



Instituto Federal de Educação, Ciência e Tecnologia da Paraíba  
Campus Campina Grande  
Coordenação do Curso Superior de Tecnologia em Telemática

**MANUTENÇÃO PREDITIVA COM IA E IOT NA  
INDÚSTRIA 4.0: UM ESTUDO DE CONCEITOS,  
ARQUITETURAS E DESAFIOS**

**ADONIAS ALVES CARDOSO JUNIOR**

Orientador: Victor Emanuel Farias da Costa Borges

Campina Grande, 2025  
©Adonias Alves Cardoso Junior



Instituto Federal de Educação, Ciência e Tecnologia da Paraíba  
Campus Campina Grande  
Coordenação do Cursos Superior de Tecnologia em Telemática

# **MANUTENÇÃO PREDITIVA COM IA E IOT NA INDÚSTRIA 4.0: UM ESTUDO DE CONCEITOS, ARQUITETURAS E DESAFIOS**

**ADONIAS ALVES CARDOSO JUNIOR**

Monografia apresentada à Coordenação do  
Curso Superior de Tecnologia em Telemática  
do IFPB - Campus Campina Grande, PB  
como requisito parcial para conclusão do  
curso de Tecnologia em Telemática.

Orientador: Victor Emanuel Farias da Costa Borges

Campina Grande, 2025

Catálogo na fonte:  
Ficha catalográfica

C268m Cardoso Junior, Adonias Alves.

Manutenção preditiva com IA e IoT na Indústria 4.0: um estudo de conceitos, arquiteturas e desafios / Adonias Alves Cardoso Junior. – Campina Grande, 2025.  
31f.: il.

Trabalho de Conclusão de Curso (Graduação em Tecnologia em Telemática) - Instituto Federal da Paraíba, 2025.

Orientador: Prof. Dr. Victor Emanuel Farias da Costa Borges.

1. Telemática - manutenção preditiva. 2. Inteligência Artificial. 3. Internet das Coisas (IoT). 4. Indústria 4.0. 5. Monitoramento de condições. I. Borges, Victor Emanuel Farias da Costa (orient.). II. Título.

CDU 004.8

# MANUTENÇÃO PREDITIVA COM IA E IOT NA INDÚSTRIA 4.0: UM ESTUDO DE CONCEITOS, ARQUITETURAS E DESAFIOS

ADONIAS ALVES CARDOSO JUNIOR

---

Victor Emanuel Farias da Costa Borges  
Orientador

---

Leilson da Silva Santos  
Membro da Banca

---

Fagner de Araújo Pereira  
Membro da Banca

Campina Grande, Paraíba, Brasil  
Dezembro/2025

# Agradecimentos

Agradeço imensamente à minha mãe, pelo amor incondicional, pelo apoio constante e por ter sido minha maior incentivadora ao longo de toda a minha trajetória. Obrigado por acreditar em mim mesmo nos momentos mais difíceis.

Ao meu orientador, Prof. Victor Emanuel Farias da Costa Borges, agradeço pela paciência, pela disponibilidade e por todo o conhecimento compartilhado. Sua orientação foi fundamental não apenas para a conclusão deste trabalho, mas para o meu crescimento acadêmico.

# Resumo

A Indústria 4.0 tem revolucionado o setor de manufatura através da integração de tecnologias digitais, como a Internet das Coisas (IoT) e a Inteligência Artificial (IA). Nesse contexto, a manutenção preditiva (PdM) surge como uma estratégia essencial para otimizar processos industriais, substituindo as manutenções corretiva e preventiva, que são custosas e ineficientes. A PdM utiliza dados coletados por sensores IoT para monitorar a condição de equipamentos em tempo real e aplica algoritmos de Aprendizado de Máquina (*Machine Learning*) para detectar anomalias e prever falhas. Esta abordagem tem evoluído com o uso de Gêmeos Digitais (*Digital Twins*), que criam réplicas virtuais de ativos físicos para simulação e prognóstico avançado. Este trabalho realiza uma revisão bibliográfica exploratória, analisando artigos publicados entre 2019 e 2025 que abordam a aplicação de IA, IoT e Gêmeos Digitais na manutenção preditiva. O estudo identifica arquiteturas de sistema, conceitos e desafios de implementação. Estudos de caso analisados demonstram resultados significativos, como uma redução de 24% no tempo de inatividade de equipamentos. A análise também explora desafios emergentes, como a segurança das redes IoT e a implementação de modelos de IA em dispositivos de borda (*TinyML*). Conclui-se que a integração dessas tecnologias é uma abordagem viável e de alto impacto para aumentar a eficiência operacional e reduzir custos na indústria.

**Palavras-chave:** Manutenção Preditiva, Indústria 4.0, Internet das Coisas, Inteligência Artificial, Aprendizado de Máquina, Gêmeos Digitais.

# Abstract

Industry 4.0 has been revolutionizing the manufacturing sector through the integration of digital technologies such as the Internet of Things (IoT) and Artificial Intelligence (AI). In this context, predictive maintenance (PdM) emerges as an essential strategy to optimize industrial processes, replacing costly and inefficient corrective and preventive maintenance. PdM uses data collected by IoT sensors to monitor equipment health in real-time and applies Machine Learning (ML) algorithms to detect anomalies and predict failures. This approach has evolved with the use of Digital Twins, which create virtual replicas of physical assets for advanced simulation and prognosis. This work conducts an exploratory literature review, analyzing articles published between 2019 and 2025 that address the application of AI, IoT, and Digital Twins in predictive maintenance. The study identifies system architectures, concepts, and implementation challenges. Case studies analyzed demonstrate significant results, such as a 24% reduction in equipment downtime. The analysis also explores emerging challenges, such as the security of IoT networks against attacks and the implementation of AI models on edge devices (TinyML). It is concluded that the integration of these technologies is a viable and high-impact approach to increasing operational efficiency and reducing costs in the industry.

**Keywords:** Predictive Maintenance, Industry 4.0, Internet of Things, Artificial Intelligence, Machine Learning, Digital Twins.

