



# Instituto Superior de Engenharia

Politécnico de Coimbra

DEPARTAMENTO DE ENGENHARIA QUÍMICA E  
BIOLÓGICA

## Implementação de Estratégias de Inovação na Gestão da Manutenção Industrial: Um Estudo de Caso sobre a Adoção de Tecnologias Emergentes

Dissertação para a obtenção do grau de Mestre em Engenharia e  
Gestão Industrial

Autor

**Sueid Pereira de Carvalho**

Orientador

**Jorge Alexandre Caldeira Gonçalves de Almeida**



INSTITUTO POLITÉCNICO  
DE COIMBRA

INSTITUTO SUPERIOR  
DE ENGENHARIA  
DE COIMBRA

Coimbra, Maio de 2025

# Implementação de Estratégias de Inovação na Gestão da Manutenção Industrial

## RESUMO

Esta dissertação tem como objetivo investigar o papel da manutenção industrial como eixo estratégico na transição digital das organizações, com foco na aplicação de tecnologias emergentes. Por meio de uma abordagem qualitativa, que combina revisão bibliográfica com dois estudos de caso, um no setor aeroespacial e outro no setor de energia eólica e uma aplicação prática, analisa-se o uso de ferramentas como *machine learning*, sensores inteligentes, gêmeos digitais e inteligência artificial na implementação de práticas de manutenção preditiva. Os resultados demonstram que a digitalização da manutenção permite antecipar falhas, reduzir paradas não programadas, otimizar recursos e aumentar a confiabilidade operacional dos ativos. Os estudos de caso ilustram na prática como essas soluções podem ser integradas aos sistemas produtivos, e revelam tanto os benefícios obtidos quanto os desafios enfrentados. A dissertação propõe ainda recomendações para uma adoção eficaz dessas tecnologias, contribuindo com orientações relevantes para profissionais e gestores interessados em alinhar suas estratégias de manutenção aos princípios da transformação digital.

**Palavras-chave:** manutenção preditiva, tecnologias emergentes, confiabilidade, inovação



## **ABSTRACT**

This dissertation aims to investigate the role of industrial maintenance as a strategic pillar in the digital transition of organizations, focusing on the application of emerging technologies. Through a qualitative approach that combines a literature review with two case studies, one in the aerospace sector and the other in the wind energy sector, and a practical application, the research analyzes the use of tools such as machine learning, smart sensors, digital twins, and artificial intelligence in implementing predictive maintenance practices. The results show that maintenance digitalization enables the anticipation of failures, reduction of unplanned downtime, resource optimization, and increased operational reliability of assets. The case studies practically illustrate how these solutions can be integrated into production systems and reveal both the benefits achieved and the challenges encountered. Furthermore, the dissertation proposes recommendations for the effective adoption of these technologies, offering relevant guidance for professionals and managers seeking to align their maintenance strategies with the principles of digital transformation.

**Keywords:** predictive maintenance, emerging technologies, reliability, innovation

# Implementação de Estratégias de Inovação na Gestão da Manutenção Industrial

## **EPÍGRAFE**

"Mesmo que algo pareça impossível, continue. Porque a força que te trouxe até aqui  
ainda está com você."  
Clarissa Pinkola Estés



## DEDICATÓRIA

Dedico esta dissertação ao meu pai, Mário Carvalho, com todo o amor que carrego no coração.

Perdi meu pai durante o processo de escrita deste trabalho, e seguir adiante sem ele tem sido uma das provas mais difíceis da minha vida. Ainda assim, encontrei forças em tudo o que ele foi e representou para mim.

Meu pai sempre fez de tudo por mim. Foi um pai presente, dedicado e honesto. Entregou-me tudo do bom e do melhor, mesmo quando isso significava abrir mão dele mesmo. Nunca deixou a minha educação em segundo plano, ao contrário, priorizou meus sonhos como se fossem dele, tirando de si para me dar tudo o que podia.

Ele foi, e sempre será, um pai extraordinário. Um exemplo de amor e dedicação.

Pai, eu sinto muito a sua falta. Esta conquista também é sua. E para sempre será.

*O meu lar é onde meu coração está. Te amo, meu pai, Mário Carvalho.*



## **AGRADECIMENTOS**

Em primeiro lugar, agradeço a Deus, por ter me sustentado em cada passo desta caminhada. Durante o processo de escrita desta dissertação, enfrentei provações profundas na minha vida pessoal, momentos de dor, dúvida e esgotamento. Ainda assim, foi pela fé que me mantive firme. Deus me concedeu serenidade quando tudo parecia desabar, e força quando eu mesma duvidei da minha capacidade.

À minha família, meu porto seguro. À minha mãe, Alice Sueid Pereira, exemplo de amor, coragem e entrega. E ao meu pai, Mário Carvalho, em memória, você vive em mim. Obrigada por tudo o que fizeram por mim, por sempre acreditarem no meu potencial e nunca medirem esforços para que eu pudesse seguir meus sonhos. Eu jamais teria conseguido chegar até aqui sem vocês.

Aos meus amigos Higor Cerqueira, Ilana Carla Freire e Camila Correa, minha segunda família em Portugal: obrigada por nunca me deixarem sozinha, pelo suporte constante, pelas palavras de incentivo e por me acolherem com tanto carinho nos momentos em que mais precisei.

Ao meu namorado, André Miguel, meu amor e meu amigo: obrigada por me acalantar nas lágrimas, por me oferecer silêncio quando precisei de paz, e presença quando eu me perdi de mim. Nunca duvidaste, nem por um instante, de que eu conseguiria, e foi a tua confiança que muitas vezes alimentou a minha.

À psicóloga Alice Mendes, do Serviço de Ação Social do Politécnico de Coimbra, meu mais sincero agradecimento. Você foi a pessoa que me acompanhou de forma próxima e humana durante toda essa jornada do mestrado. Com sua atenção e orientação sensível, me ajudou a enfrentar tantas barreiras internas, especialmente sendo imigrante e estando longe de casa. Sua presença foi fundamental para que eu me mantivesse de pé, e esse trabalho também carrega o reflexo da sua dedicação e apoio.

Aos professores do Instituto Superior de Engenharia de Coimbra, agradeço por todo o conhecimento compartilhado, pela dedicação ao ensino e pelo ambiente de aprendizado inspirador. Em especial, deixo meu profundo reconhecimento ao Professor Jorge Almeida, meu orientador, por sua paciência nos momentos mais difíceis, por sua escuta generosa e pela orientação cuidadosa ao longo deste percurso.

Aos colegas de mestrado, Paula Coelho e Danilo Gomes, sou grata pela partilha de experiências, pelas trocas construtivas e pela parceria ao longo dessa jornada tão desafiadora e transformadora.



## ÍNDICE

Resumo . . . . .	ii
Abstract . . . . .	iv
Epígrafe . . . . .	vi
Dedicatória . . . . .	viii
Agradecimentos . . . . .	x
Índice . . . . .	xii
Índice de tabelas . . . . .	xiv
Índice de figuras . . . . .	xvi
Lista de abreviaturas . . . . .	xx
1 Introdução . . . . .	2
1.1 Objetivos Gerais . . . . .	2
1.2 Objetivos específicos . . . . .	2
1.3 Metodologia de Investigação Utilizada . . . . .	3
1.4 Estrutura da dissertação . . . . .	4
1.5 A Manutenção na Primeira Revolução Industrial . . . . .	4
1.6 A Manutenção na Segunda Revolução Industrial . . . . .	6
1.7 A Manutenção na Terceira Revolução Industrial . . . . .	9
1.8 A Manutenção na Quarta Revolução Industrial . . . . .	11
1.9 A Manutenção na Quinta Revolução Industrial . . . . .	14
2 Estado da Arte . . . . .	18
2.1 Revisão da Literatura . . . . .	20
2.2 Metodologia utilizada na revisão da literatura . . . . .	21
2.3 Estrutura Semântica e Mapa Mental . . . . .	22
2.4 Conceitos básicos de gestão da manutenção industrial . . . . .	35
2.5 Definição da Manutenção . . . . .	36

## Implementação de Estratégias de Inovação na Gestão da Manutenção Industrial

2.6	Tipos de manutenção . . . . .	37
2.7	Indicadores de Desempenho . . . . .	40
2.8	Estratégias de melhorias para manutenção . . . . .	43
2.9	Sistemas de Gestão e Apoio à Manutenção . . . . .	54
2.10	Tecnologias emergentes na implementação da gestão da manutenção . . . . .	56
2.10.1	Os sensores e a Internet das Coisas . . . . .	57
2.10.2	Inteligência Artificial e <i>Machine Learning</i> . . . . .	58
2.10.3	<i>Digital Twins</i> na Manutenção Industrial . . . . .	59
2.10.4	Uso de Drones e Robôs Industriais . . . . .	61
2.10.5	Blockchain e Segurança das Informações . . . . .	62
3	Estudo de Casos . . . . .	64
3.1	Tecnologias emergentes aplicada a Indústria da Energia Eólica . . . . .	64
3.2	Tecnologias emergentes aplicadas na Indústria Aeroespacial . . . . .	83
3.3	Aplicação prática de Manutenção Preditiva em Aeronaves . . . . .	96
4	Conclusão . . . . .	138
	Referências bibliográficas . . . . .	142

## ÍNDICE DE TABELAS

1.1	Quadro resumo com fases da evolução da manutenção. . . . .	16
2.1	Consulta bibliográfica – combinação de palavras-chave por níveis temáticos . . . . .	24
2.2	Termos e estrutura de consulta para setor aeroespacial . . . . .	24
2.3	Termos e estrutura de consulta aplicados à manutenção . . . . .	24
2.4	Bases de dados consultadas com combinações para inovação . . . . .	25
2.5	Bases de dados consultadas para manutenção . . . . .	25
2.6	Bases de dados consultadas para o setor aeroespacial . . . . .	25
2.7	Números de artigos científicos por fonte e de acordo com toda a estrutura de consulta para "equipments"por intervalos de anos . . . . .	26
2.8	Números de artigos científicos por fonte e de acordo com toda a estrutura de consulta para "innovation"por intervalos de anos . . . . .	26
2.9	Números de artigos científicos por fonte e de acordo com toda a estrutura de consulta para " <i>Digital twins</i> "por intervalos de anos . . . . .	26
2.10	Sumário dos artigos científicos mais citados - Parte 1 . . . . .	28
2.11	Sumário dos artigos científicos mais citados - Parte 2 . . . . .	29
2.12	Sumário dos artigos científicos mais citados - Parte 3 . . . . .	30
2.13	Sumário dos artigos científicos mais citados - Parte 4 . . . . .	31
2.14	Sumário dos artigos científicos mais citados - Parte 5 . . . . .	32
2.15	Sumário dos artigos científicos mais citados - Parte 6 . . . . .	33
2.16	Sumário dos artigos científicos mais citados- Parte 7 . . . . .	34
2.17	Sumário dos artigos científicos mais citados - Parte 8 . . . . .	35
2.18	Componentes da estratégia para uma implementação tática . . . . .	47
3.1	Identificação do motor, configurações operacionais e sensores s1 a s5. . .	97
3.2	Leitura dos sensores s6 a s21. . . . .	97
3.3	Estatísticas descritivas: identificação do motor, configurações operacionais e sensores s1 a s4. . . . .	98
3.4	Estatísticas descritivas dos sensores s5 a s21. . . . .	98
3.5	Resultado do conjunto de dados treino calculando o RUL - Parte 1. . . .	102
3.6	Resultado do conjunto de dados treino calculando o RUL - Parte 2. . . .	103
3.7	Resultado do conjunto de dados teste calculando o RUL - Parte 1. . . .	104
3.8	Resultado do conjunto de dados teste calculando o RUL - Parte 2. . . .	104

3.9	Correlação entre as variáveis com o RUL. . . . .	105
3.10	Resultados do Modelo de Regressão Linear . . . . .	114
3.11	Resultados do Modelo de Regressão Polinomial (grau 2) . . . . .	118
3.12	Resultados do Modelo de Regressão com Árvore de Decisão (profundidade = 7) . . . . .	121
3.13	Resultados do Modelo de Regressão com Árvore de Decisão após Otimização de Hiperparâmetros . . . . .	121
3.14	Resultados do Modelo de Regressão Lasso ( $\alpha = 0,01$ ) . . . . .	124
3.15	Resultados do Modelo de Regressão com Random Forest (com <i>tuning</i> ) .	127
3.16	Resultados do Modelo de Regressão com Random Forest com otimização	127
3.17	Resultados do Modelo de Regressão com Random Forest (melhor configuração) . . . . .	129
3.18	Resultados do Modelo de Regressão com LightGBM (ajuste de parâmetros) . . . . .	132
3.19	Resultados do Modelo de Regressão com XGBoost (ajuste de parâmetros)	134
3.20	Resultados do Modelo de Regressão com CatBoost (ajuste de parâmetros)	136
3.21	Comparação do desempenho dos modelos de regressão . . . . .	136

