

FACULDADE DE TECNOLOGIA DE BAURU – FATEC

Curso Superior de Tecnologia em Automação Industrial

EDUARDO MARIANO VALENTIM
GUILHERME CARDUCCI SEBASTIÃO
RENATO ALEX LABADESSA JUNIOR

**AVALIAÇÃO DO USO DE INTELIGENCIA ARTIFICIAL GENERATIVA NO APOIO
AO DIAGNOSTICO DE FALHAS EM MANUTENÇÃO CORRETIVA INDUSTRIAL**

Bauru/2026

Eduardo Mariano Valentim
Graduando em Automação Industrial
E-mail: eduardo.valentim@aluno.cps.sp.gov.br

Guilherme Sebastião Carducci
Graduando em Automação Industrial
E-mail: guilherme.sebastiao@aluno.cps.sp.gov.br

Renato Alex Labadessa Junior
Graduando em Automação Industrial
E-mail: renato.labadessa@aluno.cps.sp.gov.br

Tiago Aparecido Vicentin
Professor Doutor em Agronomia. Docente na Fatec Bauru
E-mail: tiago.vicentin@cps.sp.gov.br

AVALIAÇÃO DO USO DE INTELIGENCIA ARTIFICIAL GENERATIVA NO APOIO AO DIAGNOSTICO DE FALHAS EM MANUTENÇÃO CORRETIVA INDUSTRIAL

Trabalho apresentado no curso de graduação da Faculdade de tecnologia de Bauru
Orientador Professor Doutor em Agronomia Tiago Aparecido Vicentin

RESUMO

A eficiência na identificação e correção de falhas pode contribuir para a redução de custos e aumento da produtividade.. Nesse contexto, a utilização de Inteligência Artificial (IA) apresenta-se como uma alternativa promissora para auxiliar profissionais na análise de sintomas e diagnóstico de falhas. Este trabalho tem como objetivo desenvolver e avaliar um sistema baseado em IA voltado ao apoio na manutenção corretiva industrial. A metodologia adotada caracteriza-se como pesquisa aplicada, de natureza experimental, com abordagem qualitativa e quantitativa. Foram realizados testes práticos utilizando cenários reais de falhas em equipamentos industriais, avaliando a capacidade da IA em identificar causas prováveis com base em sintomas fornecidos. Os resultados demonstraram potencial da IA em diagnósticos mais diretos, embora tenham sido observadas limitações significativas em falhas mais complexas. Conclui-se que a IA possui potencial significativo como ferramenta de apoio à manutenção, contribuindo para maior eficiência nos diagnósticos e redução do tempo de parada de máquinas.

Palavras-chave: Otimização de processos; Redução do tempo de parada de máquinas; Indústria 4.0; Diagnóstico de falhas; Assertividade diagnostico;

1 INTRODUÇÃO

A manutenção corretiva na indústria é uma atividade que exige agilidade, precisão e conhecimento técnico aprofundado. A dificuldade em identificar rapidamente a causa das falhas pode gerar longos períodos de inatividade das máquinas, impactando diretamente a produtividade das empresas e elevando os custos operacionais. Nesse cenário, torna-se cada vez mais necessária a utilização de ferramentas que auxiliem os profissionais da manutenção, oferecendo suporte na análise de sintomas e indicando possíveis causas para acelerar o processo de diagnóstico.

A Inteligência Artificial (IA) tem se mostrado uma tecnologia promissora em diversas áreas do conhecimento, inclusive no ambiente industrial, onde contribui para a inovação e otimização dos processos produtivos. Sistemas inteligentes são capazes de analisar grandes volumes de dados gerados por sensores, equipamentos e sistemas automatizados, identificando padrões e relações que, em determinadas situações, poderiam não ser facilmente percebidos por meio de análises convencionais. Isso possibilita prever falhas, otimizar linhas de produção, reduzir desperdícios e aumentar a segurança operacional. Dessa forma, a Inteligência Artificial deixa de ser apenas uma ferramenta de suporte e passa a desempenhar papel estratégico nos processos de tomada de decisão dentro do ambiente industrial.

No contexto da Indústria 4.0, a crescente disponibilidade de ferramentas de Inteligência Artificial Generativa tem ampliado as possibilidades de sua aplicação em atividades relacionadas à manutenção industrial. Essas tecnologias apresentam potencial para interpretar informações técnicas, analisar sintomas de falhas e sugerir possíveis causas e soluções para problemas encontrados em equipamentos e sistemas automatizados. Entretanto, apesar dos avanços observados, ainda existem questionamentos quanto à precisão, confiabilidade e capacidade dessas ferramentas em fornecer diagnósticos compatíveis com situações reais vivenciadas pelos profissionais da manutenção.

Diante desse contexto, identifica-se como problema de pesquisa a dificuldade encontrada pelos profissionais de manutenção corretiva em realizar diagnósticos rápidos e precisos diante de falhas industriais, especialmente em situações que exigem análise de grande quantidade de informações técnicas e experiência prática acumulada. Embora a Inteligência Artificial tenha apresentado avanços significativos nos últimos anos, ainda existem dúvidas quanto à sua capacidade de auxiliar de forma confiável no diagnóstico de falhas em ambientes industriais.

Nesse sentido, a presente pesquisa é orientada pela seguinte questão norteadora: A Inteligência Artificial Generativa pode auxiliar no diagnóstico de falhas em manutenção corretiva industrial, fornecendo respostas coerentes e tecnicamente compatíveis com situações reais de manutenção?

A hipótese deste trabalho parte do pressuposto de que as ferramentas de Inteligência Artificial Generativa, quando submetidas a cenários reais de falhas industriais e alimentadas com informações técnicas adequadas, possuem capacidade de auxiliar o profissional de manutenção na formulação de hipóteses iniciais de diagnóstico, reduzindo o tempo de investigação e contribuindo para a tomada de decisão. Entretanto, pressupõe-se também que essas ferramentas não substituem o conhecimento técnico, a experiência prática e a capacidade analítica do profissional responsável pela manutenção, atuando como instrumentos complementares de apoio às atividades desenvolvidas no ambiente industrial.

Dessa forma, este trabalho tem como objetivo avaliar o uso da Inteligência Artificial Generativa como ferramenta de apoio ao diagnóstico de falhas em manutenção corretiva industrial, por meio da aplicação de testes em plataformas amplamente utilizadas atualmente, como o ChatGPT e o Google Gemini. A proposta consiste em analisar a capacidade de resposta e a assertividade dos diagnósticos fornecidos por essas ferramentas diante de diferentes cenários e sintomas de falhas, verificando seu potencial de auxiliar profissionais no processo de identificação das causas prováveis dos problemas apresentados.