# Sumário

|                                                                  |           |
|------------------------------------------------------------------|-----------|
| <b>Lista de Abreviaturas</b>                                     | <b>x</b>  |
| <b>Lista de Figuras</b>                                          | <b>xi</b> |
| <b>1 Introdução</b>                                              | <b>1</b>  |
| 1.1 Contextualização . . . . .                                   | 1         |
| 1.2 Problema de Pesquisa . . . . .                               | 2         |
| 1.2.1 Questões de Pesquisa . . . . .                             | 2         |
| 1.3 Justificativa . . . . .                                      | 3         |
| 1.4 Objetivos . . . . .                                          | 3         |
| 1.4.1 Objetivos Específicos . . . . .                            | 3         |
| 1.5 Estrutura do Trabalho . . . . .                              | 4         |
| <b>2 Fundamentação Teórica</b>                                   | <b>5</b>  |
| 2.1 Indústria 4.0 e a Evolução da Manutenção . . . . .           | 5         |
| 2.1.1 Os Tipos de Manutenção Industrial . . . . .                | 5         |
| 2.2 Internet das Coisas (IoT) como Coletor de Dados . . . . .    | 6         |
| 2.2.1 Arquitetura de Referência para PdM . . . . .               | 6         |
| 2.3 Inteligência Artificial (IA) como Motor de Análise . . . . . | 7         |
| 2.3.1 Aprendizado de Máquina . . . . .                           | 8         |
| 2.3.2 Modelos de IA Relevantes na PdM . . . . .                  | 8         |
| 2.4 Gêmeos Digitais ( <i>Digital Twins</i> ) . . . . .           | 9         |
| <b>3 Metodologia</b>                                             | <b>11</b> |
| 3.1 Processo de Revisão da Literatura . . . . .                  | 11        |
| 3.1.1 Definição da Questão de Pesquisa . . . . .                 | 11        |
| 3.1.2 Estratégia de Busca . . . . .                              | 11        |
| 3.1.3 Critérios de Inclusão e Exclusão . . . . .                 | 11        |
| 3.1.4 Análise e Síntese de Dados . . . . .                       | 12        |
| <b>4 Discussão e Resultados</b>                                  | <b>13</b> |
| 4.1 Aplicações e Estudos de Caso . . . . .                       | 13        |
| 4.1.1 Implementação Computacional em Python . . . . .            | 14        |

|          |                                                              |           |
|----------|--------------------------------------------------------------|-----------|
| 4.2      | Algoritmos de Aprendizado de Máquina Utilizados . . . . .    | 15        |
| 4.3      | Desafios Técnicos Identificados . . . . .                    | 15        |
| 4.4      | Limitações e Barreiras de Adoção . . . . .                   | 16        |
| 4.4.1    | Custos de Implementação (CAPEX) . . . . .                    | 16        |
| 4.4.2    | Integração com Sistemas Legados . . . . .                    | 16        |
| 4.4.3    | Confiabilidade dos Dados e Falsos Positivos . . . . .        | 16        |
| 4.4.4    | Escassez de Mão de Obra Qualificada . . . . .                | 16        |
| <b>5</b> | <b>Conclusões e Trabalhos Futuros</b>                        | <b>17</b> |
| 5.1      | Considerações Finais . . . . .                               | 17        |
| 5.2      | Trabalhos Futuros . . . . .                                  | 18        |
| <b>A</b> | <b>Algoritmo de Geração de Sinais de Vibração Sintéticos</b> | <b>19</b> |
| A.1      | Código Fonte (Python) . . . . .                              | 19        |
|          | <b>Referências Bibliográficas</b>                            | <b>22</b> |

# Lista de Abreviaturas

|        |                                                          |
|--------|----------------------------------------------------------|
| CPS    | <i>Cyber-Physical Systems</i> (Sistemas Ciberfísicos)    |
| DT     | <i>Digital Twin</i> (Gêmeo Digital)                      |
| IA     | <i>Artificial Intelligence</i> (Inteligência Artificial) |
| IoT    | <i>Internet of Things</i> (Internet das Coisas)          |
| ML     | <i>Machine Learning</i> (Aprendizado de Máquina)         |
| PdM    | <i>Predictive Maintenance</i> (Manutenção Preditiva)     |
| RUL    | <i>Remaining Useful Life</i> (Vida Útil Restante)        |
| TinyML | <i>Tiny Machine Learning</i>                             |

# Lista de Figuras

|     |                                                                                                        |    |
|-----|--------------------------------------------------------------------------------------------------------|----|
| 1.1 | Projeção de crescimento do mercado global de Manutenção Preditiva (2020-2025). . . . .                 | 2  |
| 2.1 | Curva de Maturidade: Relação entre Complexidade e Valor Agregado. . . . .                              | 6  |
| 2.2 | Arquitetura de referência em camadas para sistemas de PdM. . . . .                                     | 7  |
| 2.3 | Principais categorias de Aprendizado de Máquina aplicadas à PdM. . . . .                               | 8  |
| 2.4 | Diagrama conceitual do fluxo de dados e informações em um sistema de Gêmeo Digital. . . . .            | 10 |
| 4.1 | Exemplos de assinaturas de vibração no tempo para operação normal e diferentes tipos de falha. . . . . | 14 |

# Capítulo 1

## Introdução

A gestão eficiente de ativos industriais e a constante busca por otimização de processos produtivos são pilares fundamentais da engenharia moderna. No cenário atual, marcado por uma rápida evolução tecnológica, a integração entre sistemas físicos e digitais deixou de ser uma tendência futurista para se tornar uma necessidade estratégica. Este trabalho se insere nesse contexto, explorando como novas ferramentas computacionais podem transformar a maneira como a indústria lida com a manutenção de seus equipamentos.

### 1.1 Contextualização

A indústria mundial vivencia uma transformação profunda impulsionada pela Quarta Revolução Industrial, também conhecida como Indústria 4.0. Esta nova era é caracterizada pela fusão de tecnologias digitais, como Inteligência Artificial (IA), Internet das Coisas (IoT), *Big Data*, Computação em Nuvem e Gêmeos Digitais (*Digital Twins*), que permitem a criação de sistemas ciberfísicos (*CPS*) e fábricas inteligentes [Marchi et al. 2021]. Diferente das revoluções anteriores, focadas na mecanização, na produção em massa e na automação inicial, a Indústria 4.0 foca na interconectividade, na digitalização de processos e na tomada de decisão descentralizada e baseada em dados.

