



UNIVERSIDADE FEDERAL DE OURO PRETO
ESCOLA DE MINAS
DEPARTAMENTO DE ENGENHARIA MECÂNICA



RAFAEL CRUZ DO ESPÍRITO SANTO

**UMA REVISÃO BIBLIOGRÁFICA SOBRE A APLICAÇÃO DE
GÊMEOS DIGITAIS E APRENDIZADO DE MÁQUINA NA
MANUTENÇÃO PREDITIVA DE SISTEMAS MECÂNICOS**

OURO PRETO - MG

2025

RAFAEL CRUZ DO ESPÍRITO SANTO

rafaelcruzsanto@hotmail.com

**UMA REVISÃO BIBLIOGRÁFICA SOBRE A APLICAÇÃO DE
GÊMEOS DIGITAIS E APRENDIZADO DE MÁQUINA NA
MANUTENÇÃO PREDITIVA DE SISTEMAS MECÂNICOS**

Monografia apresentada ao Curso de Graduação em Engenharia Mecânica da Universidade Federal de Ouro Preto como requisito para a obtenção do título de Engenheiro Mecânico.

Orientador: Dsc. Paulo Henrique Vieira Magalhães

OURO PRETO – MG

2025

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

S237r Santo, Rafael Cruz Do Espirito.

Uma revisão bibliográfica sobre a aplicação de gêmeos digitais e aprendizado de máquina na manutenção preditiva de sistemas mecânicos. [manuscrito] / Rafael Cruz Do Espirito Santo. - 2025.
54 f.: il.: color., tab..

Orientador: Prof. Dr. Paulo Henrique Vieira Magalhães Magalhães.
Monografia (Bacharelado). Universidade Federal de Ouro Preto.
Escola de Minas. Graduação em Engenharia Mecânica .

1. Manutenção - Manutenção preditiva. 2. Aprendizado do computador. 3. Tecnologia de ponta - Gêmeos digitais. I. Magalhães, Paulo Henrique Vieira Magalhães. II. Universidade Federal de Ouro Preto. III. Título.

CDU 621

Bibliotecário(a) Responsável: Maristela Sanches Lima Mesquita - CRB-1716



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE OURO PRETO
REITORIA
ESCOLA DE MINAS
DEPARTAMENTO DE ENGENHARIA MECANICA



FOLHA DE APROVAÇÃO

Rafael Cruz do Espírito Santo

Uma revisão bibliográfica sobre a aplicação de gêmeos digitais e aprendizado de máquina na manutenção preditiva de sistemas mecânicos

Monografia apresentada ao Curso de Engenharia Mecânica da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Engenheiro Mecânico

Aprovada em 29 de Agosto de 2025

Membros da banca

Dr. - Paulo Henrique Vieira Magalhães - Orientador(a) (Universidade Federal de Ouro Preto)
Dr. - Edson Alves Figueira Júnior - (Universidade Federal de Ouro Preto)
MSc. - Sávio Sade Tayer - (Universidade Federal de Ouro Preto)

Prof. Dr. Paulo Henrique Vieira Magalhães, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 05/09/2025



Documento assinado eletronicamente por **Paulo Henrique Vieira Magalhaes, PROFESSOR DE MAGISTERIO SUPERIOR**, em 05/09/2025, às 08:41, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0973685** e o código CRC **E19A4AF4**.

Para a minha família.

AGRADECIMENTO

Agradeço a minha família pelo incentivo ao estudo.

Aos meus amigos pelas parcerias.

Ao meu orientador, Paulo Henrique, pela orientação neste trabalho.

“A melhor maneira de prever o futuro é criá-lo”.

Peter Drucker

RESUMO

Este trabalho apresenta uma revisão bibliográfica sobre a aplicação integrada de gêmeos digitais e técnicas de aprendizado de máquina na manutenção preditiva de sistemas mecânicos. A pesquisa analisou artigos científicos recentes para compreender como essas tecnologias têm sido empregadas na Indústria 4.0. Os gêmeos digitais são elementos de software capazes de replicar ativos físicos em ambientes virtuais, possibilitando simulação e monitoramento contínuo em tempo real. Já os algoritmos de aprendizado de máquina, sobretudo os supervisionados, oferecem alta precisão na detecção de padrões de falhas e na estimativa da vida útil remanescente. A integração dessas abordagens mostrou benefícios relevantes, como a redução de paradas não planejadas, aumento da confiabilidade, eficiência operacional e suporte à tomada de decisão baseada em dados. Entretanto, foram identificados desafios como a escassez de dados rotulados, a complexidade de implementação e a necessidade de infraestrutura digital robusta. Conclui-se que, apesar das limitações, a combinação de gêmeos digitais e aprendizado de máquina representa uma solução inovadora e promissora para a engenharia de manutenção, contribuindo significativamente para o avanço da Indústria 4.0.

Palavras-chave: Gêmeos digitais. Aprendizado de máquina. Manutenção preditiva. Indústria 4.0. Sistemas mecânicos.

ABSTRACT

This work presents a literature review on the integrated application of digital twins and machine learning techniques in the predictive maintenance of mechanical systems. The research analyzed recent scientific articles to understand how these technologies have been employed in Industry 4.0. Digital twins are software pieces capable of replicating physical assets in virtual environments, enabling real-time simulation and continuous monitoring. Meanwhile, machine learning algorithms, especially supervised ones, offer high accuracy in detecting failure patterns and estimating remaining useful life. The integration of these approaches has demonstrated significant benefits, such as reduced unplanned downtime, increased reliability, improved operational efficiency, and support for data-driven decision-making. However, challenges were identified, including the scarcity of labeled data, implementation complexity, and the need for robust digital infrastructure. It is concluded that, despite these limitations, the combination of digital twins and machine learning represents an innovative and promising solution for maintenance engineering, contributing significantly to the advancement of Industry 4.0.

Key-words: Digital twins. Machine learning. Predictive maintenance. Industry 4.0. Mechanical systems.

LISTA DE FIGURAS

Figura 1 – Exemplo de um modelo de Digital Twin e seus processos.....	25
Figura 2 – Modelo CRISP-DM com seis fases e inter-relações cíclicas.....	27
Figura 3 – Fluxograma do funcionamento de modelos supervisionados.....	29
Figura 4 – Fluxo de coleta, processamento e aplicação de dados no gêmeo digital.....	45

LISTA DE TABELAS

Tabela 1 – Progressão tecnológica e impactos nas estratégias de manutenção ao longo das revoluções industriais.....	6
Tabela 2 – Tipos de aprendizado supervisionado (adaptado de IBM, 2025).....	13
Tabela 3 – Com variáveis e indicadores que serão usados no trabalho.....	19
Tabela 4 – Artigos Seleccionados para Revisão.....	21
Tabela 5 – Algoritmos utilizados descritos nos artigos e seus benefícios.....	23

LISTA DE SIGLAS

IA	Inteligência Artificial
IoT	Internet das Coisas (<i>Internet of Things</i>)
DT	Gêmeo Digital (<i>Digital Twin</i>)
ML	Aprendizado de Máquina (<i>Machine Learning</i>)
RUL	Vida Útil Remanescente (<i>Remaining Useful Life</i>)
SVM	Máquinas de Vetores de Suporte (<i>Support Vector Machines</i>)
KNN	K-Vizinhos Mais Próximos (<i>K-Nearest Neighbors</i>)
ANN	Redes Neurais Artificiais (<i>Artificial Neural Networks</i>)
LSTM	<i>Long Short-Term Memory</i>
CRISP-DM	<i>Cross Industry Standard Process for Data Mining</i>
RFID	Identificação por Rádio Frequência (<i>Radio Frequency Identification</i>)
DBSCAN	<i>Density-Based Spatial Clustering of Applications with Noise</i>

SUMÁRIO

1 INTRODUÇÃO	15
1.1 Formulação do Problema	15
1.2 Justificativa	17
1.3 Objetivos	18
1.3.1 Geral	18
1.3.2 Específicos	18
1.4 Estrutura do Trabalho	19
2 REVISÃO BIBLIOGRÁFICA	20
2.1 Manutenção Mecânica	20
2.1.1 Manutenção Corretiva	20
2.1.2 Manutenção Preventiva	21
2.1.3 Manutenção Preditiva	21
2.2 Gêmeos Digitais: Definição, Arquitetura e Aplicações	24
2.3 Aprendizado de Máquina: Fundamentos e Técnicas	27
2.3.1 Aprendizado de Máquina Supervisionado	28
2.3.2 Aprendizado de Máquina Não Supervisionado	31
2.3.3 Dificuldades de implementação	32
2.4 Integração entre Gêmeos Digitais e Aprendizado de Máquina	32
3 METODOLOGIA	34
3.1 Tipo de Pesquisa	34
3.2 Materiais e Métodos	35
3.3 Variáveis e Indicadores	35
3.4 Instrumento de Coleta de Dados	36
3.5 Tabulação dos Dados	37
3.6 Considerações Finais do Capítulo	37
4 RESULTADOS E DISCUSSÕES	38
4.1 Principais Algoritmos de Aprendizado de Máquina	40
4.2 Arquiteturas Mais Utilizadas	42
4.3 Benefícios Observados	42
4.4 Desafios e Limitações	43
4.5 Estudo de Caso	44
5 CONCLUSÃO E RECOMENDAÇÕES	47
5.1 Conclusão	47
5.2 Recomendações	48
REFERÊNCIA BIBLIOGRÁFICA	49

1 INTRODUÇÃO

1. 1 Formulação do Problema

A manutenção mecânica é essencial para garantir a confiabilidade dos sistemas e minimizar falhas nos processos industriais (RAGHAVIAH; HARIPRASAD, 2019). A manutenção preditiva possui o objetivo de prever falhas e agir antes que elas ocorram. É uma categoria muito relevante da manutenção mecânica, e se mostra mais presente conforme surgem novos equipamentos que permitam avaliação confiável das instalações e sistemas operacionais em funcionamento, o que permite a operação contínua por maior tempo possível (KARDEC; NASCIF, 1998).

Um marco que transforma a maneira de enxergar a manutenção preditiva é a Quarta Revolução Industrial. Segundo Schwab (2016), a Indústria 4.0 teve início na virada do século. Baseia-se na revolução digital e promove a integração entre o mundo real e digital, sendo caracterizada por uma internet mais ubíqua e móvel, por sensores menores, mais poderosos e acessíveis, além da incorporação da inteligência artificial e do aprendizado de máquina em seus processos.

A integração entre os mundos físico e digital proporcionada pela Indústria 4.0 abre novas possibilidades para a manutenção preditiva. Nesse contexto, surge o conceito de gêmeo digital (*digital twin*), uma representação virtual de um objeto físico que permite cobrir todo o ciclo de vida do ativo e utilizar dados em tempo real captados por sensores instalados no equipamento, a fim de replicar seu funcionamento e monitorar continuamente suas operações (AIVALIOTIS *et al.*, 2019).

