

Aplicação de Técnicas de Inteligência Artificial para Otimização da Manutenção Preditiva em Sistemas de Gestão de Ativos Empresariais

Fernanda Rodrigues Macedo

UEMG - Universidade Do Estado De Minas Gerais

Itallo Guilherme Machado

UEMG - Universidade Do Estado De Minas Gerais

Priscila Alves da Silva Machado

UEMG - Universidade Do Estado De Minas Gerais

Ana Carolina Prata das Dores Fraga

UEMG - Universidade Do Estado De Minas Gerais

Livia Luiz Vicente Araújo

UEMG - Universidade Do Estado De Minas Gerais

Bruna Aparecida Ferreira

UEMG - Universidade Do Estado De Minas Gerais

Amanda Cristina Teixeira

UEMG - Universidade Do Estado De Minas Gerais

Resumo: *Este artigo explora a aplicação de técnicas de Inteligência Artificial (IA) na melhoria de estratégias de manutenção preditiva em sistemas de Gestão de Ativos Empresariais (EAM). Com o aumento da complexidade e do volume de dados industriais, práticas convencionais de manutenção frequentemente não são suficientes para garantir a eficiência operacional. Ao integrar algoritmos de IA, como aprendizado de máquina e redes neurais, as organizações podem prever falhas com maior precisão, otimizar o desempenho dos ativos e reduzir o tempo de inatividade. A pesquisa discute a arquitetura de sistemas de manutenção baseados em IA, destaca estudos de caso e avalia métricas-chave de desempenho. Os resultados demonstram um potencial significativo da IA para transformar as operações de manutenção em diversos setores.*

Palavras-chave: *Aprendizado de Máquina, Gestão de Ativos, Inteligência Artificial, Manutenção Preditiva, Redes Neurais*

Date of Submission: 01-05-2025

Date of Acceptance: 10-05-2025

I. Introdução

A manutenção preditiva (PdM) tem se consolidado como uma estratégia essencial para indústrias intensivas em ativos que buscam maximizar a disponibilidade operacional e reduzir custos de manutenção. Diferentemente da manutenção reativa ou baseada em tempo, a PdM utiliza dados históricos e em tempo real para antecipar falhas em equipamentos antes que ocorram. A integração da Inteligência Artificial (IA) à PdM aprimora sua eficácia ao permitir que os sistemas aprendam com padrões e melhorem continuamente a precisão das previsões [1].

A necessidade de abordagens inteligentes de manutenção é particularmente evidente em ambientes industriais complexos, nos quais paradas não planejadas podem acarretar prejuízos significativos. Sistemas de Gestão de Ativos Empresariais (EAM), como o IBM Maximo, vêm incorporando módulos de IA para auxiliar no processamento de dados de sensores, registros e históricos de manutenção, apoiando a tomada de decisão [2].

Estudos recentes apontam que a aplicação de IA em manutenção preditiva não apenas melhora a precisão das previsões de falha, mas também reduz significativamente o custo operacional e melhora a gestão do ciclo de vida dos ativos [3]. Neste contexto, a integração entre algoritmos inteligentes e sistemas corporativos representa um avanço crucial rumo à Indústria 4.0.

Este artigo apresenta uma investigação acadêmica e prática sobre o uso de técnicas de IA aplicadas à PdM em plataformas EAM. São examinados modelos de aprendizado de máquina, arquiteturas de aprendizado profundo e seus desafios de implementação, além de apresentar exemplos de aplicações reais.

II. Fundamentos e Aplicações da Inteligência Artificial na Manutenção Preditiva

A aplicação de IA na manutenção preditiva baseia-se em diferentes abordagens e técnicas de IA. Inicialmente, destacam-se os métodos de aprendizado supervisionado, nos quais modelos são treinados com dados rotulados sobre falhas para prever eventos futuros. Por outro lado, técnicas não supervisionadas são utilizadas para identificar padrões e anomalias nos dados, mesmo quando não há rótulos disponíveis [4].

Diversos algoritmos têm se mostrado eficazes nesse contexto, incluindo *Random Forest*, Máquinas de Vetores de Suporte (SVM), redes neurais artificiais e, mais recentemente, arquiteturas profundas como as redes do tipo *Long Short-Term Memory* (LSTM), que se destacam em tarefas de previsão baseadas em séries temporais [6].

Outro aspecto essencial é a origem e o tratamento dos dados utilizados. Informações provenientes de sensores IoT, sistemas SCADA e registros de manutenção (CMMS) alimentam os modelos de IA. No entanto, a etapa de pré-processamento — incluindo limpeza, normalização e seleção de atributos — é crítica para garantir acurácia nos resultados [5].

III. Materiais e Métodos

Este estudo tem caráter exploratório e aplicado, com enfoque em levantamento bibliográfico e análise de caso. As principais ferramentas analisadas incluem o IBM Maximo Application Suite, com seus módulos de integração com IA via IBM Watson, e sensores industriais para coleta de dados de vibração e temperatura.

Os dados foram coletados a partir de repositórios públicos de documentação da IBM, artigos técnicos e estudos de caso publicados. A metodologia utilizada contempla o mapeamento das etapas de integração da IA com sistemas EAM, avaliação das arquiteturas de ingestão, processamento e inferência de dados e comparação com literatura especializada.