Nesse cenário de alta competitividade global, a otimização de custos e a maximização da eficiência operacional deixaram de ser diferenciais e tornaram-se requisitos centrais para a sobrevivência das empresas. A capacidade de prever falhas, reduzir o tempo de inatividade não planejado e otimizar o uso de recursos de manutenção é fundamental.

A expansão do mercado de Manutenção Preditiva (PdM) é uma prova direta dessa tendência. Dados recentes da consultoria *IoT Analytics* (2024) indicam que o mercado global de PdM está projetado para atingir cerca de 14,5 bilhões de dólares até 2025, representando uma taxa de crescimento anual composta (CAGR) de 28,5% (ver Figura 1.1). Este crescimento acelerado é impulsionado justamente pela maturidade e adoção em escala de tecnologias como IoT e modelos avançados de IA.

**Figura 1.1:** *Projeção de crescimento do mercado global de Manutenção Preditiva (2020-2025).*



Fonte: Adaptado de IoT Analytics (2024).

## 1.2 Problema de Pesquisa

Historicamente, a manutenção de equipamentos industriais tem sido um dos maiores desafios operacionais. As abordagens tradicionais, como a manutenção *corretiva* (reparar após a falha) e a *preventiva* (reparar em intervalos fixos), são comprovadamente ineficientes [Achouch et al. 2022]. A primeira gera paradas não programadas e custos catastróficos, enquanto a segunda desperdiça recursos ao trocar peças que ainda possuem vida útil.

A ascensão da Indústria 4.0 viabiliza uma abordagem mais inteligente: a Manutenção Preditiva (PdM), que propõe o monitoramento contínuo da condição real dos equipamentos para prever falhas [Marchi et al. 2021]. Contudo, existe uma lacuna de conhecimento na integração eficaz das diversas tecnologias emergentes para criar sistemas preditivos que sejam robustos, escaláveis e seguros.

Diante disso, este trabalho busca responder a seguinte questão central: Como as tecnologias de Inteligência Artificial, Internet das Coisas e Gêmeos Digitais podem ser integradas para criar sistemas de manutenção preditiva eficazes, e quais são as arquiteturas, aplicações e desafios dessa integração?

### 1.2.1 Questões de Pesquisa

Para guiar este estudo, foram definidas as seguintes Questões de Pesquisa (QP):

- **QP1:** Quais são os conceitos fundamentais das tecnologias habilitadoras (IoT, IA e

Gêmeos Digitais) que servem como base para a PdM?

- **QP2:** Quais são as arquiteturas de sistema e modelos de referência propostos na literatura recente para a integração dessas tecnologias?
- **QP3:** Quais são as aplicações práticas, algoritmos de Aprendizado de Máquina e desafios identificados nos estudos de caso?

## 1.3 Justificativa

A combinação da IoT com a IA é o pilar da manutenção preditiva moderna. A IoT, através de uma rede de sensores, permite a coleta massiva de dados em tempo real. O Aprendizado de Máquina (*Machine Learning*) fornece os meios para analisar esse volume de dados, identificar padrões complexos e prever a vida útil restante dos componentes (RUL) [Achouch et al. 2022]. Recentemente, o conceito de Gêmeos Digitais (DT) emergiu como um catalisador, permitindo simulações avançadas [Dinter et al. 2023, Aivaliotis et al. 2019].

Para além da viabilidade técnica, a justificativa para a adoção destas tecnologias reside no equilíbrio entre o investimento em infraestrutura permanente e o retorno sobre o investimento (ROI). Embora a implementação de sistemas de monitoramento contínuo exija custos de capital (CAPEX) em sensores e redes, bem como custos operacionais (OPEX) em processamento de dados, a literatura indica que a economia gerada pela redução de paradas não planejadas em ativos críticos compensa amplamente esses gastos. Assim, a justificativa econômica da manutenção preditiva sustenta-se quando o custo para manter o sistema rodando é inferior ao custo do lucro cessante e dos danos causados por falhas catastróficas.

A relevância deste tema é comprovada pelos resultados práticos documentados na literatura. Um estudo de caso específico, conduzido por Zaro & Webber [Zaro e Webber 2022], demonstrou uma redução de 24% no tempo de inatividade de equipamentos. A aplicação se estende por diversos setores, desde manufatura até aviação e energia [Zhang et al. 2021, Lee, Hussain e Oh 2025, Elsisi et al. 2021].

## 1.4 Objetivos

Este trabalho tem como objetivo geral realizar um estudo da literatura sobre a aplicação de IA, IoT e Gêmeos Digitais para manutenção preditiva.

### 1.4.1 Objetivos Específicos

- Apresentar os conceitos fundamentais da Indústria 4.0, PdM, IoT e IA.
- Definir o conceito de Gêmeos Digitais e seu papel na manutenção.
- Analisar as arquiteturas de sistema propostas na literatura.

- Identificar os principais algoritmos de Aprendizado de Máquina e técnicas (como *TinyML*).
- Investigar estudos de caso e aplicações práticas.
- Discutir os desafios, com foco na segurança cibernética.

## 1.5 Estrutura do Trabalho

Este trabalho está organizado da seguinte forma:

O Capítulo 1 introduz o tema, problema e objetivos.

O Capítulo 2 apresenta a fundamentação teórica.

O Capítulo 3 detalha a metodologia de revisão bibliográfica.

O Capítulo 4 apresenta a discussão e os resultados, incluindo arquiteturas e desafios.

Finalmente, o Capítulo 5 apresenta as conclusões.

# Capítulo 2

## Fundamentação Teórica

Este capítulo apresenta os conceitos teóricos que fundamentam a pesquisa, detalhando os pilares tecnológicos da Manutenção Preditiva (PdM).

### 2.1 Indústria 4.0 e a Evolução da Manutenção

A Quarta Revolução Industrial representa uma mudança de paradigma na produção, movendo-se em direção a sistemas inteligentes e conectados. Uma das áreas mais impactadas é a gestão da manutenção de ativos industriais.

