



De 11 a 14 - NOVEMBRO DE 2024

**Inteligência Artificial
na Gestão de Operações:
Limitações e possibilidades**



A UTILIZAÇÃO DA INTELIGÊNCIA ARTIFICIAL NA MANUTENÇÃO PREDITIVA

ALEXANDRE MAGNO DE ANDRADE - alexandre.andrade1@outlook.com
UNIVERSIDADE ESTADUAL DE MARINGÁ - UEM - MARINGÁ

GLÉLCIO AUGUSTO MARTINS – glelciomartins@hotmail.com
UNIVERSIDADE ESTADUAL DE MARINGÁ - UEM - MARINGÁ

THIAGO DA SILVA PINAFFI - thiagospinaffi@gmail.com
UNIVERSIDADE ESTADUAL DE MARINGÁ - UEM - MARINGÁ

FRANCIELLE CRISTINA FENERICH - fcfenerich@uem.br
UNIVERSIDADE ESTADUAL DE MARINGÁ - UEM - MARINGÁ

MARCO ANTÔNIO FERREIRA - marcoferreira@utfpr.edu.br
UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ - UTFPR – LONDRINA

ÁREA: 1. ENGENHARIA DE OPERAÇÕES E PROCESSOS DA PRODUÇÃO
SUBÁREA: 1.3 - GESTÃO DA MANUTENÇÃO

RESUMO: *Este estudo analisa a aplicação da IA na manutenção preditiva, abordando ganhos/dificuldades/limitações e tendências relacionadas ao uso dessa tecnologia em estudos de caso. Utilizamos a ferramenta BerTopic como técnica avançada de Processamento de Linguagem Natural para identificar trabalhos relevantes. Os resultados revelaram um aumento significativo de publicações em 2020 e 2021, com destaque para a Itália como o país com mais publicações. As palavras-chave mais frequentes foram Predictive Maintenance, Machine Learning, IoT e Big Data. Entre os principais ganhos, destacam-se a melhoria no monitoramento, a otimização de processos e a redução de custos. As principais dificuldades/limitações incluem a dificuldade de extração de dados, altos custos de implementação, resistência organizacional e limitações de software. As tendências emergentes apontam para o desenvolvimento de novos métodos, expansão das coletas de dados e integração contínua de IA. Apesar das limitações, como a seleção restrita de artigos, este estudo fornece percepções valiosas para futuras pesquisas e implementações práticas, destacando a importância da inteligência artificial na modernização industrial e na manutenção preditiva.*

PALAVRAS-CHAVES: *Manutenção Preditiva; Inteligência Artificial; Machine Learning; Internet das Coisas; Indústria 4.0.*

1. INTRODUÇÃO

O rápido avanço da tecnologia direcionada à indústria, marcado pela quarta revolução industrial, tem possibilitado a coleta, processamento e análise crescente nos ambientes de produção. Essa capacidade proporciona vantagens significativas na tomada de decisões e na competitividade das empresas (ACHOUCH *et al.*, 2022).

A manutenção é uma atividade essencial em qualquer operação industrial, visando garantir a confiabilidade, disponibilidade e vida útil dos ativos. Peres *et al.* (2018) afirmam que, ao processar e analisar dados provenientes de operações de fabricação, é possível obter informações valiosas que podem orientar a tomada de decisões estratégicas. Essas análises podem resultar em vantagens significativas, como redução de custos de manutenção, minimização de falhas em máquinas, otimização de estoques de peças de reposição, aumento da produção e garantia de segurança para os operadores. Carvalho *et al.* (2019) completam que é possível encontrar resultados interpretativos para a tomada de decisões estratégicas, proporcionando vantagens como a manutenção.

Três tipos de manutenção são amplamente reconhecidos: a manutenção corretiva, que intervém após a falha do equipamento ocorrer; a manutenção preventiva, que segue um calendário pré-definido para inspeções e manutenções com base nas características de confiabilidade dos componentes; e a manutenção preditiva, que consiste em monitorar continuamente o equipamento para prever seu futuro estado e identificar componentes com potenciais falhas (Bouabdallaoui *et al.*, 2021; Bevilacqua & Braglia, 2000).

Neste contexto é importante destacar a manutenção preditiva, foco principal deste estudo, que conforme Yan *et al.* (2017) e Dalzochio *et al.* (2020) é uma abordagem de manutenção que utiliza dados e análises para detectar as falhas antes que as mesmas ocorram. Isso é realizado por meio de modelos preditivos que identificam desvios das condições normais de operação, permitindo uma manutenção personalizada, já que é possível obter informações sobre o melhor momento realizar os reparos necessários.