## ÍNDICE DE FIGURAS

1.1	A evolução do paradigma da manutenção dentro das revoluções industriais. . . . .	8
1.2	Arquitetura com as três dimensões do RAMI4.0. . . . .	14
2.1	Fluxograma com o passo-a-passo da revisão bibliográfica. . . . .	22
2.2	Mapa mental conceitual. . . . .	27
2.3	Tipos de manutenção. . . . .	38
2.4	Gráfico de número de indidentes versus tempo de utilização. . . . .	42
2.5	A Pirâmide da Excelência. . . . .	44
2.6	Estratégia de manutenção baseada no modelo de estrutura. . . . .	46
2.7	Ciclo de Deming ou ciclo PDCA. . . . .	50
2.8	Matriz de Hoshin Kanri . . . . .	51
2.9	Modelo de <i>Balanced Scorecard</i> . . . . .	51
2.10	Ciclo da gestão do trabalho. . . . .	52
2.11	Escala de nível de capacidades dos <i>digital twins</i> . . . . .	60
3.1	Estrutura conceitual do <i>digital twin</i> para uma turbina eólica. . . . .	67
3.2	Custo médio de O&M versus idade do projeto e impacto combinado com <i>digital twin</i> e turbinas eólicas. . . . .	70
3.3	Custo médio da O&M versus idade do projeto e o impacto do <i>digital twin</i> em turbinas eólicas. . . . .	71
3.4	Metodologia para o DTWO. . . . .	72
3.5	Cenários de teste no âmbito do DTWO. . . . .	73
3.6	Visualização 3D para o projeto WindTwin. . . . .	75
3.7	Código de definição de modelo e das propriedades da turbina. . . . .	77
3.8	Código referente a transmissão de informações. . . . .	79
3.9	Código referente ao registro de estados e <i>logs</i> da operação da turbina. . . . .	80
3.10	Código referente aos relatórios de operação do parque eólica. . . . .	81
3.11	Exemplo de turbina eólica <i>Digital Twins</i> no XMPPro usando os modelos DTDL de código aberto e dados dos <i>Azure Digital Twins</i> . . . . .	82
3.12	Balanco com indicadores financeiros no segmento de MRO. . . . .	89
3.13	Código demonstrativo de método para controle de acessos e permissões. . . . .	92
3.14	Código demonstrativo da instância da aeronave e seus atributos. . . . .	94
3.15	Código demonstrativo para gerenciamento das taxas e pagamentos. . . . .	95

3.16	RUL para os dados de teste. . . . .	98
3.17	Histograma com as variáveis do conjunto de dados. . . . .	99
3.18	Média de todas as colunas do conjunto de dados. . . . .	100
3.19	Desvio padrão de todas as colunas do conjunto de dados. . . . .	101
3.20	Matriz de correlação do conjunto de dados. . . . .	102
3.21	Código treino do conjunto de dados. . . . .	103
3.22	Código teste para calcular RUL. . . . .	103
3.23	Código para análise de correlação no conjunto de dados treino. . . . .	104
3.24	Código para gerar gráficos de dispersão entre as variáveis e o RUL. . . . .	105
3.25	Gráficos de dispersão entre as variáveis e o RUL. . . . .	106
3.26	Código para gerar gráfico de dispersão entre as variáveis. . . . .	107
3.27	Gráfico de dispersão entre as variáveis. . . . .	107
3.28	Código para representar gráficos com curvas temporais dos sensores para o motor 21. . . . .	108
3.29	Gráficos com curvas temporais dos sensores para o motor 21. . . . .	109
3.30	Gráficos com curvas temporais dos sensores para o motor 61. . . . .	110
3.31	Modelo de predição. . . . .	111
3.32	Código para importação de bibliotecas necessárias para estimar RUL. . . . .	111
3.33	Variáveis selecionadas para correlacionar com RUL. . . . .	112
3.34	Código de divisão de dados de treinamento e teste. . . . .	112
3.35	Código com passo-a-passo para prepara os dados de treino e teste - Parte 1. . . . .	113
3.36	Código com passo-a-passo para prepara os dados de treino e teste - Parte 2. . . . .	113
3.37	Código com aplicação de modelo de regressão linear. . . . .	114
3.38	Código para gerar gráfico de resíduos da regressão linear. . . . .	114
3.39	Gráfico de resíduos da regressão linear. . . . .	115
3.40	Código para gerar gráfico com erro da predição da regressão linear. . . . .	115
3.41	Gráfico de erro da predição da regressão linear. . . . .	116
3.42	Código para o gráfico de comparação entre valores reais e valores previstos da variável RUL na regressão linear. . . . .	116
3.43	Gráfico de comparação entre valores reais e valores previstos da variável RUL na regressão linear. . . . .	117
3.44	Código de implementação da regressão polinomial. . . . .	117
3.45	Gráfico de resíduos da regressão polinomial. . . . .	118
3.46	Gráfico de erro de predição da regressão polinomial. . . . .	119
3.47	Gráfico de comparação entre os valores reais e previstos na regressão polinomial. . . . .	119
3.48	Código para implementação da regressão com árvores de decisão. . . . .	120
3.49	Código para implementação de técnica de otimização de hiperparâmetros em árvores de decisão - Parte 1. . . . .	120

3.50	Código para implementação de técnica de otimização de hiperparâmetros em árvores de decisão - Parte 2. . . . .	122
3.51	Gráfico de resíduos com técnica de otimização de hiperparâmetros em árvores de decisão. . . . .	122
3.52	Gráfico de erro de predição com técnica de otimização de hiperparâmetros em árvores de decisão. . . . .	123
3.53	Gráfico de comparação entre os valores reais e previstos pelo modelo de árvore de decisão com hiperparâmetros otimizado. . . . .	123
3.54	Código para implementação da regressão da Lasso. . . . .	124
3.55	Gráfico de resíduos da regressão de Lasso. . . . .	125
3.56	Gráfico de erro de predição da regressão de Lasso. . . . .	126
3.57	Gráfico da comparação entre os valores reais e previstos pelo modelo de regressão de Lasso. . . . .	126
3.58	Código de implementação do Random Forest. . . . .	127
3.59	Código de implementação do Random Forest com a otimização de hiperparâmetros. . . . .	128
3.60	Código do Random Forest com dez combinações de hiperparâmetros. . . . .	128
3.61	Gráfico de resíduos do Random Forest com a otimização de hiperparâmetros. . . . .	129
3.62	Gráfico de erro de predição do Random Forest com a otimização de hiperparâmetros. . . . .	130
3.63	Gráfico valores reais vs previstos do Random Forest com a otimização de hiperparâmetros. . . . .	131
3.64	Código para a implementação da regressão LGBM. . . . .	131
3.65	Gráfico de resíduos da regressão LGBM. . . . .	132
3.66	Gráfico de erro de predição da regressão LGBM. . . . .	133
3.67	Código para a implementação da regressão XGBoost. . . . .	133
3.68	Gráfico da análise de resíduos da regressão XGBoost. . . . .	134
3.69	Gráfico de dispersão da regressão XGBoost. . . . .	135
3.70	Código de implementação para a regressão de CatBoost. . . . .	135



## LISTA DE ABREVIATURAS, ACRÓNIMOS E SIGLAS

AI	<i>Artificial Intelligence</i>
AMM	<i>Aircraft Maintenance Manual</i>
BC4A	<i>Blockchain for Aviation</i>
BPM	<i>Business Process Management</i>
CatBoost	<i>Categorical Boosting</i>
CMMS	<i>Computerized Maintenance Management System</i>
CLP	<i>Controlador Lógico Programável</i>
CPS	<i>Cyber-Physical System</i>
DIN	<i>Deutsches Institut für Normung</i>
DL	<i>Deep Learning</i>
DT	<i>Digital Twin</i>
DTDL	<i>Digital Twin Definition Language</i>
DTWO	<i>Federated Digital Twins for Wind-Offshore</i>
EBIT	<i>Earning Before Interest and Taxes</i>
EVM	<i>Etherum Virtual Machine</i>
FAA	<i>Administração Federal de Aviação</i>
IA	<i>Inteligência Artificial</i>
ISEC	<i>Instituto Superior de Engenharia de Coimbra</i>
IoT	<i>Internet of Things</i>
IIoT	<i>Industrial Internet of Things</i>
KPI	<i>Key Performance Indicator</i>
LCC	<i>Life Cycle Cost</i>
LGBM	<i>Light Gradient Boosting Machine</i>
MaaS	<i>Mobility as a Service</i>
ML	<i>Machine Learning</i>
MRO	<i>Maintenance, Repair and Overhaul</i>
MTBF	<i>Mean Time Between Failures</i>
NASA	<i>National Aeronautics and Space Administration</i>
NFT	<i>Non-Fungible Token</i>
NPL	<i>Natural Language Processing</i>
OEE	<i>Overall Equipment Effectiveness</i>

## Implementação de Estratégias de Inovação na Gestão da Manutenção Industrial

O&M	<i>Operation and Maintenance</i>
PDCA	<i>Plan-Do-Check-Act</i>
RA	Realidade Aumentada
RAMI	<i>Reference Architectural Model for Industry 4.0</i>
RCM	<i>Reliability-Centered Maintenance</i>
RMSE	<i>Root Mean Square Error</i>
ROCE	<i>Return on Capital Employed</i>
ROI	<i>Return on Investment</i>
RV	Realidade Virtual
RUL	<i>Remaining Useful Life</i>
SMART	<i>Specific, Measurable, Achievable, Relevant, Time-bound</i>
SKPL	<i>SkyLink Protocol</i>
TPM	<i>Total Productive Maintenance</i>
UE	União Europeia
XGBoost	<i>Extreme Gradient Boosting</i>

# 1

## Introdução

### 1.1 Objetivos Gerais

O objetivo geral do presente estudo é investigar as principais tecnologias emergentes utilizadas na gestão da manutenção industrial e compreender quais os impactos dessas inovações no contexto mundial. É imprescindível também explorar de maneira clara quais serão os benefícios que as tecnologias podem trazer nas operações industriais.

Além disso, é importante perceber quais são os principais desafios encontrados pelas organizações no processo de adoção de tecnologias emergentes, identificar as melhores práticas e quais serão as estratégias para uma implementação bem-sucedida.

### 1.2 Objetivos específicos

Os objetivos específicos a se atingir desta dissertação são:

- Identificar as principais tecnologias emergentes na gestão da manutenção industrial;
- Analisar como essas tecnologias estão sendo implementadas em diferentes setores e contextos organizacionais;
- Perceber quais são os desafios técnicos, culturais e operacionais que as empresas enfrentam no processo de adoção e implementação dessas tecnologias;
- Avaliar quais são os impactos dessas tecnologias na eficiência dos processos de manutenção;
- Observar como estão sendo utilizadas para monitorar e prever a falha nos equipamentos e melhorar a gestão de ativos nas organizações;
- Examinar através de estudos de caso, empresas que implementaram as tecnolo-

gias, analisando quais foram os desafios e quais as práticas utilizadas;

- Propor recomendações e diretrizes para organizações que desejam implementar tecnologias emergentes na gestão da manutenção.

### 1.3 Metodologia de Investigação Utilizada

A metodologia utilizada é de abordagem mista, isto é, possui padrões de pesquisa qualitativa e quantitativa. A pesquisa qualitativa é baseada na análise de acontecimentos descritos não numéricos em um contexto através de descrições, observações, experimentos, registros de comportamento e inquéritos. Há seis delineamentos da pesquisa qualitativa: estudo de caso, análise de documentos, pesquisa-ação, pesquisa de campo, experimento qualitativo e avaliação qualitativa [1].

Enquanto, a pesquisa quantitativa utiliza fenômenos comprovados em recolhas de dados e análises numéricas. As pesquisas que utilizam métodos quantitativos costumam aprofundar a associação entre variáveis que podem ser generalizadas para uma população por meio de inferências estatísticas.

Os métodos quantitativos mais aplicados em abordagens mistas são: estudo controlado randomizado; comparação de estudo de caso; séries temporais e pesquisa transversal analítica; estudo de prevalência; estudo de incidência; pesquisa transversal descritiva e série de casos [2].

Nesta investigação, o que se propõe é o método empírico de observar, analisar casos de sucesso e considerar os melhores cenários, assim é possível ser replicado em outras organizações.

Os procedimentos utilizados nesta dissertação foram:

Revisão Bibliográfica: É essencial porque permite especificar os objetivos com base no que já é conhecido, além de discutir resultados e quais os significados das pesquisas anteriores, analisando os impactos no campo científico, na sociedade ou em um contexto mais específico [2].

Através da utilização de livros, normas, dissertações, teses, artigos e publicações sobre manutenção e tecnologias emergentes aplicadas à gestão da manutenção.