#### 2.1.1 Os Tipos de Manutenção Industrial


A manutenção industrial é definida como o conjunto de todas as ações técnicas, administrativas e de gerenciamento durante o ciclo de vida de um item, destinadas a mantê-lo ou recolocá-lo em um estado no qual possa desempenhar a função requerida. Historicamente, as estratégias de manutenção evoluíram para atender às crescentes demandas de disponibilidade e confiabilidade dos ativos:

- **Manutenção Corretiva:** Também conhecida como "quebra-conserta" (*run-to-failure*), é a abordagem mais antiga e reativa. A intervenção ocorre apenas *após* a falha ou quebra do equipamento. Embora maximize a utilização da vida útil da peça, gera custos elevados devido a paradas não programadas da produção, danos colaterais a outros componentes e a necessidade de manter grandes estoques de peças de reposição para emergências.
- **Manutenção Preventiva:** É uma abordagem baseada no tempo ou em ciclos de operação (ex: número de horas trabalhadas). As intervenções são agendadas periodicamente, independentemente do estado real do equipamento. Embora reduza a probabilidade de falhas catastróficas em comparação à corretiva, é inerentemente ineficiente, pois frequentemente resulta na substituição prematura de componentes que ainda estão em boas condições operacionais, gerando desperdício de recursos.

- **Manutenção Preditiva (PdM):** É a estratégia central na Indústria 4.0, baseando-se no monitoramento contínuo da *condição real* do equipamento via sensores e análise de dados. O objetivo é prever falhas antes que ocorram, permitindo intervenções no momento ideal. Contudo, sua viabilidade econômica não é universal; o ponto de equilíbrio entre o alto investimento inicial (sensores e infraestrutura) e os custos permanentes de sistema é atingido principalmente em *ativos críticos*. Nesses casos, o custo da infraestrutura é amplamente compensado pela eliminação do lucro cessante e de falhas catastróficas, garantindo um Retorno sobre Investimento (ROI) positivo.

A Figura 2.1 apresentada abaixo mostra a relação de proporcionalidade entre a evolução das estratégias e o retorno para o negócio. Fica evidente que a Manutenção Preditiva (no topo da curva) exige o maior nível de complexidade técnica demandando a infraestrutura de IoT e IA discutida neste trabalho porém, é a estratégia que entrega o maior valor agregado, ao reduzir drasticamente o lucro cessante e aumentar a vida útil dos ativos.

**Figura 2.1:** *Curva de Maturidade: Relação entre Complexidade e Valor Agregado.*



Fonte: Elaborado pelo autor (2025) com base em IoT Analytics.

## 2.2 Internet das Coisas (IoT) como Coletor de Dados

A Internet das Coisas (IoT) descreve a rede de dispositivos físicos interconectados que possuem sensores, software e outras tecnologias para coletar e trocar dados pela internet. No contexto industrial (IIoT), ela atua como o sistema nervoso da fábrica, permitindo a coleta de dados em tempo real de ativos distribuídos.

### 2.2.1 Arquitetura de Referência para PdM


A literatura e a imagem apresentada na Figura 2.2 descrevem uma arquitetura de IoT que não funciona apenas como uma via de mão única, mas sim como um ciclo de feedback

contínuo. Conforme observado por Van Dinter et al. [Dinter et al. 2023], o funcionamento se dá pela interação entre camadas físicas e digitais:

1. **Camada Física (Sensores e Atuadores):** Esta é a interface com o mundo real, mas com funções distintas:
  - **Sensores (Entrada):** São responsáveis pela coleta de dados brutos multimodais que incluem não apenas variáveis físicas como vibração e temperatura, mas também dados de processo como corrente elétrica, pressão e umidade e pelo envio para o sistema. Eles iniciam o fluxo de dados necessário para a análise de fusão sensorial.
  - **Atuadores (Saída):** Localizam-se no final do fluxo lógico. Eles *recebem* comandos do sistema digital para realizar ações físicas na máquina (como desligar um motor ou ajustar uma velocidade) baseados na análise feita.
2. **Camada de Borda/Gateway:** Atua como a ponte de comunicação. Recebe os dados dos sensores, realiza uma filtragem inicial e os transmite para a nuvem.
3. **Camada de Nuvem e Serviços (*Cloud Computing*):** É onde a "inteligência" reside. Os dados são armazenados e processados por algoritmos de IA e Gêmeos Digitais. Aqui, o sistema decide se uma manutenção é necessária.
4. **Camada de Aplicação e Retorno:** Após o processamento, o sistema gera visualizações para os gestores (Dashboards) e, crucialmente, envia comandos de volta para a camada física (Atuadores) para corrigir problemas ou alertar operadores.

Dessa forma, a Figura 2.2 deve ser lida como um fluxo que sobe dos sensores para a nuvem (dados) e desce da nuvem para os atuadores (ação).

**Figura 2.2:** *Arquitetura de referência em camadas para sistemas de PdM.*



Fonte: Adaptado de van Dinter et al. (2023)

## 2.3 Inteligência Artificial (IA) como Motor de Análise

A Inteligência Artificial, especificamente o Aprendizado de Máquina (*Machine Learning*), fornece a capacidade de transformar os dados brutos da IoT em previsões.

### 2.3.1 Aprendizado de Máquina

Diferente da programação tradicional baseada em regras, o Aprendizado de Máquina otimiza modelos matemáticos através da análise estatística de dados. No contexto da PdM, o objetivo é treinar um modelo capaz de classificar os padrões de operação e diferenciar o comportamento "normal" do "anômalo".

A Figura 2.3 ilustra as duas categorias principais:

- **Aprendizado Supervisionado:** Utiliza dados rotulados (histórico de falhas conhecidas).
- **Aprendizado Não Supervisionado:** Utiliza dados sem rótulos, ideal para detecção de anomalias (desvios do padrão normal).