A Inteligência Artificial (IA) tem desempenhado um papel crescente na manutenção preditiva, oferecendo métodos automatizados para monitorar continuamente o desempenho e as condições dos equipamentos em tempo real. O aprendizado de máquina - *Machine Learning* (ML), uma subárea da IA, ensina computadores a realizar tarefas sem programação específica, permitindo a execução de tarefas complexas. O ML pode ser dividido em quatro abordagens: supervisionada, semissupervisionada, não supervisionada e por reforço (THEISLER *et al.*, 2021; BOUABDALLAOUI *et al.*, 2021).

Nos últimos anos, a manutenção preditiva tem recebido atenção significativa devido ao seu potencial para reduzir custos e aumentar a eficiência operacional. A integração da IA potencializou ainda mais a capacidade de prever falhas com precisão e otimizar estratégias de manutenção (DALZUCHIO *et al.*, 2020).

Assim sendo, o objetivo deste estudo é desenvolver uma revisão sistemática da literatura com o intuito de entender a atual relação entre a manutenção preditiva e o uso de Inteligência Artificial. Tem-se como objetivo específico realizar uma busca por ganhos, dificuldades/limitações e tendências associados a aplicação da IA na manutenção preditiva, apresentados em artigos científicos que relatem estudo de caso.

O artigo está estruturado da seguinte forma: Seção 2: Manutenção Preditiva e a Inteligência Artificial, Seção 3: Metodologia utilizada, Seção 4: Resultados obtidos com a revisão sistemática, Seção 5: Considerações finais e trabalhos futuros.

2. MANUTENÇÃO PREDITIVA E A INTELIGÊNCIA ARTIFICIAL

De acordo com Paolanti *et al.* (2018), Zhang *et al.* (2019) e Zonta *et al.* (2020), o uso de métodos automatizados na manutenção preditiva faz com que, em vez de seguir um cronograma de manutenção regular, se monitore continuamente o desempenho e as condições dos equipamentos em tempo real, verificando padrões ou indicadores que possam sinalizar uma possível falha. Isso possibilita prever tendências e identificar padrões, o que, por sua vez, traz diversas vantagens, como: Evitar a parada desnecessária das máquinas e equipamentos, reduzindo o tempo de inatividade; encontrar a causa raiz da falha; minimizar os custos de produção; diminuir a poluição, aumentar a segurança e aumentar a eficiência operacional.

Além disso, Bevilacqua *et al.* (2000) complementam que os dados adquiridos dos parâmetros controlados são analisados para identificar uma possível tendência temporal. Isso possibilita prever quando o valor da quantidade controlada atingirá ou excederá os valores de limite, permitindo que a equipe de manutenção planeje quando, dependendo das condições de operação, a substituição ou revisão do componente será realmente inevitável.

De acordo com Zonta *et al.* (2020), os custos de manutenção representam entre 15 e 60% do total de custos de operações na manufatura, desta forma, é visível a grande importância deste tema, pois a manutenção preditiva desempenha um papel crucial na maximização da eficiência operacional e na minimização de custos em diversos setores industriais. Com o advento da Inteligência Artificial, surgem novas oportunidades para aprimorar a precisão e a eficácia dos métodos de manutenção preditiva. No entanto, é fundamental compreender os

ganhos, dificuldades/limitações e tendências associadas à aplicação da IA nesse contexto para orientar pesquisadores, profissionais da indústria e tomadores de decisão.

Além disso, é crucial entender como os avanços da Indústria 4.0 impactam diretamente na manutenção preditiva. Seze *et al.* (2018) afirmam que componentes como a Internet Industrial das Coisas - *Industrial Internet of Things* (IIoT), Sistemas Ciber-Físicos - *Cyber-Physical Systems* (CPSs), Computação em Nuvem, Aprendizado de Máquina (ML), Flexibilidade e Adaptabilidade, e Tomada de Decisão Descentralizada desempenham papéis essenciais na integração de dados e na análise preditiva para identificar potenciais falhas em equipamentos industriais. Portanto, compreender como esses componentes se relacionam com a manutenção preditiva é fundamental para maximizar a eficiência operacional e minimizar os custos na era da Indústria 4.0.