Casos de estudos: Uma investigação aprofundada de uma instância de algum fenômeno, e o estudo envolvendo um número estatisticamente significativo de instâncias de um mesmo fenômeno, a partir do qual seria possível generalizar para outras instâncias. Além do mais, num estudo de caso é possível utilizar tanto procedimentos qualitativos quanto quantitativos [1].

É realizado uma análise profunda de casos em contextos reais, no qual explora-se a implementação de tecnologias emergentes para a gestão da manutenção e desenvolve-

se um estudo baseado nessas experiências organizacionais.

## 1.4 Estrutura da dissertação

A dissertação está estruturada com quatro capítulos, no qual o primeiro é o capítulo de introdução, em que é feito uma contextualização histórica sobre as revoluções industriais, as tecnologias utilizadas em cada época e o avanço das tecnologias utilizadas na transição da Indústria 4.0 para a 5.0.

No capítulo dois é realizado o estudo da fundamentação teórica do tema, utilizando de revisão bibliográfica no capítulo para abordar sobre como surgiu a manutenção, quais são os tipos de manutenção, quais as principais tecnologias emergentes utilizadas nas indústrias, a importância do uso dessas tecnologias para melhorias de processos e da gestão para a implementação nas organizações.

No terceiro capítulo, são mencionados estudos de caso em organizações que adotaram as tecnologias na gestão da manutenção e que foram explorados os desafios e benefícios para a empresa, em um contexto técnico, cultural e operacional.

No quarto capítulo é feita a conclusão dessa dissertação, no qual aborda os pontos fundamentais desta dissertação e que reforça a relevância do tema, apontando as contribuições teóricas e práticas do estudo, demonstrando as limitações e propondo futuras pesquisas que explorem a aplicação tecnológica em diferentes setores.

## 1.5 A Manutenção na Primeira Revolução Industrial

A palavra “revolução”, do latim *revolutio*, ónis, que significa "ato de revolver" expressa transformação abrupta e radical. Em diversas histórias, todas as revoluções são marcadas por alterações nas estruturas sociais, em sistemas econômicos e também nas mudanças na adoção de novas tecnologias na sociedade [3].

A primeira mudança significativa na forma de viver do homem foi através da transição da busca de alimentos para a agricultura, movimento que ocorreu há cerca de dez mil anos e foi possível através da domesticação de animais. Assim como a revolução agrícola utilizou da força animal com a dos seres humanos em benefício para a produção de alimentos, para os meios de transporte e da comunicação. Essa transformação estimulou o crescimento da população e a criação de assentamentos, surgindo os núcleos das cidades e da urbanização [3].

No início do século XVII, os tecidos de lã eram muito apreciados na Europa e tinham a sua fabricação realizada nas casas, nos quais os artesãos compravam as matérias-primas e realizavam a fiação e tecelagem no seu próprio tear. Depois de pronto, ocorriam as vendas para os comerciantes. A produção tinha característica de

ser descentralizada, caseira e artesanal e subdivida em centenas de milhares unidades produtoras [4].

Em 1733 John Kay inventou a lançadeira volante de tecelagem, entretanto foi apenas em 1764 quando James Watt criou a primeira máquina a vapor que funcionava de forma eficiente. Nos anos de 1767 a 1800, desenvolveram-se as primeiras máquinas de fiar, em seguida dos teares, que foi associado a máquina a vapor e substituindo todos os tipos de força motriz que eram utilizados [4].

Assim, surge o conceito da primeira revolução industrial, que iniciou-se na Grã-Bretanha, Inglaterra, com o desenvolvimento das máquinas para a indústria dos têxteis, do ferro e do carvão, no final do século XVIII. A produção de têxteis deixa-se de ser feita de forma manual para serem ocupadas por máquinas a vapor alimentando os teares, elevando a produtividade, com reduções drásticas nos custos de materiais e no tempo de produção. Os motores a vapor, as rodas giratórias e as rodas d'água modificaram o desempenho e abriram caminhos para as invenções que temos atualmente [5].

A introdução das máquinas que aceleravam a produção, despertou o interesse por parte do comércio e a massa de desempregados causados pelo êxodo rural estavam dispostos a aceitar qualquer trabalho por um pagamento mínimo. Logo, a produção em fábricas teve uma enorme expansão produtiva com a Inglaterra exportando tecidos no qual faturaram milhares de libras esterlinas na época. Essa revolução não ficou limitada apenas aos tecidos, e se espalhou para a indústria da metalurgia, da química e do carvão [4].

Assim, na primeira revolução industrial acontece-se a passagem da manufatura para a maquinofatura, deixa-se de ser utilizado a força muscular humana e reina-se o uso das máquinas [4]. Como o uso de máquinas, equipamentos e ferramentas de produção estão constantemente sujeitos ao desgaste, logo, ocorre-se à necessidade de manutenção [6].

Durante a Primeira Revolução Industrial, a manutenção ocorria apenas quando as máquinas falhavam ou deixavam de operar, um método conhecido como Manutenção Corretiva. Com o tempo, percebeu-se que muitas peças sofrem danos devido à aplicação de tensões, o que permite estimar sua vida útil. Dessa forma, tornou-se possível programar manutenções preventivas, reparando ou substituindo componentes antes que a falha ocorra [6].

A estratégia de "deixar o equipamento operar até falhar" foi a primeira abordagem de manutenção adotada naturalmente pela humanidade. Inicialmente, essa parecia ser a solução mais simples e intuitiva, pois as máquinas eram relativamente básicas e não exigiam especialistas para reparos [6].

Este era o começo da Manutenção Corretiva, focada apenas no reparo do equipamento avariado, sem sistemas para organização e execução da manutenção, com um

nível baixo de gerenciamento, subordinada pela função da produção e com planejamento e controle rudimentares [7].

A estratégia era viável principalmente por alguns fatores, como: à interdependência dos equipamentos, fazendo com que uma avaria em um equipamento não refletivesse nos demais; não existência de sistemas de manutenção estruturados, normalmente os próprios operadores eram responsáveis pela manutenção e o pensamento limitado com alto nível de redundância em grande número de atividades produtivas industriais e de serviços [7].

Mesmo nos dias de hoje, a manutenção corretiva continua sendo a prática mais comum, representando mais de 55% das estratégias adotadas, segundo Bloch e Geitner. No entanto, com o aumento da complexidade dos equipamentos, especialmente após o início da Primeira Revolução Industrial, surgiu uma nova tendência no setor industrial, voltada para abordagens mais estratégicas e planejadas [6].

### **1.6 A Manutenção na Segunda Revolução Industrial**

O início da Segunda Revolução Industrial está caracterizada entre os períodos de 1860 e 1900, e isto porque várias tecnologias surgiram nesta época. Essas tecnologias trouxeram um grande impacto para os padrões de vida no século XX. As principais tecnologias incluem a eletricidade, o motor de combustão interna, o petróleo e outros produtos químicos, além do telefone, das rádios e das redes de encanamento [8].

O período pós-guerra e o boom da produção significaram um avanço no monitoramento e avaliação de dados, bem como nos requisitos de qualidade do produto [6].

Os historiadores consideram que o desenvolvimento da eletricidade não teve um retorno imediato em termos de produtividade, isto porque, a eletricidade foi difundida lentamente entre as fábricas e a implementação da tecnologia obrigou que muitas fábricas fossem redesenhadas para fazer um bom uso da energia elétrica. O ritmo lento da adoção foi também atribuído pela falta de lucratividade de substituição de fábricas ainda em funcionamento, associadas a tecnologias de produção adaptadas ao uso da energia mecânica derivada da água e do vapor. Além disso, ainda houve o processo de aprendizagem dos operários em novas aplicações para a eletricidade em instalações e máquinas [8].

Entretanto, os historiadores argumentam que os benefícios de adotar a eletricidade foi além dos custos diretos, porque a eletrificação das fábricas permitiu a oportunidade para a inovação contínua dos processos e procedimentos para que as fábricas melhorassem a sua eficiência produtiva global, mas que na prática os gestores precisavam de tempo para aprender a melhor forma de gerir e aproveitar essas oportunidades.

O conhecimento adquirido no uso dessas novas tecnologias também era específico de cada organização, por isso, era muito mais difícil de transferir entre elas [8].

Durante este período também ocorreu a construção da primeira linha de integração, o que facilitou ainda mais o processo da produção em massa. Assim, as linhas de montagem se expandiram e foram adotadas como método padrão de produção em massa [5].

Segundo Mokyr [9], no último terço do século XIX os processos também foram adotados em larga escala, principalmente nos espaços de armazenamento de Chicago e nas fábricas de montagem de automóveis de Henry Ford, associando o conceito de peças “padrão” com o de processos de fluxo contínuo, isso permitiu que fosse possível produzir em massa um produto complexo e ainda manter um preço baixo. O grande sucesso da Ford, foi o desenvolvimento da produção de fluxo contínuo, no qual os trabalhadores ficavam estacionários enquanto as tarefas eram transferidas diretamente. Assim, o empregador conseguia controlar a velocidade no qual as produções eram realizadas e assim poderia minimizar o tempo perdido pelos trabalhadores entre as operações.

O crescimento da produção também trouxe desafios, como o aumento dos custos decorrentes de falhas e quebras nos equipamentos. Para minimizar esses impactos, surgiram as primeiras iniciativas de manutenção preventiva, também chamada de manutenção planejada. Henry Ford foi um dos defensores dessa prática, chegando a recomendá-la no Manual Ford de 1919. Ele orientava, por exemplo, inspeções regulares no trem de pouso, verificando folgas desnecessárias nas rodas dianteiras e traseiras, além do aperto adequado de parafusos e porcas. O hábito de realizar pequenos ajustes e reparos preventivos era incentivado para evitar falhas mais graves e garantir maior confiabilidade dos veículos [6].

Assim, entre 1920 e 1930 nascia a Manutenção Preventiva insipiente, baseada na repetição de ações de manutenção primárias, como reaperto de parafuso e lubrificações periódicas. E em função, de plantas mais modernas com equipamentos interdependentes, avarias nesses equipamentos comprometiam a operação do sistema de forma global, por esse motivo, as avarias precisavam ser evitadas e não apenas corrigidas [7].

Com a crescente pressão para reduzir perdas e a necessidade de implementar a manutenção preventiva, as falhas deixaram de ser consideradas ocorrências naturais. A busca por menor tempo de inatividade e maior confiabilidade dos equipamentos levou ao desenvolvimento de estratégias de planejamento e programação das atividades de manutenção, dando origem à chamada manutenção preventiva planejada. [6].

Durante as Primeira e Segunda Revoluções Industriais, não existiam normas específicas para a manutenção e a gestão de ativos, e os poucos registros disponíveis eram destinados exclusivamente ao setor militar. A primeira regulamentação relevante nesse

## Implementação de Estratégias de Inovação na Gestão da Manutenção Industrial

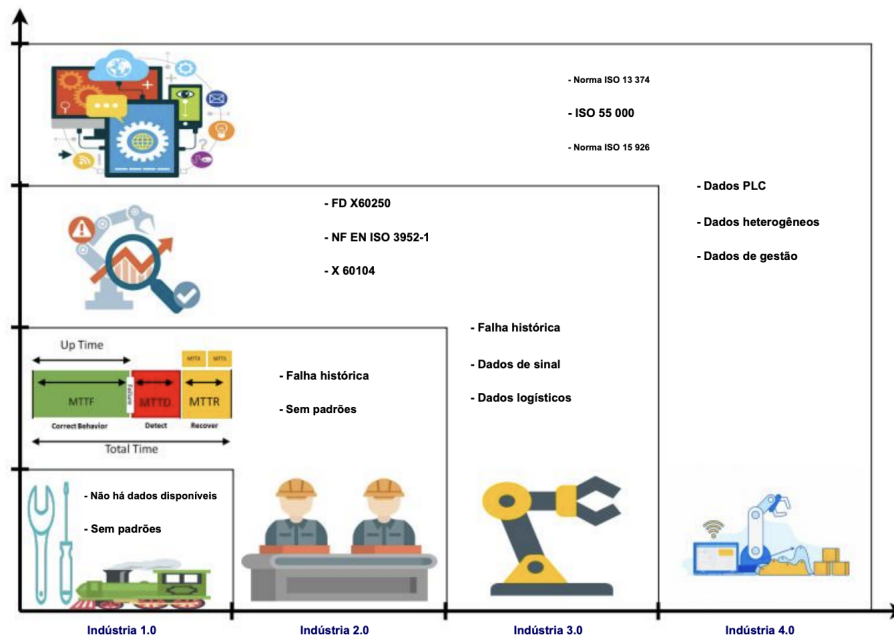


Figura 1.1: A evolução do paradigma da manutenção dentro das revoluções industriais. Fonte: [10].

domínio foi a norma X60104 (1981), que estabeleceu critérios para contratos de manutenção. Em seguida, a ISO 3952-1 foi introduzida para padronizar o uso de símbolos, simplificando a documentação e a representação das interações entre os componentes mecânicos [10].