**Figura 2.3:** Principais categorias de Aprendizado de Máquina aplicadas à PdM.



Fonte: Adaptado de IA Expert Academy

### 2.3.2 Modelos de IA Relevantes na PdM

A literatura de PdM explora diversos algoritmos, desde os mais simples até os mais complexos:


- **Modelos Estatísticos (ex: ARIMA):** Usados para prever séries temporais, mas geralmente limitados a uma única variável.
- **Modelos Clássicos de ML (ex: SVM, Random Forest):** São eficazes para tarefas de classificação (ex: "é falha" ou "não é falha") quando se tem dados bem estruturados.
- **Deep Learning (Redes Neurais):** São modelos mais complexos, como Redes Neurais Recorrentes (RNN) ou *Transformers* (mencionados em [Guan et al. 2022]), que são especialmente bons em encontrar padrões em dados sequenciais complexos, como séries temporais de múltiplos sensores ao mesmo tempo.

## 2.4 Gêmeos Digitais (*Digital Twins*)

O Gêmeo Digital (*Digital Twin*) é tecnicamente definido como uma representação virtual dinâmica e de alta fidelidade de um ativo físico, processo ou sistema. Diferente de um modelo 3D estático (CAD), que representa apenas a geometria, o Gêmeo Digital integra dados em tempo real, simulação e aprendizado de máquina para espelhar o comportamento e o estado operacional do seu correspondente físico ao longo do tempo.

Este modelo computacional é alimentado continuamente por dados de sensores (IoT), permitindo não apenas a visualização remota, mas também a realização de simulações complexas. No contexto da manutenção, essa tecnologia possibilita a execução de cenários do tipo "e se" (*what-if*) para prever o desgaste futuro e testar estratégias de intervenção em ambiente virtual antes de aplicá-las ao equipamento real. Ele constitui uma réplica virtual dinâmica e de alta fidelidade de um ativo físico. Este modelo computacional é alimentado continuamente por dados de sensores em tempo real, refletindo o estado operacional exato do equipamento com precisão.

A Figura 2.4 apresenta o diagrama conceitual desta tecnologia, evidenciando a ponte entre o mundo material e o ciberespaço. Observe que existe um fluxo bidirecional essencial: os dados fluem do ativo físico (à esquerda) para alimentar a instância virtual (à direita), que reside em ambiente de computação em nuvem. Embora a representação gráfica à direita espelhe a estrutura da máquina real para fins de monitoramento, ela consiste em um modelo matemático e estatístico (Gêmeo Digital) capaz de processar simulações em tempo real e devolver comandos de otimização para o sistema físico.

**Figura 2.4:** Diagrama conceitual do fluxo de dados e informações em um sistema de Gêmeo Digital.

Fonte: Elaboração própria, adaptado de Aivaliotis et al. (2019)

# Capítulo 3

## Metodologia

Este capítulo descreve os procedimentos metodológicos adotados para a realização desta pesquisa. O trabalho classifica-se como uma Revisão Bibliográfica Exploratória, cujo objetivo é identificar, avaliar e sintetizar o conhecimento existente sobre a integração de IA, IoT e Gêmeos Digitais na manutenção preditiva.

### 3.1 Processo de Revisão da Literatura

A condução da revisão bibliográfica seguiu um protocolo estruturado em quatro etapas principais, visando garantir a relevância e a qualidade científica das fontes selecionadas.

#### 3.1.1 Definição da Questão de Pesquisa

A revisão foi guiada pela necessidade de compreender as arquiteturas tecnológicas e os desafios de implementação da PdM na Indústria 4.0. O foco foi mantido na intersecção entre as três tecnologias habilitadoras principais (*IA, IoT, Digital Twin*).

#### 3.1.2 Estratégia de Busca

A busca por artigos científicos foi realizada em bases de dados de reconhecimento internacional nas áreas de engenharia e ciência da computação. As principais bases consultadas foram:

- **Google Scholar:** Para uma varredura ampla da literatura acadêmica.
- **IEEE Xplore:** Pela sua relevância em publicações sobre eletrônica e computação.
- **ScienceDirect e Scopus:** Para acesso a periódicos de alto impacto.

#### 3.1.3 Critérios de Inclusão e Exclusão

Para a seleção dos trabalhos, foram aplicados os seguintes filtros:

- **Temporalidade:** Foram priorizados artigos publicados nos últimos cinco anos (2019-2025) para garantir a atualidade tecnológica.
- **Idioma:** Artigos em português e inglês.
- **Tipologia:** Foco em artigos de revisão (*reviews*), que oferecem panoramas completos, e estudos de caso aplicados, que demonstram resultados práticos.
- **Palavras-chave:** Combinações de termos como "Manutenção Preditiva", "Indústria 4.0", "IoT", "Machine Learning", "Digital Twin" e "Arquitetura de Referência".

#### 3.1.4 Análise e Síntese de Dados

Após a triagem inicial, foi realizada a leitura completa dos textos selecionados. Ao final do processo, foram selecionados 11 artigos que compõem o núcleo desta revisão. A análise desses documentos permitiu categorizar os resultados em três eixos temáticos: arquiteturas de sistema, aplicações práticas e desafios de implementação, que são discutidos no capítulo a seguir.

# Capítulo 4

## Discussão e Resultados

Com base na revisão bibliográfica detalhada no capítulo anterior, este capítulo apresenta a análise das aplicações, algoritmos e, crucialmente, os desafios e limitações encontrados na literatura.


### 4.1 Aplicações e Estudos de Caso

A literatura apresenta diversas aplicações práticas que comprovam a eficácia da PdM em cenários reais.

- **Manufatura:** O estudo de caso de Zaro & Webber [Zaro e Webber 2022] demonstrou uma redução de 24% no tempo de inatividade de equipamentos em uma linha de produção, utilizando monitoramento de vibração.
- **Aviação:** Lee et al. [Lee, Hussain e Oh 2025] utilizaram um conjunto de dados robusto (mais de 4.900 amostras) para validar modelos de IA na detecção de falhas em rotores de aeronaves, evidenciando a alta confiabilidade necessária para o setor.
- **Energia:** Aplicações em medidores inteligentes (*smart meters*) para monitoramento da rede elétrica, focando na detecção de fraudes e falhas [Elsisi et al. 2021].