Espera-se que os resultados obtidos contribuam para ampliar a discussão sobre a utilização da Inteligência Artificial na manutenção industrial, evidenciando suas potencialidades, limitações e possibilidades futuras de aplicação. Além disso, busca-se demonstrar que a integração entre o conhecimento técnico humano e as novas tecnologias pode representar um importante avanço para a redução do tempo de parada de máquinas, otimização dos processos de manutenção e aumento da eficiência operacional no contexto da Indústria 4.0.

2 REFERENCIAL TEÓRICO

2.1 INDÚSTRIA 4.0

A Indústria 4.0 representa a fase mais recente da evolução dos sistemas produtivos, caracterizada pela integração entre tecnologias digitais, automação avançada e conectividade em

tempo real. Essa nova configuração industrial transforma a maneira como máquinas, pessoas e processos interagem, criando ambientes produtivos mais inteligentes, eficientes e autônomos.

2.2 TECNOLOGIAS HABILITADORAS DA INDÚSTRIA 4.0

A Indústria 4.0 representa uma nova etapa da evolução industrial baseada na integração entre sistemas físicos e digitais, permitindo maior conectividade, automação e capacidade de tomada de decisão nos ambientes produtivos. Segundo Kagermann, Wahlster e Helbig (2013), esse novo paradigma industrial utiliza tecnologias avançadas para desenvolver fábricas inteligentes capazes de operar com elevada flexibilidade e eficiência. Entre as principais tecnologias habilitadoras destacam-se os sistemas ciberfísicos, a Internet Industrial das Coisas (IIoT), computação em nuvem, análise de big data, inteligência artificial, robótica autônoma e integração horizontal e vertical de sistemas.

Os sistemas ciberfísicos possuem papel fundamental nesse cenário por promoverem a integração entre componentes físicos e sistemas computacionais. Conforme Hermann, Pentek e Otto (2016), esses sistemas permitem monitoramento em tempo real, coleta contínua de dados e comunicação entre máquinas e softwares industriais. Essa capacidade de integração contribui para maior precisão operacional, otimização da produção e redução de falhas durante os processos industriais.

A Internet Industrial das Coisas (IIoT) também se destaca como uma das principais bases tecnológicas da Indústria 4.0. De acordo com Lasi et al. (2014), a IIoT possibilita a conexão entre dispositivos industriais, sensores e equipamentos por meio de redes de comunicação inteligentes. Essa conectividade permite acompanhar continuamente o desempenho das máquinas, facilitando a implementação de estratégias de manutenção preditiva, controle remoto e monitoramento operacional em tempo real.

Outro aspecto relevante envolve a utilização de computação em nuvem e análise de big data no ambiente industrial. Segundo Lee, Bagheri e Kao (2015), essas tecnologias possibilitam armazenar, processar e analisar grandes volumes de dados provenientes dos sistemas produtivos, auxiliando na identificação de padrões, previsão de falhas e otimização dos processos industriais. Dessa forma, a integração dessas tecnologias favorece o desenvolvimento de sistemas produtivos mais inteligentes, conectados e eficientes.

2.3 DIGITALIZAÇÃO INDUSTRIAL

No contexto da Indústria 4.0, a digitalização industrial tornou-se um elemento essencial para modernização dos processos produtivos. A digitalização consiste na conversão de processos analógicos e operações manuais em sistemas digitais integrados, permitindo maior controle, rastreabilidade e eficiência operacional. Segundo Schwab (2016), a transformação digital está modificando profundamente os modelos industriais ao incorporar tecnologias digitais às atividades de produção, monitoramento e gerenciamento industrial.

A digitalização industrial permite a coleta contínua de dados provenientes de máquinas, sensores e sistemas supervisórios. Conforme Tao et al. (2018), esses dados podem ser armazenados e analisados em tempo real, permitindo identificar falhas operacionais, padrões de funcionamento e oportunidades de melhoria no desempenho dos equipamentos. Esse processo amplia significativamente a capacidade de supervisão e controle das operações industriais.

Outro benefício importante da digitalização está relacionado ao gerenciamento do ciclo de vida dos ativos industriais e à manutenção preditiva. De acordo com Lee, Bagheri e Kao (2015), o uso de sistemas digitais possibilita monitorar continuamente as condições operacionais das máquinas, reduzindo paradas não programadas e aumentando a confiabilidade dos processos produtivos. Essa capacidade de análise contínua favorece diagnósticos mais rápidos e estratégias de manutenção mais eficientes.

Da mesma forma, a digitalização industrial contribui para integração entre diferentes setores da organização, permitindo maior fluxo de informações entre produção, manutenção, logística e gestão. Segundo Hermann, Pentek e Otto (2016), essa integração melhora a tomada de decisão baseada em dados e aumenta a eficiência operacional das indústrias, fortalecendo sua competitividade em ambientes industriais cada vez mais automatizados.

2.4 DISPOSITIVOS CONECTADOS E IOT INDUSTRIAL


Com o avanço da digitalização industrial, os dispositivos conectados tornaram-se fundamentais para coleta e transmissão de dados em tempo real nos ambientes industriais. Sensores inteligentes, dispositivos IoT, sistemas embarcados e coletores de dados permitem monitorar continuamente variáveis operacionais como vibração, temperatura, pressão, ruído e comportamento dinâmico de máquinas. Segundo Xu, He e Li (2014), a IoT Industrial promove a interconexão entre equipamentos físicos e sistemas computacionais, possibilitando maior automação e controle dos processos industriais.

Os sensores inteligentes desempenham papel estratégico na aquisição de dados operacionais. Conforme Tao et al. (2018), esses dispositivos permitem detectar alterações no comportamento das máquinas antes da ocorrência de falhas críticas, contribuindo para implementação de estratégias de manutenção preditiva e monitoramento inteligente. A utilização desses sensores aumenta a confiabilidade operacional e reduz o tempo de parada dos equipamentos industriais.

Os dispositivos conectados também permitem comunicação contínua entre máquinas, sistemas supervisórios e plataformas analíticas, como representado na figura 1. Segundo Jagatheesaperumal et al. (2021), a integração entre IoT, inteligência artificial e big data possibilita desenvolver sistemas capazes de interpretar automaticamente os dados industriais, identificar padrões operacionais e auxiliar na tomada de decisões. Essa integração favorece ambientes industriais mais inteligentes, eficientes e conectados.

