

O papel da Inteligência Artificial na otimização da manutenção de frotas de caminhões para o transporte de madeira: uma RBS

The role of Artificial Intelligence in optimizing maintenance of truck fleets for timber transport: a case study

El papel de la Inteligencia Artificial en la optimización del mantenimiento de flotas de camiones para el transporte de madera: un estudio de caso

Thiago Barbosa Silva

Graduando em Engenharia de Produção

Instituição: Universidade Federal de Mato Grosso do Sul (UFMS)

Endereço: Três Lagoas - Mato Grosso do Sul, Brasil

E-mail: thiago_barbosa@ufms.br

Thiago Galbiati Lagoin

Doutor em Engenharia Mecânica

Instituição: Universidade Federal de Mato Grosso do Sul (UFMS)

Endereço: Três Lagoas - Mato Grosso do Sul, Brasil

E-mail: thiago.lagoin@ufms.br

Elizangela Veloso Saes

Doutora em Gestão de Operações

Instituição: Universidade Federal de Mato Grosso do Sul (UFMS)

Endereço: Três Lagoas - Mato Grosso do Sul, Brasil

E-mail: elizangela.saes@ufms.br

Rubens Ribeiro

Doutor em Engenharia Mecânica

Instituição: Universidade Federal de Mato Grosso do Sul (UFMS)

Endereço: Três Lagoas - Mato Grosso do Sul, Brasil

E-mail: rubens.ribeiro@ufms.br

Elida de Paula Moraes Corveloni

Doutora em Engenharia Química

Instituição: Universidade Federal de Mato Grosso do Sul (UFMS)

Endereço: Três Lagoas - Mato Grosso do Sul, Brasil

E-mail: elida.moraes@ufms.br

Sandra Cristina Marchiori de Brito

Doutora em Engenharia Elétrica

Instituição: Universidade Federal de Mato Grosso do Sul (UFMS)

Endereço: Três Lagoas - Mato Grosso do Sul, Brasil

E-mail: sandra.brito@ufms.br

RESUMO

Atualmente, a gestão de frotas para o transporte de madeira enfrenta desafios severos, como a operação em áreas remotas e a alta severidade do terreno, que limitam as abordagens tradicionais de manutenção. Este artigo apresenta uma Revisão Bibliográfica Sistemática (RBS) sobre como a Inteligência Artificial (IA) atua na otimização desses processos. A pesquisa foi realizada nas bases Scopus, IEEE Xplore e Web of Science, compreendendo o período de 2015 a 2025, resultando em um portfólio final de 31 artigos validados após a triagem de 258 registros brutos. Os resultados demonstram que técnicas de *Deep Learning*, como LSTM (*Long Short-Term Memory*) e CNN (*Convolutional Neural Networks*), são consideradas referências no prognóstico de Vida Útil Remanescente (RUL - *Remaining Useful Life*), apresentando acurácia superior a 95%. Evidencia-se que a integração de arquiteturas *Edge Computing* é fundamental para superar a baixa conectividade no setor florestal. Assim, foi possível verificar que a IA não apenas aumenta a disponibilidade da frota, mas configura-se como elemento estratégico para a redução de custos operacionais e o fortalecimento das práticas de *Environmental, Social, and Governance* (ESG) no setor.

Palavras-chave: manutenção, Inteligência Artificial, transporte florestal, engenharia de produção, Indústria 4.0.

ABSTRACT

Currently, fleet management for wood transport faces severe challenges, such as operations in remote areas and high terrain severity, which limit traditional maintenance approaches. This article presents a Systematic Literature Review (SLR) on how Artificial Intelligence (AI) acts in the optimization of these processes. The research was conducted across the Scopus, IEEE Xplore, and Web of Science databases, covering the period from 2015 to 2025, resulting in a final portfolio of 31 validated articles after screening 258 raw records. The results demonstrate that Deep Learning techniques, such as Long Short-Term Memory (LSTM) and Convolutional Neural Networks (CNN), are considered benchmarks in Remaining Useful Life (RUL) prognosis, showing accuracy levels exceeding 95%. It is evident that the integration of Edge Computing architectures is fundamental to overcoming low connectivity in the forestry sector. Thus, it was found that AI not only increases fleet availability but also serves as a strategic element for reducing operational costs and strengthening Environmental, Social, and Governance (ESG) practices in the industry.

Keywords: predictive maintenance, Artificial Intelligence, forestry transport, Industry 4.0, production engineering.

RESUMEN

En la actualidad, la gestión de flotas para el transporte de madera se enfrenta a graves retos, como la operación en zonas remotas y las duras condiciones del terreno, que limitan los enfoques tradicionales de mantenimiento. Este artículo presenta una revisión bibliográfica sistemática (RBS) sobre cómo la inteligencia artificial (IA) contribuye a la optimización de estos procesos. La investigación se llevó a cabo en las bases de datos Scopus, IEEE Xplore y Web of Science, abarcando el periodo de 2015 a 2025, lo que dio como resultado una selección final de 31 artículos validados tras la selección de 258 registros brutos. Los resultados demuestran que las técnicas de *Deep Learning*, como LSTM (*Long Short-Term Memory*) y CNN (*Convolutional Neural Networks*), se consideran referentes en la predicción de la Vida Útil Remanente (RUL -

Remaining Useful Life), con una precisión superior al 95 %. Se pone de manifiesto que la integración de arquitecturas de *Edge Computing* es fundamental para superar la escasa conectividad en el sector forestal. Así, se ha podido comprobar que la IA no solo aumenta la disponibilidad de la flota, sino que se configura como un elemento estratégico para la reducción de los costes operativos y el fortalecimiento de las prácticas de *Environmental, Social, and Governance* (ESG) en el sector.

Palabras clave: mantenimiento, Inteligencia Artificial, transporte forestal, ingeniería de producción, Industria 4.0.

1 INTRODUÇÃO

Na atual era da competitividade, a busca por excelência operacional tornou-se um requisito para a sobrevivência e o sucesso das organizações. A engenharia de produção, nesse contexto, foca na otimização de processos e na gestão eficiente de recursos para maximizar a produtividade e reduzir custos, sendo a administração da produção uma área de conhecimento central para alcançar tais objetivos (Slack *et al.*, 2018). Dentro deste escopo, a gestão da manutenção de ativos industriais evoluiu de uma função de suporte para um pilar estratégico. As abordagens tradicionais, contudo, apresentam limitações evidentes: a manutenção corretiva, por ser reativa, acarreta custos elevados de parada e reparos emergenciais, enquanto a manutenção preventiva, embora planejada, baseia-se em intervalos fixos que não refletem a condição real do equipamento, levando a intervenções prematuras ou tardias e, conseqüentemente, ao desperdício de recursos (Kardec; Nascif, 2009). Para superar essas deficiências, a Manutenção Preditiva (PdM), potencializada pela Inteligência Artificial (IA) no contexto da indústria 4.0, emerge como um paradigma transformador.

