, com foco em indicadores como OEE, MTTR e MTBF. Os resultados apontam que o uso de ML contribui para reduzir custos, prolongar a vida útil dos equipamentos e elevar a eficiência produtiva. Conclui-se que, apesar dos desafios estruturais e culturais, a tendência é de cada vez mais adoção dessas tecnologias, exigindo capacitação técnica e mudança de mentalidade por parte dos gestores industriais e de todos os envolvidos.

Palavras-chave: Gestão. Indicadores. Machine Learning.

ABSTRACT

This article aims to analyze, through a literature review, how Machine Learning (ML) optimizes industrial predictive maintenance by impacting traditional indicators (OEE, MTTR, MTBF) and operational costs (OPEX). The theoretical framework explores the concepts of predictive maintenance, the evolution of performance indicators, and the applications of machine learning algorithms. Case studies and industrial applications highlight the effectiveness of integrating IoT sensors and Machine Learning algorithms for fault prediction and resource optimization. The research adopts a mixed-methods approach, combining qualitative and quantitative analysis, with emphasis on indicators such as OEE, MTTR, and MTBF. The findings indicate that the use of ML contributes to cost reduction, extension of equipment lifespan, and improvement of production efficiency. In the end, even with structural and cultural challenges,

the trend is that these technologies will be more and more adopted, requiring technical training and a mindset switch from industrial managers and everyone else involved.

Keywords: Indicators. Machine Learning. Management.

1 INTRODUÇÃO

A manutenção industrial tem apresentado avanços expressivos nas últimas décadas, acompanhando a evolução tecnológica e a crescente complexidade dos processos produtivos. As estratégias de manutenção eram corretivas ou preventivas, frequentemente ocasionando interrupções imprevistas e elevando custos operacionais (Nakajima, 1988). Com a chegada da Indústria 4.0, novas possibilidades de gestão de equipamentos surgem por meio da integração de sensores da Internet das Coisas (*IoT*), análise de dados em tempo real e algoritmos de *Machine Learning (ML)*, viabilizando a implementação de modelos de manutenção preditiva mais precisos e eficientes (Carvalho *et. al.*, 2019).

Com a modernização dos processos produtivos e a crescente disponibilidade de dados em tempo real, surge uma nova perspectiva: a manutenção preditiva orientada por dados. Essa abordagem possibilita a antecipação de falhas a partir da análise de padrões históricos e de variáveis operacionais, favorecendo decisões mais precisas e estratégicas. A utilização de algoritmos e frameworks de *Machine Learning* amplia a capacidade de sistemas que se utilizam do aprendizado de máquina para identificar anomalias, emitir alertas antecipados e apoiar a execução de intervenções de manutenção de maneira otimizada (Zaro e Weber, 2023).

Nesse cenário, a manutenção preditiva baseada em *ML* emerge como estratégia capaz de antecipar falhas e otimizar intervenções, ao processar grandes volumes de dados provenientes de equipamentos críticos e identificar padrões que indicam degradação ou risco operacional (Barbosa, 2023; Silva *et al.*, 2023). A utilização de indicadores tradicionais, como *MTTR (Mean Time to Repair)*, *MTBF (Mean Time Between Failures)* e *OEE (Overall Equipment Effectiveness)*, continua a ser fundamental para avaliar a eficiência e a confiabilidade dos processos, fornecendo subsídios concretos para decisões estratégicas (Novochadlo e Paladini, 2024; Nakajima, 1988).

Mesmo com o crescimento de técnicas como *Random Forest* e redes neurais profundas em estudos acadêmicos, na prática industrial o foco se baseia na viabilidade de implementação, na simplicidade de interpretação dos resultados e na integração com sistemas já existentes. Embora muitas indústrias ainda não estejam preparadas para essa transição tecnológica, existe

uma oportunidade significativa de melhoria operacional para aquelas que se dispuserem a investir em tecnologias emergentes, com destaque para o *ML* (Novochadlo e Paladini, 2024).

Nesse sentido, Hoffmann e Lasch (2025) destacam que, apesar dos avanços e do reconhecimento dos benefícios da manutenção preditiva em estudos acadêmicos, sua implementação prática ainda enfrenta barreiras significativas relacionadas à integração tecnológica, à disponibilidade de dados e à complexidade organizacional e principalmente às dificuldades de adaptação de processos tradicionais.

