

UNIVERSIDADE FEDERAL DE MINAS GERAIS  
FACULDADE DE CIÊNCIAS ECONÔMICAS  
PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO

ANDRÉ LUIS CASTRO PEREIRA

**INTELIGÊNCIA ARTIFICIAL NA GESTÃO DE ATIVOS:  
UMA REVISÃO SISTEMÁTICA DA LITERATURA DA ÚLTIMA DÉCADA**

Belo Horizonte  
2025

André Luis Castro Pereira

**INTELIGÊNCIA ARTIFICIAL NA GESTÃO DE ATIVOS:  
UMA REVISÃO SISTEMÁTICA DA LITERATURA DA ÚLTIMA DÉCADA**

Trabalho de Conclusão de Curso de especialização em Gestão Estratégica apresentada a Faculdade de Ciências Econômicas da Universidade Federal de Minas Gerais, como requisito parcial a obtenção do título de Especialista em Gestão Estratégica.

Orientador: Profa. Dra. Leydiana de Sousa Pereira

Belo Horizonte  
2025

Ficha catalográfica

P436i  
2025

Pereira, André Luis Castro.

Inteligência artificial na gestão de ativos [manuscrito]: uma revisão sistemática da literatura da última década / André Luis Castro Pereira. – 2025.

1 v.: il.

Orientadora: Leydiana de Sousa Pereira.

Monografia (especialização) – Universidade Federal de Minas Gerais, Centro de Pós-Graduação e Pesquisas em Administração. Inclui bibliografia.

1. Administração. 2. Inteligência artificial. 3. Alocação de ativos. I. Pereira, Leydiana de Sousa. II. Universidade Federal de Minas Gerais. Centro de Pós-Graduação e Pesquisas em Administração. III. Título.

CDD: 658

# ATA DE DEFESA



**Universidade Federal de Minas Gerais**  
**Faculdade de Ciências Econômicas**  
**Centro de Pós-Graduação e Pesquisas em Administração**  
**Curso de Especialização em Gestão Estratégica**

ATA DA DEFESA DE TRABALHO DE CONCLUSÃO DE CURSO do Senhor **ANDRÉ LUIS CASTRO PEREIRA**, matrícula nº **2023706062**. No dia 27/10/2025 às 19:00 horas, reuniu-se em sala virtual, a Comissão Examinadora de Trabalho de Conclusão de Curso - TCC, indicada pela Coordenação do Curso de Especialização em Gestão Estratégica - CEGE, para julgar o Trabalho de Conclusão de Curso intitulado "**Inteligência artificial na gestão de ativos: uma revisão sistemática da literatura da última década**", requisito para a obtenção do Título de Especialista. Abrindo a sessão, a orientadora e Presidente da Comissão, Profa. Dra. Leydiana de Sousa Pereira, após dar conhecimento aos presentes do teor das Normas Regulamentares de apresentação do TCC, passou a palavra ao aluno para apresentação de seu trabalho. Seguiu-se a arguição pelos examinadores, seguida das respostas do aluno. Logo após, a Comissão se reuniu sem a presença do aluno e do público, para avaliação do TCC, que foi considerado:

(x) APROVADO

( ) NÃO APROVADO

85 pontos (oitenta e cinco pontos) trabalhos com nota maior ou igual a 60 serão considerados aprovados.

O resultado final foi comunicado publicamente ao aluno pela orientadora e Presidente da Comissão. Nada mais havendo a tratar, a Senhora Presidente encerrou a reunião e lavrou a presente ATA, que será assinada por todos os membros participantes da Comissão Examinadora. Belo Horizonte, 27/10/2025.

Prof<sup>a</sup> Leydiana de Sousa Pereira  
(Orientadora - CEGE/UFMG)

Documento assinado digitalmente  
**gov.br** LEYDIANA DE SOUSA PEREIRA  
Data: 29/10/2025 09:58:08-0300  
verifique em <https://validar.it.gov.br>

Prof<sup>a</sup> Natália Cristina da Silva Fonseca  
(Doutoranda CEPEAD/UFMG)

*Natália Cristina Da  
Silva Fonseca*

Assinado digitalmente via ZapSign por  
Natália Cristina da Silva Fonseca  
Data 29/10/2025 08:45:57.010 (UTC-0300)

Prof<sup>a</sup> Daniela Nunes dos Santos Ferreira  
(SENAI-PE)

**Daniela Nunes dos  
Santos Ferreira**

## **AGRADECIMENTOS**

Primeiramente à Deus, pela conclusão de mais um período da vida, a conclusão do curso de especialização em gestão estratégica de negócios na UFMG. À minha família pelo apoio constante e aos amigos da UFMG que proporcionaram a troca de experiências profissionais ao longo do curso. Agradeço a minha professora orientadora Leydiana pelo auxílio técnico e a banca avaliadora por se dedicar a avaliação do trabalho.

## RESUMO

Esse estudo investiga o papel da Inteligência Artificial (IA) na gestão de ativos, em especial na manutenção preditiva nos últimos 10 anos, uma área essencial para o funcionamento eficiente de indústrias, usinas de energia e transportes. A introdução da IA tem contribuído ao permitir a transição de modelos tradicionais de manutenção, sejam corretivos e ou preventivos, para uma abordagem preditiva. A pesquisa caracteriza-se como qualitativa exploratória, através de uma revisão da literatura sistêmica, conduzida na base Scopus mediante a utilização do protocolo Prisma. Foram selecionados os nove estudos mais citados e relevantes sobre o tema, priorizando aqueles com aplicações práticas. Os resultados destacam a IA como uma ferramenta estratégica na gestão de ativos, viabilizando o monitoramento preditivo e a manutenção inteligente. Esse avanço reduz falhas, otimiza operações, diminui custos e transforma a gestão de ativos em uma prática proativa orientada por dados. A pesquisa aborda sobre a importância de considerar os aspectos críticos durante o processo de adoção dos modelos de IA, como as questões éticas e humanas e os impactos ambientais relacionados à eficiência energética e à sustentabilidade.

**Palavras-chave:** Inteligência artificial, Gestão de ativos, Manutenção preditiva.

## ABSTRACT

This study investigates the strategic role of Artificial Intelligence (AI) in Asset Management (AM), with a specific focus on Predictive Maintenance (PdM) applications over the last decade. The introduction of AI has been crucial in enabling the transition from traditional maintenance models (corrective and preventive) to a proactive, predictive, and intelligent approach. The research is characterized as qualitative and exploratory, and was conducted through a Systematic Literature Review. The methodology employed the Prisma protocol and the Scopus database to select the nine most cited and academically relevant studies on the topic, prioritizing those with practical applications and validation. The results highlight AI as a strategic tool that facilitates predictive monitoring and smart maintenance. This advancement translates into tangible operational benefits, such as reduced failures, optimized operations, and a significant decrease in costs, transforming asset management into a data-driven practice. It is concluded that the successful adoption of AI models in Asset Management requires a comprehensive approach that extends beyond technical efficiency. The research underscores the importance of considering critical aspects such as ethical and human issues and the environmental impacts linked to energy efficiency and sustainability.

**Keywords:** Artificial intelligence. Asset management. Predictive maintenance.

## LISTA DE ILUSTRAÇÕES

Figura 1. Campos da IA: ML e DL	18
Figura 2. Tipos de IA	18
Figura 3. Fluxo metodológico Prisma	23
Figura 4. Seleção de artigos semelhantes	26
Gráfico 1. Anos de publicação dos artigos mapeados	26
Gráfico 2. Quantidade de documentos publicados “artificial Quantidade de publicações dos artigos mapeados por intervalo de anos	27
Gráfico 3. Quantidade de documentos publicados pela palavra Chave: “artificial intelligence”	27
Gráfico 4. Quantidade de publicações da IA nos 10 journals	28
Gráfico 5. Países com as maiores publicações	28
Figura 5. Mapa das Interrelações dos autores	29
Gráfico 6. Quantidade de publicações por autor na temática: IA, Gestão de Ativos e Manutenção Preditiva	30
Figura 6. Mapa das Interrelações das palavras chaves	30
Figura 7. Estrutura de decisão centrada no ser humano baseada em IA	34
Figura 8. Abordagem proposta em três etapas baseada em IA	35
Figura 9. Camadas do Sistema de Gêmeo Digital	36
Figura 10. Hierarquia de uma rede bayesiana com as interdependências entre os subsistemas	37
Figura 11. Fatores utilizados para cálculo do índice de saúde do transformador	40
Figura 12. Breve Linha do Tempo	45
Figura 13. Matriz SWOT da aplicação da IA na gestão dos ativos	47

## LISTA DE TABELAS E QUADROS

Tabela 1. Palavras-chaves mais frequentes sobre IA na Gestão de Ativos	31
Tabela 2. Artigos Seleccionados	32
Quadro 1. Classificação de Resiliência baseado em DARTS	39
Tabela 3. Índice de saúde e seus estados	40
Quadro 2. Contexto estratégico, tecnologia aplicada e resultados dos artigos mapeados	41

## LISTA DE ABREVIATURAS E SIGLAS

DL	<i>Deep Learning</i>
IA	Inteligência Artificial
IoT	<i>Internet of Things</i>
LGPD	Lei Geral de Proteção de Dados
ML	<i>Machine Learning</i>
UFMG	Universidade Federal de Minas Gerais

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	<b>12</b>
1.1 Objetivo Geral .....	14
1.2 Objetivos Específicos .....	14
1.3 Justificativa da Pesquisa .....	14
<b>2 REFERENCIAL TEÓRICO</b> .....	<b>16</b>
2.1 Inteligência artificial: conceitos e historicidade .....	16
2.2 Gestão de Ativos e Manutenção: Uma relação estratégica.....	19
<b>3 PROCEDIMENTOS METODOLÓGICOS</b> .....	<b>21</b>
3.1 Caracterização da pesquisa .....	21
3.2 Revisão sistemática da literatura: procedimentos e análises .....	21
<b>4 RESULTADOS E DISCUSSÃO</b> .....	<b>25</b>
4.1 Investigação via Litmaps .....	25
4.2 Dados bibliométricos .....	26
4.3 Análise bibliométrica via VOSViewer .....	29
4.4 Análise amostral de artigos .....	32
4.5 Análise crítica do cenário atual .....	43
4.6 Desafios atuais, implicações tóricas e gerenciais .....	45
<b>5 CONSIDERAÇÕES FINAIS</b> .....	<b>48</b>
<b>6 REFERÊNCIAS</b> .....	<b>50</b>

## 1 INTRODUÇÃO

A Inteligência Artificial (IA) tem transformado radicalmente a forma como as empresas realizam a gestão dos seus ativos (sejam eles físicos, financeiros e intangíveis). Toda essa transformação, precisa ser impulsionada por estudos empíricos sobre como a IA afeta a tomada de decisão no cenário corporativo e estar alinhada com a cultura organizacional das empresas (Kitsios; Kamariotou, 2021).

Praticar a gestão de ativos conforme as normas, significa buscar a geração de valor por meio do uso eficiente dos ativos, equilibrando desempenho, custos e riscos. Embora a gestão de ativos envolva outros pilares como o planejamento estratégico, tecnologia, dados confiáveis e cultura organizacional, a manutenção é o elo prático que conecta todos eles à operação diária conforme a ISO 55.000. Nesse contexto, a gestão estratégica dos ativos, permite que as empresas gerem valor em seus processos de forma contínua, o que reflete no aumento da confiabilidade, na otimização de custos e na mitigação de riscos, segundo os parâmetros definidos pela norma ISO 55.000 (Zampolli, 2019?).

A esfera ambiental também não pode ser esquecida, conforme destacado por Schoormann *et al.* (2023), as empresas estão sendo pressionadas por entregar serviços e produtos alinhados com o desenvolvimento sustentável. Dessa forma, essa tecnologia não apenas otimiza o uso de recursos e reduz desperdícios, mas também contribui diretamente para os objetivos globais do ODS 12 da agenda 2030. As inovações impulsionadas pela IA têm moldado setores como produção, manutenção, energia, transporte, saúde e meio ambiente ao oferecer soluções mais inteligentes e econômicas para a gestão de seus ativos, consolidando-se, assim, como uma ferramenta estratégica indispensável.

Segundo Russell e Norvig (2022), a IA é definida como o estudo de agentes inteligentes capazes de perceber e agir no ambiente para atingir objetivos. Essa definição é ampliada por Goodfellow *et al.* (2016), que explora o papel das redes neurais profundas e do aprendizado de máquina como pilares da IA moderna. Com o avanço dos algoritmos, os sistemas de IA passam a analisar grandes volumes de dados em tempo real, identificando anomalias e antecipando falhas antes que elas ocorram.

Em mercados cada vez mais competitivos e exigentes, especialmente em cenários pandêmicos, essa capacidade torna-se um diferencial indispensável como observado no estudo de Chen *et al.* (2021). Portanto, estudar e implementar a IA na gestão de ativos vai além de ser uma inovação tecnológica: é uma estratégia essencial para atender às demandas da economia atual.

Assim sendo, esse estudo evidencia a ausência de integração entre modelos de IA e a norma ISO 55000, compara os cenários distintos de aplicação da IA em setores como energia, transporte, indústria e infraestrutura, evidenciando barreiras econômicas, operacionais e regulatórias através de uma base teórica sólida. Para tal, esta pesquisa adotou uma Revisão Sistemática da Literatura (RSL), conduzida segundo os princípios do protocolo Prisma (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*). A análise caracteriza-se por uma abordagem estruturada para a identificação, seleção e interpretação dos artigos científicos mais relevantes sobre a aplicação da IA na gestão de ativos, com ênfase especial na manutenção preditiva.

Na análise, os nove principais estudos revelaram que o ser humano permanece com um papel fundamental na construção e validação dos modelos, adicionando o conhecimento tácito essencial no processo, alinhando diretamente com a indústria 5.0. Em um caso prático analisado por Chen *et al.* (2021), essa sinergia entre especialista humano e modelo de IA resultou em uma convergência de 82% de precisão, o que se torna fundamental na construção e validação dos modelos.

Ademais, observou-se que a aplicação prática da IA em maior escala é gradual e fortemente dependente de incentivo financeiro. Essa premissa foi corroborada por três artigos da autora Alice Consilvio (2020, 2022, 2024) – “*A data-driven prioritisation framework to mitigate maintenance impact on passengers during metro line operation*”; “*Towards a digital twin-based intelligent decision support for road maintenance.*” e “*On applying machine learning and simulative approaches to railway asset management: The earthworks and track circuits case studies*”. Esses trabalhos documentaram a implantação do projeto In2Smart para integrar IA na manutenção de ativos ferroviários e rodoviários, com um custo total de aproximadamente 23 milhões de euros ao longo de quatro anos. No entanto, o foco está restrito à estimativa de ações em um horizonte temporal semanal, o que reduz sua aplicabilidade em contextos de planejamento estratégico de longo prazo e na gestão completa dos ciclos de vida dos ativos.