A literatura reporta um crescente número de aplicações bem-sucedidas da Manutenção Preditiva (PdM) em ambientes industriais; entretanto, a maioria desses casos ocorre em cenários de manufatura com condições operacionais controladas. Existe uma lacuna no entendimento da aplicação e dos desafios dessas tecnologias em frotas de ativos móveis, que operam em ambientes não-estruturados, dinâmicos e de alta severidade. O setor de base florestal no Brasil é um exemplo emblemático dessa realidade, em que a frota de caminhões para o transporte de madeira é um ativo crítico, cujo desempenho é diretamente afetado por uma gama de variáveis de difícil controle. Dentre essas variáveis, destaca-se as condições das

estradas (pavimentadas, não pavimentadas, com ou sem manutenção) que impactam diretamente nos custos e nos tempos operacionais. Alves *et al.* (2013) corroboraram essa afirmação ao verificarem um aumento significativo no tempo de ciclo e no custo por metro cúbico transportado em estradas de pior qualidade. Seus estudos indicam que uma falha em um veículo nessas condições não apenas representa o custo do reparo, mas o risco de uma interrupção em cascata na cadeia de suprimentos, afetando a produção da planta industrial e evidenciando a importância estratégica de garantir a máxima disponibilidade da frota.

Assim, este trabalho é norteado pela seguinte questão de pesquisa: Como a Inteligência Artificial pode ser aplicada para otimizar a manutenção de frotas de caminhões utilizadas no transporte de madeira, e quais são seus principais benefícios, técnicas e desafios de implementação. Neste contexto, o presente estudo, por meio de uma Revisão Bibliográfica

Sistemática (RBS), busca analisar e sintetizar o conhecimento científico acerca da aplicação da Inteligência Artificial como ferramenta para a otimização da manutenção de frotas de caminhões no desafiador cenário do transporte de madeira. Para tal, os objetivos específicos são: caracterizar as principais técnicas de IA utilizadas para diagnóstico e prognóstico de falhas; mapear os benefícios operacionais e econômicos reportados na literatura; e sintetizar os desafios técnicos e organizacionais que permeiam sua implementação.

Este artigo está organizado em cinco seções. A seção 2 apresenta o referencial teórico sobre gestão de manutenção, KPIs e o paradigma da Indústria 5.0 aplicado à manutenção inteligente. A seção 3 detalha a metodologia da RBS, as bases de dados e os critérios de seleção adotados. A seção 4 dedica-se à apresentação e discussão dos dados coletados. Por fim, a seção 5 traz as considerações finais e as conclusões do estudo.

2 REFERENCIAL TEÓRICO

2.1 O PROCESSO DE MANUTENÇÃO EM FROTAS DE CAMINHÕES

A gestão da manutenção é uma função estratégica que visa assegurar a máxima disponibilidade e confiabilidade dos ativos ao menor custo global, garantindo a segurança das operações (Kardec; Nascif, 2009). Inicialmente, a abordagem predominante era a Manutenção Corretiva, também conhecida na literatura como Manutenção Baseada na Falha (*Failure-*

Based Maintenance). Essa é uma estratégia reativa, em que a intervenção ocorre apenas após a quebra do equipamento, é apontada como a de custos mais elevados, principalmente devido às perdas de produção durante a parada inesperada do ativo (Al-Najjar; Alsyouf, 2003).

Como resposta a essa ineficiência, surgiu a Manutenção Preventiva, que baseia-se na premissa de que é mais econômico intervir de forma planejada para evitar a falha. Esta estratégia utiliza critérios de tempo ou de uso para programar inspeções e trocas de componentes (Slack *et al.*, 2018). A manutenção preventiva reduz as falhas inesperadas, mas possui ineficiências intrínsecas ao possibilitar a substituição de peças que ainda teriam uma vida útil considerável.

A busca por melhorias levou ao desenvolvimento da Manutenção Preditiva (PdM). Esta abordagem foca no monitoramento da condição real do equipamento para prever o momento exato da falha. O conceito é frequentemente associado à Curva P-F, que descreve o intervalo entre a detecção de uma falha potencial (Ponto P) e a sua ocorrência funcional (Ponto F). O objetivo da PdM é identificar o Ponto P o mais cedo possível, maximizando o intervalo P-F e permitindo o planejamento da intervenção (Moubray, 1997).

A PdM tem-se mostrado uma evolução em termos de estratégia de manutenção, no entanto, a escolha da estratégia de manutenção deve ser direcionada pelas especificidades de cada caso, podendo ser apoiada pela Reliability Centered Maintenance (RCM) (Moubray, 1997). A RCM é um processo estruturado utilizado para determinar o que deve ser feito para garantir que um ativo físico continue a fazer o que seus usuários desejam que ele faça em seu contexto operacional atual. Em vez de focar em preservar o ativo em si, a RCM foca em preservar a função do sistema. Para isso, realiza uma análise detalhada dos Modos de Falha e seus Efeitos (FMEA – *Failure Mode and Effects Analysis*) e da Análise dos Modos de Falha, seus Efeitos e Criticidade (FMECA – *Failure Mode, Effects and Criticality Analysis*), a RCM ajuda a decidir qual a tática de manutenção mais apropriada para cada componente: em alguns casos, a corretiva pode ser aceitável (para itens não críticos); em outros, a preventiva é ideal; e para componentes críticos cujas falhas são evidenciadas por degradação, a preditiva é a mais indicada (Moubray, 1997). A PdM com IA, pode ser a implementação tecnológica da filosofia RCM para os ativos mais importantes de uma frota.

2.1.1 Indicadores de desempenho em manutenção (KPIs)

Conforme defendem autores clássicos da manutenção estratégica como Kardec e Nascif (2009), a eficácia de qualquer estratégia, seja ela corretiva, preventiva ou preditiva, só pode ser gerenciada mensurando o seu desempenho. Para isso, a engenharia de manutenção utiliza um conjunto de Indicadores-Chave de Desempenho (KPIs) que quantificam a eficiência e a eficácia das intervenções. Dentre os mais importantes para a gestão de frotas, destacam-se:

- **MTBF** (*Mean Time Between Failures* - Tempo Médio Entre Falhas): Este indicador mede a confiabilidade de um ativo reparável. É calculado dividindo-se o tempo total de operação de um equipamento pelo número de falhas ocorridas nesse período (Kardec; Nascif, 2009). Um MTBF alto indica que o caminhão ou componente é confiável e falha com pouca frequência. O objetivo da manutenção preditiva é aumentar o MTBF ao antecipar e corrigir as falhas em seu estágio incipiente.
- **MTTR** (*Mean Time To Repair* - Tempo Médio Para Reparo): Este KPI mede a manutenibilidade de um ativo, ou seja, a rapidez com que ele pode ser reparado e devolvido à operação após uma falha. É calculado dividindo-se o tempo total gasto em reparos corretivos pelo número de intervenções (Kardec; Nascif, 2009). Um MTTR baixo é desejável. A IA contribui para a redução do MTTR ao fornecer diagnósticos precisos, permitindo que a equipe de manutenção saiba exatamente qual componente falhou e quais ferramentas e peças serão necessárias antes mesmo de iniciar o reparo.
- **Disponibilidade** (*Availability*): Frequentemente apontado como o indicador mais importante para a gestão de frotas, a disponibilidade representa a porcentagem de tempo em que o ativo está apto a operar. Derivada dos dois indicadores anteriores, a equação clássica é $\text{Disponibilidade} = \text{MTBF} / (\text{MTBF} + \text{MTTR})$. (Kardec; Nascif, 2009). Observa-se que a manutenção preditiva impacta positivamente a disponibilidade por duas vias: aumentando o MTBF (menos falhas) e reduzindo o MTTR (reparos mais rápidos).
- **OEE** (*Overall Equipment Effectiveness* - Eficácia Geral do Equipamento): Originário da filosofia de Manutenção Produtiva Total (TPM), o OEE é um indicador composto que se tornou um padrão global para medir a eficiência produtiva (Tsarouhas, 2020).

Embora mais comum na manufatura, o conceito de OEE pode ser adaptado para frotas. Ele combina três fatores: Disponibilidade, Performance (velocidade real de transporte vs. velocidade ideal) e Qualidade (percentual de entregas feitas sem problemas ou avarias na carga). A IA, ao garantir a saúde do ativo, impacta diretamente a disponibilidade e a performance, contribuindo para um OEE superior da frota.

2.2 O PARADIGMA DA INDÚSTRIA 5.0 E A MANUTENÇÃO INTELIGENTE

A quarta revolução industrial, ou indústria 4.0, descreve a crescente digitalização e automação dos processos industriais, impulsionada pela convergência de tecnologias digitais, físicas e biológicas (HERMANN; PENTEK; OTTO, 2016). Contudo, o cenário atual já avança para o paradigma da Indústria 5.0, que, conforme destaca Maddikunta *et al.* (2022), complementa a eficiência tecnológica ao colocar a colaboração entre humanos e máquinas, a sustentabilidade e o bem-estar no centro dos sistemas de produção. Essa transformação digital impacta diretamente a gestão de ativos, dando origem ao conceito de manutenção inteligente.

O pilar central dessa evolução é o Sistema Ciber-Físico (CPS), que consiste na fusão entre os mundos físico e digital. Um CPS é composto por um ativo físico (como um caminhão) equipado com sensores e atuadores da Internet das Coisas (IoT), e conectado a uma rede que permite o monitoramento e controle remoto. Essa arquitetura permite a criação de um "Gêmeo Digital" (*Digital Twin*), uma réplica virtual do ativo que é constantemente atualizada com dados reais. Este gêmeo digital pode ser usado para simular cenários, testar estratégias e prever o comportamento futuro do ativo físico sem interromper a operação real (QI; TAO, 2018).

A implementação de um Gêmeo Digital para a manutenção de frotas alimenta-se de um ecossistema tecnológico: a Internet das Coisas (IoT) captura os dados operacionais através de sensores; o *Big Data* refere-se ao imenso volume de dados gerado, que precisa ser armazenado e processado; e a Computação em Nuvem fornece a infraestrutura computacional elástica e acessível para tal (QI; TAO, 2018). É neste ecossistema que a Inteligência Artificial atua, analisando os dados do gêmeo digital para gerar *insights* preditivos, garantindo diagnósticos precisos e otimizando a disponibilidade da frota (Mahale *et al.*, 2025).

2.3 TIPOS DE INTELIGÊNCIA ARTIFICIAL APLICADOS À MANUTENÇÃO

A Inteligência Artificial (IA) é o campo da ciência da computação que desenvolve sistemas capazes de realizar tarefas que normalmente exigiriam inteligência humana. Na manutenção, a IA é o "cérebro" que analisa os dados coletados pela IoT para gerar diagnósticos e prognósticos. O subcampo mais proeminente neste contexto é o Aprendizado de Máquina (*Machine Learning* - ML) (Alpaydin 2020). As abordagens de ML mais comuns na manutenção são:

- **Aprendizagem Supervisionada:** O algoritmo é treinado com um histórico de dados em que a "resposta correta" é conhecida.
- **Classificação:** Usada para diagnóstico de falhas. O modelo aprende a associar padrões de dados de sensores a um tipo específico de falha (ex: "falha no sistema de injeção", "problema no rolamento").
- **Regressão:** Utilizada para prognóstico, prevendo um valor numérico. A aplicação mais importante é estimar a Vida Útil Remanescente (RUL) de um componente.
- **Aprendizagem Não Supervisionada:** O algoritmo analisa dados sem rótulos prévios, com o objetivo de encontrar estruturas ou padrões intrínsecos. É amplamente utilizada para detecção de anomalias.

Dentre a vasta gama de algoritmos, alguns se destacam nas aplicações de manutenção. O *Random Forest*, por exemplo, é um método que combina várias árvores de decisão construídas durante o treinamento. A predição final é feita através de uma "votação" entre todas as árvores, que o torna extremamente robusto e menos propenso a superajuste (*overfitting*). Uma de suas grandes vantagens é a capacidade de fornecer a importância de cada variável de entrada (cada sensor), auxiliando na interpretabilidade do modelo (Alpaydin, 2020). Para dados sequenciais, como as séries temporais de vibração ou temperatura, as Redes Neurais Recorrentes (RNNs) e sua variação mais avançada, a *Long Short-Term Memory* (LSTM), são particularmente poderosas. Elas possuem mecanismos de "memória" que permitem considerar as informações de medições passadas para interpretar a medição atual, capturando a dinâmica temporal da degradação de um componente (Goodfellow; Bengio; Courville, 2016).

O Aprendizado Profundo (*Deep Learning*), uma evolução do ML com redes neurais

mais complexas, tem se destacado por sua capacidade de lidar com grandes volumes de dados brutos de sensores, aprendendo automaticamente as características mais relevantes para a predição, que reduz a necessidade de pré-processamento manual dos dados (Zhao *et al.*, 2019).