3. METODOLOGIA

Esta revisão bibliográfica sistemática tem como objetivo preencher a lacuna existente, proporcionando uma análise abrangente e crítica da literatura disponível sobre o tema. Para tanto, o artigo delinea as seguintes delimitações:

- **Foco em Estudos de Caso:** Esta revisão concentrar-se na análise de estudos de caso que abordam a aplicação da inteligência artificial na manutenção preditiva. Outros tipos de pesquisa, como revisões teóricas, não serão incluídos nesta revisão sistemática.
- **Contexto Industrial:** As análises serão restritas a estudos de caso relacionados ao ambiente industrial, abrangendo setores como manufatura, produção em larga escala, indústria automotiva, entre outros. Estudos focados em contextos não industriais serão excluídos.
- **Período de Publicação:** A busca e análise dos estudos de caso serão limitadas aos últimos cinco anos. Esta delimitação garante a relevância e a atualidade das informações coletadas.
- **Idioma:** Apenas estudos de caso publicados em inglês serão considerados. Publicações em outros idiomas serão excluídas.

O método de pesquisa utilizado foi uma mistura do Método Correlacional de Santos *et al.* (2022) e o Método Experimental de Pacheco *et al.* (2017), onde foram aplicados os passos da Figura 1.

FIGURA 1 – Etapas da pesquisa



Fonte: Autores

- **Definição de Palavras-chave:** Foram definidas palavras-chave específicas, como "*predictive maintenance*" e "*Industry 4.0*", além de variantes relacionadas as tecnologias envolvidas como por exemplo "*machine learning*", "*AI*", "*IoT*" e "*big data*";
- **Seleção de Fontes:** Utilizou-se bases de dados acadêmicas de renome (*Scopus* e *Web of Science*) para garantir a qualidade e relevância dos artigos, focando em revistas científicas bem avaliadas e reconhecidas na comunidade acadêmica;
- **Filtragem e Busca Avançada:** Realizou-se buscas combinadas das palavras-chave com operadores booleanos para refinar os resultados. Exemplo: "*predictive maintenance*" AND "*industry 4.0*";
- **Análise de Relevância:** Foram selecionados os artigos mais citados e com maior impacto na área, considerando o número de citações como um indicativo de influência e relevância;
- **Revisão Contínua:** A lista de artigos foi revisada para incluir estudos recentes e garantir que as informações mais atuais estivessem presentes;
- **Validação da Metodologia e Dados:** As informações dos artigos foram validadas quanto à precisão, verificando os resumos, autores e publicações em seus respectivos links e bases de dados para garantir a autenticidade e a exatidão dos dados apresentados.

Em vez de utilizar um método tradicional, foi escolhida uma abordagem automatizada para a análise de tópicos; para tanto, foram aplicadas técnicas avançadas de Processamento de Linguagem Natural (NLP) utilizando a biblioteca *BERTopic* em *Python*.

BERTopic é uma ferramenta poderosa de modelagem de tópicos que utiliza *embeddings* de linguagem gerados por modelos de linguagem *BERT* (*Bidirectional Encoder Representations from Transformers*). O *BERTopic* opera e foi aplicado na pesquisa da seguinte forma:

- **Embeddings de Linguagem:** Primeiro, o *BERTopic* utiliza modelos de linguagem pré-treinados, como *BERT*, para converter textos em vetores de alta dimensionalidade,

conhecidos como *embeddings*. Esses *embeddings* capturam nuances semânticas complexas dos textos;


- **Redução de Dimensionalidade:** Em seguida, aplica-se uma técnica de redução de dimensionalidade, geralmente *UMAP* (*Uniform Manifold Approximation and Projection*), para reduzir os *embeddings* a uma forma mais manejável, preservando a estrutura semântica dos dados;
- **Clustering:** Com os *embeddings* reduzidos, o *BERTopic* utiliza algoritmos de *clustering*, como *HDBSCAN* (*Hierarchical Density-Based Spatial Clustering of Applications with Noise*), para agrupar textos em tópicos coerentes. Esses tópicos são formados com base em similaridades semânticas entre os textos;
- **Identificação e Interpretação dos Tópicos:** Finalmente, o *BERTopic* extrai palavras-chave representativas para cada tópico, permitindo uma interpretação clara e acionável dos temas principais emergentes dos dados.

Na pesquisa, o *BERTopic* foi utilizado para identificar e analisar automaticamente os tópicos mais relevantes relacionados à aplicação da inteligência artificial na manutenção preditiva. Este método automatizado possibilitou:

- **Eficiência:** Processar grandes volumes de literatura de forma rápida e precisa.
- **Objetividade:** Reduzir o viés manual na categorização de tópicos.
- **Profundidade:** Identificar padrões e descobertas que poderiam passar despercebidos em uma análise manual.