A aplicação de plataformas comerciais, como a Tractian, demonstra a efetividade da integração entre *ML*, *IoT* e *frameworks* estruturados, gerando ganhos como redução de custos, diminuição de paradas não programadas e maior disponibilidade de equipamentos (Tractian, 2025).

A pesquisa concentra-se na avaliação de modelos consolidados na literatura, com destaque para a aplicação prática de algoritmos de aprendizado de máquina em contextos industriais. Sendo assim, o objetivo deste artigo é analisar como o *ML* otimiza a manutenção preditiva industrial, impactando indicadores (*OEE*, *MTTR*, *MTBF*) e custos operacionais (*OPEX*).

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Manutenção preditiva: Conceitos e evolução

A integração entre manutenção preditiva e *Machine Learning* permite estimativas mais precisas da vida útil de equipamentos, antecipando falhas e otimizando intervenções (Kamgba, 2024). Carvalho *et. al.* (2019) ressaltam que o uso de algoritmos de aprendizado de máquina pode redefinir a manutenção industrial, uma vez que permite a detecção precoce de anomalias e a otimização do momento de intervenção.

2.2 Indicadores de manutenção

Indicadores de manutenção são fundamentais para gestão de equipamentos, permitindo avaliar desempenho e subsidiar decisões estratégicas (Nakajima, 1988). Eles mensuram eficiência, confiabilidade e reduzem custos operacionais (*OPEX*).

Nesse sentido, Novochadlo e Paladini (2024) destacam que o emprego desses indicadores fortalece a melhoria contínua dos processos produtivos e amplia a disponibilidade dos ativos, o que tem sido comprovado em estudos recentes voltados à manutenção preditiva e à gestão dos equipamentos industriais.

2.2.1 MTTR - Mean Time To Repair

O *Mean Time to Repair (MTTR)* corresponde ao tempo médio necessário para que um equipamento seja reparado após a ocorrência de uma falha, configura-se como um indicador da eficiência dos processos de manutenção. Conforme Nakajima (1988), esse parâmetro apresenta estreita relação com a eficácia da *Total Productive Maintenance (TPM)*, pois avalia a rapidez da equipe e a efetividade dos procedimentos.

No contexto da Indústria 4.0, o *MTTR* pode ser acompanhado em tempo real por meio de tecnologias de Internet das Coisas (*IoT*). Em seu artigo a respeito de uso de Inteligência Artificial em manutenções preditivas, Dalzochio *et. al.* (2020) considera que a aplicação de métodos de aprendizado de máquina é fundamental para otimizar as práticas de manutenção, permitindo análise inteligente de dados, o que potencializa a tomada de decisões ágeis e baseadas em evidências.

2.2.2 MTBF - Mean Time Between Failures

O *Mean Time Between Failures (MTBF)* atua de forma complementar ao *MTTR*, ao indicar o intervalo médio em que um equipamento permanece em operação contínua sem ocorrência de falhas. Em conjunto, esses indicadores oferecem uma visão abrangente da confiabilidade dos equipamentos e do grau de maturidade da estratégia de manutenção adotada. Nakajima (1988) ressalta que a utilização integrada de *MTBF* e *MTTR* é um elemento central da filosofia *Total Productive Maintenance (TPM)*, pois possibilita prever com maior precisão a vida útil dos equipamentos e planejar intervenções de maneira mais eficaz.

De acordo com Cruz *et. al.* (2023), a prática do aprendizado de máquina combinada ao ambiente industrial pode promover melhorias na antecipação de falhas e no intervalo entre elas, estando diretamente relacionada ao indicador *MTBF*.

2.2.3 Disponibilidade

A disponibilidade é definida como a proporção entre o tempo em que um equipamento está efetivamente operando e o tempo total em que ele deveria estar disponível. Esse indicador sintetiza os impactos produzidos por falhas, reparos e atividades de manutenção preditiva.

Para Dalzochio *et. al.* (2020) A aplicação de modelos de *ML* para a estimativa do tempo de vida útil e a detecção de anomalias permite o aumento da disponibilidade dos sistemas industriais, resultando na otimização do indicador como ferramenta de suporte.