Outro fator importante está relacionado à supervisão remota dos processos produtivos. De acordo com Lasi et al. (2014), o fluxo contínuo de informações gerado pelos dispositivos conectados permite que operadores e equipes de manutenção acompanhem o desempenho dos equipamentos em tempo real, independentemente da localização física da planta industrial. Isso proporciona maior agilidade na identificação de problemas, melhora a eficiência operacional e reduz o tempo de resposta em situações de falha.

Figura 1 – Fluxograma da Internet das Coisas Industrial.



Fonte: Adaptado de SANTOS, Bruno P. et al. Internet das Coisas: da Teoria à Prática. Minicursos do XXXV Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos (SBRC), 2017.

2.5 MANUTENÇÃO INDUSTRIAL E MANUTENÇÃO CORRETIVA

A manutenção industrial desempenha papel fundamental na garantia da continuidade operacional, da segurança e da eficiência produtiva dentro das organizações industriais (Kardec; Nascif, 2012). Nesse contexto, a manutenção corretiva caracteriza-se como a intervenção executada após a ocorrência de uma falha, com o objetivo de restabelecer o funcionamento adequado do equipamento no menor tempo possível. Embora seja inevitável em diversos processos industriais, a elevada incidência de manutenções corretivas pode ocasionar impactos negativos, como aumento dos custos operacionais, paradas prolongadas de produção, redução da produtividade e maior sobrecarga das equipes de manutenção.

2.6 INTELIGÊNCIA ARTIFICIAL NA MANUTENÇÃO CORRETIVA

A aplicação da Inteligência Artificial (IA) na manutenção corretiva tem contribuído significativamente para a redução do tempo de diagnóstico e para o auxílio na identificação das causas raiz de falhas em sistemas industriais (Silva; Simões, 2018). Por meio da análise de dados históricos, parâmetros operacionais e sintomas registrados durante o funcionamento dos equipamentos, algoritmos de aprendizado de máquina são capazes de identificar padrões, sugerir causas prováveis e até indicar possíveis soluções para os problemas detectados. Nesse contexto, a IA atua como ferramenta de apoio à tomada de decisão, oferecendo respostas rápidas, consistentes e fundamentadas em dados. Entretanto, apesar dos avanços tecnológicos, a utilização da IA não substitui o conhecimento técnico e a experiência prática do profissional de manutenção, funcionando como suporte complementar às atividades humanas.

2.7 SENSORES, ANÁLISE DE DADOS E DIAGNÓSTICO INTELIGENTE

O avanço dos sensores inteligentes e das técnicas modernas de aquisição de dados tem fortalecido significativamente a aplicação da Inteligência Artificial na manutenção corretiva industrial (Chevtchenko *et al.*, 2023). Sensores conectados permitem o monitoramento contínuo de variáveis operacionais, como vibração, temperatura, sinais acústicos e comportamento dinâmico dos equipamentos, possibilitando a coleta de grandes volumes de dados em tempo real. A análise dessas informações por meio de algoritmos inteligentes contribui para a detecção precisa de anomalias e padrões de falhas, mesmo em ambientes industriais complexos. Dessa forma, o diagnóstico inteligente torna-se uma ferramenta importante para aumentar a confiabilidade operacional, reduzir o tempo de parada e apoiar a tomada de decisão das equipes de manutenção.

2.8 OTIMIZAÇÃO DO PROCESSO CORRETIVO COM IA

Estudos recentes demonstram que a Inteligência Artificial não apenas auxilia na identificação de falhas, mas também contribui diretamente para a otimização do processo de manutenção corretiva (AIRES; MOREIRA; FREIRE, 2018). A integração entre dados operacionais, históricos de manutenção e sistemas inteligentes de tomada de decisão permite que algoritmos analisem padrões de comportamento dos equipamentos e indiquem ações corretivas mais adequadas para cada situação. Além disso, a utilização da IA possibilita a eliminação de etapas redundantes no processo de diagnóstico, reduzindo significativamente o tempo de parada das máquinas e aumentando a eficiência operacional das equipes de manutenção.

3 MATERIAIS E MÉTODOS

3.1 CARACTERIZAÇÃO DO ESTUDO

Este trabalho caracteriza-se como uma pesquisa aplicada, experimental e exploratória, com abordagem qualitativa e quantitativa, voltada ao desenvolvimento e avaliação de um sistema baseado em Inteligência Artificial (IA) capaz de auxiliar profissionais na manutenção corretiva industrial.

3.2 MATERIAIS E FERRAMENTAS UTILIZADAS

Para a realização deste estudo, foram utilizados recursos computacionais e plataformas de Inteligência Artificial com capacidade de processamento de linguagem natural, visando avaliar seu potencial de aplicação no auxílio ao diagnóstico de falhas em manutenção corretiva industrial. O ambiente de desenvolvimento foi composto por um computador com sistema operacional Windows 10 e dispositivos móveis do tipo smartphone, utilizados para acesso às plataformas, realização dos testes e registro dos resultados obtidos ao longo da pesquisa.

As ferramentas de Inteligência Artificial selecionadas para o estudo foram o ChatGPT, desenvolvido pela OpenAI, utilizando o modelo GPT-4o disponibilizado por meio da assinatura ChatGPT Plus, e o Google Gemini 2.5Pro, disponibilizado pela Google em sua versão paga. A escolha dessas plataformas ocorreu devido à sua ampla popularidade e relevância no cenário atual da Inteligência Artificial generativa, sendo atualmente duas das soluções mais utilizadas mundialmente em aplicações relacionadas ao processamento de linguagem natural, análise de informações e auxílio à tomada de decisão.

Além da ampla utilização, a escolha do ChatGPT e do Gemini foi motivada pela capacidade dessas plataformas em compreender comandos em linguagem natural, interpretar informações técnicas e estabelecer relações entre diferentes dados apresentados pelo usuário. Essas

características tornam as ferramentas adequadas para estudos relacionados à manutenção industrial, uma vez que o processo de diagnóstico frequentemente depende da interpretação de sintomas, análise de possíveis causas e sugestão de procedimentos para identificação das falhas.

A utilização das versões pagas foi definida com o objetivo de garantir acesso aos modelos mais avançados disponibilizados por cada empresa, proporcionando maior capacidade de processamento, melhor compreensão contextual das informações fornecidas e maior estabilidade durante a execução dos testes. Além disso, as versões pagas apresentam menor limitação quanto ao número de interações e oferecem recursos mais avançados de raciocínio e interpretação textual, aspectos considerados importantes para garantir maior uniformidade e confiabilidade nos resultados obtidos ao longo da pesquisa.