Com isso foi utilizado o fluxo abaixo:

FIGURA 2 – Ciclo da pesquisa



Fonte: Adaptado de Kwabena *et al.* (2023)

Dessa forma, foi obtida uma listagem de inicial de 1037 artigos, após uma segunda

raspagem, teve-se uma redução para 257 artigos, e após uma terceira raspagem, focando somente nas necessidades da revisão, chegou-se em 56 artigos relacionados a aplicação de IA em manutenção preditiva. Após a realização de uma pesquisa adicional, 30 trabalhos foram retornados. Logo após, trabalhos que fossem livros ou capítulos de livros foram descartados, restando apenas artigos, papéis de conferência e revisões, que podem ser vistos na tabela 1.

A razão pela qual o *BERTopic* não seguiu estritamente as diretrizes previamente estabelecidas é que, embora a seleção de 30 artigos tenha sido estipulada, quando essa quantidade não é atingida, o método ajusta suas configurações automaticamente. Esse ajuste permitiu a inclusão de trabalhos com mais de 5 anos, de outras bases de dados, e que não sejam exclusivamente artigos acadêmicos. Além disso, os artigos 1, 5, 15 foram lidos, mas não apresentaram de forma explícita as informações necessárias, pois não se tratavam de estudos de caso relacionados ao ambiente industrial.

TABELA 1 – Artigos selecionados para a leitura integral

Número	Artigo	Número	Artigo
1	Ren e Zhao (2015)	13	Kanawaday e Sane (2017)
2	Shin, Han e Rhee (2021)	14	Susto <i>et al.</i> (2015)
3	Calabrese <i>et al.</i> (2020)	15	Cinar <i>et al.</i> (2020)
4	Parpala e Iacob (2017)	16	Florian, Sgarbossa e Zennaro (2021)
5	Compare, Baraldi e Zio (2019)	17	Achouch <i>et al.</i> (2022)
6	Cheng <i>et al.</i> (2020)	18	Passlick <i>et al.</i> (2021)
7	Rosati <i>et al.</i> (2023)	19	Theissler, Andreas <i>et al.</i> (2021)
8	Yan <i>et al.</i> (2017)	20	Zonta <i>et al.</i> (2020)
9	Hong-Linh (2018)	21	Lee <i>et al.</i> (2019)
10	Li, Wang e Wang (2017)	22	Ayvaz e Alpay (2021)
11	Shamayleh, Awad e Farhat (2020)	23	Zhu <i>et al.</i> (2024)
12	Paolanti <i>et al.</i> (2018)	24	Sang, DonHee e Youn (2019)

Fonte: Autores

4. RESULTADOS OBTIDOS

4.1 Análise bibliométrica

Esta seção consiste em realizar a bibliometria dos artigos que foram encontrados após a aplicação da metodologia. De acordo com Krymskaya (2023), Kokol *et al.* (2023) e Aria e Cuccurullo (2017), a análise bibliométrica é realizada através do uso de métodos quantitativos aos meios de comunicação acadêmica (livros, artigos, revisões ...), ela é necessária para que se possa acompanhar o rápido crescimento do número de publicações e assim analisar grandes quantidades delas, fornecendo uma visão transparente e reproduzível do desenvolvimento do registro acadêmico.

O gráfico 1 apresenta o número de publicações por ano. Observa-se que o ano com o maior número de publicações foi 2020, com um total de 6. Em segundo lugar, está 2021, com 5 publicações. O terceiro lugar é ocupado por 2017, com 4 publicações, seguido de 2019, com 3 publicações. Os anos de 2015 e 2018 registraram 2 publicações cada. Em 2022 e 2024, houve 1 publicação em cada ano, enquanto 2016 e 2023 não tiveram publicações.


GRÁFICO 1 – Publicações por ano



Fonte: Autores

O gráfico 2 apresenta o número de citações por país. A Itália lidera com um total de 1713 citações. A China segue com 1025 citações, e a Turquia ocupa a terceira posição com 813 citações. O Brasil contabiliza 738 citações, enquanto a Alemanha possui 319 citações. A Noruega e a Índia têm 303 e 281 citações, respectivamente. Os Estados Unidos registram 251 citações, seguidos pelo Canadá com 111 citações e pelos Emirados Árabes Unidos com 98 citações. O Reino Unido tem 69 citações, a Romênia 46, e a Áustria 36. Singapura não possui citações. A intensidade da coloração no gráfico indica a quantidade de citações, com cores mais fortes representando um maior número de citações e cores mais fracas indicando menos citações.