Os gêmeos digitais podem ser desenvolvidos de modo a replicar muitos itens do mundo real, desde peças únicas de equipamento em uma fábrica até instalações completas, como turbinas eólicas e até cidades inteiras. Essa tecnologia permite supervisionar a performance de um ativo, identificar possíveis falhas e tomar decisões mais bem informadas sobre manutenção e ciclo de vida (AWS, 2025).

Desse modo, o monitoramento do mundo real, a grande quantidade de dados gerados por empresas e a integração com aprendizado de máquina se tornam aliados para gerar previsões cada vez mais assertivas. Para tomar melhores decisões de negócios, as organizações precisam interpretar grandes volumes de dados complexos, e, para suprir a insuficiência das ferramentas tradicionais, o aprendizado de máquina (*machine learning*) surge para gerar *insights* com mais agilidade, acompanhando o crescimento dos dados e, reduzindo, de forma escalável, o tempo gasto pelos colaboradores (GOOGLE CLOUD, 2025).

Nesse contexto, o uso do gêmeo digital, aliado ao aprendizado de máquina auxilia na previsão de falhas, oferecendo uma ferramenta moderna para a uma redução de custos e uma previsão mais assertiva na manutenção mecânica. No entanto, até que ponto essa tecnologia tem sido efetivamente aplicada na prática industrial? Quais são seus limites, potencialidades e desafios técnicos? E, sobretudo, de que forma a literatura especializada tem explorado essa convergência entre físico e digital na otimização de sistemas mecânicos?

Diante do exposto, esse trabalho busca responder à seguinte pergunta:

Como a literatura especializada tem abordado o uso integrado de aprendizado de máquina e gêmeos digitais na manutenção preditiva em sistemas mecânicos?

1.2 Justificativa

Segundo Schwab (2016), a Indústria 4.0 é marcada pela convergência entre tecnologias digitais, físicas e biológicas, transformando a forma como vivemos, trabalhamos e nos relacionamos. Caracterizada pela integração entre tecnologias digitais, inteligência artificial (IA), Internet das Coisas (IoT) e sistemas ciber-físicos. Essa nova era demanda mudanças estruturais na gestão dos ativos físicos e nos métodos de manutenção empregados nas indústrias (SAKURAI; ZUCHI, 2018).

De acordo com Mobley (2002), estratégias baseadas em intervalos fixos de manutenção — mesmo preventivas — podem ser ineficazes ou dispendiosas, pois não consideram a condição real dos equipamentos. Já a manutenção preditiva, ao monitorar o estado operacional e intervir apenas quando necessário, permite reduzir falhas inesperadas e melhorar a eficiência operacional. Em contrapartida, a IA está transformando significativamente o setor industrial: dados recentes mostram que esta tecnologia tem o potencial de aumentar as margens de lucro em 38% e poderá contribuir para o crescimento de 16 setores diferentes em aproximadamente US\$14 trilhões até 2035 (TRACTIAN, 2025).

Adicionalmente ao uso de IA, os gêmeos digitais viabilizam ainda mais a simulação, monitoramento contínuo e a otimização de sistemas mecânicos industriais (TAO *et al.*, 2019). Em conjunto, essas soluções se mostram fundamentais para a manutenção preditiva, sendo capazes de antecipar falhas em equipamentos, reduzir custos operacionais, aumentar a confiabilidade, otimizar processos e apoiar a tomada de decisões com base em seus dados (TONIELLO, 2024).

Sendo assim, este trabalho propõe-se a realizar uma análise de literatura com o objetivo de identificar e discutir os benefícios e desafios associados à prevenção de falhas na engenharia mecânica, a partir das metodologias modernas apresentadas.

A metodologia adotada envolveu a catalogação dos artigos e documentos científicos selecionados, registrando informações como título, autoria, ano de publicação, objetivos, metodologias empregadas, tecnologias aplicadas e principais resultados. Em seguida, os estudos foram classificados por categorias temáticas, considerando os algoritmos de aprendizado de máquina utilizados, o grau de integração com gêmeos digitais, os benefícios observados e as limitações apontadas. Para apoiar a análise, foram construídas tabelas-resumo e quadros comparativos, com o objetivo de identificar padrões, tendências e lacunas na

literatura. Quando pertinente, os dados foram visualizados por meio de tabelas, facilitando a discussão crítica e a síntese das melhores práticas descritas nos estudos revisados.

Espera-se, com o presente trabalho, contribuir tanto para o avanço da literatura acadêmica quanto para a prática industrial, oferecendo subsídios teóricos e reflexões aplicadas sobre o uso integrado de tecnologias emergentes nesse campo.

1.3 Objetivos

1.3.1 Geral

Analisar, por meio de uma revisão bibliográfica, a aplicação integrada de Gêmeos Digitais e Aprendizado de Máquina na manutenção preditiva de sistemas mecânicos, identificando as principais abordagens, benefícios e desafios documentados na literatura científica.

1.3.2 Específicos

- Conceituar os fundamentos da Manutenção Preditiva, dos Gêmeos Digitais e do Aprendizado de Máquina no contexto da Indústria 4.0;
- Mapear as principais arquiteturas e modelos de Gêmeos Digitais empregados para a simulação e o monitoramento de sistemas mecânicos;
- Identificar os algoritmos de Aprendizado de Máquina mais recorrentes na literatura para o diagnóstico de falhas e a predição da vida útil remanescente de componentes mecânicos;
- Levantar revisões bibliográficas, estudos de caso e aplicações práticas documentadas que exemplificam a integração entre gêmeos digitais e aprendizado de máquina;
- Apontar os benefícios e limitações relatados na literatura sobre a integração entre gêmeos digitais e aprendizado de máquina.

1.4 Estrutura do Trabalho

O trabalho está organizado em cinco capítulos, que estão descritos abaixo:

O Capítulo 1 apresenta a introdução ao tema, contemplando a formulação do problema, a justificativa para a realização do estudo e a definição dos objetivos geral e específicos. O Capítulo 2 é dedicado à fundamentação teórica, abordando os principais conceitos relacionados à manutenção, gêmeos digitais, aprendizado de máquina e à integração dessas tecnologias em sistemas mecânicos. No Capítulo 3, descreve-se a metodologia adotada, com ênfase nos critérios de seleção dos artigos, na definição das variáveis de análise e nos procedimentos utilizados para a comparação entre os estudos selecionados. O Capítulo 4 apresenta e discute os principais resultados obtidos a partir da revisão bibliográfica, com base em uma análise crítica e comparativa das evidências disponíveis na literatura. Por fim, o Capítulo 5 expõe as conclusões do trabalho, além de sugerir recomendações para pesquisas futuras na área.

2 REVISÃO BIBLIOGRÁFICA

Este capítulo apresenta a fundamentação teórica relacionada à pesquisa, abordando conceitos essenciais para a compreensão da integração de gêmeos digitais com aprendizado de máquina na manutenção preditiva de sistemas mecânicos. Serão discutidos os principais aspectos desses conceitos e a integração dessas tecnologias na otimização de processos industriais.

2.1 Manutenção Mecânica

A manutenção mecânica pode ser entendida como o conjunto de atividades técnicas destinadas a garantir a confiabilidade, disponibilidade e segurança de equipamentos e sistemas, assegurando sua operação contínua e eficiente. Segundo Kardec e Nascif (1998), a manutenção não deve ser vista apenas como reparo, mas como uma função estratégica integrada ao processo produtivo.

Mobley (2002) destaca que a manutenção mecânica é responsável por prolongar a vida útil dos ativos, reduzir custos operacionais e minimizar falhas inesperadas. Nesse mesmo sentido, Xenos (2004) reforça que a gestão da manutenção deve estar alinhada ao planejamento estratégico da empresa, garantindo não apenas a recuperação de falhas, mas também a otimização dos recursos disponíveis. Dessa forma, a manutenção assume papel essencial na competitividade das organizações, pois impacta diretamente a produtividade, a qualidade e a segurança dos processos industriais.

2.1.1 Manutenção Corretiva

A manutenção corretiva caracteriza-se pela intervenção realizada após a ocorrência de falha ou pane em determinado equipamento. É, portanto, uma abordagem reativa, cuja atuação visa restaurar o funcionamento normal do ativo após a interrupção de sua operação. De acordo com Kardec e Nascif (2002), esse tipo de manutenção é o mais simples e tradicional, porém tende a gerar custos elevados em função das paradas não planejadas e do risco de danos secundários a outros componentes.

Apesar de suas desvantagens, a manutenção corretiva ainda é aplicável em situações em que o custo da falha é baixo ou quando a probabilidade de ocorrência é reduzida. Xenos (2004) complementa que, em sistemas de baixa criticidade, a manutenção corretiva pode ser economicamente viável, desde que monitorada e devidamente registrada para embasar futuras estratégias de confiabilidade.

2.1.2 Manutenção Preventiva

A manutenção preventiva, por sua vez, busca evitar a ocorrência de falhas por meio de inspeções e intervenções programadas em intervalos regulares de tempo ou ciclos de operação. Segundo Kardec e Nascif (1998), trata-se de uma evolução em relação à manutenção corretiva, pois reduz a probabilidade de falhas inesperadas, aumentando a confiabilidade operacional.

Esse tipo de manutenção é geralmente planejado com base em recomendações de fabricantes, históricos de falhas ou parâmetros técnicos. No entanto, Mobley (2002) ressalta que a manutenção preventiva pode ser onerosa se aplicada de forma indiscriminada, já que nem sempre considera a real condição do equipamento, ocasionando substituição prematura de componentes e desperdício de recursos.

Xenos (2004) acrescenta que a eficácia da manutenção preventiva depende da qualidade do planejamento e da correta definição de intervalos de inspeção. A falta de alinhamento entre frequência de intervenção e criticidade dos ativos pode transformar a manutenção preventiva em um processo burocrático e de alto custo.

2.1.3 Manutenção Preditiva

Ao longo das últimas décadas, a manutenção mecânica evoluiu significativamente. Com essa transformação, surge a manutenção preditiva, que permite que organizações prevejam falhas e programem a manutenção quando e onde houver necessidade imediata, fornecendo as informações necessárias para a obtenção do máximo desempenho dos ativos, sem forçá-los nem colocá-los em risco de dispendiosas panes (SAP, 2025).

A Tabela 1 apresenta a evolução dos recursos tecnológicos nas revoluções industriais e os impactos positivos no aumento da eficácia dos equipamentos.

Tabela 1 – Progressão tecnológica e impactos nas estratégias de manutenção ao longo das revoluções industriais.