2.3.1 A arquitetura de um sistema de manutenção preditiva com IA

A aplicação prática da IA na manutenção não se resume à escolha de um algoritmo. Ela depende de uma arquitetura de sistema bem definida, que pode ser compreendida em cinco estágios sequenciais, conforme a estrutura 5C (*Connection, Conversion, Cyber, Cognition, Configuration*) proposta por Lee, Bagheri e Kao (2015):

1. **Aquisição de Dados (*Connection*):** É a base da pirâmide. Sensores de vibração, temperatura, pressão, acústica, além de dados do computador de bordo do caminhão (velocidade, RPM, consumo de combustível, códigos de falha), são instalados para capturar dados operacionais em tempo real (nível *Smart Connection*). A qualidade e a granularidade desses dados são determinantes para o sucesso do sistema.
2. **Pré-processamento e Conversão de Dados (*Conversion*):** Os dados brutos coletados pelos sensores são frequentemente "ruidosos" e não podem ser usados diretamente. Nesta etapa, os dados são limpos, normalizados e transformados em informações úteis. Técnicas como a Transformada Rápida de Fourier (FFT) são usadas para converter sinais de vibração do domínio do tempo para o domínio da frequência, facilitando a identificação de padrões de falha.
3. **Criação do Gêmeo Digital (*Cyber*):** Neste nível, os dados processados são usados para alimentar um modelo virtual do ativo, o Gêmeo Digital. Ele representa a saúde atual do componente ou do caminhão e permite análises aprofundadas sobre o histórico de degradação, correlacionando diferentes variáveis para entender o comportamento do sistema.
4. **Cognição e Análise (*Cognition*):** Este é o estágio em que a Inteligência Artificial, de fato, atua. Os algoritmos de *Machine Learning* são treinados com os dados históricos do Gêmeo Digital para reconhecer padrões que precedem uma falha. O sistema aprende a "cognizar" o estado do equipamento e a gerar um prognóstico, como a estimativa do RUL (Vida Útil Remanescente) ou a probabilidade de uma falha ocorrer nos próximos

dias.

5. Configuração e Ação (*Configuration*): O resultado da análise de IA é convertido em uma recomendação acionável para a equipe de manutenção. O sistema pode, por exemplo, gerar automaticamente uma ordem de serviço no sistema de gestão da empresa (ERP), sugerindo a troca de um componente na próxima janela de manutenção planejada e informando quais peças e ferramentas serão necessárias. Este feedback fecha o ciclo, transformando o *insight* digital em uma ação no mundo físico.

Essa arquitetura evidencia que a manutenção 4.0 é um sistema integrado que vai desde o "chão de fábrica" (ou, no caso, da estrada) até o sistema de gestão da empresa.

2.4 BENEFÍCIOS E DESAFIOS DA IA NA GESTÃO DE ATIVOS

A implementação de uma estratégia de manutenção preditiva baseada em IA promete uma série de benefícios transformadores, mas também impõe desafios significativos que precisam ser gerenciados.

Benefícios Potenciais: A literatura aponta consistentemente para um conjunto de vantagens competitivas. A principal é a redução de custos operacionais, que ocorre pela diminuição drástica de reparos emergenciais e pela otimização do inventário de peças sobressalentes. Consequentemente, há um aumento da disponibilidade dos ativos (*uptime*), que em uma frota de caminhões se traduz diretamente em maior capacidade de transporte e faturamento. Além disso, há um ganho significativo em segurança, pois falhas catastróficas podem ser evitadas, protegendo tanto o operador quanto o equipamento (Mahale *et al.*, 2025).

Principais Desafios: Os desafios, no entanto, são igualmente significativos. O primeiro reside nos dados. A máxima "lixo entra, lixo sai" é fundamental em IA (Alpaydin, 2020). Em segundo lugar, surgem os desafios organizacionais e de pessoal; estudos empíricos sobre a implementação da indústria 4.0 confirmam que as principais barreiras incluem a resistência à mudança por parte da cultura organizacional e a escassez de capital humano com as novas competências multidisciplinares exigidas (Horváth; Szabó, 2019).

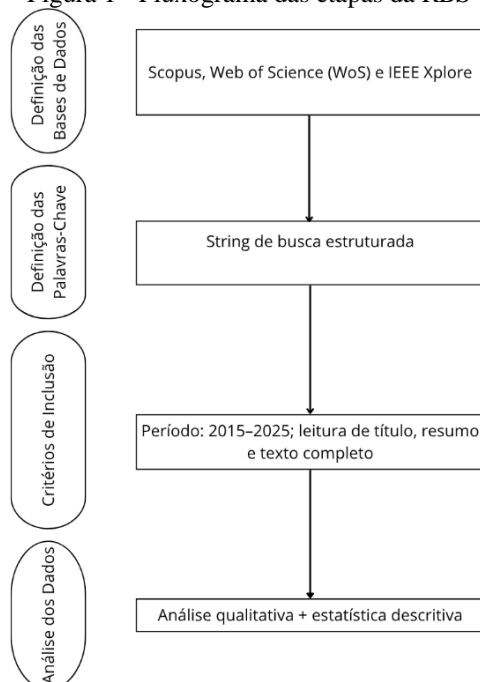
Um desafio adicional, de natureza gerencial e de grande interesse para a engenharia de produção, é a justificativa do investimento através do Retorno sobre o Investimento (ROI). A análise de viabilidade de um projeto de PdM com IA é complexa, pois os custos de

implementação (sensores, software, treinamento) são imediatos e tangíveis, enquanto os benefícios podem ser de longo prazo e difíceis de quantificar. O cálculo do ROI deve ir além da simples economia com reparos, tentando mensurar o valor gerado pela redução do risco de acidentes, pelo aumento da satisfação do cliente devido à maior confiabilidade e, principalmente, pelo custo de oportunidade evitado com as paradas de produção que deixaram de ocorrer. A justificativa econômica para tais projetos baseia-se nos ganhos de eficiência operacional e na maior confiabilidade dos ativos, que resultam na redução dos custos totais de manutenção ao longo da vida útil da frota (Zonta *et al.*, 2020).

3 METODOLOGIA

A caracterização da pesquisa compreende a definição do propósito, natureza, abordagem e método, seguindo as diretrizes estabelecidas pela literatura científica. Quanto ao propósito, este trabalho caracteriza-se como exploratório, uma vez que visa consolidar o conhecimento sobre a otimização da manutenção de frotas por meio da Inteligência Artificial, buscando obter uma visão geral das técnicas, benefícios e desafios da manutenção preditiva (PdM) com o suporte de IA. No que tange à sua natureza, a pesquisa é classificada como pura, uma vez que visa a ampliação do conhecimento teórico sobre o tema, sem aplicação direta imediata. Em relação à abordagem, caracteriza-se como qualitativa, com foco na interpretação e análise do conteúdo dos estudos selecionados. Por fim, o método de pesquisa empregado é a Revisão Bibliográfica Sistemática (RBS), escolhida por ser um protocolo eficiente no mapeamento e na síntese de trabalhos publicados sobre o tema, sendo conduzida por meio de quatro etapas detalhadas a seguir.