2.2.4 OEE - Overall Equipment Effectiveness

O *Overall Equipment Effectiveness (OEE)* constitui um dos principais indicadores de referência internacional, utilizado para mensurar a eficiência global de equipamentos industriais. Seu cálculo resulta da multiplicação de três dimensões: disponibilidade, desempenho e qualidade. De acordo com Novochadlo e Paladini (2024), a integração do OEE com tecnologias de *Internet of Things (IoT)* viabiliza a coleta automática e em tempo real dos dados, minimizando a necessidade de registros manuais e revelando de forma mais precisa as perdas que subsidiam o processo decisório.

No estudo conduzido por Oliveira *et. al.* (2022), em uma indústria metal-mecânica localizada no interior de São Paulo, observou-se a aplicação prática do OEE na identificação de ineficiências. Após a implementação de melhorias, o indicador registrou evolução de aproximadamente 78% para mais de 97%, evidenciando o potencial dessa métrica, especialmente quando aliada aos recursos da Indústria 4.0, em promover ganhos expressivos de produtividade e confiabilidade nos processos industriais.

2.3 Machine Learning: Fundamentos e aplicações industriais

O *Machine Learning* tem papel central na manutenção preditiva industrial, permitindo que sistemas aprimorem desempenho através da análise de dados (Carvalho *et. al.*, 2019). Sua vantagem prática está no reconhecimento de padrões em grandes volumes de dados de sensores IoT, ampliando o diagnóstico precoce.

Pesquisas recentes evidenciam a consolidação do aprendizado de máquina na manutenção preditiva, com avanços tanto metodológicos quanto práticos. Khaled *et al.* (2023), em *survey* abrangente, mapearam as principais arquiteturas de aprendizado profundo aplicáveis à detecção de falhas, desde redes neurais recorrentes até modelos baseados em séries temporais, demonstrando sua eficácia na redução de paradas não programadas e no aumento da precisão diagnóstica. O estudo também destacou que a adequação de cada técnica varia conforme o tipo de sinal monitorado (vibração, temperatura, corrente elétrica), requerendo seleção criteriosa. Paralelamente, Dalzochio *et. al.* (2020) analisaram desafios de implementação em ambientes industriais, identificando barreiras como a incompletude de bases de dados, a falta de padronização na instrumentação e as dificuldades de integração com sistemas legados de manutenção.

A convergência entre ML, IoT, Big Data e computação em nuvem, impulsionada pelos avanços da Indústria 4.0, fortalece a análise em tempo real e promove a automatização da

tomada de decisões. Segundo Lee *et. al.* (2013), a integração entre esses conceitos permite antecipar falhas, otimizar o planejamento da manutenção e reduzir custos, resultando em maior confiabilidade operacional.

De acordo com Cruz *et. al.* (2023), a combinação de técnicas de *Machine Learning* possibilita a previsão de falhas e a execução da manutenção apenas quando estritamente necessária, princípio central da manutenção preditiva que visa garantir precisão na identificação de anomalias e otimização dos recursos operacionais.

Nessa perspectiva, Barbosa (2023) evidencia que a aplicação de técnicas de *Machine Learning* em turbinas eólicas contribui significativamente para a redução dos custos de manutenção e para o aumento da disponibilidade dos sistemas.

De maneira convergente, Silva *et. al.* (2023) destacam o uso de redes neurais na previsão de falhas em equipamentos mecânicos, demonstrando que métodos avançados de inteligência artificial baseados em aprendizado de máquina ampliam a confiabilidade operacional e prolongam a vida útil dos equipamentos industriais.

2.4 Sistemas de Machine Learning na Manutenção: Estudo da Tractian

A Tractian, empresa brasileira especializada em soluções de manutenção preditiva, utiliza inteligência artificial para monitorar o desempenho de equipamentos industriais. Seus sensores captam dados em tempo real, incluindo parâmetros de vibração, temperatura e operação, que são processados por algoritmos de *ML* a fim de identificar padrões indicativos de falhas (Tractian, 2025).

Para esse fim, os sensores *IoT* distribuídos em diferentes componentes da máquina, geralmente nos motores, realizam a coleta de dados em tempo real. Diante de qualquer anomalia nas variáveis mencionadas, o sistema gera *insights* que permitem a identificação rápida do problema, sugerindo soluções imediatas que o tornam uma ferramenta de apoio de tomada de decisão. (Tractian 2025).