GRÁFICO 2 – Citações por país




Fonte: Autores

A Figura 3 mostra o grafo de citações, ou seja, uma rede de citações, que representa as relações e padrões de citações entre os trabalhos científicos encontrados durante a busca. Na figura, cada nó representa um trabalho, e cada aresta representa uma citação de um trabalho para outro. A cor do nó indica o ano da citação (onde a coloração mais forte indica um trabalho mais novo, e vice-versa), e o tamanho do nó indica o número de citações recebidas pelo artigo (onde um nó maior representa um maior número de citações).

Tal figura indica que aproximadamente metade dos trabalhos estão altamente conectados, ou seja, mostram-se mais relevantes para o tema de pesquisa, enquanto os demais estão completamente desconectados.


FIGURA 3 – Grafo de citações



Fonte: Autores

A Figura 4 mostra a nuvem de palavras, que é resultante da frequência com que cada palavra aparece dentro das palavras-chave nos trabalhos. A nuvem de palavras revela que as palavras *Predictive Maintenance*, *Machine Learning*, *IoT*, *Big Data* e *Industry* são as mais frequentes.

FIGURA 4 – Nuvem de palavras



Fonte: Autores

Por meio da busca por ganhos, dificuldades/ limitações e tendências identificados na leitura integral dos trabalhos selecionados, foram confeccionados três quadros com o propósito de resumir as informações encontradas, que podem ser vistas a seguir, sendo a Quadro 1 referente aos ganhos, o Quadro 2 referente as dificuldades/ limitações e o Quadro 3 apresenta as tendências.

QUADRO 1 – Resumo dos ganhos identificados nos estudos de caso

Ganhos	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	Total
Adesão de novos serviços																		✓							1
Aumento da disponibilidade de máquinas											✓		✓						✓		✓				4
Aumento da precisão na manutenção																					✓				1
Aumento da vida útil das máquinas																						✓			1
Aumento em respostas corretas		✓																							1
Aumento na eficiência																		✓							1
Aumento no interesse por I.A.		✓																							1
Auxiliar nas tomadas de decisões																✓		✓							2
Flexibilização de processo									✓					✓											2
Integração com nova tecnologias																							✓		1
Levantamento de dados relevantes																			✓						1
Maior qualidade nas manutenções									✓																1
Melhoria na detecção de falhas		✓											✓												2
Melhoria na gestão da qualidade																							✓		1
Melhoria no desempenho																					✓				1
Melhoria no diagnóstico de falhas									✓																1
Melhoria no monitoramento		✓	✓		✓	✓		✓	✓		✓	✓		✓		✓						✓	✓		11
Melhoria no planejamento							✓	✓																	2
Melhoria no tempo de respostas		✓							✓					✓											3
Metodologias eficientes																						✓			1
Otimização de processos							✓	✓	✓	✓	✓		✓			✓	✓		✓					✓	10
Prevenção de falhas																	✓								1
Propósitos claros																							✓		1
Redução de custos							✓		✓	✓		✓					✓								5
Redução de falhas																						✓			1

Fonte: Autores

A análise revela que os maiores ganhos na utilização da IA na manutenção preditiva incluem a "Melhoria no monitoramento", "Otimização de processos" e "Redução de custos", citados com maior frequência. Outros ganhos significativos são o "Aumento da disponibilidade de máquinas" e a "Melhoria no tempo de respostas". Esses benefícios destacam o potencial da IA para transformar a manutenção preditiva, aumentando a eficiência, reduzindo custos e melhorando a qualidade e disponibilidade dos equipamentos.

QUADRO 2 – Resumo das dificuldades/ limitações identificadas nos estudos de caso

Dificuldades/limitações	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	TOTAL
Atende apenas propósitos evidentes		✓																							1
Altos Custos de implementação														✓		✓	✓	✓						✓	6
Dependência do auxílio humano		✓																							1
Dificuldade de extração de dados							✓		✓	✓	✓		✓						✓	✓	✓	✓		✓	10
Falta de padronização																				✓					1
Limitação de Software																				✓			✓		2
Limitações de generalização dos resultados								✓																	1
Limitações de métodos						✓																			1
Não cita												✓													1
Necessidade de equipamentos robustos											✓														1
Não apresenta previsibilidade de falha		✓																							1
Requisitos específicos de hardware			✓																						1
Resistência organizacional											✓						✓	✓					✓		4
Retreinamento periódico							✓																		1
Segurança de dados																		✓							1
Treinamento de modelos																						✓	✓		2

Fonte: Autores

A análise dos dados revela que as limitações mais citadas na utilização da IA na manutenção preditiva são a "Dificuldade de extração de dados" e os "Altos Custos de implementação". Estes representam os maiores desafios enfrentados nos contextos estudados.