Revolução industrial	Indústria 1.0	Indústria 2.0	Indústria 3.0	Indústria 4.0
Inovação tecnológica	Mecanização, energia a vapor	Produção em massa, energia elétrica	Automação, poder computacional	Soluções digitais, sistemas de IoT na nuvem
Política de manutenção	Manutenção reativa	Manutenção preventiva	Manutenção preventiva	Manutenção preditiva
Tecnologia	Inspeção visual	Inspeção instrumental	Monitoramento por sensores	Deteção de dados e funções analíticas preditivas
Eficácia geral dos equipamentos	50%	50%-70%	70 a 90%	90%

Fonte: Adaptado de Deloitte *apud* SAP (n.d.).

A Tabela 1 apresenta a evolução das práticas de manutenção industrial ao longo das quatro revoluções industriais, e mostra a relação entre os avanços tecnológicos, as políticas de manutenção adotadas e a eficácia geral dos equipamentos. Na Indústria 1.0, marcada pela mecanização e pelo uso da energia a vapor, predominava uma abordagem reativa, em que as falhas eram tratadas somente após sua ocorrência. A inspeção era visual, o que limitava a capacidade de previsão e intervenção preventiva, resultando em uma eficácia operacional em torno de 50%. Nesse contexto, a manutenção ocorria com baixa previsibilidade, muitas vezes causando longas paradas e custos elevados.

Com o advento da Indústria 2.0, impulsionada pela eletrificação e pela produção em massa, surgiu a manutenção preventiva, orientada por cronogramas e ciclos fixos de inspeção. A utilização de instrumentos de medição e diagnóstico permitiu identificar desgastes com maior antecedência, ainda que de forma não automatizada. Isso resultou em um avanço considerável da confiabilidade dos ativos, com eficácia variando entre 50% e 70%, dependendo do grau de controle adotado pelas organizações.

A Indústria 3.0 trouxe um salto tecnológico importante com a introdução da automação e do poder computacional. A incorporação de sensores e sistemas de controle possibilitou o monitoramento em tempo real de variáveis críticas, como temperatura, vibração e pressão. Essa evolução ampliou a capacidade de detectar falhas incipientes, tornando a manutenção mais precisa e direcionada, com eficácia geral entre 70% e 90%. Embora a

política de manutenção ainda fosse predominantemente preventiva, o uso de dados já começava a influenciar a tomada de decisão técnica.

Por fim, na Indústria 4.0, o avanço das tecnologias digitais, como Internet das Coisas (IoT), gêmeos digitais, análises preditivas e inteligência artificial, consolidou a manutenção preditiva como modelo ideal. Os sistemas são agora capazes de coletar, integrar e analisar grandes volumes de dados operacionais em tempo real, gerando diagnósticos precisos e previsões sobre o comportamento futuro dos ativos. Com isso, as empresas conseguem atuar de forma proativa, antes que uma falha ocorra, alcançando uma eficácia de até 90% ou mais, com maior segurança, disponibilidade e menor custo de operação.

Nesse contexto, é inevitável mencionar o papel da inteligência artificial. De acordo com a Oracle (2025), a IA está impulsionando a manutenção em diversos aspectos, dentre os quais se destacam:

- **Monitoramento preditivo e detecção inteligente de falhas:** a IA coleta e analisa dados em tempo real, combinando informações de sensores e históricos para identificar falhas iminentes, como superaquecimento, vibração excessiva ou variações de voltagem. Diferentemente dos métodos tradicionais baseados em regras fixas, os algoritmos modernos detectam desvios sutis e padrões de anomalias ainda não mapeados, permitindo intervenções proativas e evitando paradas inesperadas. Além disso, o monitoramento contínuo possibilita a manutenção baseada na real condição dos equipamentos, em vez de cronogramas fixos;
- **Priorização e programação da manutenção:** a IA é capaz de reorganizar, em tempo real, prioridades e cronogramas de manutenção com base na criticidade das falhas previstas e nas consequências da inação. Isso torna as ações mais eficientes e melhor alinhadas aos objetivos operacionais;
- **Otimização de energia:** a IA ajuda a identificar perdas de energia e propõe intervenções que reduzem o desperdício. Um exemplo é o uso de gêmeos digitais pela Ford, que permite reduzir o consumo energético nas fábricas por meio de monitoramento e simulações inteligentes.;
- **Visão computacional:** Com o apoio de câmeras e algoritmos de IA, é possível detectar visualmente falhas como desalinhamento, desgaste ou ausência de peças. As imagens geradas complementam os dados de sensores, enriquecendo o diagnóstico e agilizando a resolução de problemas.

Segundo Schuck (2025), a partir da coleta de dados no ambiente físico, a IA ajuda a tomar decisões mais rápidas e seguras e as transforma em modelos virtuais conhecidos como gêmeos digitais, conseguindo assim dados concretos e mais segurança. Com isso, a manutenção preditiva atualmente dispõe de uma ampla gama de ferramentas modernas que auxiliam na tomada de decisões.

2.2 Gêmeos Digitais: Definição, Arquitetura e Aplicações

O conceito de gêmeos digitais foi introduzido no início dos anos 2000, com o objetivo de possibilitar o monitoramento, a previsão de falhas e o apoio à tomada de decisões em tempo real (GRIEVES; VICKERS, 2017). Desde então, essa tecnologia evoluiu e tornou-se participante ativos em negócios, com dados precisos para monitoramento, controle e previsão passou a ser aplicada em diversos setores industriais, especialmente com o avanço da Indústria 4.0 (SCHWAB, 2016).

Segundo Tao *et al.* (2019), o ponto central dos gêmeos digitais é a construção de uma réplica digital para uma entidades físicas, a fim de simular e refletir seus estados e comportamentos por meio de modelagem e análise de simulação, para assim utilizar os dados coletados para prever e controlar seus estados e comportamentos futuros por meio de feedback.

A Figura 1, reproduzida de Tao *et al.*, apresenta a arquitetura de um gêmeo digital aplicada ao contexto da manufatura, destacando a interação entre o mundo físico e o mundo virtual.




Figura 1 – Exemplo de um modelo de Digital Twin e seus processos.
Fonte: Traduzido de Tao *et al.* (2019).

A análise da Figura 1 pode ser dividida em três etapas principais, a fim de facilitar a compreensão da arquitetura do gêmeo digital no contexto citado. Cada uma dessas etapas evidencia um componente específico da interação entre o mundo físico e o mundo virtual, como a coleta de dados, o processamento em ambiente digital e a retroalimentação do sistema real. A seguir, apresentam-se esses três passos de forma detalhada citados por Tao *et al.* (2019), permitindo uma visualização mais clara do funcionamento integrado da tecnologia.

- No mundo físico, tem-se uma entidade física — como um robô industrial — equipada com sensores, sistemas embarcados e dispositivos RFID (*Radio frequency identification*), responsáveis pela coleta de dados em tempo real sobre seu funcionamento, estado e ambiente operacional;
- Esses dados são transmitidos para o mundo virtual, onde são processados e integrados a um conjunto de modelos digitais que representam diferentes aspectos da entidade física. Entre esses modelos, destacam-se: o modelo geométrico, que representa a forma e a estrutura do sistema; o modelo estrutural, que descreve os componentes internos e sua disposição; o modelo de materiais, que caracteriza as propriedades dos materiais envolvidos; e o modelo de regras, que define os comportamentos operacionais. Complementando essa estrutura, há ainda o modelo de processo, que engloba parâmetros como métodos de produção, usinagem e tolerâncias, e o modelo evolutivo, que permite análises preditivas com base em dados históricos e em tempo real;
- Os dados capturados são encaminhados a um módulo de processamento e fusão, no qual são tratados e transformados em informações úteis para a tomada de decisão. Este processo estabelece um ciclo contínuo e dinâmico de comunicação entre os mundos físico e virtual, permitindo a otimização de processos, predição de falhas, redução de custos operacionais e melhoria da eficiência produtiva.

Os gêmeos digitais são criados a partir da integração de diversas fontes de dados que representam com precisão suas contrapartes do mundo real. Essa integração combina informações em uma dimensão e modelos de duas ou três dimensões. Essa base tecnológica viabiliza avanços significativos em atividades como *design*, planejamento, simulação e monitoramento remoto em tempo real, com sensores e dispositivos IoT fornecendo dados

atualizados que mantêm os gêmeos digitais precisos e promovem uma interação dinâmica entre os mundos físico e digital (NVIDIA, 2025).

A utilização dessa tecnologia tem se mostrado promissora na área da manutenção preditiva, principalmente em sistemas mecânicos complexos. Segundo Toniello (2024), os gêmeos digitais utilizam tecnologias como IoT para funcionar de forma eficiente, com sensores coletando dados em tempo real e algoritmos de aprendizado de máquina analisando essas informações para identificar padrões, prever falhas e otimizar processos, criando um ambiente dinâmico e em constante melhoria operacional.

Gêmeos digitais estão sendo cada vez mais relevantes por permitirem a integração entre os mundos físico e virtual, impulsionados por tecnologias como aquisição e comunicação de dados. Essa integração ciber-física, reforçada por análises de *big data*, é fundamental para a manufatura inteligente, permitindo o processamento de grandes volumes de dados ao longo do ciclo de vida dos produtos (TAO *et al.*, 2019).

Na manufatura replicam virtualmente processos, equipamentos e operações, permitindo monitoramento em tempo real, simulação de cenários e validação de mudanças antes da implementação. Com isso, é possível identificar gargalos, otimizar o uso das máquinas, aplicar manutenção preditiva e melhorar o planejamento da produção, reduzindo o tempo de inatividade e o comissionamento (SIEMENS, 2021).

Por fim, essa tecnologia permite simular cenários antes da aplicação real, reduzindo custos e riscos, com benefícios visíveis como a economia de recursos ao evitar investimentos em projetos ineficazes, a melhoria da eficiência por meio da documentação dos processos, a otimização contínua com o uso de inteligência artificial e a representação digital que aprimora a experiência e apoia a tomada de decisões (TOTVS, 2024).

2.3 Aprendizado de Máquina: Fundamentos e Técnicas

O aprendizado de máquina é um ramo da inteligência artificial que permite que sistemas computacionais aprendam a partir de dados para identificar padrões e tomar decisões sem instruções explícitas para cada situação, seu uso é cada vez mais comum em diversas áreas como finanças, saúde, telecomunicações, manufatura e ciências (ALPAYDIN, 2020).

O processo de desenvolvimento em aprendizado de máquina pode ser estruturado em seis etapas principais conforme o modelo CRISP-DM (*Cross-Industry Standard Process for*

Data Mining), essas etapas são: entendimento do negócio, entendimento dos dados, preparação dos dados, modelagem, avaliação e implantação (SHEARER, 2000). O modelo propõe uma abordagem iterativa, na qual cada fase contribui para a construção de soluções mais eficazes com base em dados, sendo amplamente utilizado em projetos reais por sua flexibilidade e aplicabilidade em diferentes setores (SCHRÖER *et al.*, 2019).