Essa abordagem possibilita que gestores industriais recebam alertas antecipados sobre potenciais problemas. Para Kamgba (2024), essa estratégia promove um planejamento mais eficiente e a prevenção de paradas não programadas.

Nesse sentido, observa-se uma evolução na gestão da manutenção, que passa a incorporar tecnologias de *Machine Learning* no ambiente industrial, permitindo alcançar os mesmos resultados com maior eficiência operacional, utilizando-se de grandes quantidades de dados para treinar um algoritmo (Dalzochio *et. al.*, 2020).

3 PROCEDIMENTOS METODOLÓGICOS

Este estudo caracteriza-se como uma revisão bibliográfica sistemática de abordagem mista (qualitativa e quantitativa). Seu objetivo foi reunir e analisar o que a literatura recente apresenta sobre o uso de Machine Learning na manutenção preditiva industrial, com foco em seu impacto nos principais indicadores de desempenho do setor.

A busca pelos materiais ocorreu entre agosto e setembro de 2025 nas bases Scopus, Web of Science, ScienceDirect, IEEE Xplore e Google Scholar. Foram utilizados os seguintes termos, em inglês e português: *predictive maintenance*, *machine learning*, OEE, MTTR, MTBF, manutenção preditiva e aprendizado de máquina.

Os critérios de inclusão estabelecidos foram: (i) artigos publicados entre 2017 e 2025; (ii) foco em aplicações de Machine Learning na manutenção preditiva industrial; (iii) disponibilidade do texto integral; e (iv) idioma em inglês ou português. Foram excluídas publicações duplicadas, trabalhos sem relação direta com o ambiente industrial e pesquisas com descrição metodológica insuficiente.

O processo de seleção seguiu um fluxo estruturado. A busca inicial retornou aproximadamente 70 artigos. Após a remoção de duplicatas e a triagem por título e resumo, 40 artigos foram pré-selecionados. Destes, 30 foram submetidos à leitura integral. Após a aplicação rigorosa dos critérios de elegibilidade ao conteúdo completo, consolidou-se o corpus final da revisão, composto por 17 estudos.

A análise dos dados foi conduzida em duas etapas complementares. A etapa qualitativa envolveu análise temática de conteúdo, permitindo identificar conceitos recorrentes, algoritmos aplicados e desafios de implementação. A etapa quantitativa buscou sintetizar os resultados mensuráveis apresentados pelos estudos, com foco nos indicadores OEE, MTTR e MTBF, sempre que estes foram fornecidos de forma objetiva.

4 RESULTADOS E DISCUSSÃO

4.1 Revisão das práticas de manutenção preditiva

Segundo Carvalho *et. al.* (2019), a aplicação de algoritmos de aprendizado de máquina possibilita a análise de grandes volumes de dados coletados por sensores *IoT*, permitindo a identificação de problemas antes de sua ocorrência e a previsão da vida útil remanescente dos equipamentos. Nesse sentido, Kamgba (2024) demonstra que a implementação de sensores *IoT* em empresas industriais facilita a detecção de parâmetros que antes eram complexos de monitorar, como temperatura, pressão e umidade.

A gestão do ciclo de vida dos equipamentos permite que a manutenção seja planejada de forma alinhada aos objetivos da organização, permitindo decisões a longo prazo que impactem a sustentabilidade quanto a eficiência econômica da empresa (Campbell *et. al.*, 2015). Essa visão, alinhada à utilização dos indicadores tradicionais, garante que o investimento cumpra a função de otimizar a manutenção industrial, promovendo maior eficiência operacional, redução de custos e aumento da confiabilidade dos equipamentos.

4.2 Análises de sistemas de ML: Algoritmos e resultados

O uso de ML na manutenção preditiva permite gestão eficiente de equipamentos e automação de processos. Frameworks aplicáveis possibilitam identificar falhas precocemente (Barbosa, 2023; Carta *et. al.*, 2023).