Como suporte técnico para a elaboração dos cenários de teste, foram utilizados manuais técnicos industriais e documentação de fabricantes amplamente empregados em ambientes de automação industrial. Entre os materiais consultados destacam-se manuais de inversores de frequência da linha WEG CFW500, documentação técnica de contadores, relés de estado sólido, Interfaces Homem-Máquina (IHM), sensores e outros componentes utilizados em sistemas automatizados. A consulta a esses documentos teve como finalidade garantir que os cenários propostos apresentassem características compatíveis com situações reais encontradas na rotina da manutenção industrial.


A base de dados utilizada foi estruturada a partir de experiências práticas vivenciadas na rotina de profissionais da área de eletromecânica e manutenção industrial. Foram reunidas informações relacionadas aos sintomas apresentados pelos equipamentos, causas prováveis das falhas e soluções normalmente empregadas para restabelecimento do funcionamento dos sistemas. Essa estruturação buscou reproduzir o processo de análise realizado pelos profissionais de manutenção durante a investigação de falhas, permitindo avaliar a capacidade das Inteligências Artificiais em interpretar sintomas, correlacionar informações técnicas e sugerir diagnósticos coerentes com a realidade industrial.

A organização dos dados em sintomas de falhas, causas prováveis e soluções aplicadas foi adotada com a finalidade de estabelecer um padrão metodológico para os testes, possibilitando a comparação dos resultados obtidos e a análise da assertividade das respostas fornecidas pelas plataformas avaliadas. Dessa forma, buscou-se aproximar a pesquisa das condições efetivamente encontradas no ambiente industrial, permitindo avaliar não apenas a capacidade teórica das

ferramentas de Inteligência Artificial, mas também seu potencial como instrumento de apoio ao profissional de manutenção corretiva industrial.

3.3 PROCEDIMENTOS METODOLÓGICOS

Figura 2 – Fluxograma metodológico da pesquisa



Fonte: Texto elaborado pelos autores com design desenvolvido pelo ChatGPT (2026).

O fluxograma metodológico apresentado na Figura 2 resume as principais etapas desenvolvidas durante a realização desta pesquisa. Inicialmente, foi realizada a coleta e estruturação dos dados, utilizando informações provenientes de manuais técnicos industriais e experiências práticas da rotina de manutenção. Em seguida, os dados foram organizados em um

conjunto estruturado contendo sintomas de falhas, causas prováveis e soluções aplicadas, possibilitando a preparação dos cenários de teste.

Posteriormente, os cenários elaborados foram submetidos às plataformas de Inteligência Artificial selecionadas para o estudo, sendo registradas todas as respostas obtidas para posterior análise. Na etapa seguinte, foi realizada uma comparação entre os resultados apresentados pelas ferramentas avaliadas, considerando a coerência técnica, a assertividade dos diagnósticos e a capacidade de auxiliar no processo de identificação de falhas. Por fim, com base nos resultados obtidos, foram elaboradas as conclusões da pesquisa, destacando as potencialidades e limitações da Inteligência Artificial Generativa como ferramenta de apoio ao diagnóstico de falhas em manutenção corretiva industrial.

3.4 ARQUITETURA DO SISTEMA

A arquitetura utilizada neste estudo foi estruturada de forma a representar o fluxo de interação entre o usuário e as plataformas de Inteligência Artificial avaliadas, compreendendo três etapas principais: entrada, processamento e saída das informações. Essa estrutura foi adotada para simular o processo normalmente realizado por profissionais da manutenção corretiva durante a investigação de falhas em equipamentos e sistemas industriais.

Na etapa de entrada, foram fornecidas às Inteligências Artificiais informações relacionadas aos sintomas observados e às características das falhas apresentadas pelos equipamentos. Esses dados incluíram descrições técnicas de problemas frequentemente encontrados na rotina industrial, como falhas de acionamento, aquecimento excessivo, ruídos anormais, vibrações, falhas em sensores, alarmes operacionais e outras situações compatíveis com cenários reais de manutenção corretiva.

Após o recebimento das informações, as plataformas realizaram o processamento dos dados por meio de técnicas de Processamento de Linguagem Natural (PLN), interpretando os sintomas descritos e estabelecendo relações entre os dados fornecidos e os conhecimentos disponíveis em seus modelos de linguagem. Durante essa etapa, as ferramentas buscaram identificar padrões de falhas, correlacionar possíveis causas e elaborar respostas compatíveis com o contexto técnico apresentado nos testes.

Na etapa de saída, foram analisadas as respostas fornecidas pelas Inteligências Artificiais, considerando principalmente a indicação de causas prováveis das falhas, a coerência técnica dos diagnósticos apresentados e as sugestões de situações ou falhas semelhantes que pudessem auxiliar

no processo de investigação. Essas informações foram posteriormente comparadas com os resultados esperados, permitindo avaliar a capacidade das ferramentas em atuar como apoio ao diagnóstico de falhas em manutenção corretiva industrial.

Essa arquitetura de interação permitiu reproduzir, de forma simplificada, o fluxo de análise realizado pelos profissionais de manutenção, possibilitando verificar o potencial das Inteligências Artificiais Generativas como ferramentas de suporte técnico no contexto da Indústria 4.0.

3.6 CRITÉRIOS DE EXECUÇÃO DOS TESTES

Os testes realizados neste trabalho seguiram um padrão metodológico previamente definido, com o objetivo de garantir maior uniformidade e confiabilidade nos resultados obtidos pelas Inteligências Artificiais avaliadas. Os prompts foram elaborados com base em cenários reais de falhas industriais, utilizando sintomas comuns da manutenção corretiva, como aquecimento excessivo, vibrações, falhas de acionamento, ruídos anormais e alarmes operacionais. Os testes foram elaborados a partir de situações reais da manutenção industrial, utilizando descrições técnicas compatíveis com o cotidiano dos profissionais da área.

Durante os testes, foi estabelecido um limite máximo de até três interações complementares entre o usuário e a Inteligência Artificial. Essa limitação teve como objetivo avaliar a capacidade da IA em interpretar os sintomas iniciais e apresentar diagnósticos coerentes sem depender de grande quantidade de informações adicionais. Os testes foram conduzidos utilizando linguagem técnica compatível com a rotina da manutenção industrial.

Os resultados foram classificados como satisfatórios quando a IA conseguiu identificar corretamente a causa provável da falha ou apresentar hipóteses tecnicamente coerentes com os sintomas informados. Já os resultados considerados não satisfatórios ocorreram quando a ferramenta apresentou respostas genéricas, diagnósticos incompatíveis com o problema descrito ou necessidade excessiva de informações complementares para concluir a análise.