A figura 2 apresenta um fluxograma com as etapas presentes no modelo CRISP-DM.




Figura 2 – Modelo CRISP-DM com seis fases e inter-relações cíclicas.
Fonte: Atomatik.net (s.d.).

A Figura 2 ilustra o ciclo de vida do processo de mineração de dados segundo a metodologia CRISP-DM. Esse modelo destaca que o desenvolvimento de soluções baseadas em dados não ocorre de forma linear, mas sim iterativa, permitindo revisões e ajustes contínuos conforme novos *insights* são obtidos. A interação entre as fases especialmente entre a avaliação, modelagem e preparação dos dados reforça a natureza exploratória e dinâmica dos projetos de ciência de dados, comum em aplicações de aprendizado de máquina e manutenção preditiva.

Segundo Grus (2016), os modelos de aprendizado de máquina podem ser classificados em supervisionados — nos quais o conjunto de dados contém rótulos com as respostas

corretas usadas durante o treinamento — e não supervisionados, em que esses rótulos não estão disponíveis, e o modelo deve identificar padrões ou estruturas nos dados de forma autônoma. Embora existam outras definições e abordagens em *machine learning*, este trabalho abordará com maior profundidade essas duas categorias.

2.3.1 Aprendizado de Máquina Supervisionado

O aprendizado supervisionado é uma das abordagens mais comuns dentro do campo de *machine learning*, especialmente em tarefas de classificação, nas quais o objetivo é ensinar o sistema a identificar padrões com base em dados rotulados, isto é, entradas associadas a saídas previamente conhecidas. Essa metodologia permite que o modelo aprenda a mapear corretamente os dados de entrada para os resultados esperados, tornando-se eficaz em contextos em que a categorização é clara e bem definida (ZHANG, 2010).

Como ilustrado na Figura 3, o diagrama apresenta o processo de aprendizado supervisionado.




Figura 3 – Fluxograma do funcionamento de modelos supervisionados.
Fonte: Matsumura (2020).

A Figura 3 apresenta o fluxo de funcionamento do algoritmo supervisionado é dividido em duas fases: o treinamento do modelo com exemplos rotulados e a inferência sobre

novos dados inferência (aplicação do modelo a novos exemplos), basicamente o modelo é treinado com dados históricos e a previsão a partir dos novos dados é gerada com base nos treinamentos antigos.

A Tabela 2 apresenta alguns algoritmos que utilizam o método supervisionado, acompanhados de um resumo das suas principais características e funcionamento.

Tabela 2 – Tipos de aprendizado supervisionado

Método	Tipo	Descrição Resumida	Usos Comuns
Naive Bayes	Classificação	Assume independência entre variáveis e usa teorema de Bayes para calcular probabilidades.	Classificação de texto, spam, recomendações
Regressão Linear	Regressão	Modela relação linear entre variável dependente contínua e uma ou mais variáveis independentes.	Previsões contínuas (ex: vendas, preços)
Regressão Logística	Classificação	Modela probabilidades para variáveis dependentes categóricas binárias.	Classificação binária (ex: spam, diagnóstico)
Máquina de Vetores de Suporte (SVM)	Classificação (e regressão)	Separa classes com hiperplano que maximiza a margem entre grupos de dados.	Reconhecimento facial, fraude, imagens
K-Vizinhos Mais Próximos (KNN)	Classificação (e regressão)	Classifica pontos com base na proximidade dos vizinhos mais próximos.	Reconhecimento de padrões, recomendação
Floresta Aleatória	Classificação e Regressão	Combina várias árvores de decisão para melhorar a precisão e reduzir a variância.	Diagnóstico médico, previsão de crédito
ANN (Artificial Neural Network / Rede Neural Artificial)	Supervisão: Classificação / Regressão	Modelo de rede neural feedforward que processa entradas por camadas de neurônios, ajustando pesos com base em entradas e saídas conhecidas para aprender padrões.	Classificação de imagens, previsão de preços, reconhecimento de voz, análise de dados financeiros.
RNN (Rede	Supervisão:	Rede neural projetada para	Tradução automática,

Neural Recorrente)	Classificação / Regressão	processar dados sequenciais, mantendo informações de entradas anteriores através de um estado oculto.	análise de sentimentos, reconhecimento de fala, previsão de séries temporais.
LSTM (Long Short-Term Memory)	Supervisão: Classificação / Regressão	Variante das RNNs que resolve o problema do desvanecimento de gradiente, permitindo aprender dependências de longo prazo em sequências.	Detecção de anomalias em séries temporais, tradução automática, modelagem de linguagem, geração de texto.

Fonte: Adaptado de IBM (2025)

A Tabela 2 apresenta um panorama de alguns dos principais algoritmos de aprendizado supervisionado, descrevendo suas características centrais, tipos de tarefas que executam e aplicações mais comuns. Esses algoritmos são amplamente utilizados em contextos industriais para previsão de falhas, classificação de eventos e tomada de decisão automatizada e a sua escolha do algoritmo depende, entre outros fatores, do tipo de variável a ser prevista, da natureza dos dados e da complexidade do problema.

O algoritmo Naive Bayes, por exemplo, é um método de classificação baseado no teorema de Bayes, que parte da suposição de independência entre variáveis (MITCHELL, 1997).

A Regressão Linear, por sua vez, é utilizada para tarefas de regressão, ou seja, quando o objetivo é prever uma variável numérica contínua com base em uma ou mais variáveis independentes (BISHOP, 2006). Trata-se de um modelo simples, mas eficiente, especialmente útil em situações em que existe uma relação linear bem definida.

Segundo a Ebac (2025) a Regressão Logística, embora tenha nome semelhante, é uma técnica estatística amplamente empregada para a previsão de uma variável dependente categórica a partir de uma ou mais variáveis independentes. Essa abordagem é particularmente útil para compreender as relações entre variáveis e estimar a probabilidade de ocorrência de um determinado evento.

Já a Máquina de Vetores de Suporte (SVM) é um algoritmo supervisionado usado tanto para classificação quanto regressão, conhecido por sua capacidade de lidar com dados de alta dimensionalidade e por buscar o hiperplano que melhor separa as classes (IBM, 2023).

O algoritmo K-Vizinhos Mais Próximos (KNN), por outro lado, realiza previsões com base na proximidade entre os dados de entrada e exemplos já conhecidos, sendo eficaz em classificação e regressão simples, especialmente quando há uma relação intuitiva de semelhança entre os casos (MUSRIL *et al.*, 2023).

Por fim, o algoritmo de floresta aleatória (*random forest*) se destaca por combinar diversas árvores de decisão em um modelo conjunto, o que melhora significativamente a precisão e a robustez das previsões (BREIMAN, 2001). É um dos algoritmos mais utilizados por sua capacidade de lidar com grandes volumes de dados, detectar interações complexas entre variáveis e evitar o sobreajuste (GOMES, 2025).

Assim, a análise dos métodos apresentados na Tabela 2 evidencia que o aprendizado supervisionado oferece um arsenal técnico diverso e eficaz para diferentes necessidades da manutenção preditiva, sendo fundamental entender as vantagens e limitações de cada algoritmo para sua aplicação adequada no contexto da Indústria 4.0.

2.3.2 Aprendizado de Máquina Não Supervisionado

Em algoritmos de aprendizado não supervisionado, os rótulos das classes das amostras de treinamento não são conhecidos, e o número ou conjunto de classes pode ser desconhecido previamente, esses algoritmos são descritivos, pois resumem e caracterizam as propriedades gerais dos dados (CORCOVIA; ALVES, 2019).

O aprendizado não supervisionado é um tipo de *machine learning* em que o algoritmo recebe dados de entrada sem rótulos e identifica padrões e relacionamentos por conta própria. Entre as principais técnicas estão: o agrupamento em clusters, que categoriza dados similares; o aprendizado de regras de associação, que descobre relações entre itens, como produtos frequentemente comprados juntos; a estimativa de densidade de probabilidade, que verifica se determinados valores estão dentro de uma faixa considerada normal — útil para detecção de anomalias; e a redução de dimensionalidade, que simplifica conjuntos de dados ao diminuir o número de atributos, facilitando o processamento em tarefas como o reconhecimento de imagens. (AWS, 2025).

2.3.3 Dificuldades de implementação

A aplicação do aprendizado de máquina enfrenta desafios importantes. A base de qualquer modelo de inteligência artificial está nos conjuntos de dados de treinamento, sendo que sua qualidade e abrangência impactam diretamente a precisão dos resultados. Os principais desafios estão os dados desequilibrados, que causam vieses por representar apenas parte do problema, os dados insuficientes, que reduzem a capacidade do modelo de aprender e generalizar corretamente, e os dados de baixa qualidade, que comprometem a confiança nas previsões e exigem verificação cuidadosa das fontes utilizadas (ORACLE, 2025).

O uso crescente da Inteligência Artificial evidenciou que a má qualidade dos dados e os vieses algorítmicos são grandes obstáculos para sistemas justos e eficazes. Uma revisão de 127 estudos mostrou que 68% das falhas em IA decorrem de dados problemáticos e 43% dos modelos implantados apresentam vieses significativos, o artigo propõe soluções como pré-processamento de dados, algoritmos justos e aprendizado federado, destacando que abordagens que combinam técnicas avançadas com governança ética reduzem vieses e melhoram a confiabilidade dos modelos (AJUZIEOGU, 2024).

2.4 Integração entre Gêmeos Digitais e Aprendizado de Máquina

A integração entre DT e técnicas de ML tem se consolidado como uma abordagem promissora para o monitoramento preditivo e a tomada de decisões em sistemas complexos. Essa sinergia possibilita não apenas a modelagem precisa de ativos físicos, mas também a análise inteligente de dados históricos e em tempo real, permitindo a previsão de falhas e a otimização de desempenho (TAO *et al.*, 2018).

Os Gêmeos Digitais fornecem uma representação digital contínua e em tempo real de um ativo físico, alimentada por sensores e outras fontes de dados. Quando combinados com algoritmos de aprendizado de máquina, esses dados podem ser analisados para realizar decisões mais inteligentes na cadeia de produção (FULLER *et al.*, 2020). Isso resulta em uma abordagem proativa para a manutenção, reduzindo o tempo de inatividade e os custos operacionais.

Diversos estudos demonstram que modelos de aprendizado de máquina, como redes neurais, SVM e algoritmos de *random forest*, são altamente eficazes na predição de falhas quando integrados a sistemas de gêmeos digitais. Por exemplo, a integração de DT e ML em processos de manufatura aditiva permitiu a detecção de defeitos com precisão superior a 90%, otimizando o controle de qualidade e a eficiência operacional (JYENISKHAN *et al.*, 2023).