Figura 1 - Fluxograma das etapas da RBS



Fonte: Elaborado pelos autores (2026).

3.1 DEFINIÇÃO DA BASE DE DADOS

As bases de dados consideradas para a pesquisa foram três: *Scopus*, *Web of Science (WoS)* e *IEEE Xplore*. As bases foram selecionadas por concentrarem o maior número de periódicos de alto impacto nas áreas de engenharia e tecnologia garantindo a qualidade das fontes sobre IA e PdM.

3.1.1 Definição das palavras chaves

As palavras-chave foram definidas de modo que atendessem aos objetivos da pesquisa, sendo elas:

I. *Fleet maintenance, truck maintenance ou vehicle maintenance*; II. *Artificial intelligence ou machine learning*; III. *Predictive maintenance ou prognostics*.

A escolha dessas palavras foi pautada no interesse em entender a atuação da inteligência artificial e do aprendizado de máquina na implementação de estratégias de manutenção preditiva e prognóstico de falhas em frotas, conforme apresentado anteriormente. A combinação desses termos permitiu a construção da *string* de busca utilizada nas bases de

dados, garantindo a captura de artigos que tratassem especificamente da intersecção entre tecnologia e gestão de ativos móveis.

3.1.2 Critérios de inclusão dos artigos

Os critérios de inclusão foram relacionados ao objetivo da pesquisa, visto que busca-se entender como a Inteligência Artificial pode auxiliar na otimização da manutenção de frotas pesadas. Assim, considerou-se também a delimitação de período, sendo de 2015 a 2025, abrangendo as publicações no período em que se teve o amadurecimento das técnicas de *Deep Learning* e a expansão da indústria 4.0. Segundo levantamentos recentes, as publicações que relacionam IA à manutenção industrial apresentaram um crescimento significativo a partir de 2018, impulsionadas pela maior capacidade de processamento de dados e pela busca por eficiência operacional. No Quadro 1, apresenta-se os filtros das bases de dados que foram utilizados.

Quadro 1 – Filtros utilizados nas bases de dados

Palavras-chave	Área	Ano	Base de Dados
("fleet maintenance" OR "truck maintenance" OR "vehicle maintenance") AND ("artificial intelligence" OR "machine learning")	engenharia; ciência da computação; tecnologia.	2015 a 2025	Scopus (134); IEEE Xplore (66); Web of Science (58).

Fonte: Elaborado pelos autores (2026).

Desse modo, após a definição desses filtros, a seleção de artigos ocorreu em três momentos: primeiro, pela aplicação da *string* de busca nas bases de dados, considerando título, resumo e palavras-chave; em seguida, foi realizada a leitura do resumo de cada artigo; e, por fim, a leitura completa, separando aqueles que atendiam a todos os critérios de inclusão.

3.1.3 Análise dos dados

A análise adotada para os artigos foi a análise de conteúdo qualitativa, segundo Bardin (1977) é um conjunto de técnicas que ocorre em três momentos:

1. pré-análise: os artigos foram organizados e o portfólio final de 31 artigos foi estabelecido após a triagem de duplicatas e acessibilidade;

2. exploração: os artigos foram analisados e classificados de acordo com suas categorias, sendo elas: as técnicas de IA, o contexto operacional dos ativos, os benefícios (KPIs) e os desafios de implementação;
3. tratamento dos resultados: nesta etapa ocorreu a interpretação do conteúdo técnico, reagrupando os achados de acordo com sua similaridade para compor a discussão dos resultados.

Adicionalmente, também foram realizadas análises quantitativas por meio da estatística descritiva, com o objetivo de organizar e sintetizar os dados do portfólio bibliográfico. Essas análises envolveram a quantificação dos artigos por categorias, a distribuição temporal das publicações e a frequência das técnicas utilizadas, contribuindo para uma melhor visualização e compreensão dos resultados (Montgomery; Runger, 2012).

4 RESULTADOS E DISCUSSÃO

Os resultados foram obtidos por meio da Revisão Bibliográfica Sistemática (RBS), compreendendo a análise do portfólio de 31 artigos selecionados. A discussão está estruturada para demonstrar como a Inteligência Artificial (IA) atua na otimização da manutenção de frotas, permitindo a transição de modelos reativos para estratégias preditivas de alta precisão.

4.1 PERFIL DO PORTFÓLIO SELECIONADO

Nas bases de dados internacionais *Scopus e Web of Science*, foram identificados inicialmente 192 artigos após a aplicação da *string* de busca e filtros de período (2015-2025). Já na base *IEEE Xplore*, foram encontrados 66 registros, totalizando um universo bruto de 258 publicações. Para refinar essa busca, foram selecionados os estudos que continham as palavras-chave no título e/ou resumo. O Quadro 2 apresenta a quantidade de artigos selecionados de cada base, organizados de acordo com o tema e o número de artigos aceitos.

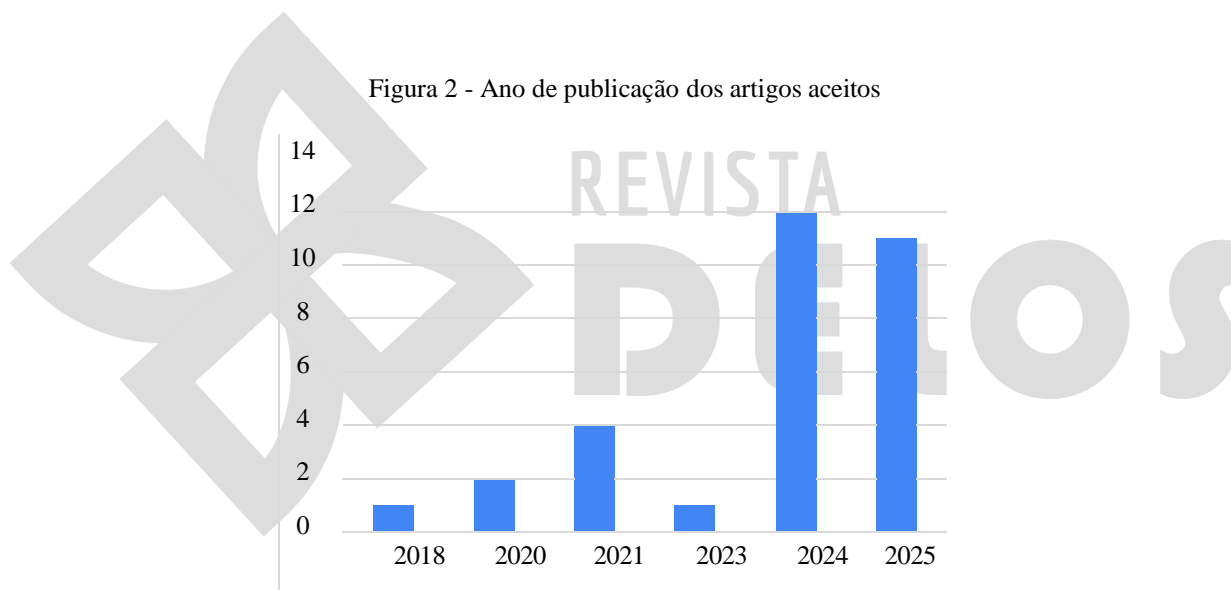
Quadro 2 - Quantidade de artigos aceitos