4 TESTES E DISCUSSÃO

4.1 ANÁLISE DOS DADOS E CRITÉRIOS DE AVALIAÇÃO DOS RESULTADOS

Os resultados obtidos durante os testes foram analisados com base na coerência técnica das respostas fornecidas pelas Inteligências Artificiais avaliadas, considerando sua capacidade de identificar corretamente causas prováveis de falhas a partir dos sintomas apresentados nos cenários propostos. Além da assertividade dos diagnósticos, também foram analisados aspectos relacionados à objetividade das respostas, à necessidade de informações complementares e à

compatibilidade prática dos diagnósticos com situações reais encontradas na manutenção corretiva industrial.

Para a avaliação dos resultados, os diagnósticos fornecidos pelas plataformas foram classificados em duas categorias: satisfatórios e não satisfatórios. Foram considerados satisfatórios os casos em que a Inteligência Artificial conseguiu identificar corretamente a causa provável da falha ou apresentar hipóteses tecnicamente coerentes e compatíveis com os sintomas informados. Essa classificação também levou em consideração a capacidade da ferramenta em fornecer respostas objetivas e alinhadas às práticas adotadas pelos profissionais da área de manutenção.

Por outro lado, os resultados foram classificados como não satisfatórios quando as respostas apresentaram caráter genérico, diagnósticos incompatíveis com o problema descrito ou quando houve necessidade excessiva de informações complementares para a conclusão da análise. Também foram incluídas nessa categoria as situações em que a ferramenta não conseguiu estabelecer uma relação coerente entre os sintomas apresentados e a possível causa da falha.

Dessa forma, os critérios de avaliação adotados permitiram não apenas verificar a assertividade dos diagnósticos fornecidos pelas Inteligências Artificiais, mas também analisar sua capacidade de atuar como ferramenta de apoio ao profissional de manutenção corretiva, considerando a aplicabilidade prática das respostas no contexto industrial e sua contribuição para a tomada de decisão durante o processo de investigação de falhas.

Quadro 1 – Resultados dos testes realizados no ChatGPT

Nº	Data	Teste Realizado	Resultado Esperado	Resultado Obtido
1	02/02/2026	Falha em sensor indutivo (ausência de detecção, LED apagado)	Identificar falha no sensor ou lógica interna	Satisfatório. A IA apontou corretamente falha provável no sensor e sugeriu substituição.
2	09/02/2026	Falha em CLP com máquina parada, saídas inativas e entrada ativa	Identificar erro lógico ou travamento do CLP	Não satisfatório. A IA apresentou hipóteses genéricas e não concluiu o diagnóstico.
3	16/02/2026	Falha em sistema pneumático com cilindro sem avanço, pressão presente	Identificar falha no cilindro ou válvula direcional	Satisfatório. A IA indicou corretamente falha mecânica ou travamento interno.
4	23/02/2026	Sobrecarga em motor elétrico com desarme frequente, corrente elevada	Identificar sobrecarga ou problema mecânico acoplado	Não satisfatório. A IA não concluiu o diagnóstico e solicitou mais dados.

5	02/03/2026	Falha em contator com não acionamento, bobina energizada	Identificar falha mecânica ou elétrica no contator	Não satisfatório. A IA apresentou respostas genéricas e sem precisão diagnóstica.
6	09/03/2026	Parada em sistema pneumático de estação automatizada (cilindro sem avanço)	Identificar falha mecânica no cilindro ou obstrução na linha	Satisfatório. A IA indicou corretamente hipóteses como travamento e desgaste de vedação.
7	16/03/2026	Falha em motor trifásico com aquecimento excessivo, baixo torque	Identificar falta de fase ou desequilíbrio entre fases	Satisfatório. A IA identificou corretamente a possibilidade de falta de fase.
8	23/03/2026	Falha em sensor indutivo (até 3 observações)	Identificar falha no sensor ou lógica interna	Satisfatório. A IA identificou corretamente falha provável no sensor.
9	30/03/2026	Falha em CLP com base nas 3 observações de forma objetiva	Identificar erro lógico ou travamento do CLP	Não satisfatório. A IA apresentou hipóteses genéricas e não concluiu.
10	06/04/2026	Falha em sistema pneumático (cilindro sem avanço, pressão presente)	Identificar falha mecânica no cilindro ou válvula direcional	Satisfatório. A IA indicou corretamente falha mecânica ou travamento.
11	13/04/2026	Sobrecarga em motor elétrico com desarme frequente	Identificar sobrecarga ou problema mecânico acoplado	Não satisfatório. A IA não apresentou diagnóstico conclusivo.
12	20/04/2026	Falha em contator com bobina energizada e ausência de fechamento	Identificar falha mecânica ou elétrica no contator	Não satisfatório. A IA forneceu respostas vagas.
13	27/04/2026	Parada em sistema pneumático (cilindro sem avanço, pressão normal)	Identificar falha mecânica no cilindro ou obstrução na linha	Satisfatório. A IA sugeriu corretamente causas como travamento.
14	04/05/2026	Falha em inversor de frequência (motor não partindo, sem erro aparente)	Identificar falha de parametrização ou comando externo	Não satisfatório. A IA não conseguiu chegar a uma causa provável.

Fonte: Elaborado pelos autores (2026).

Quadro 2 – Resultados dos testes realizados no Gemini

Nº	Data	Teste Realizado	Resultado Esperado	Resultado Obtido
1	02/02/2026	Identificar falta de fase em motor trifásico	Motor esquentando, falta de força e barulho suspeito	Não satisfatório. Foram necessárias 7 informações específicas.
2	09/02/2026	Diagnóstico de desgaste em rolamento de bomba	Vibração excessiva, ruído agudo e aumento de temperatura	Satisfatório. IA identificou o desgaste e sugeriu a troca preventiva.
3	16/02/2026	Identificar vazamento em selo mecânico	Gotejamento na base, queda de pressão e odor químico	Não satisfatório. IA solicitou análise de viscosidade e pressão.