A análise de vibração é fundamental para equipamentos rotativos. A Figura 4.1 exemplifica como diferentes falhas mecânicas geram assinaturas visuais distintas no sinal. Algoritmos de IA são treinados para distinguir a onda "limpa" (normal) das ondas ruidosas e com picos característicos de desbalanceamento ou folga mecânica.

**Figura 4.1:** Exemplos de assinaturas de vibração no tempo para operação normal e diferentes tipos de falha.



Fonte: Elaboração própria (Simulação via Python)

#### 4.1.1 Implementação Computacional em Python

A geração dos sinais sintéticos foi realizada por meio de scripts desenvolvidos em linguagem Python, utilizando as bibliotecas *NumPy* e *Matplotlib*, amplamente empregadas em aplicações científicas e de engenharia. A implementação foi executada em ambiente Google Colab, garantindo reprodutibilidade e facilidade de execução.

Inicialmente, definiu-se o vetor temporal considerando um intervalo de 0,5 segundos, com 1000 amostras igualmente espaçadas, simulando uma aquisição de sinais em alta resolução. A frequência de rotação foi fixada em 30 Hz, correspondente a aproximadamente 1800 rotações por minuto (RPM), valor típico em máquinas rotativas industriais.

O sinal de vibração normal foi modelado como ruído branco gaussiano de baixa amplitude, representando apenas o ruído de fundo do sistema. Para o desbalanceamento, foi adicionada uma componente senoidal dominante na frequência fundamental de rotação (1x RPM), característica clássica dessa falha.

No caso do desalinhamento, o sinal foi composto pela soma de componentes senoidais na frequência fundamental (1x RPM) e no segundo harmônico (2x RPM), resultando em um padrão de onda mais complexo, frequentemente observado na literatura de diagnóstico de falhas mecânicas.

A folga mecânica foi simulada por meio da combinação de múltiplos harmônicos e pela aplicação de ceifamento (*clipping*) no sinal, representando o comportamento não linear causado por impactos repetitivos entre componentes mecânicos com folga excessiva.

Por fim, os sinais foram organizados em um único gráfico com quatro subfiguras, facilitando a comparação visual entre as condições operacionais analisadas. A Figura ?? foi exportada em alta resolução (300 DPI), atendendo aos requisitos de qualidade para impressão e publicação acadêmica.

## 4.2 Algoritmos de Aprendizado de Máquina Utilizados

A eficácia da PdM depende diretamente do algoritmo utilizado para processar os dados. A revisão identificou duas categorias predominantes:

- **Detecção de Anomalias:** Uso comum em nível de borda para identificar desvios do padrão normal de operação, sem necessariamente classificar o tipo específico de erro inicialmente [Siang, Ahamd e Abidin 2021].
- **Aprendizado Profundo (*Deep Learning*):** Utilizado para dados complexos de múltiplos sensores. Guan et al. [Guan et al. 2022] propõem o modelo **GTAD** (baseado em grafos e redes temporais) para maior precisão em séries temporais multivariadas.

## 4.3 Desafios Técnicos Identificados

A implementação técnica enfrenta barreiras significativas que não podem ser ignoradas:

- **Segurança de Redes IoT:** A conexão de máquinas industriais à rede cria novas vulnerabilidades cibernéticas. A própria IA é usada para detectar ataques à infraestrutura, mas a superfície de ataque aumenta consideravelmente [Haji e Ameen 2021].

- **Processamento na Borda (*TinyML*):** O desafio de rodar modelos complexos em hardwares com recursos limitados de energia e memória. Ferramentas como *TensorFlow Lite Micro* são essenciais para viabilizar a análise local e reduzir a latência [Siang, Ahamd e Abidin 2021].

## 4.4 Limitações e Barreiras de Adoção

Embora os benefícios da PdM sejam evidentes, a revisão da literatura aponta que a sua adoção não é trivial e apresenta problemas práticos que limitam sua expansão em larga escala.

### 4.4.1 Custos de Implementação (CAPEX)

A transição para a Indústria 4.0 exige um investimento inicial elevado (*Capital Expenditure*). A aquisição de sensores de alta precisão, infraestrutura de rede robusta e servidores (ou serviços de nuvem) pode ser proibitiva para pequenas e médias empresas. Muitas vezes, o retorno sobre o investimento (ROI) só é percebido a longo prazo, o que dificulta a aprovação desses projetos.

### 4.4.2 Integração com Sistemas Legados

Um dos maiores problemas práticos é a heterogeneidade do parque industrial. Muitas fábricas operam com máquinas antigas (sistemas legados) que não possuem portas de comunicação nativas ou protocolos modernos. A "sensorização" desses equipamentos (retrofitting) é complexa e propensa a falhas de compatibilidade.

### 4.4.3 Confiabilidade dos Dados e Falsos Positivos

A eficácia da IA depende inteiramente da qualidade dos dados. Sensores mal calibrados ou sujeitos a ruído ambiental excessivo podem levar os algoritmos a gerarem "falsos positivos" (alertar uma falha que não existe). Isso gera desconfiança nas equipes de operação, que podem passar a ignorar os alertas do sistema, anulando o propósito da tecnologia.

### 4.4.4 Escassez de Mão de Obra Qualificada

A implementação da PdM exige um perfil profissional híbrido, com conhecimento tanto de mecânica industrial quanto de ciência de dados e programação. A escassez desses profissionais no mercado é um gargalo significativo apontado pelos estudos de caso analisados.

# Capítulo 5

## Conclusões e Trabalhos Futuros

Este trabalho teve como objetivo analisar a integração das tecnologias habilitadoras da Indústria 4.0 especificamente a Internet das Coisas (IoT), a Inteligência Artificial (IA) e os Gêmeos Digitais na otimização de processos de manutenção industrial. Através de uma revisão bibliográfica exploratória, foi possível mapear o estado da arte, identificar arquiteturas de referência e compreender os desafios práticos dessa implementação.

### 5.1 Considerações Finais

A análise da literatura confirmou a hipótese de que a transição da manutenção preventiva para a preditiva (PdM) não é apenas uma atualização tecnológica, mas uma mudança estratégica fundamental para a competitividade. Os estudos de caso analisados, incluindo aplicações em manufatura rotativa e aviação, demonstraram que a capacidade de monitorar a condição real dos ativos resulta em ganhos tangíveis, como a redução comprovada de até 24% no tempo de inatividade de equipamentos.