Além disso, os Gêmeos Digitais proporcionam um ambiente virtual seguro para testar algoritmos de aprendizado de máquina e realizar simulações sem afetar o sistema físico real. Essa característica é particularmente útil para o treinamento de modelos preditivos que requerem grandes volumes de dados rotulados, os quais podem ser gerados artificialmente no ambiente do gêmeo digital (ALEXOPOULOS *et al.*, 2020).

Outro benefício significativo dessa integração é a melhoria contínua dos modelos. Como o Gêmeo Digital está em constante atualização com dados operacionais, os algoritmos de aprendizado de máquina podem ser continuamente treinados com novas informações, aumentando a precisão das previsões ao longo do tempo (KREUZER *et al.*, 2024).

Por fim, a aplicação conjunta dessas tecnologias tem se mostrado fundamental na Indústria 4.0, especialmente em áreas como manufatura, manutenção preditiva e gestão de ativos, promovendo ganhos expressivos em eficiência operacional e redução de falhas (NELE *et al.*, 2024). Dessa forma, esta revisão bibliográfica apresentou os fundamentos, aplicações e desafios relacionados aos gêmeos digitais e ao aprendizado de máquina, evidenciando que sua integração representa uma solução inovadora e estratégica para otimizar o desempenho de sistemas mecânicos. As informações discutidas neste capítulo fornecem a base conceitual necessária para a definição da metodologia de pesquisa, apresentada no capítulo seguinte.

3 METODOLOGIA

Este capítulo apresenta os métodos utilizados para a realização da pesquisa, detalhando o tipo de pesquisa, materiais e métodos adotados, as variáveis e indicadores, os instrumentos de coleta de dados, além do tratamento e tabulação dos dados.

3.1 Tipo de Pesquisa

A pesquisa desenvolvida neste trabalho pode ser classificada, quanto aos objetivos, como exploratória e descritiva. Segundo Gil (2008), a pesquisa exploratória é indicada quando se busca proporcionar maior familiaridade com determinado problema, sendo especialmente útil em estudos iniciais sobre temas ainda pouco investigados ou em consolidação.

Nesta pesquisa, busca-se explorar os conceitos, aplicações e desafios da integração entre gêmeos digitais e aprendizado de máquina no contexto da manutenção preditiva de sistemas mecânicos. Já a pesquisa descritiva tem como propósito descrever as características, padrões e relações existentes entre essas tecnologias, conforme identificadas na literatura científica, evidenciando como essa integração tem sido aplicada em diferentes contextos industriais.

Quanto à abordagem metodológica, trata-se de uma pesquisa qualitativa, pois se baseia na interpretação e análise de informações extraídas de fontes bibliográficas, com foco na compreensão dos conceitos, aplicações e práticas documentadas. Embora algumas fontes apresentem dados quantitativos, o presente estudo não realizará análise estatística própria, concentrando-se na análise conceitual e interpretativa dos conteúdos revisados.

Do ponto de vista dos procedimentos técnicos, esta é uma pesquisa bibliográfica, realizada a partir da coleta, leitura e análise de livros, artigos científicos, teses, dissertações e documentos técnicos disponíveis. Essa revisão tem como objetivo construir uma base teórica sólida sobre as melhores práticas e tendências no uso combinado de gêmeos digitais e aprendizado de máquina para diagnóstico de falhas.

3.2 Materiais e Métodos

Esta pesquisa foi conduzida por meio de uma revisão bibliográfica sistemática, cujo objetivo é identificar, analisar e discutir as melhores práticas na integração de gêmeos digitais e algoritmos de aprendizado de máquina, voltadas ao diagnóstico de falhas em sistemas mecânicos.

Foram utilizados como materiais:

- Artigos científicos obtidos em bases como IEEE Xplore, ScienceDirect, Scopus, SpringerLink, Periódicos CAPES e Google Scholar;
- Livros técnicos relacionados à Indústria 4.0, manutenção preditiva, *machine learning* e sistemas mecânicos;
- Trabalhos acadêmicos como dissertações e teses;
- Ferramentas computacionais, como Microsoft Excel para organização das informações coletadas.

As etapas metodológicas da pesquisa seguiram o seguinte fluxo:

1. Definição das palavras-chave relacionadas ao tema (em português e inglês), como: gêmeos digitais, *digital twin*, aprendizado de máquina, *machine learning*, manutenção preditiva, *predictive maintenance*, falhas mecânicas;
2. Ano de publicação, priorizando estudos recentes entre 2019 e 2025;
3. Busca e seleção dos materiais em bases científicas;
4. Leitura dos resumos e seleção dos estudos relevantes;
5. Leitura completa e extração das informações principais (objetivos, metodologia, tecnologias utilizadas, resultados, desafios);
6. Organização dos dados em tabelas comparativas;
7. Síntese e análise crítica dos conteúdos, com base em critérios qualitativos.

Essa metodologia permite identificar padrões de aplicação, benefícios e limitações envolvendo essas tecnologias.

3.3 Variáveis e Indicadores

Embora esta pesquisa seja de caráter teórico e baseada exclusivamente em revisão bibliográfica, é possível identificar, a partir da literatura analisada, as principais variáveis monitoradas nos estudos que integram gêmeos digitais com aprendizado de máquina para

diagnóstico de falhas e otimização de sistemas mecânicos. As variáveis utilizadas neste trabalho possuem o objetivo de mostrar as ferramentas, técnicas, benefícios e obstáculos na implementação dos gêmeos digitais e junção com *machine learning*. Abaixo estão listadas as variáveis mais frequentemente mencionadas e seus respectivos indicadores:

Tabela 3 – Com variáveis e indicadores que serão usados no trabalho.

Variáveis	Indicadores
Tecnologias aplicadas à manutenção	- Uso de gêmeos digitais; - Tipo de técnica de aprendizado de máquina; - Arquitetura adotada.
Desempenho e aplicação industrial	- Tipos de sistema mecânico estudado; - Indicadores de desempenho; - Setor de aplicação.

Fonte: Pesquisa direta (2025).

A Tabela 3 apresenta as variáveis e os indicadores considerados na análise, os quais serão discutidos no capítulo de resultados e discussões.

3.4 Instrumento de Coleta de Dados

Como esta pesquisa é de natureza teórica, baseada em revisão bibliográfica, o principal instrumento de coleta de dados será a análise de publicações acadêmicas e técnicas. Os dados serão obtidos a partir de fontes secundárias confiáveis, como:

- Artigos científicos publicados em periódicos indexados (ex: IEEE Xplore, ScienceDirect, Scopus, SpringerLink, Periódicos CAPES);
- Trabalhos de conclusão de curso, dissertações e teses relacionadas à integração de gêmeos digitais, aprendizado de máquina e manutenção preditiva;
- Livros técnicos nas áreas de engenharia mecânica, engenharia de produção, ciência de dados e Indústria 4.0;

A coleta foi realizada por meio de pesquisas por palavras-chave relacionadas ao tema, como: *digital twin*, *machine learning*, *predictive maintenance*, *fault diagnosis*, *mechanical systems*, entre outras, em português e inglês. Após a triagem dos títulos e resumos, os materiais mais relevantes serão selecionados para leitura completa e análise.

Os dados extraídos foram organizados em quadros e tabelas comparativas, com o objetivo de identificar padrões, práticas recorrentes, resultados obtidos e desafios enfrentados nos estudos existentes sobre o tema.

3.5 Tabulação dos Dados

Como esta pesquisa é de natureza teórica e baseada em revisão bibliográfica, a tabulação dos dados foi realizada por meio da organização e categorização das informações extraídas dos estudos analisados. Para isso, serão utilizadas ferramentas computacionais como Microsoft Excel.

A análise seguirá as seguintes etapas:

- Catalogação dos artigos e documentos científicos selecionados, registrando informações como título, autores, ano, objetivos, metodologia utilizada, tecnologias aplicadas e resultados principais;
- Classificação dos estudos por categorias temáticas, como: tipo de sistema mecânico analisado, algoritmo de aprendizado de máquina utilizado, nível de integração com gêmeos digitais, benefícios relatados e limitações;
- Construção de tabelas-resumo e quadros comparativos, com o intuito de identificar padrões, tendências e lacunas na literatura;
- Visualização dos dados por meio de tabelas, quando pertinente, para facilitar a discussão crítica e a síntese das melhores práticas identificadas nos estudos revisados;

3.6 Considerações Finais do Capítulo

Neste capítulo, foram apresentados os métodos e materiais utilizados na pesquisa, detalhando a abordagem científica adotada, os instrumentos de coleta de dados e a metodologia de análise. No próximo capítulo, serão discutidos os impactos obtidos com a aplicação dos gêmeos digitais e aprendizado de máquina na manutenção preditiva, destacando os impactos e desafios dessa integração.

4 RESULTADOS E DISCUSSÕES

A seleção dos artigos para a presente revisão bibliográfica foi realizada com rigor e critérios bem definidos, de modo a garantir a qualidade e a relevância das fontes utilizadas para embasar o estudo. Inicialmente, buscou-se priorizar trabalhos publicados nos últimos anos, com foco em publicações recentes que refletem o estado da arte e as tendências mais atuais relacionadas à aplicação de gêmeos digitais e aprendizado de máquina na manutenção preditiva de sistemas mecânicos. Além disso, foram consideradas diferentes abordagens metodológicas, incluindo revisões sistemáticas, estudos empíricos, análises de casos reais e propostas teóricas que pudessem oferecer uma visão ampla e aprofundada sobre o tema.

Para assegurar a diversidade e a representatividade do universo pesquisado, foram selecionados artigos que abordam aplicações em múltiplos setores industriais. Essa heterogeneidade possibilita uma análise dos desafios, soluções e benefícios inerentes à integração das tecnologias estudadas, permitindo também identificar padrões comuns e particularidades específicas de cada área. Outro critério fundamental adotado foi o impacto científico das publicações, levando em consideração fatores como o número de citações, o prestígio das revistas científicas e a relevância dos autores para o campo da engenharia e da ciência de dados.

Como resultado desse processo criterioso, foram selecionados dez artigos que se destacam por sua contribuição significativa para o avanço do conhecimento na área de manutenção preditiva apoiada em tecnologias digitais e inteligência artificial. A Tabela 4 apresenta um resumo desses artigos, destacando informações essenciais como o título, autores, ano de publicação, objetivo principal, setor de aplicação e metodologia empregada. Essa seleção proporciona uma base sólida para as análises e discussões que serão desenvolvidas ao longo do trabalho, conferindo-lhe robustez acadêmica e aderência às demandas contemporâneas do setor industrial.