4	23/02/2026	Falha de comunicação em CLP (Rede)	LED de erro piscando, perda de pacotes, halt	Não satisfatório. IA não associou os sintomas à rede sem dados adicionais.
5	02/03/2026	Sobrecarga em esteira transportadora	Cheiro de queimado, redução de velocidade e disjuntor desarmado	Satisfatório. IA apontou corretamente sobrecarga mecânica.
6	09/03/2026	Obstrução em filtro de ar de compressor	Vácuo na entrada, aumento de ciclos de carga e superaquecimento	Não satisfatório. IA exigiu medição de vazão e diferencial de pressão.
7	16/03/2026	Desalinhamento de polias em ventilador	Vibração lateral, desgaste na correia e ruído rítmico	Não satisfatório. IA confundiu com desbalanceamento.
8	23/03/2026	Curto-circuito em bobina de contatora	Estalo forte, cheiro de ozônio e falha no fechamento	Não satisfatório. IA solicitou medição de resistência e tensão.
9	30/03/2026	Entupimento de bico injetor (Graxa)	Ponto seco, alarme de pressão alta e reservatório não esvazia	Não satisfatório. IA sugeriu falha na bomba, ignorando a obstrução.
10	06/04/2026	Fuga de corrente em resistência de estufa	Choque na carcaça, queda do DR e temperatura abaixo do setpoint	Satisfatório. IA correlacionou a queda do DR com falha de isolamento.
11	13/04/2026	Cavitação em bomba centrífuga	Som de pedras soltas, oscilação no manômetro e vibração	Não satisfatório. IA exigiu dados de NPSH disponível e temperatura.
12	20/04/2026	Falha de sensor indutivo (Posição)	Máquina parada, LED do PLC apagado e sensor riscado	Não satisfatório. IA não concluiu falha de sensor sem teste de continuidade.
13	27/04/2026	Ar no sistema hidráulico	Movimentos bruscos, espuma no reservatório e ruído 'chiado'	Não satisfatório. IA sugeriu troca de filtro, ignorando entrada de ar.
14	04/05/2026	Desgaste de escovas em motor CC	Faíscas excessivas, perda de torque e oscilação de corrente	Não satisfatório. IA solicitou verificação do comutador.

Fonte: Elaborado pelos autores (2026).

5 DISCUSSÃO

5.1 CONCLUSÃO CONFORME CHATGPT

Com base nos testes realizados no ChatGPT, observou-se equilíbrio entre os desempenhos satisfatórios e não satisfatórios, totalizando 7 diagnósticos positivos e 7 negativos, o que representa um índice de acerto de 50% nos cenários avaliados. Esse resultado demonstra que a Inteligência Artificial possui potencial relevante como ferramenta de apoio à manutenção corretiva industrial, principalmente em falhas mais diretas, com sintomas claros e bem definidos, como problemas em sensores indutivos, sistemas pneumáticos e motores trifásicos. Nesses casos, a IA foi capaz de

correlacionar corretamente os sintomas apresentados e sugerir causas prováveis coerentes com a realidade prática da manutenção industrial.

Por outro lado, os testes considerados não satisfatórios evidenciaram limitações importantes da ferramenta, especialmente em situações que exigiam análise mais aprofundada, interpretação contextual ou informações complementares. Em falhas envolvendo CLPs, contadores, inversores de frequência e sobrecargas elétricas, o ChatGPT apresentou respostas genéricas ou solicitou dados adicionais além do limite estabelecido nos testes, dificultando a obtenção de um diagnóstico conclusivo. Isso demonstra que, embora a IA apresente capacidade de auxiliar no processo de investigação de falhas, ela ainda depende significativamente da qualidade, quantidade e precisão das informações fornecidas pelo manutentor.

A análise geral dos resultados permite concluir que o ChatGPT pode ser utilizado como ferramenta de suporte técnico na manutenção corretiva, contribuindo para acelerar hipóteses iniciais de diagnóstico e auxiliar profissionais menos experientes. Entretanto, os testes também deixam claro que a IA não substitui o conhecimento técnico humano, principalmente em falhas complexas que exigem experiência prática, medições específicas e interpretação aprofundada do comportamento do equipamento. Dessa forma, conclui-se que a Inteligência Artificial possui grande potencial de evolução dentro da Indústria 4.0, podendo futuramente tornar-se uma ferramenta ainda mais precisa e confiável para apoio à manutenção industrial, desde que associada ao conhecimento técnico do profissional responsável.

5.2 CONCLUSÃO CONFORME GEMINI

Com base nos testes realizados utilizando o Gemini, observou-se predominância significativa de resultados não satisfatórios, totalizando 11 resultados negativos e apenas 3 positivos. Esse desempenho demonstra que, embora a Inteligência Artificial apresente capacidade de auxiliar em alguns cenários específicos da manutenção corretiva, sua eficiência mostrou-se limitada diante da maior parte das situações propostas nos testes. Os resultados satisfatórios ocorreram principalmente em falhas mais evidentes, como desgaste de rolamento, sobrecarga em esteira transportadora e fuga de corrente em resistência de estufa, nas quais os sintomas apresentados possuíam forte relação direta com a falha diagnosticada.

Entretanto, a maioria dos testes evidenciou dificuldades da IA em interpretar corretamente os sintomas fornecidos sem depender de informações adicionais, medições complementares ou análises mais aprofundadas. Em diversos cenários, como falhas em redes de CLP, cavitação em

bombas, obstruções, falhas em sensores e desalinhamentos mecânicos, o Gemini apresentou diagnósticos genéricos, hipóteses incorretas ou exigiu dados técnicos além do limite previamente definido para os testes. Isso demonstra uma limitação significativa na capacidade da IA em realizar correlações técnicas complexas apenas com base em sintomas iniciais apresentados pelo manutentor.

A análise final dos resultados permite concluir que o Gemini ainda apresenta baixa confiabilidade para atuar como ferramenta principal de apoio na manutenção corretiva industrial. Apesar de demonstrar potencial em diagnósticos mais simples e diretos, os altos índices de resultados não satisfatórios evidenciam que a ferramenta ainda depende fortemente de informações adicionais e de acompanhamento humano especializado para alcançar maior precisão técnica. Dessa forma, conclui-se que o uso da IA, neste contexto, deve ser considerado apenas como suporte complementar ao trabalho do manutentor, não sendo suficiente, no estágio atual de desenvolvimento dessa tecnologia, para substituir a análise técnica prática e a experiência profissional exigidas no ambiente industrial.

5.3 LIMITAÇÕES DA IA

Os testes realizados demonstraram que, apesar do potencial apresentado pelas Inteligências Artificiais na manutenção corretiva, ainda existem limitações significativas relacionadas à precisão dos diagnósticos em cenários industriais mais complexos. Em diversas situações, as ferramentas analisadas apresentaram respostas genéricas, hipóteses inconclusivas ou necessidade excessiva de informações complementares para identificar corretamente a causa das falhas. Esses resultados evidenciam que a IA ainda possui dificuldades em interpretar totalmente o contexto operacional dos equipamentos e compreender variáveis específicas presentes no ambiente industrial.