Infere-se que o elevado investimento necessário seja uma das principais razões para o pequeno volume de relatos científicos sobre a aplicação de IA na gestão de ativos, sobretudo no setor público. No setor de energia, a análise revelou dois cenários distintos para a aplicação de manutenção preditiva com IA. No primeiro cenário, de aquecimento distrital de Langroudi e Weidlich (2020), a manutenção por métodos tradicionais ainda se mostra como a solução mais viável. Isso se deve ao baixo retorno financeiro esperado e ao baixo impacto operacional decorrente de eventuais falhas, fatores que não justificam, atualmente o investimento em

tecnologias avançadas de IA.

Em contrapartida, no segmento de petróleo e gás, de Ravishankar et al. (2022), a adoção da IA na manutenção preditiva de tubulações mostra-se amplamente justificada. Essa necessidade é impulsionada por um conjunto de fatores críticos: o risco de falhas catastróficas, os custos elevados de indisponibilidade, o volume de mão de obra em inspeções visuais, manuais e a disponibilidade de ferramentas de IA integradas a drones, que oferecem uma solução mais eficiente e segura para o monitoramento desses ativos.

Embora os estudos destaquem a contribuição da IA para a antecipação de falhas, otimização de processos e confiabilidade, alguns aspectos importantes são negligenciados como: a escalabilidade, os desafios em estruturar e justificar o retorno sobre o investimento (ROI), a ausência de estudos sobre integração com a norma ISO 55.000, as métricas de sustentabilidade, as barreiras de segurança e o distanciamento entre a pesquisa acadêmica e as necessidades práticas do setor produtivo.

## **1.1 Objetivo Geral**

Realizar uma RSL sobre a aplicação da IA na gestão de ativos, utilizando o protocolo PRISMA como metodologia central, com o intuito de identificar, selecionar, analisar e sintetizar as principais tendências, aplicações e abordagens documentadas na produção científica sobre o tema.

## **1.2 Objetivos Específicos**

- I. Mapear e analisar as principais aplicações da IA na gestão de ativos físicos, com foco em setores industriais e de infraestrutura na última década.
- II. Avaliar o impacto quantitativo e qualitativo da IA na eficiência, confiabilidade e custo de operações de manutenção preditiva.

## **1.3 Justificativa da Pesquisa**

O cenário corporativo tem ganhado notoriedade diante da crescente busca por competitividade, da necessidade de prever processos, de operar de forma sustentável e de agir com maior celeridade. Nesse contexto, a aplicação da IA, tornou-se central. Como observado pelo AI Index Report - 2025, os investimentos privados globais em IA, 2024 atingiram US\$ 252,3 bilhões em 2024 (Standford University, 2025). Nessa visão, torna-se relevante estruturar uma base teórica correlacioanda com modelos de gestão conteporâneos, e, dessa

forma integrar e sintetizar as principais contribuições científicas sobre a aplicação da IA na gestão de ativos.

De acordo com Oliveira e Bicalho (2025), a gestão de ativos é fundamental e essencial para a competitividade organizacional, uma vez que impacta diretamente a eficiência operacional, a segurança e a sustentabilidade dos negócios. Diante dessa assertiva, observa-se a evolução do conceito de "Indústria 4.0" (cunhado em 2011), para o de "Indústria 5.0", (introduzido em 2021) com um novo conceito que, conforme Rios (2024), estrutura-se em três pilares: centralidade no ser humano, resiliência e sustentabilidade, incorporando nova camada de valores e prioridades ao setor industrial.

Diante deste cenário, a IA emerge como uma tecnologia transformadora, moldando as práticas tradicionais de manutenção em processos preditivos, ágeis e orientados por dados. No entanto, a literatura existente nas bases de dados científicas como a da Scopus e Web of Science (WoS), reconhecidas como duas das principais bases de dados científicas utilizadas por pesquisadores em todo o mundo, embora abundante em relatos de casos isolados e soluções tecnológicas específicas, carece de uma síntese unificada e fundamentada que correlacione de forma clara as capacidades da IA com os princípios estabelecidos da gestão de ativos.

Nessa visão, esta pesquisa justifica-se, pela necessidade de preencher a lacuna observada nos artigos de Scaife (2024), Idowu *et al.* (2022) e Orošnjak *et al.* (2025) ao reforçar a necessidade cíclica de Revisões Sistemáticas da Literatura devido ao volume de trabalhos que estão sendo recentemente publicados sobre IA. Um dos principais achados deste estudo é na identificação da limitada integração entre modelos de IA e a norma ISO 55000 (ISO, 2014), especialmente na análise de diferentes cenários de aplicação como setores de energia, transporte, indústria e infraestrutura. A investigação evidenciou a presença de barreiras econômicas, distanciamento dos objetivos globais de sustentabilidade e poucos estudos com aplicação em contextos reais.

Ao analisar e sintetizar o conhecimento disperso, esse estudo poderá ser utilizado como uma base teórica para acadêmicos e profissionais que buscam não apenas entender o fenômeno, mas fundamentar decisões estratégicas sobre a adoção da IA. Dessa forma, o estudo transcende o propósito de uma mera compilação bibliográfica, posicionando-se como uma ferramenta essencial para navegar no campo em rápida evolução da gestão de ativos.

## 2 REFERENCIAL TEÓRICO

### 2.1 Inteligência artificial (IA): conceitos e historicidade

Embora não exista um conceito universal e limítrofe sobre a IA, ela pode ser compreendida como um campo da ciência da computação dedicada a desenvolver sistemas capazes de realizar tarefas que, tradicionalmente, exigiriam a inteligência humana (Wang, 2019). Tais sistemas são projetados para simular processos cognitivos, como o raciocínio, a aprendizagem e a autonomia na tomada de decisões, utilizando-se para isso, algoritmos, redes neurais artificiais e modelos estatísticos avançados, conforme destacado por Russell e Norvig (2022).

Observou-se o início da aplicação da IA na indústria em 1980, na empresa química DuPont nos Estados Unidos para otimizar suas operações no reconhecimento de padrões em dados, na previsão de comportamentos futuros e solução de problemas complexos. No entanto, essa tecnologia passou por flutuações de utilização, desde então, um dos períodos de retração dessa tecnologia mencionado por Duan *et al.* (2019) como “inverno de IA”, que ocorreu em meados de 1984.

Durante um debate público na conferência anual da AAAI (Associação Americana de Inteligência Artificial) observou-se que as projeções superestimadas sobre o potencial da IA não se materializaram devido as limitações de processamentos de dados disponíveis na época. Momento que moldou o desenvolvimento e a percepção dessa tecnologia. Ao mesmo tempo, foram observados períodos de “verão da IA” como no final dos anos 90 em que ocorreu um aumento da capacidade computacional e disponibilidade de dados em maior escala. Um dos eventos que marcaram a ascensão da IA foi a derrota de um campeão mundial de xadrez por um supercomputador da IBM em uma série de seis partidas, colocando em evidência novamente a razão humana com a lógica computacional em atividades cognitivas conforme destacado por Campbell *et al.* (2002).

Conforme observado por Duan *et al.* (2019) em sua análise sobre a evolução da IA, havia altos volumes de relatórios técnicos elaborados por grandes empresas de tecnologia e artigos publicados em periódicos renomados da área de gestão, como a *Harvard Business Review* e a *MIT Review*. Esses materiais ofereceram às organizações orientações estratégicas e recomendações práticas para a adoção da IA. No entanto, ainda se pontua uma carência de pesquisas acadêmicas que abordem, com rigor metodológico e fundamentação teórica, o uso e os impactos da IA sob a perspectiva da aplicação tecnológica.

Em termos evolutivos, em 2011, durante a feira de Hannover na Alemanha, surgiu o termo “Indústria 4.0”, com o propósito de impulsionar a digitalização dos processos produtivos por meio da implementação de fábricas inteligentes. Esse marco passou a ser reconhecido como a quarta revolução industrial, caracterizada pela integração de tecnologias digitais ao ambiente fabril (Ghobakhloo, 2018). Já em 2021, evidenciou-se o termo “Indústria 5.0” que, fundamentado em três pilares: centralidade no ser humano, sustentabilidade e resiliência, complementa o conceito anterior, permitindo uma nova camada de valores e prioridades (Rios *et al.*, 2024).


Em uma pesquisa realizada por uma empresa americana de consultoria chamada Gartner foi identificado que apenas 59% das organizações ainda estavam na fase de coleta de informações para desenvolver suas estratégias de IA (Panetta, 2017). Atualmente, em uma publicação da Mckinsey observou-se que as empresas já estão avançadas na aplicação da IA em 65% (Cafferata; Dias, 2024). Ou seja, em um curto intervalo de tempo observa-se que ocorreu uma maturidade e identificação que a IA é uma ferramenta estratégica para a gestão das organizações apesar dos desafios atuais enfrentados pelos gestores na viabilidade e justificativa dos investimentos em IA como observado por Sewald Junior *et al.* (2025).

Para compreender melhor essa tecnologia, torna-se necessário delimitar conceitos-chave que a compõem, notadamente o Aprendizado de Máquina (do inglês *Machine Learning, ML*) e o Aprendizado Profundo (do inglês *Deep Learning, DL*) e como esses termos se relacionam com a IA, conforme destacado por Gardner e Dorling (1998). O ML, subcampo fundamental da IA, capacita sistemas a analisarem grandes volumes de dados, identificarem padrões complexos e detectarem anomalias. Por meio de algoritmos que aprendem iterativamente com os dados, essa abordagem possibilita a melhoria contínua do desempenho do sistema com base na experiência acumulada. Essa característica de autoaprimoramento é essencial para aplicações industriais, pois forma a base para a previsão precisa de falhas e a otimização de operações.

Goodfellow *et al.* (2016), mostra que a relação entre esses conceitos é comumente entendida como hierárquica e escalonável. A IA como conceito mais amplo, engloba o desenvolvimento de sistemas capazes de simular a inteligência humana para realizar tarefas e tomar decisões de forma autônoma. O ML, concentra-se no desenvolvimento de algoritmos que podem aprender com dados, identificar padrões e melhorar seu desempenho sem serem explicitamente reprogramados para cada tarefa. O DL utiliza redes neurais artificiais com muitas camadas (“redes “profundas”) para aprender representações complexas e hierárquicas dos dados, sendo especialmente potente no processamento de dados não estruturados, como

imagens, áudio e texto. O DL envolve coletar, organizar e analisar dados, essencial para alimentar o ML. A Figura 1 exemplifica a correlação de cada uma das terminologias.

Figura 1. Campos da IA: ML e DL



Fonte: Adobe-IA (2025).

A IA é tradicionalmente categorizada em três tipos principais: a IA limitada (*ANI – Artificial Narrow Intelligence*), projetada para executar tarefa específica com alto desempenho, como reconhecimento facial ou recomendação de produtos (Fjelland, 2020). A IA geral (*AGI – Artificial General Intelligence*), ainda em desenvolvimento, refere-se a um sistema hipotético com capacidade cognitiva equivalente à de um ser humano em aprender e resolver problemas em diferentes contextos e a superinteligência (*ASI – Artificial Superintelligence*), uma forma hipotética de IA que ultrapassaria a inteligência humana em todos os domínios, incluindo criatividade científica, sabedoria geral e tomada de decisão estratégica (Narain *et al.*, 2019).

Essa classificação é amplamente discutida por Bostrom (2016), que alerta para os potenciais riscos e desafios éticos associados ao desenvolvimento da superinteligência, sendo necessário estabelecer estratégias de controle e governança. A Figura 2, representa cada um desses tipos mencionados.

Figura 2. Tipos de IA



Fonte: Webnode (2023).

Apesar de atualmente a IA do tipo ANI ser considerada a mais simples dentre as demais, observa-se que sua aplicação nos equipamentos da Indústria 5.0 traz oportunidades em automação, otimização e na manutenção preditiva e consequente redução de tempo de inatividade. Com capacidades de comunicação avançadas, esses equipamentos transmitem dados em tempo real para softwares e sistemas especializados de gestão de ativos, promovendo maior integração, automação e tomada de decisão baseada em dados (Bhandari *et al.*, 2020).

Uma das tendências atuais de integração dos ativos de forma virtual são os gêmeos digitais ou *digital twins*, que possibilitam a realização de simulação, prevenção e otimização de modelos virtuais dos ativos físicos conforme é explorado pela Spallarossa e Bonicelli (2024). Nesse estudo, foi criado um modelo virtual de uma ponte em 3D com *dashboards* interativos que permitem avaliar o status atual do ativo com os possíveis cenários de danos, com suporte a tomada de decisão para cada cenário (Spallarossa; Bonicelli, 2024). Permitindo assim a redução de tempo e custo de inspeção em campo.

## **2.2 Gestão de ativos e manutenção: uma relação estratégica**

Embora seja um termo considerado recente, a gestão dos ativos físicos foi precedida por diversas práticas voltadas a manutenção ainda que distantes de uma metodologia estruturada. Segundo a Associação Brasileira de Gestão de Ativos e Manutenção - Abraman (2011), gerir os ativos engloba algumas etapas como: aquisição; utilização; manutenção; desativação e descarte ou substituição. Durante o início da revolução industrial, no século XVIII predominava-se a manutenção corretiva, definida pela NBR 5462, como uma intervenção realizada após a ocorrência de uma falha ou parada não programada (ABNT, 1994). Conforme criticado por Viana (2024), nesta categoria, a abordagem é essencialmente reativa, cujo objetivo principal é restaurar a funcionalidade do sistema.

No entanto, esta estratégia está frequentemente associada a custos operacionais elevados, ao comprometer a segurança de pessoas e instalações. Com o aumento da complexidade dos equipamentos, a manutenção preventiva foi introduzida em meados do século XX para propor ações programadas e sistemáticas, antecipando falhas por meio de atividades realizadas em intervalos de tempo predeterminados no uso ou ciclos operacionais. Essa prática depende do histórico dos ativos e da análise de seu ciclo de vida, sendo capaz, quando bem estruturada, de melhorar indicadores de confiabilidade e disponibilidade.

Conforme Gulati (2009), a otimização dos custos nas estratégias de manutenção preventiva está ligada na definição do “o que fazer” e “quando fazer”, isto é, do escopo das

ações e da sua periodicidade e a correta definição da frequência de execução. Embora a manutenção preventiva permita antecipar a correção de falhas, essa estratégia implica em períodos de indisponibilidade operacional, uma vez que cada intervenção exige a parada do processo. Isso torna a definição da periodicidade e do tempo de execução uma tarefa complexa, influenciada não apenas pela necessidade de interrupção, mas também por outros fatores, como disponibilidade de recursos.