Outro avanço significativo foi a norma FDX60250 (1983), que trouxe orientações para a criação de registros técnicos de manutenção, auxiliando os usuários na implementação eficiente dessas práticas. Com o progresso das tecnologias de informação na década de 2000, a documentação de manutenção passou por uma transformação expressiva, adaptando-se às inovações tecnológicas e se integrando a sistemas digitais modernos [10].

Nesse cenário, a norma ISO 55000 estabeleceu o conceito de gestão de ativos, expandindo o alcance da manutenção para abranger atividades relacionadas, como planejamento, concepção, execução e avaliação das práticas de gerenciamento de ativos [10].

Já a ISO 15926 foi desenvolvida para estruturar a representação das informações ao longo do ciclo de vida de uma planta de processo, utilizando um modelo de dados com um contexto unificado para a definição de informações. No mesmo âmbito das normas voltadas à gestão de dados, foi criada a série ISO 13374, dedicada ao monitoramento de condições e diagnóstico de máquinas [10].

Na fig 1.1 é possível analisar a evolução do paradigma da manutenção dentro das revoluções industriais.

## 1.7 A Manutenção na Terceira Revolução Industrial

Segundo Mohajan [11], a Terceira Revolução Industrial iniciou na década de 1950 e atingiu o seu pico no final da década de 1990, com a previsão de que finalize por volta de 2030.

A Terceira Revolução Industrial ou Revolução Digital começou com o uso de controles e computadores programáveis por memória. Foi uma época caracterizada principalmente pela ampla produção e utilização de chips, lógica digital, transistores, o uso de computadores, telefone sem fio, microprocessadores e a Internet. Um tempo de transição da era analógica para a revolução digital [5].

A Revolução Digital é considerada a era de mais rápido progresso tecnológico associada ao desenvolvimento das tecnologias de informação. O autor [11] sugere que a Primeira e a Segunda Revolução Industrial melhoraram apenas a Europa Ocidental e os EUA, com um desenvolvimento local. Enquanto a Terceira Revolução Industrial tornou-se global, e o mundo ficou aproximadamente dez vezes mais rico, com a criação de milhares de organizações empresariais e milhões de empregos. O desenvolvimento econômico aumentou consideravelmente, a tecnologia mudou drasticamente o transporte rodoviário, aéreo e aquático. Os custos de transporte e entrega em todos os setores foram reduzidos e houve um aumento no PIB per capita de países desenvolvidos e em desenvolvimento.

As máquinas foram significativamente automatizadas ao introduzir transistores e circuitos integrados de dispositivos eletrônicos, no qual aumentou-se a velocidade da produção, reduziu o esforço e melhorou a precisão e para alguns casos específicos, os computadores substituíram completamente o ser humano. Uma das invenções mais importantes da Terceira Revolução Industrial foi o Controlador Lógico Programável (CLP), responsável por controlar as máquinas, equipamentos e linhas de processos através de softwares específicos [5].

À proporção que o *hardware* eletrônico foi integrado nos sistemas de produção, foi também necessário ter sistemas de softwares para operar estes dispositivos, o que aumentou o mercado de desenvolvimento de software. Além de controlar o *hardware*, também foi necessários os processos de gerenciamento, como planejamento de recursos empresariais, gerenciamento de estoque, logística e rastreamento em toda a fábrica [5].

À medida que os fabricantes buscavam reduzir os custos, muitos mudaram suas fábricas para países de baixo custo e a dispersão desses locais de produção levaram ao conceito de *Supply Chain Management*, que basicamente é o gerenciamento de toda a estrutura do negócio desde o recebimento do pedido até entrega para o cliente final [5].

Como respostas às demandas da Segunda Guerra Mundial, as indústrias básicas sentiram a necessidade de não apenas corrigir as falhas ou atrasar a ocorrência de defeitos que paravam a produção, mas de implementar a Manutenção Preventiva sistemática, com procedimentos formalizados e periodicidade estabelecidas [7].

Assim a Manutenção foi colocada no papel pela primeira vez, ocorrendo um boom principalmente nos Estados Unidos da América, na época da Segunda Guerra, motivada principalmente devido à falta de pessoal especializado em diagnóstico e reparo, causado pela convocação de homens para guerra e a utilização de mulheres para esse tipo de tarefa [7].

Essa estratégia considerava a substituição em caráter preventivo dos itens nos quais se desgastavam, visando prevenir as avarias, e essa substituição era economicamente justificada pelos crescentes níveis de segurança exigidos [7].

Além disso, os aspectos econômicos passaram a ser considerados na definição das estratégias de manutenção. Equipamentos cuja falha inesperada ou redução dos parâmetros operacionais impacta significativamente a quantidade ou qualidade da produção são classificados como “críticos” [12].

Com isso, surge o conceito de “custo de falha”, que leva em conta não apenas os custos diretos, mas também os impactos financeiros indiretos da manutenção. No entanto, não basta considerar apenas os fatores econômicos na tomada de decisão sobre a manutenção, sendo essencial avaliar também os riscos e a probabilidade de falhas nos equipamentos [12].

Outra abordagem relevante é o uso da teoria da confiabilidade (RCM). Inicialmente, os modelos de confiabilidade eram de difícil aplicação nas unidades industriais, mas, com o tempo, sua utilização se tornou cada vez mais comum. Após a década de 1970, duas principais filosofias relacionadas à manutenção industrial começaram a se desenvolver [12].

A RCM, uma manutenção voltada para a confiabilidade, tentava eliminar as consequências da falha. Essa teoria iniciou-se na indústria aeronáutica americana e propagou-se para as áreas nuclear, militar e de geração de energia elétrica [7].

Nos Estados Unidos, foi aplicado o conceito de Custo do Ciclo de Vida (LCC), que abrange todos os custos envolvidos na pesquisa, projeto, construção, operação e manutenção ao longo da vida útil de um equipamento. O principal objetivo dessa abordagem é a minimização desses custos [12].

A segunda filosofia, originada no Japão, é a Manutenção Produtiva Total (TPM). Enquanto o LCC enfoca a manutenção sob uma perspectiva econômica, o TPM aborda do ponto de vista humano. Seu objetivo é maximizar a eficiência global dos equipamentos produtivos, considerando a participação de todos os envolvidos no processo:

projetistas, operadores (equipe de produção), equipe de manutenção e todos os níveis hierárquicos da gestão, desde os trabalhadores até a alta administração [12].

Voltado para a indústria de produção seriada, o TPM viraliza no Ocidente, em todos os ramos de atividades e tentam obter a maior eficiência global do sistema (meta de zero defeitos), assim garante-se o uso do Nível Global de Eficiência (OEE) [7].

O OEE é definido pela disponibilidade do equipamento, a eficiência e o ritmo da operação. Assim, as organizações com OEE superior a 85 % são classificadas como "Primeira Classe"[7].

Dessa forma, a manutenção industrial se torna um elemento estratégico no sistema de garantia da qualidade. Para que a gestão da empresa assegure a qualidade da produção, a manutenção eficiente é um fator essencial nesse processo [12].

Muitos autores consideram que estamos vivendo uma fase de transição entre a Terceira e a Quarta Revolução Industrial, mas as invenções mais marcantes no início da Revolução Digital são as que abriram portas para que as tecnologias emergentes da Quarta Revolução Digital pudessem se expandir.

## 1.8 A Manutenção na Quarta Revolução Industrial

Apesar de na Terceira Revolução Industrial ter sido incorporado a automação e processos, a Quarta Revolução Industrial destaca a permanência e a integração digital definitiva e completa de um ambiente industrial digital, buscando soluções que sejam totalmente integradas [5].

A Quarta Revolução Industrial ou Indústria 4.0, é a era da transformação digital da manufatura e da produção, assim como das indústrias e dos processos que são relacionados à criação de valor. A utilização de *Internet of Things*(IoT), computação em nuvem, Sistemas *Ciber-Físicos* (CPSs), dispositivos inteligentes, *MaaS*, *BPM* e outros, é uma das principais tecnologias e que desempenham um papel importante na implementação da Indústria 4.0 [5].

Segundo Hwang [13], a visibilidade, rastreabilidade, previsibilidade e simulações sofisticadas, aliadas e velocidade, agilidade e flexibilidade são as características subjacentes da fabricação inteligente. O CPSs poderá reduzir as distâncias entre o mundo físico e o mundo *cyber* físico através da comunicação inteligente, no qual as máquinas podem se comunicar, interagindo em diferentes níveis, em uma ampla variedade de contexto e não importando onde estejam fisicamente, apenas através do uso de softwares que utilizam a Internet para acessar e processar os dados disponíveis e chegar a conclusões. Além do suporte da IoT e da produção baseada em nuvem, que a torna a parte integrante na implementação da Indústria 4.0 [5].

A partir de 1975, os avanços em monitoramento, processamento de sinais e a

significativa redução nos custos dos computadores tornaram viável a implementação da Manutenção Preventiva Preditiva. Esse método permite que as ações de manutenção sejam planejadas com base na análise das condições atuais da máquina. Também é conhecida por diversos termos, como *Condition-Based Maintenance*, *Diagnostic-Based Maintenance*, *Condition Monitoring*, *Health Monitoring* e Manutenção Sintomática [7].

“Através da fusão o mundo físico e o mundo virtual, a interoperabilidade, a inteligência artificial avançada e a autonomia serão partes integrantes da nova era industrial” [13].

A sociedade está em frente a uma enorme quantidade de desafios que são fascinantes, dentre eles, o mais intenso e determinante é a compreensão e a modelagem da nova revolução tecnológica, o que implica diretamente a transformação de toda a humanidade, no qual irá alterar toda a maneira em escala, escopo e complexidade a forma que todos os seres humanos vivem, trabalham e se relacionam[3].

De um lado, há ainda uma incerteza profunda do desenvolvimento e da adoção das tecnologias emergentes porque ainda não conhece-se os desdobramentos das transformações geradas completamente pela quarta revolução industrial, por outro lado essa complexidade e interconexão entre os diversos setores implicam que todos os *stakeholders* da sociedade global, os governos, empresas, universidade e sociedade civil, devem se unir e trabalhar em conjunto para compreender as tendências emergentes [3].

"Devem ser feitos esforços importantes na coletividade e conectividade das tecnologias, na integração perfeita de dados, na utilização eficaz de ferramentas digitais e na visão e implementação contínua de novas tecnologias para alcançar a otimização operacional e a excelência empresarial" [13].

A globalização e o ritmo da inovação propiciam um ambiente cada vez mais competitivo, isto significa que os ciclos de vida são mais curtos tanto para produtos quanto para serviços, e isto exige flexibilidade e agilidade nos negócios. Para responder este desafio, a Indústria 4.0 se propõe a ter sistemas modulares que são autoconfiguráveis e que podem ser facilmente reorganizados, o que reduz o tempo de lançamento no mercado. Além disso, este tipo de sistema pode criar produtos personalizados, com custos baixos, possibilitando o lucro em mercados considerados pequenos [14].

As empresas vão precisar desenvolver cada vez mais uma compreensão profunda das tecnologias, traduzindo quais são os objetivos dos negócios em relação a aplicabilidade tecnológica visando a eficiência operacional. Este objetivo será alcançado através da comunicação máquina-máquina, da interação da máquina-humano, da computação em nuvem e da análise avançada. Como por exemplo, a possibilidade das máquinas inteligentes desencadearem processos de manutenção de forma autônoma, dos quais serão capazes de prever as falhas e analisar todos os dados para detectar ineficiências

no processo, reduzindo assim diretamente os custos de produção [13].

Na era da Indústria 4.0, os gerentes de manutenção devem possuir habilidades técnicas avançadas e a capacidade de gerenciar processos de manutenção de forma estratégica. Além disso, precisam compreender o impacto da manutenção em outros setores da empresa, influenciando diretamente os objetivos de negócios, a qualidade, a eficiência e a segurança operacional [6].

O processo físico, conectado ao virtual através da *internet* e equipado com inteligência embarcada distribuída, possui maior flexibilidade e autonomia, podendo responder rapidamente às demandas e restrições do mercado. Isso significa que a produção de pequenos lotes a custos baixos permite atender às exigências sem a necessidade de escala [15].

Cada vez mais recursos são destinados à gestão da manutenção, levando muitas empresas a adotar não apenas o gerenciamento direto, mas também o controle remoto. Com o avanço da tecnologia, tornou-se possível coletar e processar dados por meio de softwares de forma eficiente e com custos reduzidos [6].

Duas tendências se destacam nesse cenário: a análise da grande quantidade de dados gerados pelos ativos e máquinas ao longo de sua vida útil e a compreensão das necessidades das partes interessadas [6].