5.4 DEPENDÊNCIA DA QUALIDADE DO PROMPT

Outro fator relevante observado durante os testes foi a forte dependência da qualidade e da clareza dos prompts utilizados. A forma como os sintomas eram descritos influenciou diretamente a coerência e a precisão das respostas fornecidas pelas Inteligências Artificiais. Em alguns casos, pequenas alterações na descrição das falhas resultaram em respostas mais assertivas ou mais genéricas, demonstrando que o desempenho da IA depende significativamente da qualidade das informações fornecidas pelo usuário durante o processo de análise.

5.5 DIFICULDADES EM DIAGNÓSTICOS COMPLEXOS

As Inteligências Artificiais apresentaram melhor desempenho em falhas mais simples e diretas, principalmente quando os sintomas possuíam relação clara com a causa do problema. Entretanto, em diagnósticos mais complexos, envolvendo múltiplas variáveis, integração entre sistemas automatizados, falhas em redes industriais ou necessidade de medições específicas, observou-se maior dificuldade na obtenção de respostas precisas. Isso demonstra que a IA ainda enfrenta limitações na realização de análises técnicas aprofundadas em cenários industriais de maior complexidade.

5.6 IMPORTÂNCIA DO CONHECIMENTO HUMANO NA MANUTENÇÃO

Os resultados obtidos reforçam a importância do conhecimento técnico humano no processo de manutenção corretiva industrial. A experiência prática do manutentor continua sendo fundamental para interpretar sintomas, validar hipóteses, realizar medições e compreender o comportamento real dos equipamentos durante as falhas. Nesse contexto, a Inteligência Artificial deve ser compreendida como uma ferramenta de apoio à tomada de decisão, auxiliando o profissional na análise inicial dos problemas, mas sem substituir a capacidade analítica, a experiência prática e o raciocínio técnico humano.

5.7 LIMITAÇÕES DO ESTUDO

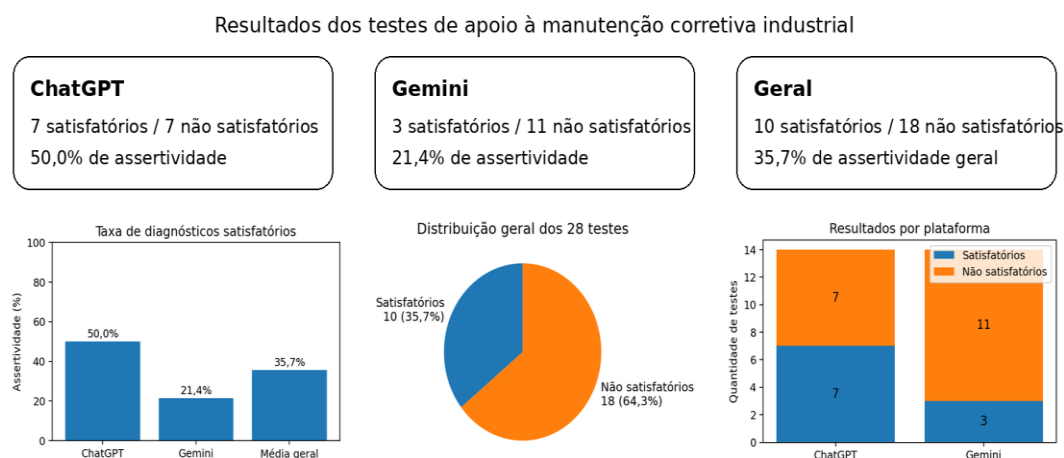
Embora os resultados obtidos tenham demonstrado potencial da Inteligência Artificial como ferramenta de apoio à manutenção corretiva industrial, este estudo apresenta algumas limitações que devem ser consideradas. A primeira refere-se ao número reduzido de testes realizados, o que limita uma análise estatística mais ampla sobre o desempenho das plataformas avaliadas. Além disso, parte da avaliação dos resultados envolveu interpretação técnica dos autores, gerando certo grau de subjetividade na classificação entre diagnósticos satisfatórios e não satisfatórios.

Outra limitação importante está relacionada ao uso de Inteligências Artificiais prontas e já disponibilizadas comercialmente, sem treinamento específico voltado exclusivamente para manutenção industrial. Dessa forma, os resultados obtidos refletem o desempenho geral das plataformas diante dos cenários apresentados, e não de modelos especializados para diagnóstico técnico industrial. Também deve ser considerada a ausência de validação externa por especialistas independentes da área de manutenção, o que poderia ampliar a confiabilidade dos critérios de avaliação utilizados neste trabalho.

6 CONCLUSÃO

A análise quantitativa dos resultados obtidos nos testes realizados demonstra diferenças relevantes no desempenho das Inteligências Artificiais avaliadas. Nos testes realizados com o ChatGPT, foram obtidos 7 resultados satisfatórios e 7 não satisfatórios, representando um índice de acerto de 50% e um índice de falha de 50%. Já nos testes realizados com o Gemini, foram registrados 3 resultados satisfatórios e 11 não satisfatórios, correspondendo a aproximadamente 21,4% de acerto e 78,6% de falhas. Os resultados consolidados podem ser observados na Figura 3.

Figura 3 – Resultados dos testes



Fonte: Imagem elaborada pelos autores com design desenvolvido pelo ChatGPT (2026).

Considerando os resultados gerais das duas tabelas em conjunto, foram realizados 28 testes ao total, sendo 10 resultados satisfatórios e 18 não satisfatórios. Dessa forma, o índice geral de acerto obtido pelas Inteligências Artificiais foi de aproximadamente 35,7%, enquanto o índice geral de resultados não satisfatórios foi de 64,3%. Esses números demonstram que, embora as ferramentas avaliadas apresentem potencial para auxiliar em diagnósticos industriais, ainda existem limitações significativas relacionadas à precisão técnica, interpretação contextual e dependência de informações complementares para alcançar diagnósticos mais confiáveis.

Com base nos resultados obtidos ao longo deste trabalho, conclui-se que a utilização de Inteligência Artificial aplicada à manutenção corretiva industrial representa uma tecnologia promissora dentro dos conceitos da Indústria 4.0, principalmente como ferramenta de apoio à tomada de decisão. Os testes demonstraram que a IA possui maior eficiência em falhas mais diretas e sintomas claramente associados ao defeito apresentado, conseguindo auxiliar na formulação de hipóteses iniciais de diagnóstico. Entretanto, em situações mais complexas, envolvendo múltiplas

variáveis, sistemas automatizados ou necessidade de análises específicas, observou-se limitação significativa na assertividade das respostas fornecidas pelas plataformas testadas.