A manutenção preditiva representa uma evolução técnica ao permitir o monitoramento contínuo dos ativos com apoio de sensores e tecnologias analíticas, conforme destacado por Kardec (2012). Ela detecta sinais de desgaste antes que se tornem falhas, utilizando métodos como análise de vibração, termografia e qualidade do óleo por exemplo. Em 2004 foi criada uma especificação técnica nomeada como PAS 55 (*Publicly Available Specification*) no Reino Unido que buscava estabelecer diretrizes para garantir que os ativos fossem gerenciados de forma eficiente, segura e sustentável ao longo de seu ciclo de vida (Abraman, 2011; Tavares; Gomes, 2015). O motivador da criação desse documento foi a ausência de padrões na gestão dos ativos físicos, tornando-se referência internacional e servindo-se de base para criação da norma ISO 55000 em 2014 como uma abordagem estratégica e integrada para diversos setores e tipos de ativos.

Zampolli (2019?), mostra que praticar a gestão de ativos conforme as normas significa buscar a geração de valor por meio do uso eficiente dos ativos, equilibrando desempenho, custos e riscos. Essa prática exige uma reflexão estratégica inicial sobre o posicionamento da empresa no mercado, seus objetivos de longo prazo e suas expectativas e necessidades. Conforme destacado por Oliveira e Bicalho (2025), é fundamental compreender que a adoção de tecnologias emergentes como a IA na gestão de ativos é um caminho irreversível para empresas que buscam a tomada de decisões assertivas, maior competitividade, sustentabilidade e a otimização da vida útil dos seus ativos.

Ao mesmo tempo, deve-se levar em consideração dois fatores importantes: quanto tempo o investimento trará retorno e o distanciamento entre um ambiente controlado (teoria) com o mundo real na prática, conforme estudo de Buczynski *et al.* (2021). Apesar de ser voltado para o mercado financeiro (ativos intangíveis), pode-se realizar abrangência da sua análise crítica entre contextos controlados e cenários reais como na gestão de ativos. O estudo da utilização de drones integrados com IA para inspeção de ativos de Ravishankar *et al.* (2022) é um exemplo que vai de encontro com esse viés, a validação em laboratório é importante para etapa de criação dos modelos de IA, mas torna-se necessário refinar os modelos considerando aspectos próximos à realidade.

### 3 PROCEDIMENTOS METODOLÓGICOS

#### 3.1 Caracterização da pesquisa

Esta pesquisa caracteriza-se por sua proposta qualitativa exploratória, uma vez que busca compreender como as tecnologias baseadas em IA estão sendo moldadas para otimizar processos e prever tendências no cenário da gestão de ativos e na manutenção. O seu caráter qualitativo deve-se a análise aprofundada dos impactos e desafios dessa transformação digital, em artigos científicos, enquanto o caráter exploratório se justifica pela necessidade de investigar um campo ainda emergente e em constante evolução (Edgar; Manz, 2017). Essa condução metodológica permite a identificação de lacunas e oportunidades de pesquisas.

Especificamente, os passos metodológicos foram estruturados diante de uma RSL, segundo os princípios do protocolo PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) com base nas recomendações contidas por Page *et al.* (2021) e Moher *et al.* (2009). A revisão da literatura foi conduzida a partir da consulta e seleção artigos científicos indexados nas bases de dados Web of Science (WoS) e Scopus. Reconhecidas como duas das principais bases de dados científicas utilizadas por pesquisadores em todo o mundo. Segundo Costa *et al.* (2023), elas se destacam por sua ampla abrangência temática e pelo rigor metodológico na indexação de publicações científicas de elevado padrão acadêmico.

#### 3.2 Revisão sistemática da literatura: procedimentos e análises

Antes de iniciar a investigação aprofundada desse tema central, foi conduzida uma análise preliminar para identificar a existência de revisões sistemáticas da literatura que já abordassem o assunto. A composição das strings foram na língua inglesa, tendo em vista a maior abrangência internacional dos artigos publicados, bem como as palavras chave da pergunta da pesquisa: “Como a IA tem impactado a gestão de ativos na indústria e na infraestrutura na última década?”.

Dessa maneira, foram mapeadas três palavras chave com base no objetivo da pesquisa. A primeira foi ["*systematic review*"], pois inicialmente o objetivo é investigar as últimas revisões sistemáticas sobre o tema e as outras duas palavras chave selecionadas foram ["*artificial intelligence*"] e ["*assets management*"]. Os termos ["*Infrastructure*"], ["*Industry*"] e ["*Maintenance*"] não foram inicialmente utilizados para não restringir os resultados de busca, permitindo assim uma abordagem mais ampla da aplicação da IA na gestão de ativos independentemente do setor.

Nesse sentido, foram encontradas 64 publicações na base da Scopus voltadas para os setores de energia, aviação, medicina, construção civil, logística, recursos humanos e governança de dados. Ademais, para proporcionar robustez analítica recorreu-se plataforma Litmaps. O Litmaps foi lançada em 2016 como uma ferramenta adicional e interativa para construção da pesquisa. Conforme destacado por Kaur *et al.* (2022), o Litmaps é capaz de mostrar caminhos, conexões e evolução entre artigos de forma dinâmica. Após iniciar a pesquisa na plataforma, buscou-se o primeiro artigo que correlacionasse diretamente com o objeto de estudo desse trabalho.

Foram encontrados artigos relacionados a revisões sistemáticas aplicadas a casas verdes ou *greenhouses*, eficiência energética, saúde, educação, IA em ativos intangíveis e três artigos que vão de encontro ao objeto de pesquisa atual. O primeiro artigo selecionado na plataforma Litmaps para avaliar possíveis duplicidades na pesquisa foi o *“Improve predictive maintenance through the application of artificial intelligence: A systematic review”* de Scaife (2024). Após a validação do alinhamento temático desse artigo com a proposta de estudo, buscou-se por outros estudos correlacionados sugeridos pela plataforma. O segundo artigo identificado foi de Idowu *et al.* (2022), *“Asset Management in Machine Learning: State-of-research and State-of-practice”* e o terceiro artigo: *“Prescriptive Maintenance: A Systematic Literature Review and Exploratory Meta-Synthesis”* de Orošnjak *et al.* (2025).

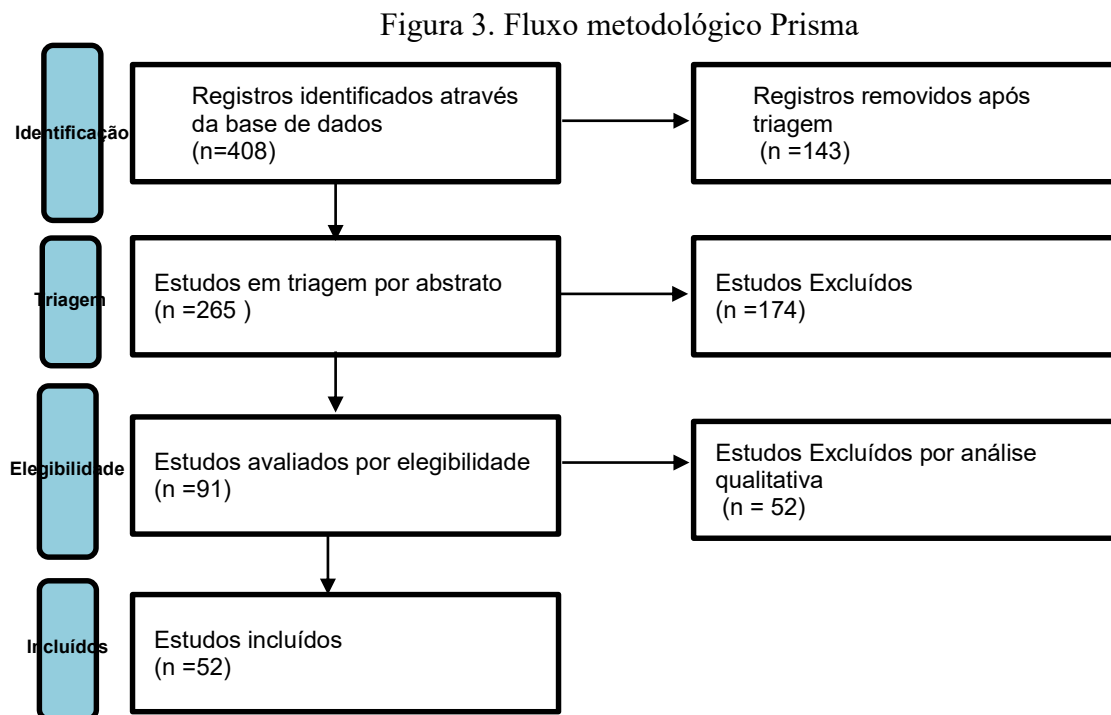
Dessa maneira, foi definida uma *string* de busca primária composta pelos descritores [“*artificial intelligence*”] AND [“*assets management*”], excluindo o termo [“*systematic review*”], pois o foco nessa segunda etapa foi na identificação de artigos que possam responder as interconexões entre esses dois campos. Observou-se um ponto de inflexão no volume de publicações em 2019 que permanece em constante crescimento até os dias atuais, enquanto o período de 1982 até 2019 as publicações anuais sobre esse tema não ultrapassavam 250 artigos.

Ao observar o volume de publicações científicas nos últimos 10 anos na base da Scopus, foi possível avaliar um crescimento significativo de publicações, com aumento médio de 130 publicações ao mês, atingindo atualmente mais de 1.250 artigos ao ano. Diante desse cenário, foi utilizado o intervalo de publicações dos últimos 10 anos (2015-2025) como filtro adicional de busca a fim de mapear tendências atuais na área que abrangem 86% em volume de artigos publicados. Essa identificação vai de encontro com o período inicial da quarta revolução industrial (Ghobakhloo, 2018).

A busca inicial foi realizada também em ambas bases de dados WoS e Scopus para comparar o volume de estudos sobre o tema. Após realizar a pesquisa, resultou em um volume significativo de publicações: 818 documentos na Web of Science (WoS) e 1.850 na Scopus.

Como estratégia de busca secundária, foi incluído o descritor ["*maintenance*"], por se tratar de uma das palavras-chave mais recorrentes na norma ISO 55000 (ocupando a 20ª posição em frequência) e optou-se por não utilizar os termos ["*Infrastructure*"] e ["*Industry*"] neste momento, a fim de evitar restrições excessivas na abrangência da pesquisa, especialmente considerando o uso da técnica de truncamento de palavras. Foram encontradas 225 publicações via WoS, mas identificando 408 artigos na Scopus. Considerando-se o maior volume total de artigos, a base de dados da Scopus foi selecionada para o desenvolvimento desta pesquisa.

De posse dos 408 artigos (ver Figura 3), realizou-se uma nova triagem considerando trabalhos na língua inglesa com o as palavras chave de maior frequência nos artigos identificados e alinhadas com o objeto de pesquisa : *Artificial Intelligence (AI)*, *Predictive Maintenance*, *Asset Management*, *Machine Learning*, *Internet of Things (IoT)*, *Big Data*, *Predictive Analytics*, *Remote Sensing*, *Real-Time Monitoring*, *Equipment Failure*, *Automated Decision-Making*, *Operational Efficiency*, *Asset Lifecycle*, *Predictive Models*, *Digital Transformation in Industry*. Após esse processo, a base de dados de artigos reduziu para 265 artigos.



Fonte: Autor (2025).

Em seguida, a base de dados dos 265 artigos foi exportada em formato “.csv” e organizada em Microsoft Excel<sup>(R)</sup>, permitindo a visualização estruturada de informações como título, autores, resumo e palavras-chave. Após essa consolidação foram excluídos os artigos

distantes da temática em estudo. Conforme a Figura 3, foi realizada a leitura dos resumos dos artigos e excluídos os artigos distantes do tema ou sem relação direta. Após esse refino, a base de dados foi reduzida para 52 artigos e realizado novo refino. Três critérios foram considerados: o número de citações, utilizado como métrica de influência acadêmica, a aplicação prática da IA e, a disponibilidade diante do portal CAPES (alguns precisavam adquirir para ter acesso ao arquivo). Por fim, foram selecionados nove artigos que apresentaram maior convergência temática na indústria e impacto na literatura, pois abordam diretamente sobre o tema em cenários industriais e de infraestrutura reais bem como maior acadêmica dentre os demais.

A aplicação das ferramentas bibliométricas possibilitou a elaboração de um mapa de visualização de redes para identificar as interconexões através do *software VOSviewer<sup>(R)</sup>*, o qual destaca os termos mais frequentes e as sua inter-relações. Para a elaboração desse mapa, foi realizada uma análise de coocorrência de palavras-chave e suas respectivas inter-relações com o intuito de consolidar diferentes variações de uma mesma palavra em uma forma padronizada. Pontua-se que para as análises bibliométricas considerou-se a amostra dos 408 artigos.

## 4 RESULTADOS E DISCUSSÃO

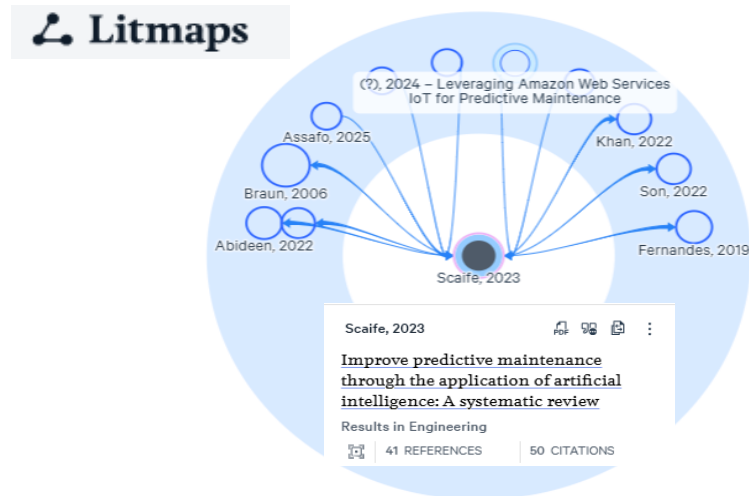
### 4.1 Investigação via Litmaps

Foi utilizada a plataforma Litmaps, como uma ferramenta de pesquisa complementar para investigar as possíveis RSL semelhantes ao tema proposto. Foram encontrados 3 artigos que vão de encontro com o tema em estudo. O primeiro artigo selecionado na plataforma Litmaps para avaliar possíveis duplicidades na pesquisa foi o: *“Improve predictive maintenance through the application of artificial intelligence: A systematic review”* de Scaife (2024), que aborda sobre uma RSL de 14 artigos da base de dados *Mendeley Web*, focado principalmente sobre a aplicação da IA em operações das instalações prediais em casos reais. O autor identifica que uma das principais barreiras para a implementação da IA está vinculada a estruturação e insuficiência de dados e ao mesmo tempo sua análise é limitada ao selecionar artigos com estudos de casos exclusivos dos Estados Unidos.