Limitações como "Dependência do auxílio humano" e "Falta de padronização" foram mencionadas com menos frequência, mas ainda assim representam obstáculos importantes.

Essas informações podem ajudar a direcionar futuras pesquisas e desenvolvimento de soluções, focando em superar as limitações mais impactantes e criando metodologias de IA mais robustas e amplamente aplicáveis na manutenção preditiva.

QUADRO 3 – Resumo das tendências identificadas nos estudos de caso

Tendências	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	Total
Adoção de melhores práticas																							✓		1
Aprendizagem automática							✓																		1
Desenvolvimento de novos algoritmos de I.A.																					✓				1
Desenvolvimento de novos frameworks de I.A.																						✓			1
Desenvolvimento de novos métodos						✓				✓	✓							✓	✓			✓		✓	7
Expandir para outros componentes, e/ou máquinas e/ou setores			✓							✓	✓					✓									4
Expansão das coletas de dados										✓	✓						✓	✓		✓		✓			6
Foco em eficiência																							✓		1
Foco em precisão																					✓				1
Foco em qualidade																								✓	1
Generalização para multiferramentas							✓																		1
I.A. com auxílio humano			✓							✓															2
Integração contínua de I.A.																	✓				✓	✓	✓		4
Integração de I.A. com software										✓									✓						2
Não Cita				✓			✓						✓												3
Otimização de custos																	✓		✓						2
Prevenção de falhas																	✓								1
Padronização de processos																				✓					1
Previsão da durabilidade de máquinas												✓													1
Redução da dependência humana						✓																			1

Fonte: Autores

A análise revela que as tendências mais citadas na utilização da IA na manutenção preditiva incluem o "Desenvolvimento de novos métodos", "Expansão das coletas de dados" e "Integração contínua de IA". Essas tendências indicam um foco crescente em inovação e expansão das capacidades da IA, bem como na integração contínua de novas tecnologias para melhorar a manutenção preditiva.

5. CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS

Por meio dos avanços tecnológicos aplicados a indústria, a utilização da manutenção preditiva tem se tornado uma realidade em ambientes industrial, permitindo que, dentre diversas vantagens, as empresas otimizem sua lucratividade e competitividade.

O presente trabalho tratou da realização de uma revisão sistemática da literatura com o intuito de entender a atual relação entre manutenção preditiva e o uso da inteligência artificial, visando também identificar ganhos, dificuldades/limitações e tendências relacionadas ao seu uso em estudos de caso.

Os resultados obtidos por meio do estudo mostram que, dentre os trabalhos encontrados, há um pico no número de textos publicados no ano de 2020, seguido por 2021. Encontrou-se

também que o país com um maior número de citações foi a Itália, seguida por China, Turquia e Brasil, ocupando desde a 2ª à 4ª posição, respectivamente.

Por intermédio do Grafo de citações foi possível entender a ligação/ relação entre os trabalhos, além de que a nuvem de palavras revelou que as palavras *Predictive Maintenance*, *Machine Learning*, *IoT*, *Big Data* e *Industry* são as que mais aparecem nas palavras-chave dos trabalhos.

A aplicação da Inteligência Artificial na manutenção preditiva apresenta diversos ganhos significativos, incluindo a melhoria no monitoramento, a otimização de processos e a redução de custos, que destacam seu potencial transformador. No entanto, há dificuldades e limitações que precisam ser superadas, como a dificuldade de extração de dados, altos custos de implementação, resistência organizacional e limitações de software. As tendências emergentes indicam um foco crescente no desenvolvimento de novos métodos, na expansão das coletas de dados e na integração contínua de IA. Essas tendências refletem um cenário de inovação constante e aprimoramento das práticas de manutenção preditiva. Apesar das limitações, este estudo oferece percepções valiosas que podem orientar futuras pesquisas e aplicações práticas, sublinhando a importância da IA na modernização industrial.

Apesar das limitações deste artigo, como a leitura de somente trabalhos encontrados por meio da ferramenta *BERTopic* (o que pode ter causado a não inclusão de outros artigos relevantes) e o rápido surgimento de novas tecnologias e métodos (pode fazer com que resultados encontrados se tornem obsoletos rapidamente), é possível utilizar-se dos resultados obtidos neste estudo como fonte sólida e ponto de partida para trabalhos futuros, tal como exemplo a definição das principais palavras-chave e trabalhos relacionados ao tema em questão. Além disso, como consequência da análise dos trabalhos, o compilado de ganhos, dificuldades/ limitações e tendências servem de auxílio para futuros estudos de caso.