No mesmo estudo, Barbosa (2023) descreve um caso em que um sistema de manutenção preditiva foi implementado em equipamentos reais, nos quais sensores monitoram continuamente parâmetros como vibração e corrente elétrica. Algoritmos de aprendizado supervisionado analisam esses dados para identificar padrões indicativos de falhas iminentes. Esse monitoramento antecipado possibilitou o planejamento preciso de intervenções, evitando paradas não programadas e promovendo maior eficiência operacional.

De acordo com informações da plataforma Tractian (2025), a implementação de sensores *IoT* permite monitorar parâmetros críticos como temperatura, pressão e umidade, antes difíceis de acompanhar. Integradas ao *Machine Learning*, essas tecnologias possibilitam antecipar falhas e realizar intervenções ágeis, prevenindo paradas não programadas e dessa forma otimizando o planejamento da manutenção.

Além disso, diferentes algoritmos de *ML* podem ser aplicados em variadas situações práticas. O algoritmo *Random Forest*, por exemplo, é reconhecido por sua capacidade de lidar com dados ruidosos e por sua robustez contra o *overfitting*, mostrando-se eficaz na detecção de falhas em bombas hidráulicas (Bromberger *et al.*, 2024). Paralelamente, redes neurais profundas têm sido empregadas na análise de séries temporais complexas. Silva *et. al.* (2023), por exemplo, utilizaram essa técnica para prever falhas em equipamentos mecânicos, evidenciando melhorias significativas na confiabilidade dos dados e no desempenho preditivo.

Tabela 1 - Machine Learning em manutenção preditiva baseado em literatura revisada

| Autor | Algoritmo utilizado | Aplicação |
|---------------------------------|----------------------------|--|
| Barbosa (2023) | Aprendizado Supervisionado | Monitoramento de equipamentos críticos |
| Bromberger <i>et al.</i> (2024) | <i>Random Forest</i> | Bombas hidráulicas |

| | | |
|-----------------|-------------------|-------------------------------|
| Tractian (2025) | Algoritmo próprio | Monitoramento de equipamentos |
|-----------------|-------------------|-------------------------------|

Fonte: Elaborada pelo autor após revisão da pesquisa.

4.3 Impacto do ML em indicadores e custos operacionais (OPEX)

Segundo Nakajima (1988), as perdas nos custos de produção estão diretamente associadas tanto às falhas inerentes aos processos quanto às ineficiências mensuradas pelo OEE. No cenário real, a aplicação do *Machine Learning (ML)* possibilita o monitoramento desses indicadores em tempo real, antecipando falhas e otimizando intervenções, como demonstrado por Novochadlo e Paladini (2024) em estudos relacionados à manutenção preditiva e à gestão de equipamentos industriais.

Em análise mais detalhada, os mesmos autores (Novochadlo e Paladini, 2024) evidenciam que a integração do *ML* permitiu identificar com precisão os momentos de menor desempenho operacional, possibilitando a realização de intervenções pontuais que reduziram perdas e otimizaram os custos operacionais (*OPEX*).

Além disso, frameworks estruturados de *Machine Learning*, como o apresentado por Carta et al. (2023) em estudos ambientais, possibilitam a coleta e análise de dados em tempo real, gerando insights que apoiam decisões estratégicas e ações corretivas rápidas. Softwares comerciais, como a plataforma Tractian (2025), exemplificam a aplicação prática desses conceitos, utilizando sensores *IoT* para emitir alertas antecipados de falhas.

No contexto industrial, essa lógica se aplica igualmente à gestão de equipamentos, ao consolidar a estruturação e a abstração dos dados. Essa abordagem, como evidenciado por Barbosa (2023) permite que intervenções sejam realizadas antes que os problemas se agravem, evitando custos adicionais e promovendo maior eficiência operacional.

4.4 Exemplos de Estudos de Caso

Os estudos já publicados na área reforçam a aplicabilidade do *Machine Learning* na manutenção preditiva em diferentes contextos industriais. Khaled et al. (2023), em sua survey abrangente, analisaram diversas arquiteturas de aprendizado profundo e observaram que técnicas baseadas em redes neurais apresentam melhor desempenho principalmente em cenários com grande volume de dados históricos, aprimorando a detecção de padrões de degradação.