O segundo artigo de Idowu *et al.* (2022), *“Asset Management in Machine Learning: State-of-research and State-of-practice”*, selecionou 30 estudos dos últimos cinco anos dos quais 18 eram práticos e 12 de pesquisa. O autor aborda sobre o gerenciamento de ativos focados em *machine learnig* e seus principais desafios, como a reprodutibilidade e interoperabilidade dos sistemas desenvolvidos por IA. Foi o único artigo que expôs sobre esse tema frequentemente negligenciado: implementações práticas de IA no cenário científico.

O terceiro artigo que aborda sobre uma RSL consiste no *“Prescriptive Maintenance: A Systematic Literature Review and Exploratory Meta-Synthesis”* de Orošnjak *et al.* (2025). Esse estudo realiza uma revisão sistemática dos últimos dez anos nos setores industriais para mapear tecnologias e métodos da aplicação da IA na manutenção. O autor utilizou de cinco bases de dados distintas e ao final incluiu em sua base 61 estudos em sua análise bibliométrica. O estudo aproxima com o estudo atualmente proposto na aplicação da IA no setor ferroviário e de energia e ao mesmo tempo se distancia ao trabalhar nos setores aeroespacial e de manufatura que são disntintos dos pontos focais de desse trabalho, a Figura 4 ilustra o mapa gerado pela plataforma Litmaps.

Figura 4. Seleção de artigos semelhantes




Fonte: Litmaps (2025)

## 4.2 Dados bibliométricos

A amostra contemplou estudos publicados entre 2015 e 2025, período selecionado para refletir a evolução mais recente da IA no contexto da gestão de ativos, com destaque para as contribuições de pesquisadores dos Estados Unidos, Itália, Índia e Alemanha. Com base no Gráfico 1, observa-se um crescimento expressivo de aproximadamente 180% no volume de publicações em 2024 em relação a 2023.


Gráfico 1. Anos de publicação dos artigos mapeados



Fonte: Scopus (2025).


A aplicação de uma projeção linear nos dados de Janeiro a Setembro de 2025 sugere a manutenção do número de publicações em relação a 2024, com uma estimativa de 89 artigos. Infere-se também que o intervalo de estudo escolhido é bastante representativo, cobrindo 86% das publicações realizadas desde 1999, conforme demonstrado no Gráfico 2.

Gráfico 2. Quantidade de publicações dos artigos mapeados por intervalo de anos



Fonte: Autor (2025).

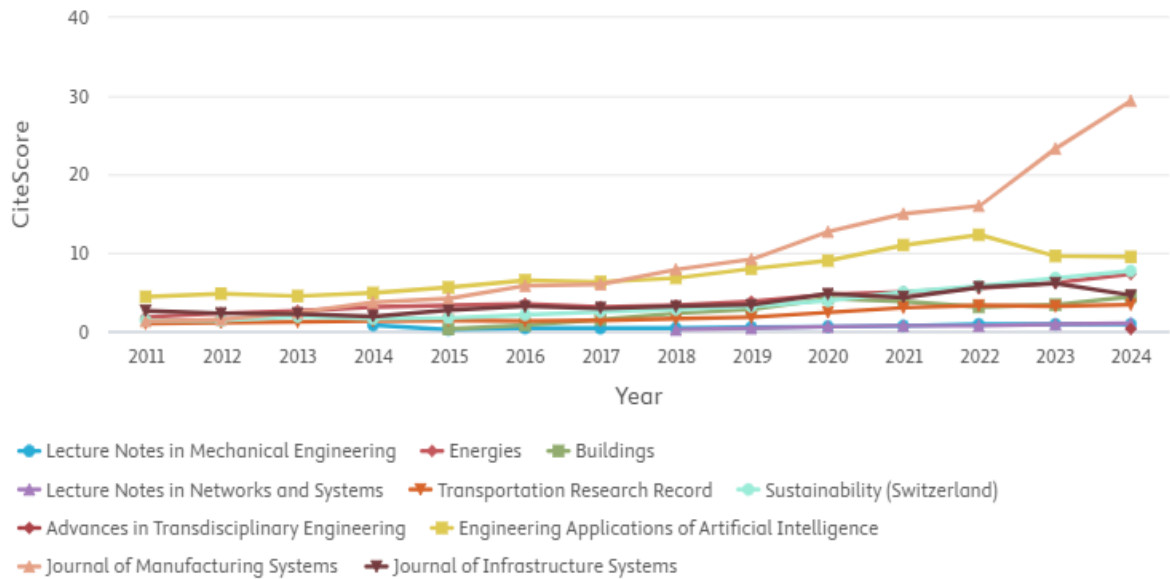
A trajetória da IA em sua forma ampla (descriptor: ["*artificial intelligence*"]) foi avaliada para comparar a tendência do tema da gestão de ativos. Para a IA, a projeção para 2025 é um crescimento de 20%, saindo de 103 mil e atingindo 124 mil publicações anuais. Esse dado contrasta com a queda projetada nas publicações específicas sobre gestão de ativos com IA e reforça que o campo mais amplo da IA mantém um crescimento constante ao longo dos últimos dez anos, conforme o Gráfico 3.

Gráfico 3. Quantidade de documentos publicados pela palavra Chave: “*artificial intelligence*”

Fonte: Autor (2025).

A avaliação do volume anual de publicações nos principais journals da área, revela o “*Journal of Manufacturing Systems*” como destaque. Essa predominância decorre à sua elevada relevância temática, que abrange de forma central, tópicos diretamente alinhados com a interseção entre IA e gestão de ativos, tais como engenharia de controle de sistemas, engenharia industrial de manufatura e o desenvolvimento de software para manufatura inteligente. Essa distribuição anual do volume de publicações por journal é ilustrada detalhadamente no Gráfico 4.

Gráfico 4. Quantidade de publicações da IA nos 10 journals




Fonte: Autor (2025).

A análise dos países com o maior volume de publicações sobre o tema revela os Estados Unidos na liderança. Esse resultado está em consonância com os altos investimentos do país em pesquisa e desenvolvimento de IA nos últimos anos. Essa correlação é evidenciada pelo AI Index Report - 2025, publicado pelo Instituto de Pesquisa em IA da Universidade de Stanford (Stanford HAI), que indica que, apenas em 2024, os Estados Unidos investiram aproximadamente US\$ 109 bilhões em IA provenientes de fontes corporativas, governamentais e de capital de risco (Standford University, 2025).

Esse valor representa mais do que o dobro do investimento da China (que ocupa a segunda posição no ranking de investimentos) e é aproximadamente sessenta e quatro vezes maior que o investimento do Brasil, que totalizou cerca de US\$ 1,7 bilhão no mesmo período.


Gráfico 5. Países com as maiores publicações



Fonte: Autor (2025).

### 4.3 Análise bibliométrica via VOSViewer

Realizou-se uma análise de rede de cocitação de autores com o objetivo de mapear a influência intelectual e identificar os estudos mais pertinentes ao escopo desta pesquisa. A análise da rede demonstrou uma forte correlação entre os autores dos artigos avaliados, permitindo inferir que Alice Consilvio exerce uma influência significativa no campo de estudo. Sua posição proeminente na rede atua como um ponto de convergência teórica e metodológica para os demais pesquisadores, indicando que suas pesquisas são amplamente referenciadas, conforme a Figura 5.



Fonte: Autor (2025).

Ao consultar o Google Scholar e a base de publicações da Scopus, observa-se que a autora Alice Consilvio possui uma produção científica significativa voltada para IA na manutenção preditiva e gestão de infraestrutura ferroviária. Alice Consilvio é uma pesquisadora italiana vinculada à Universidade de Gênova, com atuação destacada na área de engenharia de transportes. Nos últimos quatro anos a autora tem publicado de dois a três estudos científicos por ano, sendo 40% deles artigos.

Outro autor em destaque é o Karim R., professor de Harvard e cofundador do laboratório de ciência e inovação, especialista em estratégia e gestão de negócios na era da IA. Em 2020 esse professor lançou seu livro “Competindo na Era da IA” que discute como as empresas nativas digitais (como Google, Amazon e Microsoft) operam com uma arquitetura fundamentalmente nova, exigindo que as empresas tradicionais reinventem seus modelos de negócios e estratégias para se manterem competitivas. Observa-se no gráfico 6, a quantidade de publicações por autor na temática IA.



Diante da Figura 6, o cluster vermelho está diretamente relacionado a área de tecnologia e análise de dados, como “*machine learning*”, “*big data*” e “*data analytics*”. O cluster azul indica estudos que tratam de ferramentas de suporte à tomada de decisão e análise de incertezas em ativos de infraestrutura, especialmente no contexto ferroviário. O cluster verde evidencia uma correlação entre as práticas de gestão predial (BIM), foco em sustentabilidade e eficiência energética e o amarelo evidencia a interseção entre tecnologias (Indústria 4.0 e *Data Analytics*) e a gestão estratégica de ativos, onde a IA funciona como ponto focal da integração. Embora tenha fornecido ideias iniciais sobre o tema, tornou-se necessário aprofundar nos artigos selecionados para identificação de padrões, relações e lacunas a serem exploradas nos estudos científicos

Com o objetivo de realizar a identificação das palavras-chave mais frequentes nas obras selecionadas foi observado a base de dados, também do software VosViwer, contendo as palavras-chave, a quantidade de ocorrências e o volume de interrelações conforme a Tabela 1. Ao analisar a base de dados, foram unificadas as palavras-chave que o software considera como distintas, como “*machine learning*” e “*machine-learning*” devido à presença do hífen alocada de forma equivocada por exemplo, termos no plural “*digital twin*” e “*digital twins*”, bem como os termos genéricos como “*highway administration*”.

Tabela 1. Palavras-chaves mais frequentes sobre IA na Gestão de Ativos

<b>Rank</b>	<b>Keywords</b>	<b>Ocorrências</b>	<b>Inter-Relações</b>
1°	<i>artificial intelligence</i>	88	431
2°	<i>assets management</i>	70	396
3°	<i>machine learning</i>	37	243
5°	<i>maintenance</i>	37	222
6°	<i>decision making</i>	27	172
7°	<i>predictive maintenance</i>	26	123
8°	<i>life cycle</i>	11	73
9°	<i>condition based maintenance</i>	9	59
10°	<i>decision support systems</i>	9	53
11°	<i>railroad transportation</i>	8	57
12°	<i>building information modelling</i>	8	56
13°	<i>neural-networks</i>	7	52
14°	<i>condition monitoring</i>	7	48
15°	<i>neural networks</i>	6	48

Fonte: Autor (2025).

É possível observar também que as palavras-chave que lideram o rank acima estão diretamente relacionadas à estratégia de pesquisa utilizada. Os termos “*machine*

*learning*", *"predictive analytics"* e *"condition based maintenance"* indicam a utilização de técnicas específicas para análise de dados e tomada de decisão e a presença das palavras *"internet of things"*, *"industry 4.0"* e *"data analytics"* revela a integração da IA com tecnologias emergentes e ambientes digitais.

#### 4.4 Análise amostral de artigos

Através da metodologia de seleção sistemática previamente delineada foram identificados e selecionados os nove artigos que apresentaram a maior convergência temática para aplicações na indústria e maior impacto na literatura científica da área. A Tabela 2 sintetiza as principais informações desses estudos, listados abaixo reunindo-se informações sobre: autor, journal, fator de impacto, ano de publicação, título, contribuição, aplicação prática, e referências.

Tabela 2. Artigos Selecionados

#	Autor; Ano	Journal; Fator de Impacto	Título	Contribuição	Aplicação Prática
1	Chen <i>et al.</i> (2021)	<i>Annals of Operations Research</i> ; 4,5	<i>Artificial intelligence-based human-centric decision support framework: an application to predictive maintenance in asset management under pandemic environments</i>	Sugere a aplicação de um sistema híbrido de IA com participação humana em pequenas e médias empresas durante cenários de crise.	Sim
2	Consilvio <i>et al.</i> (2024)	<i>European Transport Research Review</i> ; 4,2	<i>A data-driven prioritisation framework to mitigate maintenance impact on passengers during metro line operation</i>	Enumera a priorização das intervenções de manutenção em sistemas metroviários centralizando no impacto da disponibilidade do "cliente" - passageiros.	Sim
3	Consilvio <i>et al.</i> (2022)	<i>Transportation Research Procedia</i> ; 2,8	<i>Towards a digital twin-based intelligent decision support for road maintenance</i>	Desenvolve uma arquitetura de Digital Twin (réplica digital dos ativos físicos da estrada) integrada com IA para planejamento de intervenções em tempo real.	Sim

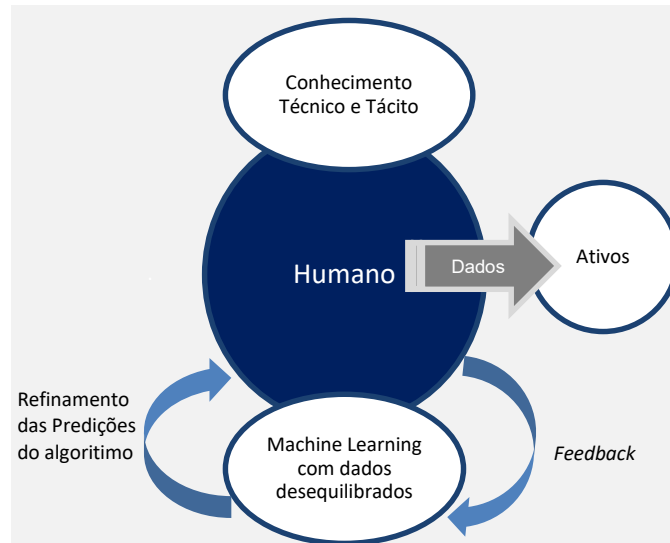
4	Consilvio <i>et al.</i> (2020)	<i>Sustainability</i> ; 3,3	<i>On applying machine learning and simulative approaches to railway asset management: The earthworks and track circuits case studies</i>	Propõe um sistema de apoio à decisão para manutenção ferroviária e rodoviária combinando IA, estudo serviu como base para os artigos 2 e 3.	Sim
5	Scaife (2024)	<i>Results in Engineering</i> ; 7,9	<i>Improve predictive maintenance through the application of artificial intelligence: A systematic review</i>	Realiza uma revisão sistemática sobre o uso de IA na manutenção preditiva de sistemas prediais e sugere recomendações práticas para adoção organizacional da IA.	Não
6	Langroudi e Weidlich (2020)	<i>Environmental and Climate Technologies</i> ; 1,6	<i>Applicable Predictive Maintenance Diagnosis Methods in Service-Life Prediction of District Heating Pipes</i>	Apresenta a teoria para estimar a vida útil de tubulações de aquecimento distrital com a aplicação da IA teoricamente.	Não
7	Ravishankar <i>et al.</i> (2022)	<i>International Journal of Disaster Risk Science</i> ; 4,0	<i>DARTS—Drone and Artificial Intelligence Reconsolidated Technological Solution for Increasing the Oil and Gas Pipeline Resilience</i>	Desenvolve um sistema que utiliza drones e IA para inspeção automatizada de dutos e classifica o estado dos ativos com base em critérios estruturais.	Sim
8	Alabdullh <i>et al.</i> (2024)	<i>Heliyon</i> ; 3,6	<i>A novel method to estimate the lifetime of mineral oil-type power transformers based on the analysis of chemical and physical indicators using artificial intelligence</i>	Sugere um índice que traduz o estado de "saúde" dos transformadores "Health Index" através da análise química para determinar o ciclo de vida dos transformadores de potência.	Sim
9	Shim, <i>et al.</i> 2022	<i>Water</i> 3,0	<i>Smart Water Solutions for the Operation and Management of a Water Supply System in Aracatuba, Brazil</i>	Desenvolve um sistema para implementação de soluções de Água Inteligentes (Smart Water Solutions) para mitigar os desperdícios através da detecção de vazamentos	Sim

Fonte: Autor (2025).