A busca por melhorias na manutenção tornou-se uma prioridade para as empresas, pois reduzir falhas e quebras impacta diretamente a eficiência operacional. Empresas que adotam estratégias de manutenção eficazes conquistam uma vantagem competitiva, uma vez que a manutenção bem planejada possibilita reduzir custos e aumentar a confiabilidade da produção [6].

Na era da Indústria 4.0, a concorrência entre as empresas é competitiva, e até mesmo os menores detalhes podem fazer grande diferença. Esse conceito inovador aproveita ao máximo os avanços dos sistemas cibernéticos, computação em nuvem e Internet das Coisas, impulsionando a evolução da manutenção para um nível mais avançado: a Manutenção Preditiva [6].

Segundo Xu [16], a Quarta Revolução Industrial é considerada a revolução impulsionada pela tecnologia para alcançar a maior eficiência e produtividade, sendo reforçado através de três dimensões do RAMI4.0, um modelo em que consiste em um sistema de coordenadas tridimensionais que representa a arquitetura dos sistemas da Indústria 4.0, estas coordenadas são definidas em: Ciclo de Vida do Produto, Camadas de Negócios e Hierarquia de Fábrica, como pode-se visualizar na fig 1.2 .

As principais tecnologias da Indústria 4.0 são: big data e as análises de dados, os robôs autônomos, integração de sistemas horizontais e verticais, Internet das Coisas, segurança cibernética, computação em nuvem, manufatura aditiva e realidade aumentada e simulações. As tecnologias citadas são os pilares dos cinco temas centrais da




Figura 1.2: Arquitetura com as três dimensões do RAMI4.0. Fonte: [16].

Indústria 4.0: Integração horizontal através de redes de valor, engenharia de ponta a ponta em toda a cadeia de valor, integração vertical e sistemas de produção em rede, tecnologia de sistemas *ciber*-físicos e novas infraestruturas nos locais de trabalho [16].

Nos estudos é possível observar que apesar da Quarta e da Quinta Revolução Industrial ainda não ter eras e épocas bem definidas, já que ainda estamos em uma fase de transformações, analisa-se que as principais diferenças entre estas revoluções é que na Indústria 4.0 a abordagem é centrada nas melhorias de processos enquanto Indústria, já na Indústria 5.0 utilizamos da tecnologia para melhorar o ambiente quanto sociedade.

## 1.9 A Manutenção na Quinta Revolução Industrial

No ano de 2022, a Comissão Europeia solicitou um apelo formal para a Quinta Revolução Industrial, após seguidas discussões entre os participantes das organizações de pesquisa e tecnologias, além das agências de financiamento de toda a Europa. Essas discussões, denominadas de “Prosperidade”, ocorreram em *workshops* organizados pela Direção Geral de Investigação e Inovação, nos dias 2 e 9 de julho de 2020. O resultado foi a divulgação formal do documento denominado de “Indústria 5.0: Rumo a uma Indústria Europeia Sustentável, Centrada no Ser Humano e Resiliente” em 4 de janeiro de 2021 [16].

Na indústria 5.0 o ser humano é quem está centrado nesta abordagem, porque no processo de produção é considerado o ser humano e o social, já que o número de

funcionários em uma indústria deixará de ser visto como um custo e passará a ser considerado um investimento [5].

Segundo Xu [16], a Indústria 5.0 possui três valores fundamentais que são interligados: a centralização no ser humano, a resiliência e a sustentabilidade. O ser humano no centro da abordagem para promover talentos, diversidade e empoderamento. A resiliência para ser ágil, persistente e flexível para se adaptar às novas tecnologias e a sustentabilidade para sermos líderes de ações sustentáveis e de respeito às fronteiras planetárias.

A tecnologia passará a ser realizada para atender às necessidades e à diversidade dos colaboradores da indústria, focando no bem-estar humano e social. Na criação de um local de trabalho seguro, saudável e inclusivo, para que seja possível proteger os direitos dos trabalhadores, como a independência, a dignidade humana e a privacidade [16].

Além disso, a fim de buscar as melhores oportunidades de emprego, no qual seja possível equilibrar a vida profissional e pessoal, os trabalhadores devem continuar a desenvolver competências e está sempre requalificando as suas habilidades. A sustentabilidade será o pilar das indústrias, isso requer a redução, a reutilização e a reciclagem dos recursos naturais, reduzindo os desperdícios e aumentando a eficiência dos recursos [5].

O autor Muller [17], identificou as seis principais tecnologias da Quinta Revolução Industrial:

- Tecnologias individuais para a interação homem-máquina capaz de se interconectar e combinar os pontos positivos entre os humanos e as máquinas;
- Tecnologias de inspiração biológicas e de materiais inteligentes que são capazes de ter sensores e associados e recursos aprimorados, que sejam recicláveis;
- *Digital twins* e de simulações que sejam possíveis modelar sistemas complexos;
- Tecnologias de transmissão, armazenamento e análise de dados que são capazes de lidar com os dados e a interoperabilidade dos sistemas integrados;
- Inteligência artificial para detectar as causalidades em sistemas que são complexos e dinâmicos;
- Tecnologias utilizadas para a eficiência energética, com energias renováveis, armazenamento e autonomia.

Na quinta revolução industrial, a Manutenção considerada será a Pró-Ativa, utilizando abordagens semelhantes às da Manutenção Preditiva, busca implementar ações preventivas que garantam a estabilidade do sistema e impeçam o surgimento de falhas. Esse conceito vem conquistando cada vez mais adeptos, e a US Navy já demonstrou interesse na sua aplicação. [7]

## Implementação de Estratégias de Inovação na Gestão da Manutenção Industrial

A Manutenção Pró-Ativa é uma abordagem avançada de manutenção que vai além da Manutenção Preditiva. Enquanto a Manutenção Preditiva foca na identificação da iminência de falhas para planejar ações corretivas ou preventivas, a Manutenção Pró-Ativa busca eliminar as causas raiz das falhas antes mesmo que os sintomas apareçam. [7]

A Indústria 5.0 não é uma revolução estimulada pela tecnologia, mas sempre por uma iniciativa de valor que será impulsionada pela transformação tecnológica com um propósito específico [16].

Para acompanhar a evolução dessas revoluções e as suas principais diferenças, é exibido na tabela abaixo com um quadro resumo com as fases da evolução da manutenção de acordo com as revoluções industriais.

Tabela 1.1: Quadro resumo com fases da evolução da manutenção. Fonte: [7].

Período	Tipo de Manutenção	Característica
1750-1914	Manutenção improvisada	"Quebra-repara"
1914-1930	Manutenção corretiva	Sem planejamento, sem controle
1930-1950	Manutenção preventiva + corretiva	Com planejamento, sem controle
1950-1970	Engenharia de manutenção	Com planejamento, com controle
1970- atualidade	Manutenção preditiva	Análise de sintomas, análise estatística e processamento digital de dados
Futuro	Manutenção preditiva contínua	Medição contínua de sintomas com centros de diagnósticos



## 2

### Estado da Arte

No capítulo dois será abordado sobre as tecnologias emergentes utilizadas na gestão da manutenção e como as entidades implementam as novidades tecnológicas nas indústrias, os maiores desafios, oportunidades de melhorias nessas organizações e o impacto dessas tecnologias no ambiente industrial.

A gestão da manutenção industrial tem passado por uma profunda transformação impulsionada pelas inovações tecnológicas da Indústria 4.0 e 5.0. O foco está na integração de sistemas físicos e digitais, visando melhorar a eficiência, aumentar a previsibilidade e reduzir custos operacionais. A aplicação de tecnologias emergentes, como *Internet das Coisas* (IoT), *Inteligência Artificial* (IA) e *digital twin*, tem proporcionado maior controle sobre processos e equipamentos.

A IoT tem sido amplamente adotada para conectar sensores e dispositivos, permitindo o monitoramento em tempo real de equipamentos. Essa conectividade possibilita a coleta contínua de dados sobre o desempenho dos ativos, facilitando a manutenção preventiva e preditiva. Em setores industriais, a instalação de sensores IoT nos equipamentos críticos permite antecipar falhas, minimizando paradas inesperadas.

A IA tem se mostrado uma ferramenta essencial na análise de dados complexos, fornecendo previsões precisas sobre a ocorrência de falhas e otimizando os processos de manutenção. Por meio de algoritmos de aprendizado de máquina, é possível identificar padrões nos dados históricos e operacionais, o que permite uma abordagem proativa na gestão dos ativos. Empresas que adotam manutenção preditiva baseada em IA conseguem reduzir o tempo de inatividade e aumentar a confiabilidade dos seus sistemas, melhorando a eficiência global.

Os *digital twins* também estão revolucionando a manutenção industrial. Eles consistem em réplicas virtuais de equipamentos ou processos físicos, que permitem simulações e análises antes da intervenção real. Ao testar soluções no ambiente virtual, os técnicos conseguem otimizar a manutenção e evitar erros que poderiam comprometer a operação. Em fábricas automotivas, essa tecnologia tem sido utilizada para prever o

desgaste de componentes e otimizar cronogramas de manutenção.

A aplicação de realidade aumentada (RA) e realidade virtual (RV) tem proporcionado avanços significativos na capacitação e no suporte remoto. A RA permite que técnicos visualizem, sobrepostos aos equipamentos reais, instruções e dados operacionais em tempo real. A RV, por sua vez, oferece ambientes de treinamento imersivos, nos quais os operadores podem praticar procedimentos de manutenção sem interferir nas operações reais. Essas tecnologias reduzem o tempo de treinamento e aumentam a precisão das intervenções.

Os robôs colaborativos são outra inovação relevante na manutenção industrial. Projetados para trabalhar ao lado de humanos, eles executam tarefas repetitivas e perigosas, aumentando a produtividade e melhorando a segurança. Em linhas de produção automotivas, por exemplo, os robôs realizam montagens complexas enquanto os operadores se concentram em atividades que exigem maior precisão.

A implementação dessas tecnologias emergentes, embora promissora, enfrenta alguns desafios importantes. A integração de sistemas legados é um dos principais obstáculos, pois a modernização de infraestruturas antigas para acomodar novas tecnologias pode demandar investimentos significativos. Plataformas como *CMMS* (*Computerized Maintenance Management Systems*) têm sido utilizadas para consolidar dados de diferentes fontes e facilitar essa integração.

Outro desafio está relacionado à capacitação da força de trabalho e à resistência à mudança. A adoção de novas tecnologias requer que os colaboradores adquiram novas habilidades, o que pode gerar resistência. Investir em programas de treinamento contínuo e envolver a equipe desde o início do processo é essencial para garantir uma transição suave.

Os custos iniciais de implementação também podem ser um entrave, especialmente para pequenas e médias empresas. A adoção gradual de soluções tecnológicas e a formação de parcerias estratégicas são abordagens recomendadas para mitigar esse desafio e garantir a sustentabilidade das operações.

A Indústria 4.0 trouxe um novo paradigma para a manutenção industrial, caracterizado pela automação e pela interconectividade dos sistemas. As tecnologias emergentes permitem que as empresas monitorem seus ativos em tempo real, identifiquem problemas antecipadamente e automatizem intervenções, reduzindo custos e aumentando a eficiência.

Enquanto, a Indústria 5.0 amplia esse conceito, ao priorizar a colaboração entre humanos e máquinas e ao promover a sustentabilidade e o bem-estar dos trabalhadores. A manutenção passa a ser vista não apenas como um meio de garantir eficiência operacional, mas também como uma atividade estratégica que contribui para a segurança e o conforto dos colaboradores.

## 2.1 Revisão da Literatura

As tecnologias emergentes estão ligadas principalmente a Indústria 4.0 e este movimento acontece principalmente pela transformação digital, o que possibilitou um maior avanço em diversas áreas, incluindo a gestão da manutenção [18].

A Indústria 4.0 é uma mudança absoluta de todo o escopo da produção industrial através da fusão da internet e da tecnologia digital com a indústria tradicional e foi motivada por três grandes mudanças no mundo industrial produtivo relacionadas à imensa quantidade de informações digitalizada, o desenvolvimento exponencial da capacidade computacional e estratégias de inovação (pessoas, pesquisa e tecnologia) [18].

Entretanto para que a Indústria 4.0 se torne viável, é necessário a adoção de uma estrutura tecnológica que seja composta por sistemas físicos e virtuais, visando obter um ambiente benéfico para que novas tecnologias sejam disseminadas e aceitas pela indústria, com o suporte da tecnologia de Análise de *Big Data*, robôs automatizados, simulações, manufatura avançada, realidade aumentada e a IoT, empregando o monitoramento de tendências tecnológicas, auxiliando gestores em toda a cadeia industrial [18].

Com um ecossistema interconectado, os dados desempenham um papel fundamental. Com a demasiada quantidade de sensores e dispositivos inteligentes são gerados enormes quantidades de dados em cada etapa da produção. A entrada de dados é então aproveitada através da Análise de *Big Data*, possibilitando que as empresas obtenham insights acionáveis, otimizem fluxos de trabalho e tomem decisões informadas [18].