Além disso, outras pesquisas discutem a integração de algoritmos com abordagens de raciocínio computacional. Dalzochio *et. al.* (2020) destacam que a combinação entre modelos preditivos e mecanismos de tomada de decisão oferece suporte mais estruturado à manutenção na Indústria 4.0. Tais exemplos confirmam a maturidade crescente do ML na prática industrial.

5 CONCLUSÃO

O estudo evidenciou que a utilização de *Machine Learning* melhora as práticas de manutenção preditiva. A combinação de algoritmos de ML com tecnologias IoT e indicadores tradicionais (OEE, MTBF, MTTR) aumenta a confiabilidade e otimização dos dados.

Observa-se que a implementação de soluções baseadas em ML possibilita a transição para um modelo de manutenção preditivo, capacitando as organizações não apenas na detecção precoce de falhas, mas também no refinamento dos mecanismos de tomada de decisão técnica e gerencial. A análise das aplicações práticas, incluindo a plataformas comerciais como Tractian, apresentou benefícios operacionais efetivos, tais como a redução de custos operacionais (OPEX), diminuição de paralisações não planejadas, extensão do ciclo de vida dos equipamentos e aprimoramento geral da eficiência produtiva.

Ressalta-se, contudo, que a efetiva implantação dessas tecnologias requer considerações que vão além do aspecto técnico. Os desafios mais relevantes identificados na literatura referem-se à necessária adaptação organizacional e ao desenvolvimento de competências analíticas entre os profissionais para interpretação e aplicação dos *insights* gerados pelos sistemas. A transição de um modelo baseado em conhecimento empírico para uma cultura orientada em análise de dados se apresenta como requisito fundamental para o sucesso da implementação.

Sob esta perspectiva, observa-se que o avanço da manutenção industrial está diretamente associado à incorporação do *Machine Learning*, que se consolida gradualmente como um componente essencial para a competitividade e a sustentabilidade operacional. A adoção do aprendizado de máquina como abordagem padrão torna-se cada vez mais necessária para garantir a integração eficaz entre as atividades de manutenção preditiva e a gestão das operações fabris. Essa convergência tecnológica otimiza processos e fortalece a tomada de decisão orientada por dados, ampliando a confiabilidade e promovendo excelência operacional.

REFERÊNCIAS

- BARBOSA, J. D. M. *Manutenção preditiva com recurso a Machine Learning*. 2023. Dissertação (Mestrado Integrado em Engenharia Electrotécnica e de Computadores) – Universidade de Coimbra, Coimbra, 2023. Disponível em: [//hdl.handle.net/10316/113099](https://hdl.handle.net/10316/113099). Acesso em: 15 set. 2025.
- BROMBERGER, D. A. *et. al.* Desenvolvimento de modelos de machine learning para manutenção preditiva de bombas hidráulicas. In: **Encontro Nacional de Engenharia de**

Produção, 44., 2024, Porto Alegre. **Anais [...]**. Porto Alegre: ABEPRO, 2024. Disponível em: [//researchgate.net/publication/385635295](https://researchgate.net/publication/385635295). Acesso em: 13 set. 2025.

CAMPBELL, J. D.; REYES-PICKNELL, J. V.; KIM, S. *Managing the lifecycle of facilities: strategic decision-making for long-term organizational advantage*. **Journal of Facilities Management**, v. 13, n. 3, p. 234-247, 2015.

CARTA, F. *et al.* *Advancements in Forest Fire Prevention: A Comprehensive Survey*. **Sensors**, v. 23, n. 14, p. 6635, 2023. Disponível em: [//doi.org/10.3390/s23146635](https://doi.org/10.3390/s23146635). Acesso em: 15 set. 2025.

CARVALHO, T. P. *et al.* *A systematic literature review of machine learning methods applied to predictive maintenance*. **Computers & Industrial Engineering**, v. 137, p. 106024, 2019. Disponível em: [//doi.org/10.1016/j.cie.2019.106024](https://doi.org/10.1016/j.cie.2019.106024). Acesso em: 12 set. 2025.

CRUZ, A. R. S.; GALDAMEZ, E. V. C.; SAMED, M. M. A. Manutenção preditiva com Machine Learning na indústria: uma revisão sistemática da literatura. In: **CONBREPRO – Congresso Brasileiro de Engenharia de Produção**, 2023, Ponta Grossa. **Anais [...]**. Ponta Grossa: Unicesumar, 2023. Disponível em: [//aprepro.org.br/conbrepro/anais/2023/arquivos/11032023_111107_654500a799cf3.pdf](https://aprepro.org.br/conbrepro/anais/2023/arquivos/11032023_111107_654500a799cf3.pdf). Acesso em: 23 set. 2025.