O primeiro artigo, de Chen *et al.* (2021), trata-se da manutenção preditiva na gestão de ativos em ambientes pandêmicos, especialmente em pequenas e médias empresas. O estudo integra as tecnologias da Indústria 4.0 com o conhecimento tácito de especialistas humanos e a necessidade de enfrentar os desafios impostos por eventos como a pandemia da Covid-19,

que exige maior previsibilidade e decisões rápidas, em uma integração conforme a Figura 7. A estratégia inclui o desenvolvimento do modelo T-BKS (*Trust-based Behaviour Knowledge Space*), capaz de combinar modelos de aprendizado de máquina com interação humano-máquina.

Figura 7. Estrutura de decisão centrada no ser humano baseada em IA



Fonte: Adaptado de Chen *et al.* (2021)

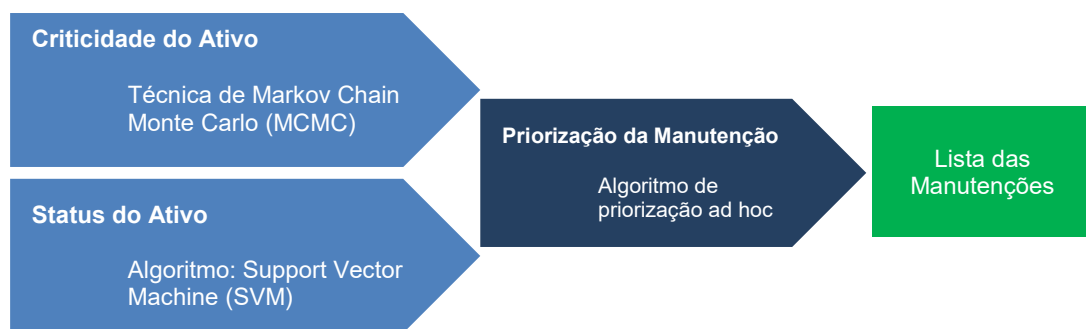
O estudo realizado demonstrou resultados com uma taxa de confiança de 82% nas avaliações humanas (ou seja, em oito de cada dez casos, o especialista concordou com a previsão do sistema). Foram observados ainda benefícios como redução de custos de inatividade e maior previsibilidade na saúde dos ativos. Embora o tipo exato de equipamento não tenha sido especificado, o estudo sugere aplicação em sistemas industriais sujeitos a desgaste, como motores ou bombas. A integração entre IA e conhecimento humano mostrou-se essencial para decisões assertivas em cenários incertos, principalmente para as para PMEs que possuem restrição de capital e não contam com grande fôlego financeiro para lidar com os imprevistos (Chen *et al.*, 2021).

Um ponto importante a ser observado também é a resistência humana à mudanças, mas o artigo não aprofunda a discussão sobre os fatores organizacionais e culturais necessários para sustentar a transformação digital na gestão de ativos a longo prazo. Além disso o estudo não explora os potenciais desafios éticos associados ao desenvolvimento de uma IA como discutido por Bostrom (2016).

O segundo artigo, de Consilvio (2024) apresenta um modelo de priorização de manutenção preditiva em sistemas metroviários, em específico na linha M5 do metrô de Milão na Itália (12,8 km de extensão e conta com 19 estações). Foi incorporado o fluxo de usuários

como variável determinante na definição da criticidade dos equipamentos. O modelo emprega a técnica de *Markov Chain Monte Carlo* (Modelo MCMC) que simula múltiplos cenários possíveis de fluxo de passageiros, gerando uma distribuição de probabilidades para cada estação e horário. Em seguida, a avaliação do status dos ativos é realizada por meio do algoritmo One-Class SVM (OCSVM), treinado exclusivamente apenas com dados de comportamento “normal”. Dessa forma, ele aprende o “padrão saudável” de funcionamento de um ativo e posteriormente, identifica qualquer desvio como uma possível anomalia. Os dados gerados são integrados on algoritmo de priorização, que determina a sequência ideal de intervenções, com base em múltiplos critérios.

Figura 8. Abordagem proposta em três etapas baseada em IA



Fonte: Adaptado de Consilvio *et al.* (2024)

O sistema alcançou uma taxa de acerto de 75% na detecção de falhas e aproximadamente 54% das intervenções corretivas (que causam indisponibilidade) teriam sido evitadas com a adoção antecipada da manutenção preditiva sugerida pelo modelo. A inclusão da previsão de fluxo de passageiros contribuiu para uma redução de cerca de 37% no número de usuários impactados por interrupções no serviço, evidenciando o potencial da abordagem orientada ao usuário para aprimorar a qualidade operacional.

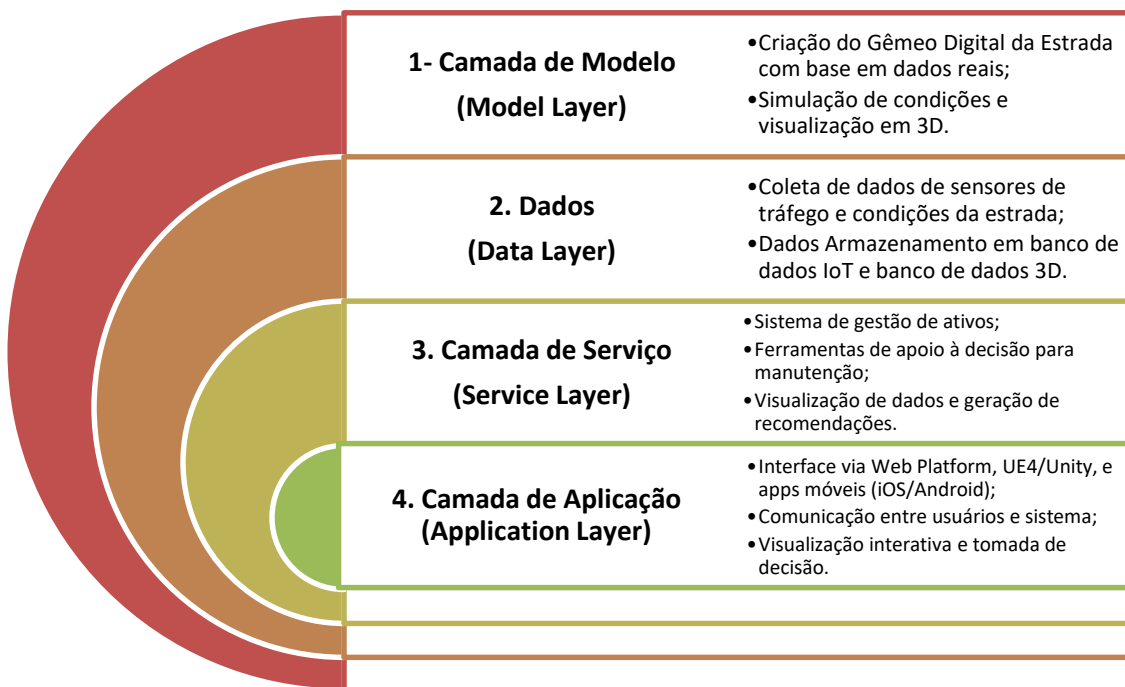
O estudo apresenta oportunidades de melhoria, especialmente no que diz respeito a consideração das intervenções de manutenção corretivas. Apesar de ser uma metodologia de manutenção essencialmente reativa, conforme criticado por Viana (2024), o objetivo principal é restaurar a funcionalidade do sistema e essa condição foi pouco explorada no estudo. Embora os autores reconheçam essa limitação, e indiquem que tais intervenções poderiam ser incorporadas à lista de priorização, essa exclusão compromete a abrangência da abordagem.

Além disso, o foco do estudo está restrito à estimativa de ações necessárias dentro de um horizonte temporal semanal, o que reduz sua aplicabilidade em contextos de planejamento estratégico de longo prazo e na gestão completa dos ciclos de vida dos ativos. Esse estudo

explorou pouco a reprodutibilidade dos sistemas conforme já inicialmente apontado por Idowu *et al.* (2022) como uma das principais falhas durante a criação de projetos de IA.

O terceiro artigo, de Consilvio *et al.* (2022) apresenta um sistema inteligente de apoio à decisão para manutenção rodoviária, baseado na tecnologia de *Digital Twin* (DT) com capacidade de atualização contínua do modelo em tempo real. O objetivo principal é integrar dados de diferentes fontes - como sensores, imagens, registros históricos e inspeções manuais - para criar uma réplica digital dos ativos físicos da estrada. Essa réplica permite simular, monitorar e prever o estado das infraestruturas, transformando dados brutos em informações estratégicas, de forma similar ao artigo de Spallarossa e Bonicelli (2024). A arquitetura proposta é composta por quatro camadas: física, banco de dados, servidor e aplicação. Ela utiliza técnicas de IA e visão computacional para analisar a condição dos pavimentos e sugerir planos de manutenção otimizados.

Figura 9: Camadas do Sistema de Gêmeo Digital



Fonte: Adaptado de Consilvio *et al.* (2022)

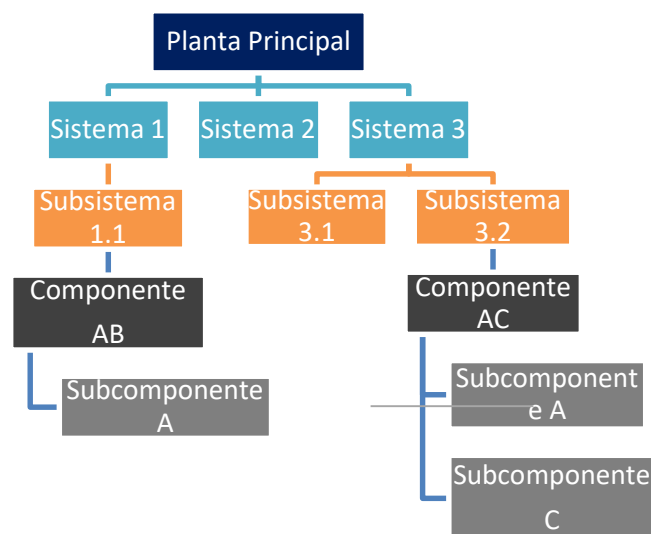
Os resultados demonstraram ganhos significativos: redução de 10% no volume de grandes intervenções, 12% nos custos de manutenção, e aumento de 15% na disponibilidade da infraestrutura, resultando em menos interrupções no tráfego. Adicionalmente, observou-se uma redução de 20% no Índice de Risco Rodoviário (RHI), indicando maior segurança para os usuários. O estudo reforça, assim, mais o potencial dos *Digital Twins* como ferramentas

estratégicas para transformar a gestão de ativos rodoviários.

O segundo, terceiro e quarto artigos, Consilvio *et al.* (2020), revelam a evolução e a aplicabilidade de IA em infraestruturas de ferrovias e vias. Cronologicamente, o quarto artigo sendo o mais antigo, estabelece a base conceitual para estruturar o trabalho do segundo e terceiro artigo. Basicamente o artigo 2 traz a priorização orientada ao usuário, o artigo 3 apresenta uma infraestrutura digital e sensorial - DT e o quarto propõe uma ideia genérica para sistemas de apoio à decisão (DSS - *Decision Support System*) voltado à gestão de ativos ferroviários e viários, desenvolvido no âmbito do projeto europeu In2Smart.

Esse projeto europeu é voltado para a modernização da manutenção de ativos ferroviários em 2020. Nesse estudo, foi realizada a análise dos dados dos subsistemas, considerando variáveis como tempo médio entre falhas (MTBF), custo de manutenção e frequência de falhas. Além disso, os ativos foram agrupados em diferentes níveis, representados por cores distintas, conforme ilustra Figura 10.

Figura 10. Hierarquia de uma rede bayesiana com as interdependências entre os subsistemas 1.1 e 3.2



Fonte: Autor (2025)

Essa rede de interdependências calcula as probabilidades condicionais de falha para cada nível, com base nas suas conexões, as ligações representam os subsistemas que dependem dos componentes anteriores e a confiabilidade de todo o sistema avaliada com base na probabilidade conjunta de falha dos componentes.

Essa visualização permite identificar padrões de comportamento entre os subsistemas e facilita a priorização de ações de manutenção. Os resultados indicaram uma taxa de antecipação de falhas de 80%, redução de 15% no risco de interrupções no serviço e ganhos

significativos na alocação de recursos e na eficiência das manutenções. O sistema mostrou adaptável a cenários incertos e eficaz no suporte à tomada de decisão em tempo real.

Todos os três artigos compartilham objetivos comuns: redução de custos, melhoria na disponibilidade dos ativos, previsão de falhas e suporte à decisão baseado em dados. Ambos os artigos 3 e 4 não abordam sobre o nível de treinamento necessário para que os técnicos usem as interfaces HMI (Interface Homem-Máquina) e os DSS de forma eficaz na prática diária. Um dos principais pilares como observado no artigo 1 é a participação ativa do ser humano no processo de decisão das manutenções. Um dos cenários não explorados nos modelos matemáticos é a escassez de mão de obra o que representaria um desafio prático de gestão de ativos. Além disso, os artigos 3 e 4 não quantificam o custo de investimento inicial da solução de IA (sensores, licenciamento de software) versus os benefícios de economia bem como não apresenta um modelo financeiro para validar a transição da manutenção preventiva para a preditiva baseada em IA.