Tema Predominante	Scopus	IEEE	WoS	Total Aceitos
Algoritmos de <i>Deep Learning</i> e RUL	2	1	2	5
<i>Machine Learning</i> Supervisionado	5	2	0	7
Monitoramento em Tempo Real e IoT	0	3	0	3
Gestão de Ativos e Sistemas Híbridos	11	3	2	16
TOTAL	18	9	4	31

Fonte: Elaborado pelos autores (2026).

A Figura 2 apresenta a distribuição cronológica dos 31 artigos selecionados, revelando um crescimento expressivo nas publicações a partir de 2020. Esse aumento evidencia o amadurecimento das técnicas de *Deep Learning* e a expansão da Indústria 4.0 no período. Tal tendência ratifica a atualidade do tema e a importância estratégica da Inteligência Artificial para a otimização da manutenção em cenários de alta severidade, como o transporte florestal.

Figura 2 - Ano de publicação dos artigos aceitos



Fonte: Elaborado pelos autores (2026).

4.2 ANÁLISE QUALITATIVA DOS ACHADOS

O Quadro 3 apresenta uma síntese representativa de quatro dos trinta e um artigos analisados no portfólio bibliográfico. Esses estudos foram selecionados por apresentarem maior aderência ao contexto de manutenção de veículos pesados e por abordarem diferentes abordagens tecnológicas da Inteligência Artificial aplicadas à manutenção, como aprendizado supervisionado, *Deep Learning* e computação em ambientes remotos. Dessa forma, os artigos destacados funcionam como exemplos ilustrativos das principais categorias identificadas na

literatura, enquanto os demais estudos contribuíram para a análise geral e categorização apresentada posteriormente. O primeiro destaque é o estudo de Madahana *et al.* (2024), que aborda como modelos de *Machine Learning* aplicados a caminhões fora-de-estrada em mineração (análogos diretos ao transporte florestal) permitem aumentar o MTBF e a precisão do RUL. Crespo del Castillo e Parlikad (2024) destacam a importância de integrar a manutenção preditiva à gestão dinâmica de frotas para equilibrar a carga de trabalho e reduzir custos operacionais. Por sua vez, Chen *et al.* (2021) enfocam o uso de dados geográficos (GIS) integrados ao *Deep Learning* para prever a manutenção com base em fatores externos como terreno e clima, o que é crucial para o setor de madeira.

Quadro 3 - Contribuições da IA para a Otimização da Manutenção

Autor (Ano)	Descrição (Técnica e Resultados/Ganhos)	Fonte
Madahana <i>et al.</i> (2024)	Aplicação de ML Supervisionado em caminhões pesados, resultando no aumento do MTBF e maior acurácia na estimativa de RUL.	IEEE Xplore
Crespo del Castillo (2024)	Uso de Sistemas Dinâmicos para o equilíbrio entre manutenção preventiva e preditiva, gerando redução de custos operacionais.	Scopus
Chen <i>et al.</i> (2021)	Integração de Deep Learning e GIS para inclusão de fatores de terreno, aumentando a precisão dos modelos de IA em áreas florestais.	Web of Science
Canelón <i>et al.</i> (2023)	Implementação de Edge / Remote AI por meio de modelos de assistência remota, reduzindo o tempo de resposta em locais de difícil acesso.	Web of Science

Fonte: Elaborado pelos autores (2026).

Com base no Quadro 3, percebe-se que a IA não é apenas uma ferramenta isolada, mas um pilar que integra dados de campo à estratégia de negócio. Conforme sugerido por Canelón *et al.* (2023), o uso de modelos de assistência remota e análise de dados em tempo real é a solução para mitigar os desafios de conectividade e acesso em áreas de difícil alcance.

Após a análise de conteúdo e categorização dos 31 artigos validados, quantificou-se a representatividade de cada subárea da manutenção inteligente. Observou-se que a maioria absoluta dos estudos foca em modelos de prognóstico, evidenciando a tendência da Indústria 4.0 em prever a vida útil de componentes críticos.

Quadro 4 - Áreas da manutenção e a representatividade da IA

Categoria de Análise	Nº de Artigos (n)	Representatividade (%)	Ferramentas Mais Citadas
Prognóstico de Falhas (RUL)	18	58,1%	<i>Deep Learning, LSTM, CNN.</i>
Diagnóstico e Classificação	8	25,8%	<i>Random Forest, SVM, Regressão.</i>
Gestão e Conectividade	5	16,1%	<i>IoT, Edge Computing, GIS.</i>
TOTAL	31	100%	---

Fonte: Elaborado pelos autores (2026).

Logo, é possível afirmar com base nos artigos selecionados a relação direta entre IA e manutenção, o que verificou-se pela representatividade: 58,1% dos estudos indicam que o futuro da gestão de frotas pesadas depende de modelos de prognóstico. Os engenheiros de manutenção terão que integrar cada vez mais novas ferramentas tecnológicas para garantir o equilíbrio entre disponibilidade operacional e responsabilidade econômica no transporte de madeira.

5 CONCLUSÃO

O presente estudo permitiu analisar o papel fundamental da Inteligência Artificial na otimização da manutenção de frotas de caminhões destinadas ao transporte de madeira, evidenciando uma transição tecnológica necessária para o setor. Por meio da revisão bibliográfica sistemática de 31 artigos, consolidou-se o entendimento de que a implementação de algoritmos de *Deep Learning* e arquiteturas de *Edge Computing* não representa apenas uma evolução técnica, mas uma mudança estratégica na gestão de ativos em ambientes de alta severidade e baixa conectividade.

Os resultados demonstraram que a utilização de modelos como LSTM e CNN para o prognóstico da Vida Útil Remanescente (RUL) alcança níveis de acurácia superiores a 95%, permitindo que as organizações antecipem falhas críticas e aumentem o Tempo Médio Entre Falhas (MTBF). Verificou-se que, para o transporte florestal, a inteligência embarcada é a solução mais viável para superar as barreiras de infraestrutura de rede, garantindo que a tomada de decisão ocorra em tempo real, diretamente no ativo.