DALZOCHIO, J. *et al.* *Machine learning and reasoning for predictive maintenance in Industry 4.0: Current status and challenges*. **Computers in Industry**, v. 123, p. 103298, 2020. Disponível em: [//doi.org/10.1016/j.compind.2020.103298](https://doi.org/10.1016/j.compind.2020.103298). Acesso em: 1 dez. 2024

HOFFMANN, M. A.; LASCH, R. *Unlocking the Potential of Predictive Maintenance for Intelligent Manufacturing: A Case Study on Potentials, Barriers, and Critical Success Factors*. **Schmalenbach Journal of Business Research**, v. 77, p. 27–55, 2025. Disponível em: [//doi.org/10.1007/s41471-024-00204-3](https://doi.org/10.1007/s41471-024-00204-3). Acesso em: 22 set. 2025

KAMGBA, R. B. *A Machine Learning Approach for Predictive Maintenance in Manufacturing Companies*. **Authorea**, 2024. Disponível em: [//doi.org/10.22541/au.172775864.48120288/v1](https://doi.org/10.22541/au.172775864.48120288/v1). Acesso em: 17 set. 2025.

KHALED, A.; YOUNES, M. B.; TRAD, A. *Deep learning for predictive maintenance: A comprehensive survey and taxonomy*. **Engineering Applications of Artificial Intelligence**, v. 123, p. 106299, 2023. Disponível em: [//doi.org/10.1016/j.engappai.2023.106299](https://doi.org/10.1016/j.engappai.2023.106299). Acesso em: 1 dez. 2024.

LEE, J.; LAPIRA, E.; BAGHERI, B.; KAO, H. *Recent advances and trends in predictive manufacturing systems in big data environment*. **Manufacturing Letters**, v. 1, n. 1, p. 38-41, 2013.

NAKAJIMA, S. *Introduction to TPM: Total Productive Maintenance*. Cambridge: Productivity Press, 1988.

NOVOCHADLO, C. A.; PALADINI, E. P. *The application of real-time overall equipment efficiency indicator in a medium-sized company*. **Brazilian Journal of Operations & Production Management**, v. 21, n. 1, p. 1-15, 2024. Disponível em: [//bjopm.org.br/bjopm/article/view/2042](https://bjopm.org.br/bjopm/article/view/2042). Acesso em: 9 set. 2025.

OLIVEIRA, A. S.; PACHECO, F. A.; MERCES, R. S. Aplicação do OEE em uma indústria metal-mecânica no interior do estado de São Paulo. **Revista FOCO**, v. 15, n. 4, p. 165-178, 2022. Disponível em: [//researchgate.net/publication/366554674](https://researchgate.net/publication/366554674). Acesso em: 9 set. 2025.

SILVA, W. R. P. *et. al.* A utilização de redes neurais na previsão de falhas de equipamentos mecânicos. In: **CONBREPRO – Congresso Brasileiro de Engenharia de Produção**, 2023, Ponta Grossa. **Anais [...]**. Ponta Grossa: Unicesumar, 2023. Disponível em: [//aprepro.org.br/conbrepro/anais/2023/arquivos/10312023_221014_6541a5b2703cc.pdf](https://aprepro.org.br/conbrepro/anais/2023/arquivos/10312023_221014_6541a5b2703cc.pdf). Acesso em: 13 set. 2025.

TRACTIAN. *Tractian: Monitoramento Online e Gestão de Ativos*. 2025. Disponível em: [//tractian.com/](https://tractian.com/). Acesso em: 25 ago. 2025.

ZARO, E. M.; WEBER, C. G. Estudo de caso de desenvolvimento de sistema para manutenção preditiva 4.0. **Brazilian Journal of Operations & Production Management** v. 22, n. 3, p. e4557, 2023. Disponível em: [//doi.org/10.14488/1676-1901.v22i3.4557](https://doi.org/10.14488/1676-1901.v22i3.4557). Acesso em: 25 ago. 2025.