O artigo 5, de Scaife (2024), aproxima-se do artigo 4 devido ao viés teórico e metodológico da aplicação da IA na manutenção preditiva em instalações prediais, no entanto o artigo não apresenta um estudo de caso único, mas sim analisa diversos trabalhos acadêmicos e técnicos publicados anteriormente, com o objetivo de identificar padrões, tecnologias utilizadas e impactos da IA em instalações civis. O artigo 6 analisa métodos de manutenção preditiva em tubulações de sistemas de aquecimento distrital (District Heating, DH), a pesquisa detalha os principais componentes das tubulações (aço, poliuretano e polietileno) e os modelos de envelhecimento matemáticos associados a cada material.

O artigo 6, de Langroudi e Weidlich (2020), evidencia a escassez de dados históricos, sendo necessário combinar modelos estatísticos baseados em dados climáticos e operacionais para enriquecer os conjuntos de dados e melhorar a acurácia das previsões. Apesar de ser interessante realizar a previsão da vida útil remanescente dos tubos de DH o autor afirma que não há uma resposta direta para o processo de envelhecimento dos tubos de DH, sendo necessário o uso combinado de métodos. Uma única abordagem de ML não é suficiente para lidar com um sistema tão complexo, sendo necessários múltiplos modelos de classificação e regressão.

Por fim, o artigo 6 evidencia que não existe um protocolo universal para que concessionárias e proprietários de ativos registrem essas informações para estratégias de manutenção preditiva (PdM) em sistemas DH e sugere a criação de uma estrutura universal de dados para facilitar a adoção de modelos em diferentes redes de aquecimento. Ao mesmo tempo, infere-se que se o retorno financeiro ou operacional da IA for inferior ao custo de

desenvolvimento, treinamento e manutenção do sistema, é melhor optar por métodos tradicionais de manutenção.

O artigo 6 apresenta uma abordagem mais superficial em comparação aos demais estudos analisados, uma vez que os autores não implementam nem validam um modelo de IA em uma rede real de distribuição de calor (DH). Embora sugiram que RNA'S seriam as mais adequadas para esse tipo de aplicação, não são fornecidas métricas de desempenho, como acurácia ou precisão, que permitam avaliar a eficácia desses modelos no contexto específico dos dutos de DH. Ao contrário da tubulação do sistema de aquecimento distrital que geralmente fica instalada subterraneamente, as tubulações de dutos de petróleo e gás ficam em sua maioria acima do solo pela facilidade manutenção como evidenciado no último artigo selecionado de número 7.

O artigo 7, de Ravishankar *et al.* (2022) apresenta o sistema DARTS, uma solução integrada que combina drones e IA para inspeção automatizada de dutos de petróleo e gás. A metodologia envolve a coleta de vídeos e processamento por redes neurais profundas, especialmente o modelo DeepLabV3+ (desenvolvida pelo Google), adaptado para segmentar componentes específicos dos dutos. O sistema detecta defeitos como peças ausentes, desalinhamentos e corrosão, e classifica o estado dos dutos em três níveis: resiliente, em alerta e não resiliente conforme Quadro 1.

Quadro 1. Classificação de Resiliência baseado em DARTS

<b>Classificação de Resiliência</b>	<b>Tipo de Defeito</b>
<b>Resiliente</b>	Nenhum defeito identificado
<b>Alarming Resilient</b>	Deformações + sem desalinhamento crítico
<b>Não Resiliente</b>	Desalinhamento crítico
	Componentes ausentes
	Trincas (Cracks)
	Componentes quebrados

Fonte: Adaptado de Ravishankar *et al.* (2022)

Os resultados mostram que o DARTS supera limitações das inspeções visuais tradicionais (Precisão de: 99,20%), oferecendo maior precisão, agilidade e redução de custos operacionais. Apesar disso, o artigo reconhece desafios como a necessidade de re-treinamento dos modelos para diferentes estruturas, interferências climáticas e dificuldade na detecção de componentes pequenos. Ao mesmo tempo os autores planejam aprimorar o sistema com drones mais avançados e bases de dados reais para ampliar sua aplicação na indústria.


É importante ressaltar que o estudo não foi aplicado a uma rede de oleoduto ou

gasoduto real e extensa. As dificuldades do modelo encontrados em laboratório tendem ser menores pois na prática, o modelo de IA e o drone precisam lidar com poeira, vegetação, reflexos de luz, pássaros e outras condições climáticas e ambientais dinâmicas que podem reduzir drasticamente a precisão da segmentação de imagens.

O artigo 8, de Alabdullh *et al.* (2024) aborda sobre um modelo de IA aplicada em um dos principais equipamentos nas grandes indústrias, os transformadores de potência. São considerados, os ativos mais caros e críticos para as empresas de geração, transmissão e distribuição de energia. Como observado as falhas em transformadores podem ser complexas e são geralmente divididas em três categorias: elétricas, térmicas e mecânicas. As principais causas de falhas estão relacionadas a degradação do sistema de isolamento devido a fatores como tempo de uso, estresse térmico e elétrico. A manutenção preditiva, em especial a análise de gases dissolvidos (DGA) no óleo isolante é a principal ferramenta para detectar esses problemas antes que se transformem em falhas catastróficas.

O principal objetivo do artigo 8 é propor uma metodologia inovadora para prever a vida útil remanescente de transformadores de potência a óleo mineral, foi desenvolvido um índice de saúde “*Health Index*” conforme ilustrado na Figura 11. São utilizados os dados da DGA, qualidade do óleo, histórico de carga, condição das buchas, envelhecimento e outras observações físicas através de um modelo de *machine learning* que classifica os cinco tipos de defeitos e define a estratégia de manutenção mais apropriada para cada situação para otimizar os custos conforme evidenciado na Tabela 3.

Figura 11. Fatores utilizados para cálculo do índice de saúde do transformador



Fonte: Do Autor (2025)

Tabela 3. Índice de saúde e seus estados

Índice de Saúde	Estado	Vida Útil Estimada	Manutenção
85–100	Muito Bom	Taxa de envelhecimento normal	Operação normal
70–85	Bom	Taxa de envelhecimento acelerada	Manutenção leve
50–70	Regular	Taxa de envelhecimento excessiva	Manutenção pesada
30–50	Ruim	Alto risco	Reparo imediato

0–30	<b>Muito Ruim</b>	Fim da vida útil esperada	Substituição
------	-------------------	---------------------------	--------------

Fonte: Do Autor (2025)

Foram avaliados 5 transformadores distintos e a aplicação do modelo permitiu observar que a vida útil operacional dos transformadores pode aumentar em aproximadamente 20%, devido a detecção antecipada de falhas, possibilitando intervenções de manutenção mais oportunas e eficazes. Dependendo das condições de uso representa uma economia de 50 a 100 mil dólares por unidade. No entanto, o artigo não explora os custos envolvidos com a implementação da tecnologia como aquisição de sensores, infraestrutura de coleta e processamento de dados, treinamento de pessoal e integração com sistemas existentes. Essa omissão limita a avaliação da viabilidade econômica da solução, especialmente para empresas que operam com restrições orçamentárias ou em contextos de infraestrutura limitada.

O artigo número 9, de Shim *et al.* (2022) aborda sobre a implementação da solução de “Água Inteligente” GSWaterS em Araçatuba, no estado de São Paulo. Possui como objetivo principal reduzir as perdas de água através da integração com os sistemas existentes “SCADA e GIS”, e a criação de novas zonas de medição distrital (DMAs) equipadas com sensores de fluxo e pressão. Essa iniciativa está alinhada diretamente com o Objetivo de Desenvolvimento Sustentável 6 (ODS 6) da Agenda 2030 da ONU, que visa “assegurar a disponibilidade e gestão sustentável da água e saneamento para todas e todos” conforme abordado por Schoormann *et al.* (2023). Através da leitura dos sensores de fluxo e de pressão é possível identificar o volume de água que entra e sai de cada área mapeada bem como a detecção das flutuações de pressão na rede de distribuição de água.

O sucesso na redução em aproximadamente 50% das perdas de água (de 38% para 17%) foi demonstrado em uma área específica e limitada, na região de Jussara. O estudo não valida a aplicação da solução em toda a rede de Aracatuba, nem em outras cidades com diferentes topografias, densidades populacionais ou idades de infraestrutura. Além disso, aborda superficialmente sobre a manutenção preditiva, focando-se na detecção de anomalias existentes para permitir a correção rápida e proativa, mas não aprofunda na previsão de falhas futuras. O Quadro 2 é possível avaliar o resumo dos principais resultados em cada estudo.

Quadro 2. Contexto estratégico, tecnologia aplicada e resultados dos artigos mapeados

Nº Artigo	Contexto estratégico ou Setor	Técnicas aplicadas ou mencionadas	Principais resultados alcançados (quantitativos e qualitativos)
-----------	-------------------------------	-----------------------------------	---

1	Pandemias	<i>Trust-Based Behaviour Knowledge</i> para combinar dados técnicos e conhecimento tácito	Acurácia preditiva de 82%
2	Ferrovário	<i>Machine Learning</i> para detecção de anomalias e classificação	Taxa de acerto de 75% na detecção de falhas; 54% das indisponibilidades poderiam ter sido evitadas com a adoção do modelo; Redução de cerca de 37% no número de usuários impactados por interrupções .
3	Rodoviário	<i>Clustering (K-means)</i> para agrupamento de trechos críticos.	Redução de 10% no volume de grandes intervenções, 20% do risco rodoviário e 12% nos custos de manutenção; Aumento de 15% na disponibilidade.
4	Ferrovário e Rodoviário	<i>Machine Learning</i> para detecção de anomalias e classificação. Simulações (Monte Carlo)	Precisão na detecção de anomalias: 67% Taxa de antecipação de falhas: 80% Tempo médio entre detecção e falha: 3,5 dias
5	Instalações prediais	<i>Machine Learning</i> para detecção de anomalias e classificação Redes Neurais Artificiais	Implementar IA gradualmente: em áreas específicas antes de expandir para todos os ativos; Necessidade de estabelecer uma governança estratégica para apoiar a implementação da IA com os riscos, competências e metas mapeados.
6	Redes de aquecimento	<i>Clustering (K-means)</i> para agrupamento de trechos críticos. Redes Neurais Artificiais Deep Learning	Torna-se necessário combinar modelos estatísticos da condição do ambiente bem como modelos que estimam a vida útil dos materiais para maior acuracidade. A falta de dados históricos limita a aplicação dos modelos preditivos.
7	Óleo e gás	Segmentação de imagens para previsão; <i>Deep Learning</i> Simulações (Monte Carlo)	Acurácia de segmentação ( <i>DeepLab</i> ) 99,2%

8	Subestações de Energia	<i>Machine Learning</i> para detecção de anomalias e classificação	Precisões de até 99,2% Prolongar a vida útil dos transformadores em 20%
9	Sistema de Abastecimento de Água	Modelo de <i>machine learning</i> aplicado em séries temporais.	Reduzida a perda de água de 37,8% para 16,5%; Taxa de erro global de cerca de 10%

Fonte: Autor (2025).

#### 4.5 Análise crítica do cenário atual

Através da análise das bases teóricas, dos dados bibliométricos com relação aos anos de publicação, os principais journals, os mapas de densidade, as palavras-chaves mais frequentes e da seleção de nove artigos para aprofundamento das análises da aplicabilidade da IA foram identificados pontos relevantes e lacunas no campo de estudo.

A sustentabilidade ambiental nos estudos avaliados é tratada como consequência da aplicação dos modelos de IA e não como um problema inicial a ser resolvido no contexto da gestão de ativos. No artigo 3 por exemplo, de Alice (2022) o cálculo do momento “ótimo” para realizar a manutenção do asfalto irá contribuir para reduzir o desperdício de asfalto, bem como a redução do desperdício de água em linhas de abastecimento de água de Shim *et al.* (2022) promove a otimização dos recursos (ODS 12 da agenda 2030).

Os estudos selecionados possuem forte convergência em torno dos pilares da gestão de ativos como: performance, custos, e riscos, conforme estabelece a norma ISO 55000, (Abraman, 2011). Isso pode ser observado nos estudos de Consilvio (2020, 2024) ao reduzir a indisponibilidade de ferrovias em 54% e vias em 15% bem como no estudo de Alabdullh *et al.* (2024) ao prolongar a vida útil de transformadores em 20% e no estudo de Shim *et al.* (2022) ao reduzir pela metade o desperdício de água em sistemas de abastecimento. No entanto, não correlacionam a utilização da IA nas fases de aquisição, utilização e desativação dos ativos, apenas na manutenção dos mesmos.

O desenvolvimento de métricas para simular a vida útil dos ativos através da sua degradação em diversos cenários é importante, mas foi pouco explorada. Um dos artigos que preenchem essa lacuna é o estudo de Langroudi e Weidlich (2020), que aborda sobre métricas para estabelecer a vida útil de tubos de aquecimento distrital apenas de forma teórica. Já Spallarossa e Bonicelli (2024), realiza um estudo completo sobre a vida útil de pontes através de um modelo BIM, que vai de encontro com o cluster verde do mapa gerado do VosViwerer ao estabelecer correlação direta dos artigos selecionados com as práticas atuais na

infraestrutura.

Gardner e Dorling (1998) ilustra que dados de alta qualidade são a base para qualquer modelo preditivo. Ou seja, para criação dos modelos de IA é fundamental a construção de uma base de dados de forma estruturada com dados históricos suficientes para melhorias dos próprios modelos criados por IA. Devido ao baixo volume de dados e a necessidade de validar os modelos preditivos, os autores estudados utilizaram alguns métodos de validação como modelo MCMC para medir o nível de precisão de seus modelos. Nos estudos avaliados as taxas de acerto foram maiores que 67%. Isso pode ser observado no trabalho de Alabdullh *et al.* (2024) de 99,2%, no estudo de Shim *et al.* (2022) 90%, de Consilvio (2020, 2024) com 67%.

O estudo de Chen *et al.* (2021) já explora mais que os demais trabalhos sobre o tratamento de dados desbalanceados e a acurácia preditiva, atingida de 82% ao combinar dados técnicos com conhecimento tácito de especialistas especialmente em ambientes pandêmicos, onde há escassez de dados relevantes e confiáveis. Ao mesmo tempo esse autor vai de encontro com o conceito de “indústria 5.0”. Baseada em três pilares principais: centralidade no ser humano, resiliência e sustentabilidade, Rios (2024). Percebe-se a centralidade do ser humano ao incorporar a validação do modelo o conhecimento tácito de especialistas, a resiliência, ao avaliar um cenário pandêmico e a sustentabilidade organizacional e operacional ao reduzir desperdícios.