Tabela 4 – Artigos Selecionados para Revisão

Título	Autor/Ano	Foco Principal	Citação
The advance of digital twin for predictive maintenance	Chen et al., 2023	Revisão sistemática sobre DT e ML em manutenção preditiva	[1]
Machine-Learning-Driven Digital Twin for Lifecycle Management	Ren et al., 2022	Integração de ML em DT para manutenção de locomotivas	[2]
Using Digital Twins for Fault Detection and Root Cause Analysis	Pasupuleti, 2025	DT para detecção de falhas e análise de causa raiz	[3]
Intelligent fault diagnosis of machinery using digital twin-assisted deep transfer learning	Xia et al., 2021	DT e deep transfer learning para diagnóstico de falhas	[4]
Predictive maintenance using digital twins: SLR	van Dinter et al., 2022	Revisão sistemática sobre DT em manutenção preditiva	[5]
Learning phase in a LIVE Digital Twin	Bondoc et al., 2022	Metodologia LIVE DT para simulação de falhas	[6]
Overview of predictive maintenance based on digital twin	Zhong et al., 2023	Frameworks e desafios de DT em manutenção preditiva	[7]
The use of Digital Twin for predictive maintenance	Aivaliotis et al., 2019	DT e simulação física para cálculo de RUL	[8]
Digital twin-driven aero-engine intelligent predictive maintenance	Xiong et al., 2021	DT e LSTM para manutenção preditiva em motores aeronáuticos	[9]
Machine learning-based digital twin of a conveyor belt	Pulcini e Modoni, 2024	DT e ML para manutenção preditiva em esteiras industriais	[10]

Fonte: Pesquisa direta (2025).

Os estudos selecionados, apresentados na Tabela 4, exploram a integração entre gêmeos digitais e técnicas de aprendizado de máquina, com foco na manutenção preditiva, cada um adotando abordagens e aplicações distintas. Chen *et al.* (2023) apresentam uma revisão sistemática abrangente sobre o uso em cenários de manutenção, apontando avanços,

lacunas e tendências na literatura. Ren *et al.* (2022) investigam a aplicação dessa integração especificamente na gestão do ciclo de vida de equipamentos ferroviários, destacando os benefícios na manutenção de locomotivas. Pasupuleti (2025) propõe o uso de gêmeos digitais para detecção de falhas e análise de causa raiz, reforçando o papel dessas tecnologias na antecipação de problemas operacionais. Xia *et al.* (2021) combinam técnicas de *deep transfer learning* para diagnóstico inteligente de falhas, evidenciando a eficácia desse modelo híbrido em contextos industriais complexos.

Complementando a discussão, van Dinter *et al.* (2022) também realizaram uma revisão sistemática, categorizando diferentes estratégias adotadas em aplicações industriais. Bondoc *et al.* (2022) propõem uma metodologia que visa simular falhas em tempo real e aprimorar a resposta a eventos críticos. Zhong *et al.* (2023), por sua vez, oferecem uma visão geral dos principais *frameworks* e desafios associados à adoção de DT na manutenção preditiva. O trabalho de Aivaliotis *et al.* (2019) destaca a utilização de simulações físicas por meio de gêmeos digitais para estimativa da vida útil remanescente (RUL) de componentes industriais. Já Xiong *et al.* (2021) empregam modelos LSTM (*Long Short-Term Memory*) acoplados a gêmeos digitais no contexto da manutenção preditiva de motores aeronáuticos. Por fim, Pulcini e Modoni (2024) aplicam a integração entre DT e ML à manutenção de esteiras industriais, ilustrando um caso concreto de implementação em linha de produção.

A seguir, apresenta-se os principais aspectos observados nas análises dos artigos selecionados, de forma que os recortes temáticos realizados se deram com base nas recorrências identificadas.

4.1 Principais Algoritmos de Aprendizado de Máquina

Os artigos analisados mostram que tanto algoritmos supervisionados quanto não supervisionados são amplamente empregados em manutenção preditiva com gêmeos digitais. Entre os supervisionados, destacam-se *random forest*, SVM, Redes Neurais Artificiais (ANN), e modelos de *deep learning* como LSTM e *autoencoders*, devido à sua alta precisão na classificação de falhas e na vida útil restante. Os algoritmos não supervisionados, como K-Means e DBSCAN, são utilizados principalmente para detecção de anomalias e agrupamento de padrões de falha, especialmente quando há escassez de dados rotulados.

A Tabela 5, apresentada a seguir, reúne os algoritmos utilizados nos trabalhos

analisados, bem como seus respectivos tipos e vantagens, destacando as características em comum entre eles.

Tabela 5 – Algoritmos utilizados descritos nos artigos e seus benefícios.

Algoritmo	Tipo	Vantagens	Artigos Citados
Random Forest	Supervisionado	Alta precisão, robustez a ruídos	CHEN et al. (2023); VAN DINTER et al. (2022); PULCINI; MODONI (2024)
SVM	Supervisionado	Bom para classificação e anomalias	CHEN et al. (2023); PASUPULETI (2025); VAN DINTER et al. (2022)
LSTM/Deep Learning	Supervisionado	Captura padrões temporais complexos	XIA et al. (2021); XIONG et al. (2021)
Autoencoder	Não Supervisionado	Redução de dimensionalidade, detecção de anomalias	XIA et al. (2021)
K-Means	Não supervisionado	Simplicidade, útil para agrupamento	CHEN et al. (2023); XIA et al. (2021); VAN DINTER et al. (2022)
DBSCAN	Não supervisionado	Identifica clusters de forma flexível	VAN DINTER et al. (2022)

Fonte: elaboração própria, 2025

Ao analisar a tabela 5 podemos perceber que, para aplicações que envolvem grande volume de dados históricos e exigem previsões em séries temporais, os modelos de *deep learning*, como as redes LSTM, apresentam desempenho superior. Esses modelos são capazes de capturar dependências temporais de longo prazo, o que os torna particularmente eficazes em contextos industriais onde a variação ao longo do tempo é crítica para a predição de falhas.

Além disso, em cenários com dados tabulares e necessidade de interpretabilidade, algoritmos supervisionados como o *random forest* mostram-se bastante eficazes, oferecendo alta precisão e robustez a ruídos. No caso de dados não rotulados, os métodos não supervisionados, como K-Means e DBSCAN, são amplamente utilizados.

4.2 Arquiteturas Mais Utilizadas

A análise dos artigos revela que as arquiteturas mais comuns integram gêmeos digitais com módulos de aprendizado de máquina em plataformas modulares, frequentemente conectadas a sistemas IoT e nuvem para coleta e processamento de dados em tempo real (CHEN *et al.*, 2023; REN *et al.*, 2022; VAN DINTER *et al.*, 2022; ZHONG *et al.*, 2023; PULCINI; MODONI, 2024). Essa configuração possibilita a coleta contínua de dados em tempo real, viabilizando análises dinâmicas do estado operacional dos sistemas físicos. Os sensores instalados nos equipamentos captam dados que são transmitidos para os módulos de processamento, onde algoritmos de aprendizado de máquina realizam a análise e alimentam os modelos digitais com informações atualizadas. Essa conexão entre o mundo físico e o digital é fundamental para a eficácia das aplicações em manutenção preditiva, controle de desempenho e resposta a falhas.

Um elemento recorrente nas arquiteturas analisadas é o uso de simulações físicas combinadas com dados reais. Essa abordagem híbrida permite que os modelos digitais sejam constantemente refinados com base no comportamento real dos equipamentos, aumentando significativamente a precisão das previsões (XIA *et al.*, 2021; AIVALIOTIS *et al.*, 2019; XIONG *et al.*, 2021).

Outro aspecto observado é a predominância de *frameworks* modulares e escaláveis, que organizam as arquiteturas em camadas ou blocos funcionais. Essas arquiteturas costumam separar claramente as etapas de aquisição de dados, pré-processamento, modelagem, treinamento e inferência de modelos, além da tomada de decisão baseada em previsões. Essa estrutura facilita a integração entre diferentes componentes do sistema permitindo uma maior reutilização e flexibilidade no desenvolvimento.

4.3 Benefícios Observados

Entre os aspectos observados nas arquiteturas que integram gêmeos digitais e aprendizado de máquina, destacam-se os principais benefícios a seguir.

Inicialmente foi possível perceber aspectos que referem-se à redução de paradas não planejadas e dos custos de manutenção, uma vez que os alertas de falha são emitidos com

antecedência significativa. Isso permite que intervenções preventivas sejam realizadas de forma mais eficaz (REN *et al.*, 2022; XIONG *et al.*, 2021; PULCINI; MODONI, 2024).

Outro aspecto percebido nas análises e que merece ser mencionado é o aumento da precisão na previsão de falhas e RUL (CHEN *et al.*, 2023; XIA *et al.*, 2021; AIVALIOTIS *et al.*, 2019; XIONG *et al.*, 2021). Essa maior precisão otimiza o uso de recursos e prolonga a vida útil dos ativos, o que contribui significativamente para uma manutenção mecânica mais eficiente. Além disso, decisões mais assertivas e fundamentadas em dados tornam-se viáveis, aumentando a confiabilidade operacional e contribuindo para ambientes industriais mais inteligentes e sustentáveis.

A automação dos processos e a tomada de decisão em tempo quase real também se destacam entre os benefícios mais citados nas análises. Essa capacidade de atuação imediata promove uma melhora significativa na eficiência operacional, ao reduzir o tempo de resposta diante de falhas ou desvios, além de aumentar a segurança, ao antecipar riscos e acionar protocolos preventivos de maneira ágil e eficaz (CHEN *et al.*, 2023; REN *et al.*, 2022; ZHONG *et al.*, 2023; PULCINI; MODONI, 2024).

Por fim, a adaptabilidade a diferentes setores industriais. Literaturas como (CHEN *et al.*, 2023; REN *et al.*, 2022; ZHONG *et al.*, 2023; PULCINI; MODONI, 2024) ressaltam tal benefício e destacam a sua importância para a eficiência operacional, além do impacto significativo sobre a segurança.

4.4 Desafios e Limitações

Claro que, além dos benefícios, também foram identificados desafios e limitações importantes na integração entre gêmeos digitais e aprendizado de máquina. Um dos principais obstáculos diz respeito à escassez e à qualidade dos dados de falha, o que compromete o treinamento de modelos preditivos robustos e confiáveis (VAN DINTER *et al.*, 2022; BONDOC *et al.*, 2022; ZHONG *et al.*, 2023). Isso se deve ao fato de que, na maioria dos cenários industriais, não existem históricos de falhas devidamente contextualizados que possam ser utilizados no treinamento de modelos de *machine learning*.

Além disso, muitas falhas são eventos raros, o que dificulta ainda mais o processo, pois limita a disponibilidade de dados representativos e estatisticamente significativos. Outro desafio relevante é a ausência de *pipelines* de dados bem estruturados, que realizem, de forma

eficiente, a extração, o tratamento e o carregamento dos dados. A inexistência desses fluxos robustos compromete a qualidade e a disponibilidade das informações necessárias para o consumo por modelos preditivos.