A integração da IoT na Indústria 4.0 facilita a centralização do físico e do digital, através da realidade aumentada e simulações avançadas, os trabalhadores podem visualizar processos, solucionar problemas e aumentar a produtividade. Assim como, os robôs automatizados otimizam as operações, aumentando as capacidades humanas e garantindo eficiência em tarefas repetitivas [18].

A Internet Industrial das Coisas demonstra uma oportunidade transformadora para indústrias em todo o mundo. As empresas podem adaptar-se às dinâmicas de mercado em evolução, impulsionar a inovação e manter uma vantagem competitiva na era digital. Através da tecnologia de Inteligência Artificial aplicada na indústria, é possível auxiliar uma empresa a alcançar um melhor tempo para avaliar, reduzir custos, aumentar a produtividade e melhorar o relacionamento com partes interessadas e clientes [18].

Atualmente, as empresas querem maximizar a produção de bens e serviços e minimizar a entrada de recursos – financeiros, humanos e físicos. Entregando o melhor

valor tanto para o cliente quanto para o acionista, mas ao mesmo tempo ser seguro e ambientalmente consciente. Entregar valor significa oferecer a melhor qualidade e serviço, rapidamente e pelo menor preço [19].

Segundo Campbell [19], o corpo humano e a entidade coletiva sofrem porque não prestamos atenção suficiente à saúde física por meio da manutenção. Essa referência traz um ponto de reflexão porque manter-se saudável tanto no nível pessoal quanto ao nível empresarial, representa ter todos os seus ecossistemas e partes em bom funcionamento. Ser negligente leva a falhas e problemas, enquanto ter uma manutenção regular em conjunto com o cuidado preventivo pode levar a uma maior vida útil e ao desempenho constante. Em uma organização, isso se traduz em manter os ativos físicos em ordem, realizando manutenção preventiva e corretiva conforme necessário para evitar interrupções e minimizar o tempo de inatividade.

Em um ambiente de crise, a empresa recua o problema da competitividade para o segundo plano e o objetivo se torna sobreviver. Assim, começam a cortar gastos e economizar dinheiro, principalmente nas áreas de inovação, consultoria, *marketing* e publicidade. Por isso, a crise favorece a redução dos ativos intangíveis enquanto, os ativos tangíveis aumentam. Apesar disto, a estratégia de sobrevivência não deve consistir em abandonar investimentos, mas em adotar e aplicar abordagens que possibilitem o uso mais eficiente de recursos e tecnologias inovadoras [20].

Organizações que são bem sucedidas compreendem a importância de utilizar uma abordagem proativa e investir em recursos que são necessários para manter os seus ativos em um estado positivo, as empresas melhoram a sua eficiência, reduzem custos e aumentam a satisfação dos funcionários e dos clientes [19].

## 2.2 Metodologia utilizada na revisão da literatura

A pesquisa é reconhecida como teórica, porque busca realizar uma revisão bibliográfica sistemática, possibilitando uma análise metódica dos artigos selecionados sobre o tema em estudo, além de um aprofundamento em um caso específico de implementação de tecnologias emergentes em setores industriais.

Adicionalmente, caracteriza-se como utilização a abordagem mista, uma vez que o levantamento bibliográfico viabiliza tanto a análise quantitativa dos dados quanto a análise qualitativa dos conceitos e definições. Para a análise e argumentação, foi adotado o método indutivo, permitindo que, a partir da sistematização e análise das informações, sejam extraídas conclusões sobre o tema.

A pesquisa foi conduzida em cinco etapas, da qual a primeira etapa consistiu na definição das palavras-chave relacionadas ao tema da pesquisa. Na segunda etapa, a busca por artigos foi realizada nas bases de dados MDPI, Springer, IEEE, Semantic

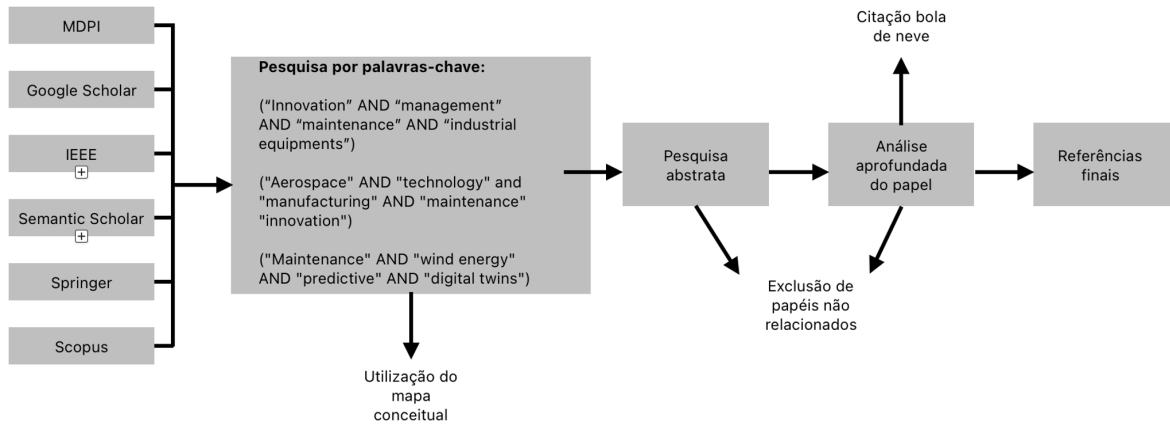


Figura 2.1: Fluxograma com o passo-a-passo da revisão bibliográfica.

Scholar, SCOPUS, e também no Google Scholar. As etapas seguintes serão detalhadas no próximo capítulo, por meio de um mapa mental.

Todos os artigos obtidos a partir da pesquisa das palavras-chave foram inicialmente examinados por meio da revisão dos dados, e apenas os textos relevantes para o tema desta dissertação foram incluídos. Os artigos selecionados passaram por uma análise e síntese antes de serem considerados como referências finais. Além disso, foi feita uma busca por literatura adicional com base nas referências dos textos já coletados.

A seguir a figura 2.1 que representa os passos realizados durante a revisão bibliográfica.

## 2.3 Estrutura Semântica e Mapa Mental

Com a quantidade de dados disponíveis na Web, a busca por informações torna-se um processo trivial e portanto a busca através das palavras-chave é a forma mais popular para encontrar conteúdo na internet. Ao utilizar as palavras-chave, essa está relacionada com um conjunto de documentos, entretanto nem sempre os termos buscados serão a intenção do usuário ou eles apresentarão uma precisão baixa devido à grande quantidade de documentos irrelevantes. Justamente porque um buscador tradicional não permite resolver a ambiguidade em uma consulta, porque não conhece o contexto da pesquisa [21].

Seguindo este fundamento, esta dissertação utilizou do método de consulta semântica, no qual propõe-se a entender o conceito de cada termo, ao invés da utilização da consulta por palavra-chave. O objetivo é melhorar a precisão através dos resultados da pesquisa por meio da compreensão dos termos e da intenção do em relação a busca, além de permitir expandir a abrangência da pesquisa [21].

Para consultas relacionadas com a "*innovation*", o primeiro nível foi obtido através do mapa mental conceitual, estabelecendo a base da pesquisa. Em seguida, a busca foi refinada com a orientação para consulta de dados através do termo "*management*", permitindo uma abordagem mais estruturada e gerencial. No terceiro nível, a pesquisa foi aprofundada com a inclusão de "*maintenance*", direcionando o foco para estratégias e práticas de manutenção. O quarto nível expandiu a análise para o setor "*industrial*", abrangendo aplicações e impactos no ambiente produtivo. Por fim, o quinto e último nível foi definido com a inclusão de "*equipments*", permitindo uma visão detalhada dos dispositivos e tecnologias utilizadas no contexto da inovação.

Em relação ao estudo de caso na Indústria Aeroespacial, a pesquisa começa com o termo "*aerospace*", abrangendo informações gerais sobre a indústria aeroespacial. No segundo nível, adicionamos "*technology*", refinando a busca para inovações e avanços tecnológicos aplicados ao setor aeroespacial. No terceiro nível, incluímos "*manufacturing*", focando na tecnologia de fabricação aeroespacial, como produção de aeronaves, materiais e processos industriais. No quarto nível, acrescentamos "*maintenance*", direcionando a pesquisa para a manutenção de equipamentos aeroespaciais, confiabilidade e estratégias de reparo. No nível mais avançado, integramos "*innovation*", explorando as tendências inovadoras em tecnologia, fabricação e manutenção aeroespacial. Essa estrutura permite uma pesquisa progressiva e detalhada, garantindo resultados mais precisos sobre a indústria aeroespacial e suas áreas estratégicas.

Para o estudo de caso no setor da energia eólica, a pesquisa se inicia com "*maintenance*", estabelecendo a base do estudo. No segundo nível, adicionamos "*wind energy*", delimitando o setor de aplicação. No terceiro, incluímos "*predictive*", abordando a antecipação de falhas para reduzir custos e otimizar o desempenho. No quarto e último nível, utilizamos "*digital twins*", explorando a simulação e análise digital para aprimorar a eficiência dos processos de manutenção.

Nas tabelas (2.1 - 2.9) a seguir, apresenta-se a referida estrutura.

O mapa mental conceitual utiliza de associações de ideias para formar conceitos, enquanto o mapa mental é livre e não se organiza hierarquicamente, estabelecidos em associações livres de palavras [22].

Os mapas mentais conceituais são usados para obter uma visualização da organização conceitual que é utilizada no processo de aprendizagem a um dado conhecimento, e trata-se de uma técnica não tradicional de avaliação, na qual busca as informações sobre os significados e as relações significativas entre os conceitos-chave [23].

Segundo Correa [24], os mapas mentais conceituais são divididos nas seguintes classes:

- **Supraordenado:** é um tipo de proposição abrangente, que engloba outras proposições, ajudando a identificar e evidenciar as características essenciais do conceito.

## Implementação de Estratégias de Inovação na Gestão da Manutenção Industrial

Tabela 2.1: Consulta bibliográfica – combinação de palavras-chave por níveis temáticos

	Nível	Palavra	Estrutura de Consulta
1	Nível 1	Innovation	"Innovation"
2	Nível 2	Management	"Innovation"AND "Management"
3	Nível 3	Maintenance	"Innovation"AND "Management"AND "Maintenance"
4	Nível 4	Industrial	Innovation AND "Management"AND "Maintenance"AND "Industrial"
5	Nível 5	Equipments	Innovation AND "Management"AND "Maintenance"AND "Industrial"AND "Equipments"

Tabela 2.2: Termos e estrutura de consulta para setor aeroespacial

	Nível	Palavra	Estrutura de Consulta
1	Nível 1	Aerospace	"Aerospace"
2	Nível 2	Technology	"Aerospace"AND "Technology"
3	Nível 3	Manufacturing	"Aerospace"AND "Technology"AND "Manufacturing"
4	Nível 4	Maintenance	"Aerospace"AND "Technology"AND "Manufacturing"AND "Maintenance"
5	Nível 5	Innovation	"Aerospace"AND "Technology"AND "Manufacturing"AND "Maintenance"AND "Innovation"

Tabela 2.3: Termos e estrutura de consulta aplicados à manutenção

	Nível	Palavra	Estrutura de Consulta
1	Nível 1	Maintenance	"Maintenance"
2	Nível 2	Wind energy	"Maintenance"AND "Wind energy"
3	Nível 3	Predictive	"Maintenance"AND "Wind energy"AND "Predictive"
4	Nível 4	<i>Digital twins</i>	"Maintenance"AND "Wind energy"AND "Predictive"AND " <i>Digital twins</i> "

- Isoordenado: refere a uma correspondência parcial, destacando relações e conexões entre proposições próximas, possibilitando a estruturação de conceitos antecedentes.