Dessa forma, conclui-se que a Inteligência Artificial ainda não pode substituir o conhecimento técnico, a experiência prática e a capacidade analítica do profissional de manutenção industrial. Contudo, os resultados obtidos evidenciam que a evolução contínua dessas tecnologias poderá, futuramente, proporcionar sistemas mais precisos, capazes de reduzir o tempo de parada de máquinas, otimizar diagnósticos e auxiliar diretamente na produtividade industrial. Assim, a IA deve ser compreendida, no contexto tecnológico analisado neste estudo, como uma ferramenta complementar ao trabalho humano, contribuindo como suporte técnico e não como substituição integral da atuação do manutentor.

REFERÊNCIAS

AIRES, Regina Wundrack do Amaral; MOREIRA, Fernanda Kempner; FREIRE, Patricia de Sá. *Indústria 4.0: desafios e tendências para a gestão do conhecimento*. Revista E-Tech: Tecnologias para Competitividade Industrial, Florianópolis, v. 11, n. 1, p. 67-87, 2018. DOI: 10.18624/e-

tech.v11i1.988. Disponível em: <https://etech.sc.senai.br/revista-cientifica/article/view/988>. Acesso em: 8 abr. 2026.

AULETTA, Guilherme Bellido; SANTOS, José Roberto dos; CAMUSSO, Daniel; VICENTINI, Ricardo Martinez. *Governança de dados e a Indústria 4.0*. Revista Científica SENAI-SP - Educação, Tecnologia e Inovação, São Paulo, v. 1, n. 2, p. 1-12, 2023. Disponível em: <https://periodicos.sp.senai.br/index.php/rcsenaisp/article/view/23>. Acesso em: 8 abr. 2026.

CAPELLI, Alexandre. *Energia elétrica: qualidade e eficiência para aplicações industriais*. São Paulo: Érica, 2013.

CARVALHO, Gabriel Gomes de; TIOSSO, Fernando; REIS, Helena Macedo. *Indústria 4.0: adoção de tecnologias como fator de competitividade*. Revista Interface Tecnológica, Taquaritinga, v. 17, n. 2, p. 256-268, 2020. DOI: 10.31510/inf.v17i2.980. Disponível em: <https://revista.fatectq.edu.br/interfacetecnologica/article/view/980>. Acesso em: 8 abr. 2026.

CHEVTCHENKO, Sérgio F. et al. *Anomaly detection in industrial machinery using IoT devices and machine learning: a systematic mapping*. arXiv, 2023. Disponível em: <https://arxiv.org/abs/2307.15807>. Acesso em: 8 abr. 2026.

EMPRESA DE PESQUISA ENERGÉTICA (EPE). *Caderno sobre ações de eficiência energética em indústrias brasileiras*. Rio de Janeiro: EPE, [s.d.]. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/caderno-sobre-acoes-de-eficiencia-energetica-em-industrias-brasileiras>. Acesso em: 8 abr. 2026.

HERMANN, Mario; PENTEK, Tobias; OTTO, Boris. *Design principles for Industrie 4.0 scenarios*. In: HAWAII INTERNATIONAL CONFERENCE ON SYSTEM SCIENCES, 49., 2016. Proceedings [...]. Hawaii: IEEE, 2016.

JAGATHEESAPERUMAL, Senthil Kumar et al. *The Duo of Artificial Intelligence and Big Data for Industry 4.0: Review of Applications, Techniques, Challenges, and Future Research Directions*. Sensors, v. 21, n. 17, 2021.

KAGERMANN, Henning; WAHLSTER, Wolfgang; HELBIG, Johannes. *Recommendations for implementing the strategic initiative INDUSTRIE 4.0*. Frankfurt: German National Academy of Science and Engineering, 2013.

KARDEC, Alan; NASCIF, Júlio. *Manutenção: função estratégica*. 4. ed. Rio de Janeiro: Qualitymark, 2012.

LASI, Heiner et al. *Industry 4.0*. Business & Information Systems Engineering, v. 6, n. 4, p. 239-242, 2014.

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.

MATTEDE, Henrique. *Como funciona o inversor de frequência*. Mundo da Elétrica, 2022. Disponível em: <https://www.mundodaeletrica.com.br/como-funciona-o-inversor-de-frequencia/>. Acesso em: 8 abr. 2026.

PETRUZELLA, Frank D. *Electric motors and control systems*. New York: McGraw-Hill, 2013.

ROCKWELL AUTOMATION. *Produtos e soluções em automação industrial*. Disponível em: <https://www.rockwellautomation.com/pt-br/products.html>. Acesso em: 8 abr. 2026.

SANTOS, Antônio Henrique de Melo et al. *Conservação de energia: eficiência energética de equipamentos e instalações*. Itajubá: FUPAI, 2006.

SANTOS, Nilza Aparecida dos; RUGGERO, Sergio Miele; SILVA, Marcia Terra da. *Indústria 4.0 no Brasil: desafios do segmento automotivo para integração da cadeia de suprimentos*. Research, Society and Development, v. 10, n. 8, e18110817251, 2021. DOI: 10.33448/rsd-v10i8.17251. Disponível em: <https://rsdjournal.org/rsd/article/view/17251>. Acesso em: 8 abr. 2026.

SCHWAB, Klaus. *A quarta revolução industrial*. São Paulo: Edipro, 2016.

SILVA, Leandro dos Santos; SIMÕES, Marcelo Godoy. *Aplicações de inteligência artificial na manutenção industrial*. São Paulo: Blucher, 2018.

SILVA, P. *Indústria 4.0*. Brasília, DF: SENAI, 2025. Disponível em: <http://www.senai.com.br>. Acesso em: 25 nov. 2025.

SÓRIA, A. F. S.; FILIPINI, F. A. *Eficiência energética*. Curitiba: Base Editorial, 2010.

TAO, Fei et al. *Digital twin-driven product design, manufacturing and service with big data*. The International Journal of Advanced Manufacturing Technology, v. 94, p. 3563-3576, 2018.

VIANA, A. N. C. et al. *Eficiência energética: fundamentos e aplicações*. Campinas: FUPAI, 2012.

XU, Li Da; HE, Wu; LI, Shancang. *Internet of Things in Industries: A Survey*. IEEE Transactions on Industrial Informatics, v. 10, n. 4, p. 2233-2243, 2014.