Em resumo, a revisão sistemática apresentada demonstra o papel fundamental do uso da inteligência artificial na manutenção preditiva como forma de modernização industrial, demonstrando a importância do acompanhamento contínuo as inovações e publicações da área. Espera-se que as descobertas apresentadas incentivem a realização de futuras pesquisas e implementações práticas, promovendo avanços eficazes na indústria.

REFERÊNCIAS

ACHOUC, 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, 2022.

AYVAZ, S.; ALPAY, K. **Predictive maintenance system for production lines in manufacturing: A machine learning approach using IoT data in real-time**. Expert Systems with Applications, v.173, 2021.

BEVILACQUA, M; BRAGLIA, M. **The analytic hierarchy process applied to maintenance strategy selection**. Reliability Engineering and System Safety 70. 71–83, 2000.

BOUABDALLAOUI, Y.; LAFHAJ, Z.; YIM, P.; DUCOULOMBIER, L.; BENNADJI, B. **Predictive Maintenance in Building Facilities: A Machine Learning-Based Approach**. Sensors, v.21, n.4:1044, 2021.

CALABRESE, M.; CIMMINO, M.; FIUME, F.; MANFRIN, M.; ROMEO, L.; CECCACCI, S.; PAOLANTI, M.; TOSCANO, G.; CIANDRINI, G.; CARROTTA, A.; MENGONI, M.; FRONTONI, E.; KAPETIS, D. **An Event-Based IoT and Machine Learning Architecture for Predictive Maintenance in Industry 4.0**. Information, 2020.

CARVALHO, T. S.; SOARES, F. A. A. M. N.; VITA, R.; FRANCISCO, R.; BASTO, J. P.; ALCALÁ, S. G. S. **A systematic literature review of machine learning methods applied to predictive maintenance**. Computers & Industrial Engineering, v.137, 2019.

CHENG, J. C. P.; CHEN, W.; CHEN, K.; WANG, Q. **Data-driven predictive maintenance planning framework for MEP components based on BIM and IoT using machine learning algorithms**. Automation in Construction, v.112, 2020.

CINAR, Z. M.; ABDUSSALAM N., ABUBAKAR; Z., QASIM; K., ORHAN; ASMAEL, M.; SAFAEI, B. **Machine Learning in Predictive Maintenance towards Sustainable Smart Manufacturing in Industry 4.0**. Sustainability, 2020.

COMPARE, M.; BARALDI, P.; ZIO, E. **Challenges to IoT-enabled Predictive Maintenance for Industry 4.0**. IEEE Internet of Things Journal, 2019.

DALZIOCHIO, J.; KUNST, R.; PIGNATON, E.; BINOTTO, A.; SANYAL, S.; FAVILLA, J.; BARBOSA, J. **Machine learning and reasoning for predictive maintenance in Industry 4.0: Current status and challenges**. Computers in Industry, v.123, 2020.

FLORIAN, E.; SGARBOSSA, F.; ZENNARO, I. **Machine learning-based predictive maintenance: A cost-oriented model for implementation**. International Journal of Production Economics, v.236, 2021.

HONG-LINH T. **Integrated Analytics for IIoT Predictive Maintenance using IoT Big Data Cloud Systems**. IEEE International Conference on Industrial Internet, 2018.

KANAWADAY, A.; SANE, A. **Machine Learning for Predictive Maintenance of Industrial Machines using IoT Sensor Data**. 8TH IEEE International Conference on

Software Engineering and Service Science, 2017.

KWABENA, A. E.; WIAFE, O. B.; JOHN, B. D.; BERNARD, A.; BOATENG, F. A. F. **An automated method for developing search strategies for systematic review using Natural Language Processing (NLP)**. MethodsX, v. 10, 2023.

LEE, W. J.; WU, H.; YUN, H.; KIM, H.; JUN, M. B. G.; SUTHERLAND, J. W. **Predictive Maintenance of Machine Tool Systems Using Artificial Intelligence Techniques Applied to Machine Condition Data**. 26th CIRP Life Cycle Engineering, 2019.

LI, Z.; WANG, Y.; WANG, K. **Intelligent predictive maintenance for fault diagnosis and prognosis in machine centers: Industry 4.0 scenario**. Springer Nature, 2017.