Tabela 2.4: Bases de dados consultadas com combinações para inovação

	Fonte	"Innovation"	+Management	+Maintenance	+Industrial	+Equipments
1	MDPI	95 202	829	201	54	10
2	Google Scholar	5 470 000	1 110 000	36	0	0
3	IEEE	216 506	56 714	2 018	595	139
4	Semantic Scholar	1 180 000	7 760 000	340 000	23 400	2 813
5	Springer	74 271	416 407	95 393	49 825	1 143

Tabela 2.5: Bases de dados consultadas para manutenção

	Fonte	"Maintenance"	+Wind Energy	+Predictive	+ <i>Digital twins</i>
1	MDPI	23 268	397	95	5
2	Google Scholar	6 410 000	2 410 000	359 000	265 000
3	IEEE	121 234	5 398	518	43
4	Semantic Scholar	1 150 000	275 000	26 300	2 770
5	Springer	1 398 436	64 824	7 647	578

Tabela 2.6: Bases de dados consultadas para o setor aeroespacial

	Fonte	"Aerospace"	+Technology	+Manufacturing	+Maintenance	+Innov.
1	MDPI	21 029	1 477	346	7	1
2	Google Scholar	3 300 000	2 550 000	1 710 000	280 000	84 000
3	IEEE	157 195	72 576	5 504	342	36
4	Semantic Scholar	129 000	6 470 000	308 000	14 700	1 290
5	Springer	179 962	104 407	45 155	11 637	4 820

- **Infraordenado:** apresenta subdivisões ou ramificações, ordenadas por exemplo e pela sequência em proposições, ideias e categorias evoluem.
- **Exclusões:** são classes mutuamente opostas ou exclusivas, ligadas à operação de

## Implementação de Estratégias de Inovação na Gestão da Manutenção Industrial

Tabela 2.7: Números de artigos científicos por fonte e de acordo com toda a estrutura de consulta para "equipments" por intervalos de anos

	Fonte	+Equipments	+>2015	+>2020	+>2025
1	MDPI	12	0	3	9
2	Google Scholar	69 300	16 400	16 400	16 200
3	IEEE	156	48	22	86
4	Semantic Scholar	3 010	1 330	771	837
5	Springer	1 177	659	278	240

Tabela 2.8: Números de artigos científicos por fonte e de acordo com toda a estrutura de consulta para "innovation" por intervalos de anos

	Fonte	+Innovation	+>2015	+>2020	+>2025
1	MDPI	1	0	0	1
2	Google Scholar	83 200	17 800	15 900	16 900
3	IEEE	36	10	6	20
4	Semantic Scholar	1 300	542	330	385
5	Springer	4 836	1 952	997	1 871

Tabela 2.9: Números de artigos científicos por fonte e de acordo com toda a estrutura de consulta para "Digital twins" por intervalos de anos

	Fonte	+Digital twins	+>2015	+>2020	+>2025
1	MDPI	5	0	0	5
2	Google Scholar	24 000	16 600	15 600	17 100
3	IEEE	44	0	2	42
4	Semantic Scholar	2 830	393	499	1 870
5	Springer	582	60	60	462

negação ou exclusão de uma conexão entre classes adjacentes.

A seguir na Figura 2.2 é possível observar o desenvolvimento do mapa mental

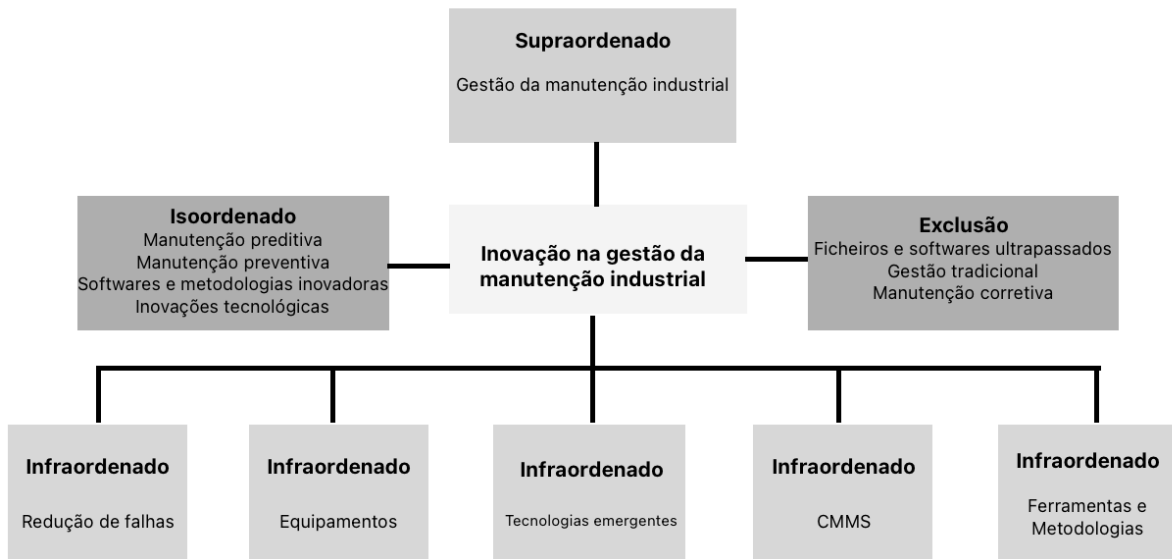


Figura 2.2: Mapa mental conceitual.

conceitual.

O tema central é representado pelo tópico que está no meio do fluxograma, sobre a inovação na gestão da manutenção industrial. No topo aparece o supraordenado, que é o conceito mais abrangente do mapa conceitual, que é a gestão da manutenção em um contexto industrial. A esquerda temos o isoordenado, e são conceitos que estão no mesmo nível hierárquico e representam diferentes abordagens na gestão da manutenção. A direita representa as exclusões, ou seja, as relações de negação ou incompatibilidade nesse contexto. Os itens que estão subdivididos são os infraordenados e que detalham os conceitos principais.

# Implementação de Estratégias de Inovação na Gestão da Manutenção Industrial

Referência	Resumo	Conclusões
1 Okpeke Paul, P., Ogugua, J. O., Eyo-Udo, N. L. (2024). Innovations in fixed asset management: Enhancing efficiency through advanced tracking and maintenance systems. <i>International Journal of Research Archive in Science and Technology</i> , 7(1), 19–26. <a href="https://doi.org/10.53771/ijstra.2024.7.1.0053">https://doi.org/10.53771/ijstra.2024.7.1.0053</a>	RFID, GPS, integração com IoT, manutenção preditiva impulsionada por IA e plataformas CMMS são tecnologias emergentes fundamentais que estão aprimorando a eficiência da gestão de manutenção ao reduzir o tempo de inatividade, otimizar a utilização de ativos e melhorar o gerenciamento do ciclo de vida.	Sistemas avançados de rastreamento aprimoram a eficiência operacional na gestão de ativos. A IA e o aprendizado de máquina mitigam desafios na implementação de sistemas de manutenção.
2 Liu, Yunxiang., Yao, Wenbin., Li, Xiaodan., Liu, Xubo. (2017). Intelligent industrial device maintenance management system.	O sistema inteligente de gerenciamento de manutenção de dispositivos industriais integra de forma inovadora vários subsistemas de manutenção para manutenção eficiente e oportuna de equipamentos industriais, melhorando os processos de manutenção e os tempos de resposta.	Modos de manutenção multifuncionais fornecidos para manutenção de dispositivos industriais. O banco de dados central armazena informações de manutenção e esquemas de soluções correspondentes.
3 Ritu, Malhotra., Tara, Alzahawi., Elora, McLeod. (2019). Management and Maintenance of Electrical Equipment in Industrial Facilities. doi: 10.1109/ICPS.2019.8733336	O artigo discute a importância do gerenciamento de programas de manutenção preventiva elétrica para equipamentos industriais, destacando desafios, métodos de implementação e benefícios na manutenção e atualização eficaz de sistemas elétricos.	Importância do gerenciamento de programas de manutenção preventiva elétrica. Benefícios da manutenção regular em instalações industriais.
4 Fernando, F, Espinosa., Acires, Dias., Gonzalo, E., Salinas. (2011). Un procedimiento para evaluar el riesgo de la innovación en la gestión del mantenimiento industrial A procedure for assessing the risks of innovation in the management of industrial maintenance.	É delineado um procedimento para avaliar riscos na gestão da inovação da manutenção industrial, visando prevenir resultados inesperados e aumentar a eficácia dos projetos de melhoria nesta área.	Gestão eficaz de riscos é crucial para o sucesso do projeto. Ferramentas, liderança e medidas de controle essenciais para gerenciar riscos de inovação.
5 Anaba, D. C., Kess-Momoh, A. J., Ayodeji, S. A. (2024). Innovative maintenance strategies for industrial equipment: A review of current practices and future directions. <i>Open Access Research Journal of Science and Technology</i> , 11(2), 29–37. <a href="https://doi.org/10.53022/oarjst.2024.11.2.0081">https://doi.org/10.53022/oarjst.2024.11.2.0081</a>	Estratégias de manutenção inovadoras, incorporando IoT, IA e robótica, aumentam a confiabilidade e a eficiência dos equipamentos industriais. Os desafios incluem integração técnica, custos, treinamento e regulamentações, com recomendações para práticas ideais.	Vantagens e limitações das estratégias de manutenção atuais discutidas. Desafios e recomendações para implementação de estratégias avançadas de manutenção abordadas.
6 Vasile, Deac., Gheorghe, Carstea., Constantin, Bagu., Florea, Parvu. (2010). (5) The Modern Approach to Industrial Maintenance Management.	A abordagem moderna à gestão da manutenção industrial enfatiza a utilização de meios modernos como a informatização para aprimorar as atividades de manutenção de equipamentos industriais, garantindo eficiência e confiabilidade.	A gestão da manutenção requer meios modernos de informatização para ser eficiente. Os fatores humanos desempenham um papel crucial nas atividades de manutenção.
7 Agustiady, T., and Cudney, E. A. (2024). Total productive maintenance strategies and implementation guide (2nd ed.)	Discute a inovação e gestão através do uso do TPM e oferece capacitação e incentivo aos associados para que se sintam mais confortáveis usando o TPM diariamente.	Atualizado especificamente com novos estudos de caso de implementação do TPM após a pandemia, mudança cultural e o que isso implica.
8 Schwab, K. (2016). A Quarta Revolução Industrial. Editora: Porter, Tradução: Fernandes.	Explora as características e implicações da Quarta Revolução Industrial, destacando como as tecnologias emergentes, como inteligência artificial e Internet das Coisas, estão transformando a economia, a sociedade e a maneira como vivemos e trabalhamos.	É essencial que indivíduos, empresas e governos colaborem na criação de um futuro que priorize o bem-estar humano e a inclusão social.

Tabela 2.10: Sumário dos artigos científicos mais citados - Parte 1

Referência	Resumo	Conclusões	
9	NP EN 13306:2021. (2021). Gestão de ativos - Terminologia. Lisboa: Instituto Português da Qualidade.	Define a terminologia padronizada para a gestão de ativos, facilitando a comunicação e o entendimento comuns na manutenção e gestão de ativos.	A norma NP EN 13306:2021 contribui para a uniformidade e clareza na gestão de ativos, garantindo uma base comum para práticas eficazes e comunicação precisa.
10	Farinha, J. M. T. (1994). Uma abordagem terológica da manutenção dos equipamentos hospitalares.	Propõe uma abordagem terológica para a manutenção de equipamentos hospitalares, focando na otimização e confiabilidade desses ativos críticos.	Destaca a importância de uma manutenção eficiente para garantir a confiabilidade e o desempenho seguro dos equipamentos hospitalares.
11	Farinha, J. M. T. (1994). Uma abordagem terológica da manutenção dos equipamentos hospitalares.	Propõe uma abordagem terológica para a manutenção de equipamentos hospitalares, focando na otimização e confiabilidade desses ativos críticos.	Destaca a importância de uma manutenção eficiente para garantir a confiabilidade e o desempenho seguro dos equipamentos hospitalares.
12	Campbell, J. D., and Reyes-Picknell, J. V. (2016). Uptime: Strategies for Excellence in Maintenance Management (3rd ed.). Taylor and Francis.	Apresenta estratégias para alcançar excelência na gestão da manutenção, com foco na maximização da eficiência e da disponibilidade dos ativos.	Enfatiza que a excelência na gestão da manutenção é fundamental para maximizar a eficiência operacional e garantir a alta disponibilidade dos ativos.
13	Levitt, J. (2011). The complete guide to preventive and predictive maintenance (2nd ed.). Industrial Press. ISBN 978-0-8311-3441-9.	Oferece um guia abrangente sobre manutenção preventiva e preditiva, abordando técnicas para melhorar a confiabilidade e a eficiência dos equipamentos industriais.	Reforça que a aplicação eficaz de manutenção preventiva e preditiva é essencial para otimizar a confiabilidade dos equipamentos e minimizar custos operacionais.
14	Anandan, R., Gopalakrishnan, S., Pal, S., e Zaman, N. (Eds.). (2022). The Industrial Internet of Things (IIoT): Intelligent analytics for predictive maintenance. John Wiley e Sons, Inc. e Scrivener Publishing LLC.	Explora o uso da Internet Industrial das Coisas (IIoT) e da análise inteligente para aprimorar a manutenção preditiva.	Destaca que a aplicação de IIoT e análises inteligentes é crucial para transformar a manutenção preditiva, aumentando a eficiência e a proatividade na gestão de ativos industriais.
15	Explora a evolução histórica da indústria, desde a Indústria 1.0 até a Indústria 5.0, destacando as transformações tecnológicas e os avanços nas áreas de computação, comunicação e controle que moldam a manufatura moderna.	Explora o uso da Internet Industrial das Coisas (IIoT) e da análise inteligente para aprimorar a manutenção preditiva.	Destaca que a aplicação de IIoT e análises inteligentes é crucial para transformar a manutenção preditiva, aumentando a eficiência e a proatividade na gestão de ativos industriais.
16	Günther, H. (2006). Pesquisa qualitativa versus pesquisa quantitativa: esta é a questão? [Qualitative research versus quantitative research: is that really the question?]. Psicologia: Teoria e Pesquisa, 22(2). <a href="https://doi.org/10.1590/S0102-37722006000200010">https://doi.org/10.1590/S0102-37722006000200010</a>	Debata as diferenças e complementaridades entre a pesquisa qualitativa e quantitativa, questionando se essas abordagens são realmente excludentes ou se podem ser integradas para enriquecer a compreensão científica em psicologia.	Enfatiza que, em vez de ver as abordagens qualitativa e quantitativa como opostas, é mais produtivo considerá-las complementares, permitindo uma compreensão mais ampla e profunda dos fenômenos psicológicos.
17	Galvao, M. C. B., Pluye, P., and Ricarte, I. L. M. (2017). Métodos de pesquisa mistos e revisões de literatura mistas: conceitos, construção e critérios de avaliação. InCID: Revista De Ciência Da Informação E Documentação, 8(2), 4-24. <a href="https://doi.org/10.11606/issn.2178-2075.v8i2p4-24">https://doi.org/10.11606/issn.2178-2075.v8i2p4-24</a>	Aborda os conceitos, a construção e os critérios de avaliação para métodos de pesquisa e revisões de literatura mistos, destacando a importância da integração de abordagens qualitativas e quantitativas para enriquecer a análise e a interpretação dos dados.	Sugere que métodos e revisões de literatura mistos oferecem uma compreensão mais abrangente e profunda dos fenômenos estudados.