Também se destaca a complexidade na integração entre os sistemas físicos, digitais e as plataformas de dados, exigindo infraestrutura tecnológica avançada e equipes multidisciplinares para garantir a interoperabilidade (PASUPULETI, 2025; VAN DINTER *et al.*, 2022; ZHONG *et al.*, 2023). Tal limitação pode gerar o aumento de custos operacionais e dificuldades na padronização de processos, especialmente em ambientes industriais legados que não foram originalmente concebidos para suportar tecnologias conectadas e inteligentes. Além disso, a falta de integração eficiente pode comprometer a consistência dos dados coletados, prejudicando diretamente a acurácia das análises preditivas e a confiabilidade dos modelos de decisão.

Outro ponto crítico refere-se à elevada carga computacional necessária para realizar simulações e processar grandes volumes de dados em tempo real, o que pode limitar a aplicação em ambientes com recursos computacionais restritos (CHEN *et al.*, 2023; VAN DINTER *et al.*, 2022).

Por fim, há uma dificuldade recorrente na generalização dos modelos desenvolvidos, ou seja, na capacidade de aplicá-los de forma eficaz em diferentes tipos de equipamentos e contextos operacionais, o que demanda ajustes constantes e personalizações específicas (VAN DINTER *et al.*, 2022; BONDOC *et al.*, 2022; ZHONG *et al.*, 2023).

4.5 Estudo de Caso

Um exemplo emblemático da aplicação prática de gêmeos digitais combinados com técnicas de *machine learning* na manutenção preditiva é apresentado por REN *et al.* (2022), que desenvolveram um sistema de monitoramento inteligente para rolamentos de locomotivas a diesel modelo CDD5B1.

O estudo focou na previsão de falhas nos rolamentos dos eixos, componentes críticos cuja queima ou desgaste acentuado pode levar a paradas não programadas, elevados custos de reparo e até riscos operacionais. Tradicionalmente, o sistema de alarme baseava-se em um limite fixo de temperatura (90°C), o que frequentemente resultava em alertas tardios, já durante a ocorrência da falha.

Para superar essa limitação, os autores propuseram uma arquitetura baseada em um gêmeo digital para a manutenção, integrado a um modelo preditivo híbrido, utilizando três algoritmos de aprendizado de máquina: LASSO, SVR e XGBoost. O modelo combinado (em série) foi treinado com dados históricos de temperatura, velocidade e condições ambientais, e validado com dados em tempo real. A Figura 1 ilustra o fluxo de dados e processos envolvidos nessa arquitetura.




Figura 4 – Fluxo de coleta, processamento e aplicação de dados no gêmeo digital.
Fonte: Adaptado de Ren *et al.* (2022).

Conforme ilustrado na Figura 4, a arquitetura proposta divide-se em três módulos principais:

- Seção A (Coleta de dados): Mostra a integração entre dados em tempo real - coletados por redes de sensores - e dados históricos armazenados em nuvem. Essas informações são consolidadas em um banco de dados associado ao gêmeo digital em manutenção;
- Seção B (Processamento e modelagem): Representa o núcleo do sistema, onde ocorre a construção do modelo preditivo. Utiliza técnicas de aprendizado de máquina para processar os dados coletados e gerar o modelo de previsão que alimentará o sistema de manutenção preditiva;
- Seção C (Manutenção de equipamentos): Apresenta a aplicação prática do modelo, por meio de gráficos de controle, análises de confiabilidade, avaliação de estado e ações de manutenção preditiva orientadas pelos resultados.

Os resultados obtidos foram os seguintes:

- RMSE (Erro Quadrático Médio): 0,7105, indicando que o modelo comete um erro médio de apenas 0,71°C em suas previsões, demonstrando alta precisão;
- R² (Coeficiente de Determinação): 0,8739, mostrando que o modelo explica 87,39% da variabilidade dos dados, confirmando sua confiabilidade e ajuste aos padrões reais;
- Antecipação de falhas: cerca de sete dias, em que o sistema foi capaz de identificar anomalias térmicas significativas quase uma semana antes de uma falha crítica ocorrer;
- Redução de paradas: a manutenção proativa possibilitada pelo modelo evitou interrupções não planejadas e reduziu custos de reparo.

Concluiu-se que o uso do gêmeo digital aliado ao *machine learning* permitiu não apenas uma transição da manutenção corretiva para a preditiva, mas também elevou o padrão de confiabilidade e segurança operacional do equipamento. Os resultados numéricos comprovam a alta assertividade do modelo e sua aplicabilidade em ambientes industriais reais, reforçando o potencial dessa abordagem para a manutenção de sistemas mecânicos complexos na era da Indústria 4.0.

5 CONCLUSÃO E RECOMENDAÇÕES

5.1 Conclusão

Este trabalho teve como objetivo realizar uma revisão bibliográfica sobre a aplicação integrada de gêmeos digitais e aprendizado de máquina na manutenção preditiva de sistemas mecânicos. A partir da análise de artigos científicos e relatórios técnicos recentes, foi possível compreender como essa integração tem sido implementada de diferentes formas na engenharia mecânica.

Em síntese, a metodologia adotada se mostrou eficaz para alcançar os objetivos propostos e fornecer uma base teórica sólida sobre o tema. A revisão bibliográfica sistemática permitiu não apenas reunir e classificar o conhecimento existente, mas também desenvolver uma análise crítica sobre o estágio atual de desenvolvimento dessas tecnologias. Recomenda-se que pesquisas futuras combinem essa abordagem com estudos de caso ou análises empíricas, de modo a validar na prática as tendências observadas na literatura e contribuir para o avanço das soluções tecnológicas aplicadas à manutenção preditiva.

A revisão mostrou que os gêmeos digitais, ao replicarem digitalmente o comportamento de ativos físicos, fornecem uma base robusta de dados em tempo real, que alimenta algoritmos de aprendizado de máquina. Quando treinados com dados históricos e operacionais, esses algoritmos são capazes de realizar previsões precisas sobre falhas, desgaste de componentes e necessidade de manutenção, promovendo uma abordagem mais eficaz e econômica.

Entre os principais benefícios identificados, destacam-se: a redução do tempo de parada não planejada, a otimização do ciclo de vida útil dos ativos, o aumento da confiabilidade operacional e a automatização dos processos de manutenção. Além disso, os estudos analisados evidenciam que a aplicação dessa tecnologia já é uma realidade e como o uso auxilia na tomada de decisões.

No entanto, a literatura também apontou desafios relevantes, escassez e qualidade dos dados de falha, complexidade de integração, carga computacional elevada para simulações e dificuldade de generalização dos modelos para diferentes equipamentos e ambientes operacionais.

Conclui-se, portanto, que a integração entre gêmeos digitais e aprendizado de máquina representa uma inovação promissora para a engenharia de manutenção, mas que ainda exige

avanços técnicos, normativos e operacionais para atingir todo o seu potencial, principalmente em ambientes industriais com baixa digitalização ou infraestrutura limitada.

5.2 Recomendações

Com base nas conclusões obtidas ao longo deste estudo, recomenda-se a adoção gradual e planejada da integração tecnológica entre gêmeos digitais e aprendizado de máquina. Empresas interessadas devem iniciar esse processo por meio de projetos-piloto, priorizando ativos críticos e com histórico de falhas devidamente documentadas. Essa abordagem progressiva permite validar a viabilidade técnica e operacional das soluções antes de sua escalabilidade para toda a planta industrial, além de possibilitar maior compreensão das etapas envolvidas e das competências necessárias à implantação bem-sucedida.

Outro ponto fundamental é o investimento em infraestrutura de dados. A confiabilidade e a performance dos modelos preditivos dependem diretamente da qualidade dos dados obtidos por sensores e de todo o *pipeline* de processamento. Nesse sentido, torna-se essencial o desenvolvimento de estruturas robustas para coleta, tratamento, armazenamento e disponibilização de dados, garantindo precisão, consistência e acessibilidade às informações utilizadas pelos modelos analíticos.

Além disso, destaca-se a necessidade de capacitação técnica das equipes envolvidas. A implementação eficaz dessas tecnologias requer profissionais com conhecimentos multidisciplinares, abrangendo áreas como engenharia, ciência de dados e tecnologia da informação. Programas de treinamento e formação continuada são indispensáveis para garantir a sustentabilidade do sistema, bem como o correto entendimento do ecossistema de dados e suas aplicações.

Por fim, é importante incentivar a pesquisa aplicada e o desenvolvimento de estudos de caso voltados à realidade de pequenas e médias empresas, que frequentemente enfrentam maiores obstáculos na adoção dessas tecnologias, principalmente devido a restrições orçamentárias. Iniciativas acadêmicas que explorem soluções mais acessíveis e escaláveis podem desempenhar um papel importante na democratização e difusão das inovações digitais no setor industrial.

REFERÊNCIA BIBLIOGRÁFICA

AIVALIOTIS, P.; GEORGOULIAS, K.; CHRYSSOLOURIS, G. The use of digital twin for predictive maintenance in manufacturing. **International Journal of Computer Integrated Manufacturing**, v. 32, n. 11, p. 1067–1080, 2019.

AJUZIEOGU, U. C. AI data quality and bias: challenges, implications, and solutions in modern machine learning. **ResearchGate**, nov. 2024. Disponível em: https://www.researchgate.net/publication/386083845_AI_Data_Quality_and_Bias_Challenges_Implications_and_Solutions_in_Modern_Machine_Learning. Acesso em: 13 jul. 2025.

ALEXOPOULOS, K.; NIKOLAKIS, N.; CHRYSSOLOURIS, G. Digital twin-driven supervised machine learning for the development of artificial intelligence applications in manufacturing. **International Journal of Computer Integrated Manufacturing**, v. 33, n. 5, p. 429–439, 2020. Disponível em: <https://doi.org/10.1080/0951192X.2020.1747642>. Acesso em: 29 jul. 2025.

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

AMAZON WEB SERVICES. **What is digital twin technology?** Disponível em: <https://aws.amazon.com/pt/what-is/digital-twin/>. Acesso em: 29 jun. 2025.

AMAZON WEB SERVICES. **The difference between machine learning supervised and unsupervised.** Disponível em: <https://aws.amazon.com/pt/compare/the-difference-between-machine-learning-supervised-and-unsupervised/>. Acesso em: 13 jul. 2025.

AUTOMATIK.NET. **AI & machine learning.** [S.d.]. Disponível em: <https://www.automatik.net/ai.html>. Acesso em: 27 jul. 2025.

BISHOP, C. M. **Pattern recognition and machine learning**. New York: Springer, 2006.

BONDOC, A. E.; TAYEFEH, M.; BARARI, A. Learning phase in a LIVE digital twin for predictive maintenance. **Autonomous Intelligent Systems**, v. 2, p. 13, 2022. Disponível em: <https://doi.org/10.1007/s43684-022-00028-0>. Acesso em: 29 jul. 2025.

BREIMAN, L. **Random forests**. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001.