Outro aspecto pouco abordado nos artigos selecionados é junção entre a ética nos modelos de IA, proposto por Bostrom (2016) em seu estudo que explora o alinhamento de valores para criticar o: “Como programar sistemas inteligentes que são autônomos para tomar decisões que tenham objetivos alinhados com os nossos?”. No modelo proposto por Chen (2021) são discutidas formas de garantir que decisões automatizadas sejam validadas por humanos, o que é uma prática ética essencial em sistemas de IA, principalmente quando trata-se de sistemas autônomos que envolvem a segurança das pessoas.

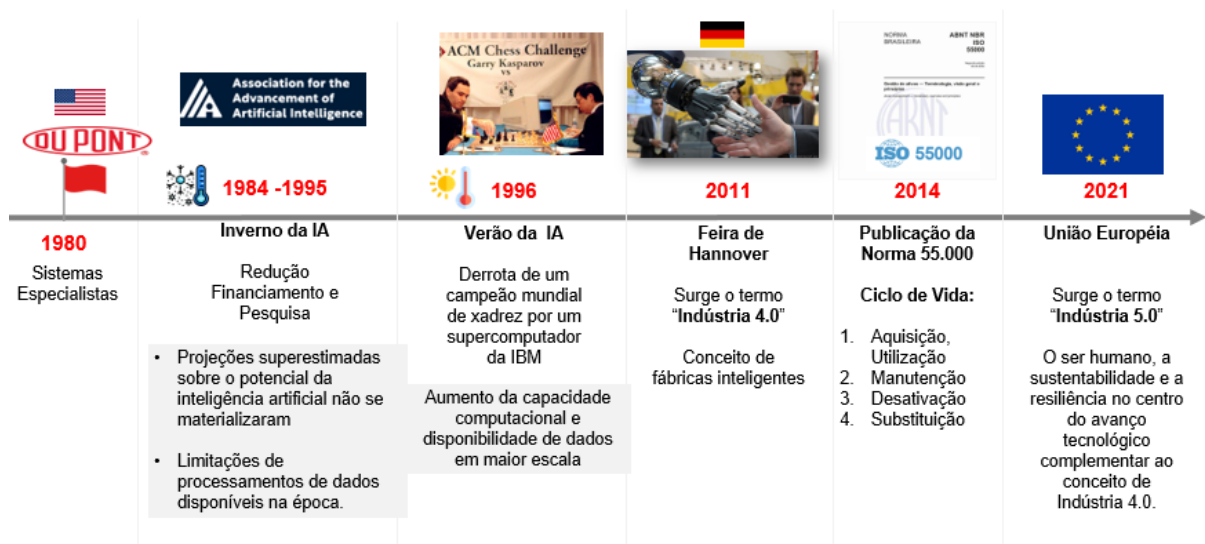
Embora os artigos trabalhem em torno da otimização dos processos de gestão de ativos a preocupação com a segurança cibernética, especialmente em sistemas ferroviários como no estudo de Consilvio (2024) deve ser tratada como um tema central. A crescente digitalização e integração de tecnologias como IoT, BIM e gêmeos digitais exigem atenção rigorosa à proteção de dados e à resiliência dos sistemas. Negligenciar aspectos como interoperabilidade e segurança compromete diretamente a confiabilidade das soluções, colocando em risco não apenas a integridade dos ativos, mas também a segurança das pessoas.

O vínculo dos projetos abordados com os requisitos mínimos estabelecidos pela ISO

55.000 que define os sistema de gestão de ativos poderia ser mais explorado bem como os softwares utilizados para implementação dos projetos de IA e sua escalabilidade para outros tipos de ativos. Para que uma indústria consiga gerenciar essas soluções tecnológicas, alcançar todos esses níveis elevados de maturidade depende fortemente de suas capacidades digitais organizacionais, de sua cultura e de seus objetivos estratégicos.

Diante de todo esse cenário evolutivo da aplicação da IA, “o inverno de IA” está cada vez mais distante como observado em 1984 pela Figura 12. Através de inovações responsáveis e éticas, alinhadas com o desenvolvimento sustentável não teremos um inverno de IA em breve. Possivelmente precisaremos cada vez mais da IA para apoiar na construção de modelos voltados para uma economia circular regenerativa, em que os recursos são reaproveitados, restaurados e reintegrados ao ciclo produtivo com inteligência. Dessa maneira, a Indústria 6.0 e a gestão de ativos, estará cada vez mais alinhada por valores éticos, ambientais e sociais com sistemas capazes de aprender e adaptar de forma autônoma.

Figura 12. Breve Linha do Tempo



Fonte: Autor (2025).

#### 4.6 Desafios atuais, implicações teóricas e gerenciais

A adoção da IA na gestão de ativos enfrenta uma série de obstáculos relacionando a aspectos de segurança de dados, sustentabilidade ambiental, responsabilidade social e de reprodutibilidade em ambientes corporativos. A literatura selecionada concentra-se em mecanismos específicos focados no resultado que a IA irá gerar no final de cada análise, negligenciando abordagens organizacionais mais amplas e pertinentes no contexto da indústria 5.0: os aspectos ambientais e sociais.

Conforme apontado por Buczynski *et al.* (2021) e Tjebane e Musonda (2025), embora os avanços na aplicação da IA sejam notáveis, as soluções propostas permanecem, em sua maioria, restritas a contextos controlados, sem alcançar maturidade suficiente para implementação em cenários reais. Reforçando assim, a necessidade de estratégias que promovam maior integração entre universidades, centros de pesquisa e as empresas.

A dificuldade em selecionar artigos atuais que abordassem estudos de casos práticos na indústria e na infraestrutura revela a predominância do cunho exploratório dos trabalhos, com propostas conceituais. Uma das possíveis razões para essa limitação poderá estar associada a natureza relativamente recente da norma de gestão de ativos (foi lançada em 2014) e os conceitos de indústria 5.0, que foram estruturados em 2011. Além disso, essa escassez, poderá também estar associada a existência de segredos industriais, vinculados entre empresas e *statups* protegidos por contratos de confidencialidade, o que restringe a divulgação de informações no meio acadêmico.

Para avançar na implementação desses sistemas, torna-se essencial fortalecer a interface entre as universidades com os setores corporativos, por meio de estratégias que promovam a capacitação de jovens estudantes com a força de trabalho das empresas com seus conhecimentos técnicos e tácitos. Um dos desafios para reduzir esse distanciamento são as políticas robustas que as empresas possuem em disponibilizar seus dados, que em sua maioria são classificados como confidenciais. A falta de alinhamento entre os objetivos práticos do setor produtivo e o foco acadêmico em pesquisas teóricas e de longo prazo propiciam o distanciamento entre universidades e empresas. Enquanto as empresas buscam soluções ágeis e aplicáveis, as universidades enfrentam limitações de acesso a dados reais (base para construção de modelos), além de barreiras burocráticas para estabelecer parcerias.

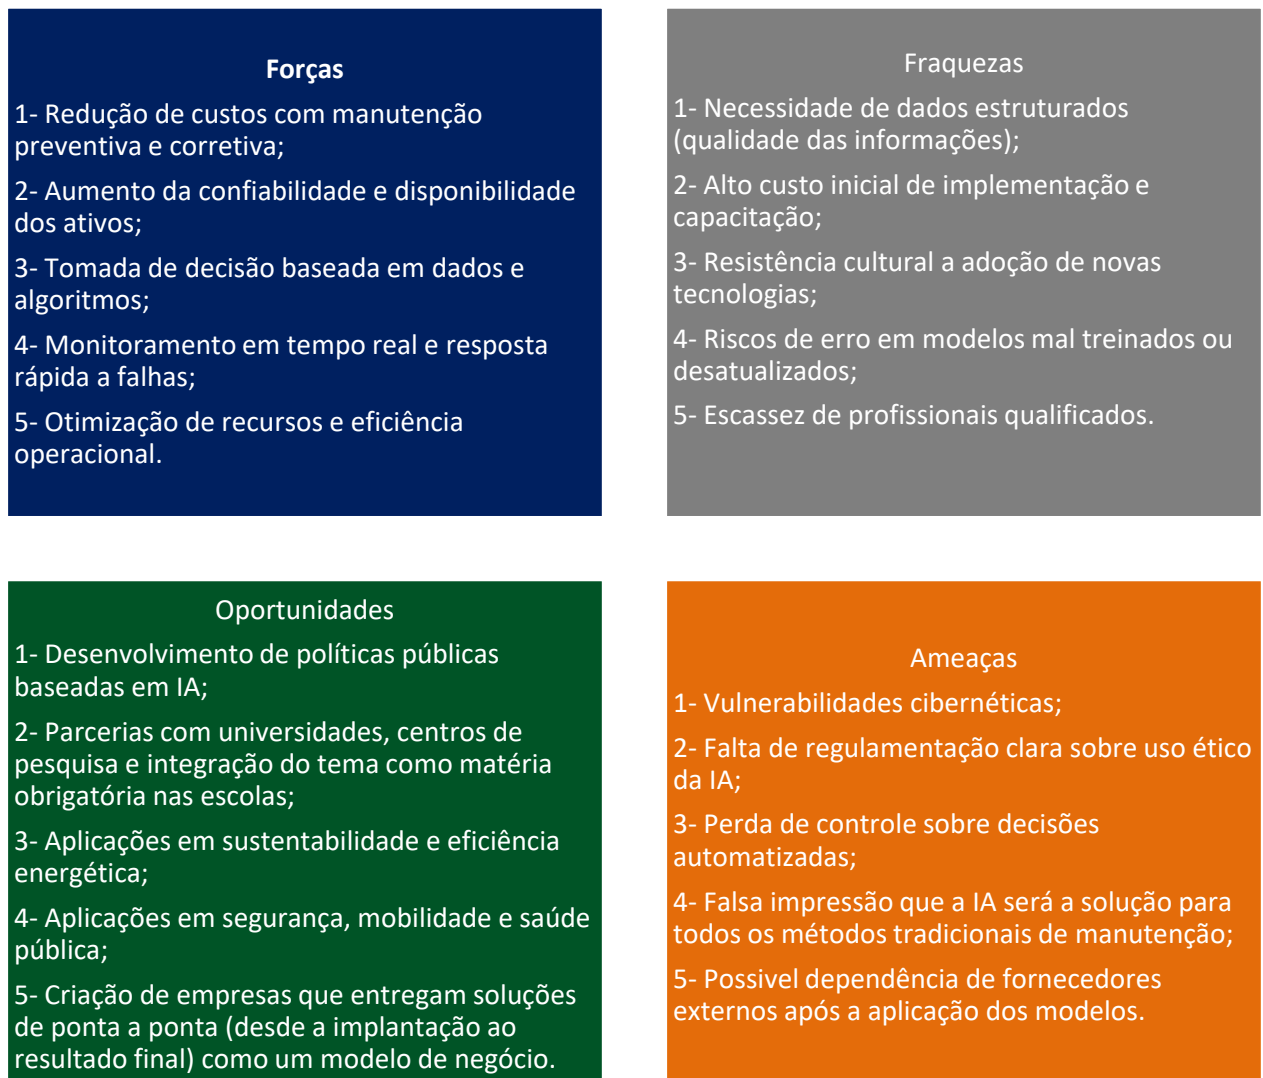
Apesar da menção sobre a redução de custos utilizando a IA, os artigos não aprofundam sobre o retorno sobre o investimento (ROI) para a implementação das tecnologias propostas. Os artigos mencionam de forma superficial os altos custos de implementação e manutenção de novos sistemas como um desafio, mas não fornecem estrutura robusta para justificar o investimento inicial em hardware (sensores) e software (plataformas de IA) para os gestores de ativos.

A expertise humana e os fatores socioéticos desempenham um papel crucial na adoção bem-sucedida dos modelos de IA. A confiança nos sistemas e o desenvolvimento de habilidades técnicas são essenciais para equilibrar a interação entre humanos e máquinas. A melhoria dos fluxos de trabalho de manutenção pode ser alcançada por meio de *feedback* humano contínuo e integrado em ambientes de co-decisão.

Outro aspecto também pouco abordado nos estudos é a integração dos modelos de IA com métricas de sustentabilidade, como consumo de energia e impactos ao longo do ciclo de vida dos ativos. Não foi observado uma discussão sobre como as novas metodologias avançam com o atual sistema de gestão de ativos sob a ótica da norma ISO 55.000, que define os requisitos mínimos para um sistema de gestão de ativos.

No decorrer desse trabalho, foi possível evidenciar o quanto a IA contribui para a antecipação de falhas, otimização de processos, confiabilidade e sustentabilidade. No entanto, sua implementação apresenta desafios que vão desde os financeiros até os de base educacional e ética que precisam ser superados com planejamento estratégico. Para consolidar essa reflexão, a Figura 13 a seguir representa uma matriz SWOT que sintetiza os principais aspectos observados.

Figura 13. Matriz SWOT da aplicação da IA na gestão dos ativos



## 5 CONSIDERAÇÕES FINAIS

Este estudo conduz uma RSL com o objetivo de investigar o uso da IA como ferramenta aplicada à manutenção e à gestão de ativos. A análise permitiu extrair dados relevantes e evidências práticas, métodos utilizados e lacunas existentes no estado atual da produção científica sobre o tema. Os resultados desta pesquisa reafirmam o papel da IA como ferramenta integradora e essencial na gestão de ativos, embora tenham sido identificados poucos estudos de casos com validação empírica e aplicações focadas em sustentabilidade.

Evidencia-se que as organizações que adotam e desenvolvem soluções de IA como diferencial em sua gestão estratégica, tendem a alcançar resultados otimizados no aproveitamento das horas de trabalho, aumento da disponibilidade dos ativos, redução significativa de custos e maior capacidade de tomada de decisão baseada em dados.

É importante observar que, em cenários de crise, o uso da IA representa um diferencial estratégico crucial para a sobrevivência de pequenas e médias empresas, especialmente aquelas com baixo capital de giro. A capacidade de automatizar processos, prever falhas e otimizar recursos torna-se ainda mais valiosa quando os há desafios financeiros e a margem para erro é mínima.

Ao mesmo tempo, é fundamental reconhecer que o ser humano desempenha um papel central na construção dos modelos, na interpretação dos dados e na incorporação do conhecimento tácito. Portanto, a colaboração entre pessoas e tecnologia é o meio que realmente potencializa os resultados e garante a efetividade das soluções de IA.

Embora esta pesquisa tenha seguido uma abordagem abrangente é importante reconhecer as limitações inerentes a cada etapa metodológica. A revisão sistemática concentrou-se exclusivamente na base Scopus, o que restringiu a possibilidade de acessar publicações relevantes não indexadas nessa plataforma. A China por exemplo, possui grande volume de produção de patentes e publicações científicas em cidades inteligentes e vigilância em suas bases de dados como CNKI (China National Knowledge Infrastructure). No entanto, a predominância de conteúdo em mandarim, impôs limitações de compreensão da língua, dificultando a inclusão e a interpretação adequada desses estudos.