Em resposta às questões de pesquisa formuladas, conclui-se que:

1. **Integração Tecnológica:** A eficácia da PdM depende da simbiose entre as três tecnologias. A IoT atua como o sistema sensorial (coleta), a IA como o sistema cognitivo (análise de padrões e detecção de anomalias) e os Gêmeos Digitais como a plataforma de simulação e prognóstico.
2. **Arquitetura de Sistema:** A arquitetura padrão consolidada na literatura é baseada em camadas (Borda, Névoa e Nuvem). Observou-se uma tendência crescente de mover o processamento de IA para a borda (*Edge Computing*), utilizando técnicas de *TinyML* para reduzir a latência e a dependência de largura de banda.
3. **Desafios Persistentes:** Apesar dos benefícios claros, a adoção em larga escala enfrenta barreiras significativas. A segurança cibernética emergiu como uma preocupação crítica, visto que a conexão de sistemas industriais legados à internet expande a superfície de ataque. Além disso, a complexidade de implementação e a escassez de mão de obra

qualificada para lidar com ciência de dados e mecânica simultaneamente continuam sendo gargalos.

Em suma, a manutenção preditiva 4.0 provou ser uma abordagem viável e de alto retorno sobre o investimento, desde que as organizações estejam preparadas para lidar com os requisitos de infraestrutura e segurança de dados que ela impõe.

## 5.2 Trabalhos Futuros

Como desdobramento natural desta pesquisa exploratória, sugerem-se as seguintes linhas de investigação focadas em simulação e análise de dados para trabalhos futuros:

- Simulação de Cenários com Gêmeos Digitais: Utilização de plataformas de software (como MATLAB/Simulink ou Anylogic) para criar um modelo virtual de um ativo industrial e simular diferentes cenários de falha, validando a eficácia de algoritmos preditivos em um ambiente controlado e seguro.
- Estudo Comparativo de Algoritmos em Datasets Públicos: Realização de experimentos práticos utilizando bases de dados reais e abertas (como o dataset da NASA para turbinas ou rolamentos) para comparar o desempenho de diferentes técnicas de IA (ex: Redes Neurais vs. Árvores de Decisão) na detecção de anomalias.
- Análise de Cibersegurança em Protocolos IoT: Investigação teórica ou simulada sobre as vulnerabilidades do protocolo MQTT em ambientes industriais, propondo e testando camadas de criptografia ou autenticação para proteger os dados de manutenção.
- Avaliação de Ferramentas de TinyML: Teste e comparação de diferentes frameworks de software para *TinyML* (como TensorFlow Lite for Microcontrollers vs. Edge Impulse), avaliando a facilidade de uso e a precisão dos modelos gerados para aplicações de borda.

# Apêndice A

## Algoritmo de Geração de Sinais de Vibração Sintéticos

### A.1 Código Fonte (Python)

O script abaixo foi desenvolvido em Python 3.8+ e utiliza as bibliotecas *NumPy* e *Matplotlib*. Ele pode ser copiado e executado integralmente para reproduzir as formas de onda de falhas de desbalanceamento, desalinhamento e folga mecânica.

```
1 import numpy as np
2 import matplotlib.pyplot as plt
3
4 import numpy as np
5 import matplotlib.pyplot as plt
6
7 # Configura o para alta resolução (300 DPI padrão de impressão)
8 plt.rcParams['figure.dpi'] = 300
9 plt.rcParams['font.family'] = 'serif' # Fonte estilo acadêmico (Times New
    Roman similar)
10
11 # Dados simulados (Tempo)
12 t = np.linspace(0, 0.5, 1000) # 0.5 segundos de amostragem
13 f_rotacao = 30 # 30 Hz (equivalente a 1800 RPM)
14
15 # 1. Sinal Normal (Ruído baixo aleatório)
16 sinal_normal = 0.1 * np.random.randn(len(t))
17
18 # 2. Desbalanceamento (Senoidal pura em 1x a rotação)
19 sinal_desbal = 1.5 * np.sin(2 * np.pi * f_rotacao * t) + 0.1 * np.random.
    randn(len(t))
20
21 # 3. Desalinhamento (Forte em 1x e 2x a rotação — clássico "M" shape)
22 sinal_desalin = 1.0 * np.sin(2 * np.pi * f_rotacao * t) + \
23     0.8 * np.sin(2 * np.pi * (2 * f_rotacao) * t) + \
```

```

24         0.1 * np.random.randn(len(t))
25
26 # 4. Folga Mecânica (Harmônicos múltiplos e comportamento caótico/
    ceifado)
27 sinal_folga = 0.8 * np.sin(2 * np.pi * f_rotacao * t)
28 sinal_folga[sinal_folga > 0.5] = 0.5 # Simula "ceifamento" (pancada/limite
    f_sico)
29 sinal_folga = sinal_folga + 0.3 * np.sin(2 * np.pi * (3 * f_rotacao) * t)
    + \
30         0.2 * np.random.randn(len(t))
31
32 # Criando os Gráficos (4 linhas, 1 coluna)
33 fig, axs = plt.subplots(4, 1, figsize=(8, 10), constrained_layout=True)
34
35 # Plot 1: Normal
36 axs[0].plot(t, sinal_normal, color='green', linewidth=1)
37 axs[0].set_title('1. Vibração Normal (Operação Saudável)', fontsize
    =12, fontweight='bold')
38 axs[0].set_ylabel('Amplitude (g)')
39 axs[0].set_ylim([-2, 2])
40 axs[0].grid(True, linestyle='—', alpha=0.6)
41
42 # Plot 2: Desbalanceamento
43 axs[1].plot(t, sinal_desbal, color='orange', linewidth=1)
44 axs[1].set_title('2. Falha: Desbalanceamento (Pico em 1x RPM)', fontsize
    =12, fontweight='bold')
45 axs[1].set_ylabel('Amplitude (g)')
46 axs[1].set_ylim([-2, 2])
47 axs[1].grid(True, linestyle='—', alpha=0.6)
48
49 # Plot 3: Desalinhamento
50 axs[2].plot(t, sinal_desalin, color='red', linewidth=1)
51 axs[2].set_title('3. Falha: Desalinhamento (Picos em 1x e 2x RPM)',
    fontsize=12, fontweight='bold')
52 axs[2].set_ylabel('Amplitude (g)')
53 axs[2].set_ylim([-2, 2])
54 axs[2].grid(True, linestyle='—', alpha=0.6)
55
56 # Plot 4: Folga
57 axs[3].plot(t, sinal_folga, color='purple', linewidth=1)
58 axs[3].set_title('4. Falha: Folga Mecânica (Harmônicos e Ceifamento)',
    fontsize=12, fontweight='bold')
59 axs[3].set_ylabel('Amplitude (g)')
60 axs[3].set_xlabel('Tempo (s)')
61 axs[3].set_ylim([-2, 2])
62 axs[3].grid(True, linestyle='—', alpha=0.6)
63
64 # Salvar a imagem final