MATZKA, Stephan. **Explainable Artificial Intelligence for Predictive Maintenance Applications**. 2020 3rd International Conference on Artificial Intelligence for Industries, AI4I: Institute of Electrical and Electronics Engineers. 69–74, 2020.

PACHECO, D. L.; SILVA, E. R.; NAVARRO, L. L. L.; OLIVEIRA, N. N. P.; CAULLIRAUX, H. M. **Algumas caracterizações dos métodos científicos em engenharia de produção: Uma análise de periódicos nacionais e internacionais**. ENEGEP, 2007.

PAOLANTI, M.; FELICETTI, L. R. A.; FRONTONI, A. M. E.; LONCARSKI, J. **Machine Learning approach for Predictive Maintenance in Industry 4.0**. In: 14th IEEE/ASME International Conference on Mechatronic and Embedded Systems and Applications (MESA), 2018.

PARPALA, R. C; IACOB, R. **Application of IoT concept on predictive maintenance of industrial equipment**. MATEC Web of Conferences, v.121, 2017.

PASSLICK, J.; DREYER, S.; OLIVOTTI, D.; GRUETZNER, L.; EILERS, D.; BREITNER, M. H. **Predictive maintenance as an internet of things enabled business model: A taxonomy**. Electronic Markets, 2021.

PERES, R. S.; ROCHA, A. D.; LEITAO, P.; BARATA, J. **IDARTS – Towards intelligent data analysis and real-time supervision for industry 4.0**. Computers in Industry, v. 101, 138–146, 2018.

REN, S.; ZHAO, X. **A predictive maintenance method for products based on big data analysis**. International Conference on Materials Engineering and Information Technology Applications, 2015.

ROSATI, R. ROMEO, L.; CECCHINI, G.; TONETTO, F.; VITI, P.; MANCINI, A.; FRONTONI, E. **From knowledge-based to big data analytic model: a novel IoT and machine learning based decision support system for predictive maintenance in Industry 4.0**. Journal of Intelligent Manufacturing, 2023.

SANG M. L.; DONHEE L.; YOUN S. K. **The quality management ecosystem for predictive maintenance in the Industry 4.0 era**. International Journal of Quality Innovation, 2019.

SEZER, ERIM; ROMERO, DAVID; GUEDEA, FEDERICO; MACCHI, MARCO; EMMANOUILIDIS, CHRISTOS. **An Industry 4.0-enabled Low Cost Predictive Maintenance Approach for SMEs: A Use Case Applied to a CNC Turning Centre**. IEEE International Conference on Engineering, Technology and Innovation (ICE/ITMC), 2018.

SHAMAYLEH, A.; AWAD, M.; FARHAT, J. **IoT Based Predictive Maintenance Management of Medical Equipment**. Journal of Medical Systems, 2020.

SHIN, W.; HAN, J.; RHEE, W. **AI-assistance for predictive maintenance of renewable energy systems**. Energy, v.221, 2021.

SILVA, I. J. S.; MELLO, L. T. C. **Fatores que auxiliam os estudantes na escolha do curso universitário: um estudo de caso na Engenharia de Produção**. UFERSA - Curso de bacharelado em ciência e tecnologia, 2022.

SUSTO, G. A.; SCHIRRU, A.; PAMPURI, S.; MCLOONE, S.; BEGHI, A. **Machine Learning for Predictive Maintenance: A Multiple Classifier Approach**. IEEE Transactions on Industrial Informatics, v. 11, n. 3, 2015.

THEISSLER, A.; VELÁZQUEZ, J. P.; KETTELGERDES, M.; ELGER, G.. **Predictive maintenance enabled by machine learning: Use cases and challenges in the automotive industry**. Reliability Engineering and System Safety, v. 215, 2021.

YAN, J.; MENG, Y.; LU, L.; LI, L. **Industrial Big Data in an Industry 4.0 Environment: Challenges, Schemes, and Applications for Predictive Maintenance**. IEEE Access, v. 20, 23484–23491, 2017.

ZHANG, W.; YANG, D.; WANG, H. **Data-Driven Methods for Predictive Maintenance of Industrial Equipment: A Survey**. IEEE Systems Journal, v.13, n.3, 2019.

ZHU, T.; YONGYI, R.; ZHOU, X.; WEN, YONGGANG. **A Survey of Predictive Maintenance: Systems, Purposes and Approaches**. IEEE, 2024.

ZONTA, T.; COSTA, C. A.; RIGHI, R. R.; LIMA, M. J.; TRINDADE, E. S.; Li, G. P. **Predictive maintenance in the Industry 4.0: A systematic literature review**. Computers & Industrial Engineering, v.150, 2020.