Assim, torna-se essencial a formulação de políticas públicas e a oferta de incentivos governamentais que viabilizem e democratizem de forma ética e equitativa, o acesso à IA sob a ótica da indústria 5.0, promovendo a adoção responsável dessa tecnologia em todos os segmentos industriais e de infraestrutura. Nesse contexto, recomenda-se o desenvolvimento de trabalhos inovadores que explorem:

- I. Soluções de IA voltadas à sustentabilidade, como algoritmos que priorizam decisões com menor impacto ambiental e maior eficiência energética;
- II. Modelos de IA aplicados à manutenção preditiva, com foco em confiabilidade das decisões automatizadas, visando a segurança dos usuários;
- III. Aplicações em ativos urbanos inteligentes, como redes de água, energia e transporte, com foco em resposta adaptativa atuando na prevenção e na antecipação de falhas;
- IV. Plataformas colaborativas de IA, que integrem conhecimento humano e aprendizado de máquina para decisões mais contextualizadas e éticas.

Essas abordagens podem preencher lacunas identificadas na literatura e contribuir para uma gestão de ativos mais inteligente, sustentável e alinhada aos princípios da Indústria 6.0.

## REFERÊNCIAS

ABNT – Associação Brasileira de Normas Técnicas. **NBR 5462 - Confiabilidade e manutenibilidade.** Rio de Janeiro: ABNT, 1994. Disponível em: <https://ufsb.edu.br/propa/images/dinfra/coman/Legisla%C3%A7%C3%B5es/NBR-5462.pdf>

Abraman - Associação Brasileira de Manutenção e Gestão de Ativos. **PAS 55:2008: Gestão de Ativos.** Rio de Janeiro: Qualitymark, 2011. Disponível em: <https://pt.scribd.com/document/673969527/PAS-55-2008-Gestao-de-Ativos>

Adobe, **Artificial Intelligence & Machine Learning.** Adobe Research, 2025. Disponível em: <https://business.adobe.com/br/products/real-time-customer-data-platform/ai-vs-machine-learning.html>

Alabdullh M.K.K.; Joorabian, M.; Seifossadat, S.G.; Saniei, M.; Abasi, M. A novel method to estimate the lifetime of mineral oil-type power transformers based on the analysis of chemical and physical indicators using artificial intelligence. **Heliyon**, v. 10, n. 22, e40447, 2024. <https://doi.org/10.1016/j.heliyon.2024.e40447>

Bhandari *et al.* An Implementation of an Industrial Internet of Things on an SMT Assembly Line. **2020 International Conference on COMMunication Systems & NETWORKS (COMSNETS)**, Bengaluru, India, 2020, pp. 688-690, DOI: <https://doi.org/10.1109/COMSNETS48256.2020.9027475>

Bostrom, N.; **Superintelligence: Paths, Dangers, Strategies.** Oxford: Oxford University Press, 2016.

Buczynski, W., Cuzzolin, F.; Sahakian, B.; A review of machine learning experiments in equity investment decision-making: why most published research findings fail to translate into practice. **International Journal of Data Science and Analytics**, v. 11, pp. 221-242, 2021. <https://doi.org/10.1007/s41060-021-00245-5>

Cafferata, P.; Dias, Y.B. **65% das empresas usam Gen AI no mundo; líderes apontam caminhos para obter retorno financeiro.** McKinsey & Company, 17 jul. 2024. Disponível

em: <https://www.mckinsey.com.br/our-insights/all-insights/65-das-empresas-usam-gen-ai-no-mundo>

Campbell, M.; Hoane Jr., A.J.; Hsu F.; Deep Blue. **Artificial Intelligence**, v. 134, n. 1-2, pp. 57-83, 2002. DOI: [https://doi.org/10.1016/S0004-3702\(01\)00129-1](https://doi.org/10.1016/S0004-3702(01)00129-1)

Chen, J.; Lim, C. P.; Tan, K. H.; Govindan, K.; Kumar, A. Artificial intelligence-based human-centric decision support framework: an application to predictive maintenance in asset management under pandemic environments. **Annals of Operations Research**, v. 350, pp. 493-516, 2021. <https://doi.org/10.1007/s10479-021-04373-w>

Consilvio, A.; Vignola, G.; Arévalo, P. L.; Gallo, F.; Borinato, M.; *et al.* A data-driven prioritisation framework to mitigate maintenance impact on passengers during metro line operation. **European Transport Research Review**, v. 16, 6, 2024. DOI: <https://doi.org/10.1186/s12544-023-00631-z>

Consilvio A.; Hernández J. S.; Chen W.; Brilakis I.; Bartoccini L.; *et al.* Towards a digital twin-based intelligent decision support for road maintenance. **Transportation Research Procedia**, v. 69, pp. 791-798 2023. DOI: <https://doi.org/10.1016/j.trpro.2023.02.237>

Consilvio A.; Solís-Hernández, J.; Jiménez-Redondo, N.; Sanetti, P.; Papa, F.; *et al.* On applying machine learning and simulative approaches to railway asset management: the earthworks and track circuits case studies. **Sustainability**, v. 12, n. 6, 2544, 2020. DOI: <https://doi.org/10.3390/su12062544>

Consilvio, A. **Perfil acadêmico. Google Scholar.** Disponível em: <https://scholar.google.com/citations?user=1eQLjDcAAAAJ&hl=en>. Acesso em: 20 ago. 2025.

Costa, D., Silva, G.J.C., Assunção, M.A. Scopus vs. Web of Science: uma avaliação comparativa das principais bases de dados para a pesquisa acadêmica. **Cadernos do FNDE**, v. 4, n. 9, 2023. DOI: <https://doi.org/10.5281/zenodo.10777653>

Duan, Y.; Edwards, J.S.; Dwivedi, Y.K. Artificial intelligence for decision making in the era of Big Data – evolution, challenges and research agenda. **International Journal of Information**

**Management**, v. 48, p. 63-71, 2019. DOI: <https://doi.org/10.1016/j.ijinfomgt.2019.01.021>

Edgar, T.W.; Manz, D.O. **Exploratory study In: ScienceDirect Topics**. Elsevier, 2017. Disponível em: <https://www.sciencedirect.com/topics/computer-science/exploratory-study>

Fjelland R. Why general artificial intelligence will not be realized. **Humanities and Social Sciences Communications**, v. 7, n. 1, 2020. DOI: <https://doi.org/10.1057/s41599-020-0494-4>

Gardner, M.W.; Dorling, S.R. Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. **Atmospheric Environment**, v. 32, n. 14–15, pp. 2627–2636, 1998. DOI: [https://doi.org/10.1016/S1352-2310\(97\)00447-0](https://doi.org/10.1016/S1352-2310(97)00447-0)

Ghobakhloo, M.; The future of manufacturing industry: a strategic roadmap toward Industry 4.0. **Journal of Manufacturing Technology Management**, v. 29, n. 6, p. 910–936, 2018. DOI: <https://doi.org/10.1108/JMTM-02-2018-0057>

Goodfellow, I.; Bengio, Y.; Courville, A. **Deep learning**. Cambridge: MIT Press, 2016. Disponível em: <https://www.deeplearningbook.org/>

Gulati, R. **Maintenance and Reability, Best Practices**. New York: Industrial Press, 2009.

Idowu, S.; Strüber, D.; Berger, T. Asset Management in Machine Learning: State-of-research and State-of-practice. **ACM Computing Surveys**, v. 55, 144, 2022. DOI: <https://dl.acm.org/doi/10.1145/3543847>

ISO - Internacional Organization for Standardization. ISO 55000:2014 – **Asset management – Overview, principles and terminology**. Geneva: ISO, 2014. Disponível em: <https://www.iso.org/obp/ui/#iso:std:iso:55000:ed-1:v2:en>

Kardec, A.; Nascif, J. **Manutenção: função estratégica**. Rio de Janeiro: QualityMark, 2012.

Kaur A.; Gulati S.; Sharma R.; Sinhababu A; Chakravarty R. Visual citation navigation of open education resources using Litmaps. **Library Hi Tech News**, v. 39, n. 5, p. 7–11, 2022. DOI: <https://doi.org/10.1108/LHTN-01-2022-0012>

Kitsios F.; Kamariotou M. Artificial intelligence and business strategy towards digital transformation: a research agenda. **Sustainability**, v. 13, n. 4, 2021. DOI: <https://doi.org/10.3390/su13042025>

Moher, D.; Liberati, A.; Tetzlaff, J.; Altman, D.G. PRISMA Group. Preferred Reporting Items for Systematic Reviews and Meta-Analyses: The PRISMA Statement. **PLOS Medicine**, v. 6, n. 7, e1000097, 2009. DOI: <https://doi.org/10.1371/journal.pmed.1000097>

Narain, K.; Swami A.; Srivastava A.; Swami S. Evolution and control of artificial superintelligence (ASI): a management perspective. **Journal of Advances in Management Research**, v. 16, n. 5, p. 698-714, 2019. <https://doi.org/10.1108/JAMR-01-2019-0006>

Oliveira, D.; Bicalho, A.; **Digitalização transforma a gestão de ativos e eleva a competitividade industrial.** Falconi Consultoria, 2025. Disponível em: <https://falconi.com/insight/digitalizacao-transforma-a-gestao-de-ativos-e-eleva-a-competitividade-industrial/>

Orošnjak, M.; Saretky, F.; Kedziora, S.; Prescriptive maintenance: a systematic literature review and exploratory meta-synthesis. **Applied Sciences**, v. 15, n. 15, 8507, 2025. <https://doi.org/10.3390/app15158507>

Panetta, K. **Gartner Top 10 Strategic Technology Trends for 2018**, 03 de Outubro de 2017. Disponível em: <https://www.gartner.com/smarterwithgartner/gartner-top-10-strategic-technology-trends-for-2018>

Page M.J.; McKenzie, J.E.; Bossuyt, P.M.; Boutron, I.; Hoffmann, T.C.; Mulrow, C. D., *et al.* (2021). The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. **BMJ**, 372, n71. DOI: <https://doi.org/10.1136/bmj.n71>

Langroudi, P. P.; Weidlich, I. Applicable predictive maintenance diagnosis methods in service-life prediction of district heating pipes. **Environmental and Climate Technologies**, v. 24, n. 3, pp. 294-304, 2020. <https://doi.org/10.2478/rtuect-2020-0104>

Ravishankar, P.; Hwang, S; Zhang J., Khalilullah I. X.; Eren-Tokgoz B.; DARTS - drone and artificial intelligence reconsolidated technological solution for increasing the oil and gas pipeline resilience. **International Journal of Disaster Risk Science**, v. 13, pp. 810–821, 2022. DOI: <https://doi.org/10.1007/s13753-022-00439-w>

Rios, A.J.; Petrou, L.M.; Ramirez, R.; Plevriz, V.; Nogal, M. Industry 5.0 concepts and enabling technologies, towards an enhanced conservation practice: systematic literature review protocol. **Open Research Europe**, v. 4, 75, 2024. DOI: <https://doi.org/10.12688/openreseurope.17505.1>

Russell, S.; Norvig, P. **Inteligência artificial: A modern approach**. 3. ed. São Paulo: Pearson Prentice Hall, 2022. Disponível em: [http://lib.ysu.am/disciplines\\_bk/efdd4d1d4c2087fe1cbe03d9ced67f34.pdf](http://lib.ysu.am/disciplines_bk/efdd4d1d4c2087fe1cbe03d9ced67f34.pdf)

Scaife, A. D. Improve predictive maintenance through the application of artificial intelligence: A systematic review. **Results in Engineering**, v. 21, 101645, 2024. <https://doi.org/10.1016/j.rineng.2023.101645>

Schoormann T.; Strobel G.; Moller F.; Petrick D.; Zschech P; Artificial intelligence for sustainability - a systematic review of information systems literature. **Comunnications of the Association for Information Systems**, v. 52, n. 8, p. 199–237, 2023. DOI: <https://doi.org/10.17705/1CAIS.05209>

Sewald Junior, E.; Prazeres, R.; Borguezan, L.; Allesio, H.A. Inverno da Inteligência Artificial: uma análise sobre a viabilidade operacional e econômica sob ótica de investimento. **Navus**, v. 16, pp. 1-22, 2025 Disponível em: <https://navus.sc.senac.br/navus/article/download/2009/1205/12426>

Shim, K.; Berrettini, E.; Park, Y.-G.; Smart water solutions for the operation and management of a water supply system in Aracatuba, Brazil. **Water**, v. 14, n. 23, 3965, 2022. <https://doi.org/10.3390/w14233965>

Spallarossa, E.; Bonicelli, A.; Digital twin, BIM and asset management systems implementation. In: **Bridge Maintenance, Safety, Management, Digitalization and Sustainability**. [S. l.]: Taylor & Francis, 2024. p. 1845–1852. Disponível em:

<https://www.taylorfrancis.com/chapters/oa-edit/10.1201/9781003483755-216>

Standford University - Human-centered Artificial Intelligence. **The AI Index Report 2025**. Stanford: Stanford University, 2025. Disponível em: <https://hai.stanford.edu/ai-index/2025-ai-index-report>

Tavares, A. D.; Gomes. C.F.S. ISO 55000: The Evolution of Asset Management. **Business and Management Review**, v. 4, n. 8, pp. 97-103, 2015. Disponível em: <https://www.researchgate.net/publication/274698990>

Tjebane, M.M.; Musonda, I. Artificial intelligence in healthcare facilities asset information management: mixed review. **Infrastructure Asset Managemen**. v. 12, n. 2, p. 94–109, 2025. <https://doi.org/10.1680/jinam.23.00033>

Viana, H.R.G. **Curso de Gestão e Engenharia da manutenção**. Clube de Autores, 2024.

Wang, P. On defining artificial intelligence. **Journal of Artificial General Intelligence**, v. 10, n. 2, p. 1–37, 2019. DOI: <https://doi.org/10.2478/jagi-2019-0002>

Webnode; **Vantagens da inteligência artificial e por que você se deve entusiasmar com ela**. Webnode, 06 abr. 2023. Disponível em: <https://www.webnode.com/pt/blog/vantagens-da-inteligencia-artificial-e-por-que-voce-se-deve-entusiasmar-com-ela/>

Zampolli, M. **Gestão de ativos: guia para a aplicação da norma ABNT NBR ISO 55001 considerando as diretrizes da ISO 55002:2018**. 2019. International Copper Association Brazil. 2 ed. Disponível em: <https://ab cobre.org.br/wp-content/uploads/2021/06/gestao-de-ativos-guia-para-a-aplicacao-da-iso-55001.pdf>