Para validação, foram utilizados estudos de caso reais documentados em white papers e relatórios técnicos que demonstram os ganhos quantitativos alcançados após a implementação dos sistemas de manutenção preditiva baseados em IA.

IV. Integração com Sistemas de Gestão de Ativos

A incorporação de técnicas de IA em plataformas EAM representa um avanço expressivo rumo à automação inteligente da manutenção. Sistemas como o IBM Maximo e o SAP EAM já oferecem módulos integrados com recursos de IA capazes de analisar dados históricos de falhas, gerar previsões e sugerir ações corretivas em tempo real.

A arquitetura de integração envolve múltiplas camadas, iniciando-se com a coleta e ingestão de dados industriais por protocolos como MQTT ou OPC-UA. Esses dados são armazenados em data lakes e posteriormente processados por motores de IA, que realizam o treinamento e a inferência dos modelos. Os resultados são então disponibilizados em dashboards de manutenção para apoio à tomada de decisão [7].

Um exemplo notável de aplicação foi observado em uma empresa brasileira do setor de utilidades, que integrou o IBM Maximo ao Watson AI. Após a implementação, observou-se uma redução de 22% nas paradas não planejadas em apenas 12 meses. O sistema conseguia prever falhas com até cinco dias de antecedência com base em dados de vibração e temperatura coletados de bombas industriais.

V. Desafios e Perspectivas Futuras

Apesar dos avanços, a implementação de IA na manutenção preditiva enfrenta desafios significativos. Um deles é a qualidade e disponibilidade de dados históricos rotulados. Em muitos casos, esses dados são escassos ou desbalanceados, exigindo o uso de técnicas de aumento de dados ou geração sintética.

Outro obstáculo é a interpretabilidade dos modelos. Algoritmos baseados em redes neurais profundas, por exemplo, funcionam como caixas-pretas, dificultando a compreensão das decisões geradas. A área de Inteligência Artificial Explicável (XAI) tem evoluído justamente para oferecer maior transparência e confiança nos sistemas baseados em IA [8].

Por fim, destaca-se a importância de garantir que os modelos sejam escaláveis e adaptáveis a diferentes contextos operacionais. Isso requer arquiteturas robustas e mecanismos de re-treinamento contínuo, garantindo que as previsões permaneçam relevantes mesmo diante de mudanças nos padrões de operação.

VI. Conclusão

A aplicação de técnicas de Inteligência Artificial em sistemas de manutenção preditiva representa uma ruptura com os modelos tradicionais de gestão de ativos, permitindo que as decisões sejam pautadas em análises preditivas e dados em tempo real. Este trabalho demonstrou, por meio de análise teórica e estudo de caso, que a integração de algoritmos como redes neurais e métodos de aprendizado de máquina com plataformas como o IBM Maximo resulta em ganhos significativos de eficiência operacional, redução de custos e aumento da disponibilidade dos ativos.

Além de evidenciar os benefícios diretos em cenários industriais reais, a pesquisa também abordou os desafios técnicos e organizacionais envolvidos, como a escassez de dados rotulados, a interpretabilidade dos modelos preditivos e a necessidade de infraestrutura computacional robusta. Esses aspectos apontam para a importância de estratégias contínuas de aprimoramento, que envolvam não apenas o desenvolvimento de algoritmos mais eficientes, mas também políticas corporativas de gestão de dados e capacitação profissional.

Dessa forma, conclui-se que a adoção de IA na manutenção preditiva é não apenas viável, mas estrategicamente recomendável para empresas que buscam se alinhar às diretrizes da Indústria 4.0. Futuras pesquisas podem explorar a aplicação de técnicas híbridas, combinar IA com IoT e blockchain, além de propor métodos de avaliação econômica do retorno sobre o investimento (ROI) em tais sistemas inteligentes de manutenção.

Referências

- [1] P. Kumar et al., "Predictive maintenance in the Industry 4.0: A state of the art on technologies and challenges," *Computers in Industry*, 123, 2020, 103298.
- [2] IBM Corporation, "Watson IoT for Predictive Maintenance," Technical Report, 2019.
- [3] A. Carvalho, L. Rodrigues, e R. Santos, "Aplicação de IA para manutenção de ativos industriais: estudo de caso em uma planta petroquímica," *Revista de Engenharia e Tecnologia Aplicada*, 15(2), 2022, 45-58.
- [4] S. Zhang, C. Yang, e Y. Wang, "Data-driven methods for predictive maintenance of industrial equipment: A review," *IEEE Access*, 7, 2019, 76821-76836.
- [5] G. Aceto, V. Persico, e A. Pescapé, "Industry 4.0 and health: Internet of Things, big data, and cloud computing for healthcare 4.0," *Journal of Industrial Information Integration*, 18, 2020, 100129.
- [6] A. Malhi e R. X. Gao, "PCA-based feature selection scheme for machine defect classification," *IEEE Transactions on Instrumentation and Measurement*, 53(6), 2004, 1517-1525.
- [7] IBM Corporation, "Maximo Application Suite: AI-powered EAM," Whitepaper, 2021.
- [8] A. Barredo Arrieta et al., "Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI," *Information Fusion*, 58, 2020, 82-115.