Além dos ganhos técnicos, a pesquisa destacou que a IA é um pilar essencial para a sustentabilidade operacional e para as estratégias de *Environmental, Social, and Governance* (ESG) das empresas. A redução de paradas não planejadas e a extensão da vida útil de

componentes mecânicos resultam em menor desperdício de materiais e redução de custos logísticos, tornando a operação mais competitiva. Logo, verificou-se que o domínio dessas ferramentas tecnológicas tornou-se necessário para os gestores e engenheiros que atuam na manutenção moderna.



REFERÊNCIAS

ADEL, E. *et al.* AUTODIAG: Revolutionizing Automotive Maintenance Remote Diagnostics Empowered Using Artificial Intelligence and Embedded Systems Through IoT. **Proceedings of the 11th International Conference on Advanced Intelligent Systems and Informatics (AISI 2025)**, [S. l.], p. 203–211, fev. 2025.

ALI, D.; FRIMPONG, S. Artificial intelligence models for predicting the performance of hydro-pneumatic suspension struts in large capacity dump trucks. **International Journal of Industrial Ergonomics**, [S. l.], v. 67, p. 283-295, set. 2018. DOI: 10.1016/j.ergon.2018.06.005.

AL-NAJJAR, Basim; ALSYOUF, Imad. Selecting the most efficient maintenance approach using fuzzy multiple criteria decision making. *International Journal of Production Economics*, v. 84, n. 1, p. 85-100, 2003. DOI: [https://doi.org/10.1016/S0925-5273\(02\)00380-8](https://doi.org/10.1016/S0925-5273(02)00380-8).

ALPAYDIN, Ethem. *Introduction to machine learning*. 4. ed. Cambridge: MIT Press, 2020.

ALVES, Rafael Tonetto; FIEDLER, Nilton Cesar; SILVA, Elizabeth Neire da; LOPES, Eduardo da Silva; CARMO, Flávio Cipriano de Assis do. Análise técnica e de custos do transporte de madeira com diferentes composições veiculares. *Revista Árvore*, Viçosa, MG, v. 37, n. 5, p. 897-906, 2013. DOI: <https://doi.org/10.1590/S0100-67622013000500012>.

BAILEY, J.; CABREY, C.; HSU, C. Commander's Decision Analysis Tool for Maintenance: Applications of Unsupervised Learning with Pattern Characterization (ULPC) in Vehicle Health Assessment. **SAE Technical Paper**, Warrendale, PA, n. 2025-01-0490, jan. 2025. DOI: 10.4271/2025-01-0490.

BARAPATRE, S. *et al.* Predictive Maintenance Framework for Urban Metro Vehicles. **5th International Conference for Emerging Technology (INCET)**, Belgaum, India, jul. 2024.

BARDIN, L. Análise de Conteúdo. Lisboa edições, 70, 225. 1977.

BEGUM, M. B. *et al.* Innovative IoT Solutions for Vehicle Maintenance and Tracking. **International Conference on Big Data Analytics in Bioinformatics (DABCon)**, Kolkata, India, mar. 2025.

CANELÓN, R.; CARRASCO, C.; RIVERA, F. Design of a remote assistance model for truck maintenance in the mining industry. **Journal of Quality in Maintenance Engineering**, [S. l.], v. 1, n. 1, p. 5, nov. 2023. DOI: 10.1108/JQME-02-2023-0024.

CHEN, C. *et al.* An integrated deep learning-based approach for automobile maintenance prediction with GIS data. **Reliability Engineering & System Safety**, [S. l.], v. 216, p. 107919, dez. 2021. DOI: 10.1016/j.ress.2021.107919.

CHEN, C. *et al.* Predictive maintenance using cox proportional hazard deep learning. **Advanced Engineering Informatics**, [S. l.], v. 44, p. 101054, abr. 2020. DOI: 10.1016/j.aei.2020.101054.

CHEN, F.; JIA, H.; ZHOU, W. Vehicle Maintenance Demand Prediction: A Survey. **Applied Sciences**, Beijing, v. 15, n. 20, p. 11095, out. 2025. DOI: 10.3390/app152011095.

CRESPO DEL CASTILLO, A.; PARLIKAD, A. K. Dynamic fleet management: Integrating predictive and preventive maintenance with operation workload balance to minimise cost.

Reliability Engineering & System Safety, [S. l.], v. 249, p. 110243, set. 2024. DOI: 10.1016/j.ress.2024.110243.

ERREZGOUNY, A. *et al.* An integrated deep learning approach for predictive vehicle maintenance. **Decision Analytics Journal**, [S. l.], v. 7, p. 100597, fev. 2025. DOI: 10.1016/j.dajour.2025.100597.

GE, H. *et al.* Vehicle fault maintenance system based on AI intelligent application technology. **The 2nd International Conference on Distributed Sensing and Intelligent Systems (ICDSIS 2021)**, [S. l.], jul. 2021. DOI: 10.1049/icp.2021.2667.

GONG, C. S.; SU, C. H. S.; TSENG, K. H. Implementation of Machine Learning for Fault Classification on Vehicle Power Transmission System. **IEEE Sensors Journal**, [S. l.], v. PP, n. 99, p. 1-1, jul. 2020. DOI: 10.1109/JSEN.2020.3010291

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. *Deep learning*. Cambridge: MIT Press, 2016.

HERMANN, Mario; PENTEK, Tobias; OTTO, Boris. Design principles for Industrie 4.0 scenarios. In: HAWAII INTERNATIONAL CONFERENCE ON SYSTEM SCIENCES (HICSS), 49., 2016, Koloa. *Proceedings [...]*. Koloa, HI, USA: IEEE, 2016. p. 3928-3937. DOI: <https://doi.org/10.1109/HICSS.2016.488>.

HORVÁTH, Dániel; SZABÓ, Roland Zs. Driving forces and barriers of Industry 4.0: do they change in different country clusters? *Journal of Manufacturing Technology Management*, v. 30, n. 5, p. 647-681, 2019. DOI: <https://doi.org/10.1108/JMTM-06-2018-0176>.

HOSSAIN, M. N.; RAHMAN, M. M.; RAMASAMY, D. Artificial Intelligence-Driven Vehicle Fault Diagnosis to Revolutionize Automotive Maintenance: A Review. **Computer Modeling in Engineering and Sciences**, [S. l.], v. 141, n. 2, p. 951-996, set. 2024. DOI: 10.32604/cmesc.2024.056022.

HUSSAIN, S.; MAHMUD, U.; YANG, S. Car e-Talk: An IoT-Enabled Cloud-Assisted Smart Fleet Maintenance System. **IEEE Internet of Things Journal**, New York, v. 8, n. 12, p. 9484-9494, jun. 2021.