```

```
65 plt.savefig('sinal_vibricao_tcc.png', dpi=300, bbox_inches='tight')
66 plt.show()
67
68 # Execução do gerador
69 sinais = gerar_dataset_preditivo()
70 print("Sinais gerados com sucesso para fins de treinamento e teste.")
```

**Listing A.1:** *Script completo para simulação de falhas em ativos rotativos.*

# Referências Bibliográficas

- [Achouch et al. 2022]ACHOUCHE, M. et al. On predictive maintenance in industry 4.0: Overview, models, and challenges. *Applied Sciences*, MDPI, v. 12, n. 16, p. 8081, 2022. Baseado no arquivo. 2, 3
- [Aivaliotis et al. 2019]AIVALIOTIS, P. et al. The use of digital twin for predictive maintenance in manufacturing. *International Journal of Computer Integrated Manufacturing*, Taylor & Francis, v. 32, n. 11, p. 1067–1080, 2019. 3
- [Dinter et al. 2023]DINTER, R. van et al. Reference architecture for digital twin-based predictive maintenance systems. *Computers & Industrial Engineering*, Elsevier, v. 177, p. 109099, 2023. 3, 7
- [Elsisi et al. 2021]ELSISI, M. et al. Reliable industry 4.0 based on machine learning and iot for analyzing, monitoring, and securing smart meters. *Sensors*, MDPI, v. 21, n. 2, p. 487, 2021. Baseado no arquivo. 3, 13
- [Guan et al. 2022]GUAN, S. et al. Gtad: Graph and temporal neural network for multivariate time series anomaly detection. *Entropy*, MDPI, v. 24, n. 6, p. 759, 2022. Baseado no arquivo. 9, 15
- [Haji e Ameen 2021]HAJI, S. H.; AMEEN, S. Y. Attack and anomaly detection in iot networks using machine learning techniques: A review. *Asian Journal of Research in Computer Science*, v. 9, n. 2, p. 30–46, 2021. Baseado no arquivo. 15
- [Lee, Hussain e Oh 2025]LEE, K. Y.; HUSSAIN, K.; OH, I.-Y. Validation for predictive maintenance of aircraft systems using ai models developed with rotor blade vibration data. *IEEE Access*, v. 13, p. 26788–26799, 2025. Baseado nos arquivos. 3, 13
- [Marchi et al. 2021]MARCHI, C. d. S. et al. UtilizaÇão das tecnologias da indÚstria 4.0 na manutenÇão preditiva atravÊs do monitoramento de equipamentos e instalaÇões. In: *XXVIII Simpósio de Engenharia de Produção (SIMPEP)*. Bauru, SP: [s.n.], 2021. Baseado no arquivo. 1, 2
- [Siang, Ahamd e Abidin 2021]SIANG, Y. Y.; AHAMD, M. R.; ABIDIN, M. S. Z. Anomaly detection based on tiny machine learning: A review. *Open International Journal of Informatics (OIJI)*, v. 9, n. 2, p. 67–78, 2021. Baseado no arquivo. 15, 16
- [Zaro e Webber 2022]ZARO, E. M.; WEBBER, C. G. Estudo de caso de desenvolvimento de sistema para manutenÇão preditiva 4.0. *Produção Online*, v. 22, n. 3, p. 3418–3440, 2022. Baseado no arquivo. 3, 13
- [Zhang et al. 2021]ZHANG, X. et al. Research on vibration monitoring and fault diagnosis of rotating machinery based on internet of things technology. *Nonlinear Engineering, De Gruyter*, v. 10, n. 1, p. 245–254, 2021. Baseado no arquivo. 3

|                                                                                   |                                                                                  |
|-----------------------------------------------------------------------------------|----------------------------------------------------------------------------------|
|  | <b>INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DA PARAÍBA</b>            |
|                                                                                   | Campus Campina Grande - Código INEP: 25137409                                    |
|                                                                                   | R. Tranquílino Coelho Lemos, 671, Dinamérica, CEP 58432-300, Campina Grande (PB) |
|                                                                                   | CNPJ: 10.783.898/0003-37 - Telefone: (83) 2102.6200                              |

# Documento Digitalizado Restrito

## Entrega versão final tcc

|                      |                                                    |
|----------------------|----------------------------------------------------|
| Assunto:             | Entrega versão final tcc                           |
| Assinado por:        | Adonias Junior                                     |
| Tipo do Documento:   | Dissertação                                        |
| Situação:            | Finalizado                                         |
| Nível de Acesso:     | Restrito                                           |
| Hipótese Legal:      | Informação Pessoal (Art. 31 da Lei no 12.527/2011) |
| Tipo do Conferência: | Cópia Simples                                      |

Documento assinado eletronicamente por:

- Adonias Alves Cardoso Júnior, DISCENTE (202311210032) DE TECNOLOGIA EM TELEMÁTICA - CAMPINA GRANDE, em 08/01/2026 14:28:59.

Este documento foi armazenado no SUAP em 08/01/2026. Para comprovar sua integridade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifpb.edu.br/verificar-documento-externo/> e forneça os dados abaixo:

Código Verificador: 1724728  
Código de Autenticação: 30fa0c2eee