CHEN, C. *et al.* The advance of digital twin for predictive maintenance: the role and function of machine learning. **Journal of Manufacturing Systems**, 2023. Disponível em: <https://doi.org/10.1016/j.jmsy.2023.10.010>. Acesso em: 29 jul. 2025.

CORCOVIA, L. O.; ALVES, R. S. Aprendizagem de máquina e mineração de dados: avaliação de métodos de aprendizagem. **Revista Interface Tecnológica**, v. 16, n. 1, p. 90–101, 2019. Disponível em: <https://revista.fatectq.edu.br/interfacetecnologica/article/view/562>. Acesso em: 13 jul. 2025.

FULLER, A. *et al.* Digital twin: enabling technologies, challenges and open research. **IEEE Access**, v. 8, p. 108952–108971, 2020. Disponível em: <https://doi.org/10.1109/ACCESS.2020.2998358>. Acesso em: 1 jul. 2025.

GIL, A. C. **Métodos e técnicas de pesquisa social**. 6. ed. São Paulo: Atlas, 2008.

GOMES, P. C. T. **Random forest: introdução ao algoritmo de machine learning**. DataGeeks, 5 jan. 2025. Disponível em: <https://www.datageeks.com.br/random-forest/>. Acesso em: 9 ago. 2025.

GOOGLE CLOUD. **What is machine learning?** Disponível em: <https://cloud.google.com/learn/what-is-machine-learning?hl=pt-BR>. Acesso em: 29 jun. 2025.

GRIEVES, M.; VICKERS, J. Digital twin: mitigating unpredictable, undesirable emergent behavior in complex systems. In: **TRANSdisciplinary perspectives on complex systems**. Cham: Springer, 2017. p. 85–113. Disponível em: https://doi.org/10.1007/978-3-319-38756-7_4. Acesso em: 30 jul. 2025.

GRUS, J. **Data science do zero: primeiras regras com o Python**. Rio de Janeiro: Alta Books, 2016.

IBM. **Aprendizado supervisionado**. 28 dez. 2024. Disponível em: <https://www.ibm.com/br-pt/think/topics/supervised-learning>. Acesso em: 13 jul. 2025.

IBM. **Long Short-Term Memory (LSTM)**. Disponível em:

<https://developer.ibm.com/articles/cc-machine-learning-deep-learning-architectures/>. Acesso em: 1 ago. 2025.

IBM. **O que são máquinas de vetores de suporte (SVMs)?** 27 dez. 2023. Disponível em:

<https://www.ibm.com/br-pt/think/topics/support-vector-machine>. Acesso em: 1 ago. 2025.

IBM. **Redes Neurais Recorrentes (RNNs)**. Disponível em:

<https://www.ibm.com/think/topics/recurrent-neural-networks>. Acesso em: 1 ago. 2025.

JYENISKHAN, N. *et al.* Integrating machine learning model and digital twin system for additive manufacturing. **IEEE Access**, v. 11, p. 71113–71126, 2023. Disponível em:

<https://doi.org/10.1109/ACCESS.2023.3294486>. Acesso em: 29 jul. 2025.

KARDEC, A.; NASCIF, J. **Manutenção: função estratégica**. Rio de Janeiro: Qualitymark, 1998.

KREUZER, T.; PAPAPETROU, P.; ZDRAVKOVIC, J. Artificial intelligence in digital twins—a systematic literature review. **Computers in Industry**, v. 151, p. 103646, 2024.

Disponível em: <https://doi.org/10.1016/j.compind.2024.103646>. Acesso em: 29 jul. 2025.

MATSUMURA, R. **Aprendizado supervisionado**. Medium, 5 out. 2020. Disponível em:

<https://ricardomatsumura.medium.com/aprendizado-supervisionado-5bfacca7566e>. Acesso em: 13 jul. 2025.

MITCHELL, T. M. **Machine learning**. New York: McGraw-Hill, 1997.

MOBLEY, R. K. **An introduction to predictive maintenance**. 2. ed. Houston: Butterworth-Heinemann, 2002.

MUSRIL, H. A. *et al.* Using k-NN artificial intelligence for predictive maintenance in facility management. **SSRG International Journal of Electrical and Electronics Engineering**, v.

10, n. 6, p. 1–8, jun. 2023. Disponível em:

https://www.researchgate.net/publication/372081536_Using_k-NN_Artificial_Intelligence_for_Predictive_Maintenance_in_Facility_Management. Acesso em: 9 ago. 2025.

NELE, L. *et al.* Towards the application of machine learning in digital twin technology: a multi-scale review. **Discover Applied Sciences**, 2024. Disponível em: <https://doi.org/10.1007/s42452-024-06206-4>. Acesso em: 29 jul. 2025.

NVIDIA. **Gêmeo digital (digital twin)**. Disponível em: <https://www.nvidia.com/pt-br/glossary/digital-twin/>. Acesso em: 13 jul. 2025.

ORACLE. **Desafios no treinamento de modelos de IA**. Disponível em: <https://www.oracle.com/br/artificial-intelligence/ai-model-training-challenges/>. Acesso em: 13 jul. 2025.

ORACLE. **Manutenção preditiva com IA**. Disponível em: <http://oracle.com/br/scm/ai-predictive-maintenance/>. Acesso em: 30 jun. 2025.

PASUPULETI, S. Using digital twins for fault detection and root cause analysis in mechanical systems. **International Scientific Journal of Engineering and Management**, 2025. Disponível em: <https://doi.org/10.55041/isjem01640>. Acesso em: 29 jul. 2025.

PULCINI, V.; MODONI, G. Machine learning-based digital twin of a conveyor belt for predictive maintenance. **International Journal of Advanced Manufacturing Technology**, v. 133, p. 6095–6110, 2024. Disponível em: <https://doi.org/10.1007/s00170-024-14097-3>. Acesso em: 29 jul. 2025.

QI, Q. *et al.* Digital twin service towards smart manufacturing. **Procedia CIRP**, v. 72, p. 237–242, 2021. Disponível em: <https://doi.org/10.1016/j.procir.2018.03.103>. Acesso em: 29 jul. 2025.

RAGHAVAIAH, N. V.; HARIPRASAD, I. Maintenance and reliability strategy of mechanical equipment in industry. **International Research Journal of Engineering and Technology**, v. 6, n. 6, p. 2937–2940, 2019. Disponível em: https://www.researchgate.net/publication/339874453_MAINTENANCE_AND_RELIABILITY_STRATEGY_OF_MECHANICAL_EQUIPMENT_IN_INDUSTRY. Acesso em: 19 jul. 2025.

REN, Z.; WAN, J.; DENG, P. Machine-learning-driven digital twin for lifecycle management of complex equipment. **IEEE Transactions on Emerging Topics in Computing**, v. 10, n. 1,

p. 9–22, jan./mar. 2022. Disponível em: <https://doi.org/10.1109/TETC.2022.3143346>. Acesso em: 29 jul. 2025.

SAKURAI, R.; ZUCHI, J. D. **As revoluções industriais até a indústria 4.0**. Revista Interface Tecnológica, v. 15, n. 2, p. 480–491, 2018.

SAP. **What is predictive maintenance?** Disponível em: <https://www.sap.com/brazil/products/scm/apm/what-is-predictive-maintenance.html>. Acesso em: 30 jun. 2025.

SCHRÖER, C.; KRUSE, F.; GÓMEZ, J. M. A systematic literature review on applying CRISP-DM process model. **Procedia Computer Science**, v. 181, p. 526–534, 2021.

SCHUCK, S. **Nvidia usa IA e gêmeos digitais para impulsionar parques eólicos offshore no Brasil**. Exame ESG, 17 jan. 2025. Disponível em: <https://exame.com/esg/nvidia-usa-ia-e-gemeos-digitais-para-impulsionar-parques-eolicos-offshore-no-brasil/>. Acesso em: 30 jun. 2025.

SCHWAB, K. **A quarta revolução industrial**. 1. ed. São Paulo: Edipro, 2016.

SHEARER, C. **The CRISP-DM model: the new blueprint for data mining**. Journal of Data Warehousing, v. 5, p. 13–22, 2000.

SIEMENS. **Digital twin**. Disponível em: <https://www.sw.siemens.com/en-US/technology/digital-twin/>. Acesso em: 13 jul. 2025.

TAO, F. *et al.* Digital twin in industry: state-of-the-art. **IEEE Transactions on Industrial Informatics**, v. 15, n. 4, p. 2405–2415, 2019. Disponível em: <https://doi.org/10.1109/TII.2018.2873186>. Acesso em: 29 jul. 2025.

TAO, F.; QI, Q.; WANG, L.; NEE, A. Y. C. Digital twins and cyber–physical systems toward smart manufacturing and industry 4.0: correlation and comparison. **Engineering**, v. 5, n. 4, p. 653–661, 2019. Disponível em: <https://doi.org/10.1016/j.eng.2019.01.014>. Acesso em: 29 jul. 2025.

TONIELLO, E. **Gêmeos digitais na indústria 4.0**. Schneider Electric, 2024.

TOTVS. **Digital twin: o que é, vantagens, desafios e tendências da tecnologia.** *TOTVS Blog*, 2023. Disponível em: <https://www.totvs.com/blog/inovacoes/digital-twin/>. Acesso em: 13 jul. 2025.

TRACTIAN. **A inteligência artificial na manutenção: o futuro das plantas industriais.** Disponível em: <https://traction.com/blog/a-inteligencia-artificial-na-manutencao-o-futuro-das-plantas-industriais>. Acesso em: 29 jun. 2025.

VAN DINTER, R.; TEKINERDOGAN, B.; CATAL, C. Predictive maintenance using digital twins: a systematic literature review. **Information and Software Technology**, v. 151, p. 107008, 2022. Disponível em: <https://doi.org/10.1016/j.infsof.2022.107008>. Acesso em: 29 jul. 2025.

XENOS, G. **Maintenance Engineering Handbook**. 7. ed. New York: McGraw-Hill, 2004.

XIA, M. *et al.* Intelligent fault diagnosis of machinery using digital twin-assisted deep transfer learning. **Reliability Engineering & System Safety**, v. 215, p. 107938, 2021. Disponível em: <https://doi.org/10.1016/j.ress.2021.107938>. Acesso em: 29 jul. 2025.

XIONG, M. *et al.* Digital twin–driven aero-engine intelligent predictive maintenance. **International Journal of Advanced Manufacturing Technology**, v. 114, p. 3751–3761, 2021. Disponível em: <https://doi.org/10.1007/s00170-021-06976-w>. Acesso em: 29 jul. 2025.

ZHANG, Y. (Ed.). **New advances in machine learning**. Rijeka: InTech, 2010.

ZHONG, D. *et al.* Overview of predictive maintenance based on digital twin technology. **Heliyon**, v. 9, n. 4, p. e14534, 2023. Disponível em: <https://doi.org/10.1016/j.heliyon.2023.e14534>. Acesso em: 29 jul. 2025.