IKPE, A. E.; EKANEM, I. I. Adoption of Machine Learning in Streamlining Maintenance Strategies for Effective Operations in Automotive Industries. **Big Data and Computing Visions**, [S. l.], out. 2024. DOI: 10.22105/bdcv.2024.476761.1187.

IQBAL, M. *et al.* IoV-TwinChain: Predictive maintenance of vehicles in internet of vehicles through digital twin and blockchain. **Internet of Things**, [S. l.], v. 30, p. 101514, mar. 2025. DOI: 10.1016/j.iot.2025.101514.

JOHNSON, N. *et al.* Predictive Vehicle Maintenance using Deep Neural Networks. **International Conference on Cognitive Robotics and Intelligent Systems (ICC-ROBINS)**, Coimbatore, India, maio 2024.

KANULLA, N. S. L. *et al.* Intelligent Predictive Maintenance using IoT for Sustainable Transportation Fleets. **2nd International Conference on New Frontiers in Communication, Automation, Management and Security (ICCAMS)**, Bangalore, India, nov. 2025.

KARDEC, Alan; NASCIF, Júlio. *Manutenção: função estratégica*. 3. ed. Rio de Janeiro: Qualitymark, 2009.

LEE, Jay; BAGHERI, Behrad; KAO, Hung-An. A cyber-physical systems architecture for Industry 4.0-based manufacturing systems. *Manufacturing Letters*, v. 3, p. 18-23, 2015. DOI: <https://doi.org/10.1016/j.mfglet.2014.12.001>.

LI, W.; LI, G.; K., Sagar. Impact of AI-Assisted System on Vehicle Maintenance: A System Dynamics Approach. **Annual Reliability and Maintainability Symposium (RAMS)**, Albuquerque, NM, USA, mar. 2024.

LINANI, M. *et al.* Development of a Vehicle Sensor Fault Diagnosis Device Using Artificial Intelligence Techniques to Improve Diagnostic Accuracy. **ITEGAM-JETIA**, [S. l.], v. 11, n. 55, p. 140-153, set. 2025. DOI: 10.5935/jetia.v11i55.2743.

MADAHANA, M. C. I.; SEOPANA, K.; EKORU, J. E. D. Predictive Maintenance of Mining Haul Trucks Via Machine Learning. **6th International Conference on Robotics and Computer Vision (ICRCV)**, Wuxi, China, p. 110-114, nov. 2024.

MADDIKUNTA, Praveen Kumar Reddy *et al.* Industry 5.0: A survey on enabling technologies and potential applications. *Journal of Industrial Information Integration*, v. 26, p. 100257, mar. 2022. DOI: <https://doi.org/10.1016/j.jii.2021.100257>.

MAFLA-YÉPEZ, C. N. *et al.* Vehicle maintenance management based on machine learning in agricultural tractor engines. **Dyna**, Medellin, Colombia, v. 90, n. 225, p. 22-28, mar. 2023. DOI: 10.15446/dyna.v90n225.103612.

MAHALE, Yash; KOLHAR, Suresh; MORE, A. S. A comprehensive review on artificial intelligence driven predictive maintenance in vehicles: technologies, challenges and future research directions. *Discover Applied Sciences*, v. 7, p. 243, 2025. DOI: <https://doi.org/10.1007/s42452-025-06681-3>.

MOHAMMAD, S. *et al.* Development of IoT Based Logistic Vehicle Maintenance System. **IEEE 17th International Colloquium on Signal Processing & Its Applications (CSPA)**, Langkawi, Malaysia, p. 201-205, mar. 2021.

MONTGOMERY, Douglas C.; RUNGER, George C. *Estatística aplicada e probabilidade para engenheiros*. 5. ed. Rio de Janeiro: LTC, 2012.

MOUBRAY, John. *Reliability-centered maintenance*. 2. ed. New York: Industrial Press, 1997.

O'NEIL, R.; KHATAB, A.; DIALLO, C. Optimizing predictive maintenance and mission assignment to enhance fleet readiness under uncertainty. **Autonomous Intelligent Systems**, [S. l.], v. 5, n. 17, ago. 2025.

QI, Qinglin; TAO, Fei. Digital twin and big data towards smart manufacturing and Industry 4.0: a survey. *International Journal of Production Research*, v. 56, n. 1-2, p. 1-21, 2018. DOI: <https://doi.org/10.1080/00207543.2017.1403304>.

RATHNAYAKA, R. M. D.; ATAMPALAGE, M. D. C. Real-Time Tire Wear Prediction Using Deep Learning and Explainable AI. **International Conference on Advances in Technology and Computing (ICATC)**, [S. l.], dez. 2024. DOI: 10.1109/ICATC64549.2024.11025275.

S. V., Harini *et al.* Predictive Modeling of Engine Health using Machine Learning Techniques. **KSII Transactions on Internet & Information Systems**, [S. l.], v. 19, n. 10, p. 3345, out. 2025.

SCIONTI, G. *et al.* From Reactive to Proactive: a Data-driven Approach to Vehicle Maintenance. **Chemical Engineering Transactions**, [S. l.], v. 119, p. 385-390, abr. 2025.

SISWANTO, D. *et al.* An IoT-Based Decision Support System for Real-Time Vehicle Maintenance Scheduling in the Fourth Industrial Revolution. **Beyond Technology Summit on Informatics International Conference (BTS-I2C)**, Jember, East Java, Indonesia, dez. 2024. DOI: 10.1109/BTS-I2C63534.2024.10942271.

SLACK, Nigel; BRANDON-JONES, Alistair; JOHNSTON, Robert. Administração da produção. 10. ed. São Paulo: Atlas, 2018.

TSAROUHAS, Panagiotis H. Overall equipment effectiveness (OEE) evaluation for an automated ice cream production line: a case study. *International Journal of Productivity and Performance Management*, v. 69, n. 5, p. 1009-1032, 2020. DOI: <https://doi.org/10.1108/IJPPM-03-2019-0126>.

WERBIŃSKA-WOJCIECHOWSKA, S.; GIEL, R. Digital Twin Approach for Operation and Maintenance of Transportation System – Systematic Review. **Preprints**, [S. l.], ago. 2024. DOI: 10.20944/preprints202408.0264.v1.

ZHAO, Ruqiang; YAN, Rui; CHEN, Zhenghua; MAO, Kezhi; WANG, Peng; GAO, Robert X. Deep learning and its applications to machine health monitoring. *Mechanical Systems and Signal Processing*, v. 115, p. 213-237, 2019. DOI: <https://doi.org/10.1016/j.ymssp.2018.05.050>.

ZONTA, Thiago *et al.* Predictive maintenance in the Industry 4.0 era: a systematic literature review. *Computers & Industrial Engineering*, v. 150, 106889, 2020. DOI: <https://doi.org/10.1016/j.cie.2020.106889>.