Tabela 2.11: Sumário dos artigos científicos mais citados - Parte 2

## Implementação de Estratégias de Inovação na Gestão da Manutenção Industrial

Referência	Resumo	Conclusões
18 Santos, L. S., and Araújo, R. B. D. (2018). A revolução industrial. <i>História Econômica e Geral</i> .	Discute a Revolução Industrial, examinando seu impacto econômico e social e como as transformações industriais moldaram o desenvolvimento da sociedade moderna.	Destaca que a Revolução Industrial foi um marco fundamental para o progresso econômico e social, gerando profundas mudanças nas estruturas produtivas e nas relações de trabalho, cujos efeitos ainda influenciam a sociedade contemporânea.
19 Atkeson, A., & Kehoe, P. J. (2001). The transition to a new economy after the second industrial revolution (NBER Working Paper No. 8676). National Bureau of Economic Research. <a href="https://doi.org/10.3386/w8676">https://doi.org/10.3386/w8676</a>	Analisa a transição para uma nova economia após a Segunda Revolução Industrial, explorando como as inovações tecnológicas transformaram a produtividade e crescimento da economia.	Sugere que a transição para uma nova economia após a Segunda Revolução Industrial foi impulsionada por avanços tecnológicos que aumentaram significativamente a produtividade, preparando o terreno para um crescimento econômico sustentável a longo prazo.
20 Mokyr, J. (1998). <i>The Second Industrial Revolution, 1870-1914</i> . Northwestern University, 2003 Sheridan Rd., Evanston, IL 60208.	Explora as inovações tecnológicas e as mudanças econômicas e sociais que caracterizaram o período da Segunda Revolução Industrial, destacando seu impacto no desenvolvimento industrial e na transformação da sociedade.	Destaca que a Segunda Revolução Industrial foi um período decisivo de inovações tecnológicas e mudanças sociais que moldaram o desenvolvimento econômico e as relações sociais, cujos impactos ainda são sentidos na sociedade contemporânea.
21 Mohajan, H. (2021). Third industrial revolution brings global development. <i>Journal of Social Sciences and Humanities</i> , 7(4), 239-251. <a href="http://www.aiscience.org/journal/jssh">http://www.aiscience.org/journal/jssh</a> .	Examina como a Terceira Revolução Industrial, marcada pela digitalização e pela inovação tecnológica, tem impulsionado o desenvolvimento global, transformando economias, sociedades e interações humanas.	Conclui que a Terceira Revolução Industrial impulsionou avanços significativos no desenvolvimento global, mas enfatiza a necessidade de investimentos em educação e políticas inclusivas para maximizar seus benefícios e promover um crescimento sustentável e equitativo.
22 Hwang, J. S. (2016). The fourth industrial revolution (industry 4.0): intelligent manufacturing. <i>SMT Magazine</i> , 3, 616-630.	Explora o conceito de Indústria 4.0, destacando como a integração de tecnologias inteligentes e conectividade está transformando a manufatura e promovendo eficiência, inovação e personalização na produção.	Representa uma transformação fundamental na manufatura, exigindo que as empresas adotem tecnologias inteligentes e conectividade para se manterem competitivas e atender às demandas de um mercado em rápida evolução.
23 Klingenberg, C., and Antunes, J. (2017). Industry 4.0: what makes it a revolution. <i>EuroMA</i> 2017, 1-11.	Analisa os principais elementos que caracterizam a Indústria 4.0 como uma revolução, enfatizando a integração de tecnologias digitais, automação e big data na transformação dos processos industriais e na criação de novos modelos de negócios.	Destaca que a Indústria 4.0 não é apenas uma evolução tecnológica, mas uma revolução abrangente que redefine práticas industriais, impulsiona a eficiência e exige uma reavaliação dos modelos de negócios tradicionais para se adaptar a um ambiente em constante mudança.
24 Brettel, M., Friederichsen, N., Keller, M., and Rosenberg, M. (2014). How virtualization, decentralization and network building change the manufacturing landscape: An industry 4.0 perspective. <i>International Journal of Mechanical, Industrial Science and Engineering</i> , 8(1), 37-44.	Explora como a virtualização, a descentralização e a formação de redes estão transformando o setor manufatureiro, destacando o impacto da Indústria 4.0 na criação de sistemas de produção mais flexíveis e interconectados.	Afirmam que a Indústria 4.0, por meio da virtualização e descentralização, está revolucionando o cenário manufatureiro, permitindo uma maior agilidade, eficiência e colaboração nas cadeias produtivas, o que é crucial para a competitividade no futuro.

Tabela 2.12: Sumário dos artigos científicos mais citados - Parte 3

Referência	Resumo	Conclusões	
26	Rastegari, A., and Salonen, A. (2015). Strategic maintenance management: Formulating maintenance strategy. <i>International Journal of Condition Monitoring and Diagnostic Engineering Management</i> , 18, 5-14.	Discute a importância da gestão estratégica da manutenção, propondo um framework para a formulação de estratégias de manutenção que maximize a eficiência operacional e minimize os custos associados.	Os autores destacam que uma abordagem estratégica na gestão da manutenção é crucial para otimizar os recursos e garantir a confiabilidade dos ativos, contribuindo assim para o desempenho geral das organizações.
27	V., Karacharovskii. (2011). Innovation Management in Industrial Production. <i>Problems of Economic Transition</i> , doi: 10.2753/PET1061-1991531103	Analisa os desafios e oportunidades da gestão da inovação na produção industrial, enfatizando a necessidade de estratégias eficazes para integrar novas tecnologias e práticas de inovação para melhorar a competitividade das empresas.	Argumenta que a adoção de uma abordagem sistemática para a gestão da inovação é fundamental para enfrentar as demandas dinâmicas do mercado e promover o crescimento sustentável nas indústrias de produção.
28	Petr, Korba., P., Svab., Michael, L., Veres., Ján, Lukáč. (2023). 2. Optimizing Aviation Maintenance through Algorithmic Approach of Real-Life Data. <i>Applied Sciences</i> , doi: 10.3390/app13063824	A identificação de tecnologia para atender à necessidade de melhoria no treinamento tradicional, utilizando as aplicações de Realidade Virtual e Realidade Aumentada no treinamento de manutenção, dotaria os Trainees de Manutenção de Aeronaves (AMT's) com conhecimentos e práticas completos.	O artigo destaca a necessidade de avanços tecnológicos no treinamento em manutenção de aeronaves indianas. Sugere a utilização de Sistema Informatizado de Gestão de Manutenção (CMMS) e aplicações de Realidade Virtual (VR) e Realidade Aumentada (AR) em treinamentos.
29	Qasim, Zeeshan. (2023). 5. Applications of Machine Learning in Aircraft Maintenance. doi: 10.56578/jemse020105	Uma revisão abrangente das técnicas de ML, como Multilayer Perceptron (MLP), Regressão Lógica (LR), Random Forest (RF), Rede Neural Artificial (ANN), SVR, Regressão Linear e outras técnicas comuns de ML para sua implementação atual e potencial futuro aplicações em manutenção de aeronaves são fornecidas neste artigo.	As técnicas de ML têm aplicações potenciais na manutenção de aeronaves. Vários algoritmos de ML podem otimizar sistemas de manutenção.
30	Ali, Aghazadeh, Ardebili., Antonella, Longo., Antonio, Ficarella. (2021). 7. <i>Digital twins</i> (DT) in Smart Energy Systems - Systematic Literature Review of DT as a growing solution for Energy Internet of the Things (EIoT). doi: 10.1051/E3SCONF/202131209002	A integração de <i>Digital twins</i> em sistemas de energia eólica aumenta a eficiência energética ao otimizar as operações e a manutenção, ao mesmo tempo que melhora a confiabilidade por meio de monitoramento em tempo real e análises preditivas para mitigar possíveis falhas.	O <i>Digital twin</i> torna o sistema energético inteligente e dinâmico. A DT contribui para a tomada de decisões e facilita o controle.
31	Soares, L., González, M., Aguirre, L., Vasconcelos, R., e Nogueira, L. (2023). Tecnologia do <i>Digital twin</i> aplicado à manutenção de turbinas eólicas offshore. Política Industrial Verde e Transição Energética Justa: O Protagonismo Brasileiro.	O artigo explora a aplicação da tecnologia do <i>digital twin</i> na manutenção de turbinas eólicas offshore, com foco em monitoramento e otimização das operações. O estudo enfatiza a relevância do DT para planejamento e gestão de atividades de operação e manutenção (OeM) e propõe perspectivas para novas pesquisas.	A aplicação do <i>digital twin</i> no setor de energia eólica offshore é recente, mas apresenta grande potencial para melhorar a eficiência e reduzir custos nas atividades de OeM. A pesquisa destaca a necessidade de expandir o número de estudos práticos e a implementação de tecnologias do DT no setor. Sugere-se a realização de métodos como survey, pesquisa-ação e experimentos para compreender melhor os benefícios e os desafios dessa tecnologia.

Tabela 2.13: Sumário dos artigos científicos mais citados - Parte 4

## Implementação de Estratégias de Inovação na Gestão da Manutenção Industrial

Referência	Resumo	Conclusões
32 Sari, A. N., e Gelar, T. (2024). Blockchain: Teknologi dan implementasinya. Jurnal MNEMONIC, 7(1), 63-70.	O trabalho aborda os conceitos básicos de blockchain, incluindo a estrutura de blocos interligados que registra transações de forma segura e imutável. Os autores discutem também aplicações como contratos inteligentes, que automatizam acordos entre partes, eliminando a necessidade de intermediários confiáveis.	O artigo conclui que a adoção da tecnologia blockchain oferece vantagens significativas, especialmente em setores que demandam alta integridade de dados e transparência. Entretanto, os autores sugerem que a implementação ainda enfrenta desafios relacionados à regulamentação, custos iniciais e escalabilidade.
33 Lufthansa Technik. (n.d.). Innovation e digitalization. Lufthansa Technik. <a href="https://www.lufthansa-technik.com/en/innovation-digitalization">https://www.lufthansa-technik.com/en/innovation-digitalization</a>	Lufthansa Technik adota um papel pioneiro no uso da digitalização e inovação tecnológica para melhorar os processos de manutenção, reparo e operações de aviação.	O compromisso da Lufthansa Technik com inovação demonstra como a tecnologia pode transformar a aviação, desde a manutenção preditiva até experiências aprimoradas para passageiros e tripulantes.
34 U. Karaoglu, O. Mbah, and Q. Zeeshan, "Applications of machine learning in aircraft maintenance," J. Eng. Manag. Syst. Eng., vol. 2, no. 1, pp. 76-95, 2023. <a href="https://doi.org/10.56578/jemse020105">https://doi.org/10.56578/jemse020105</a>	Explora o uso de Machine Learning (ML) na manutenção de aeronaves, um campo complexo que busca aumentar a confiabilidade e a segurança por meio da previsão de falhas e otimização de processos.	A pesquisa destaca o impacto transformador do ML em operações de manutenção de aeronaves. Ao analisar padrões complexos de dados, esses algoritmos permitem prever e mitigar falhas antes que ocorram, resultando em benefícios significativos para a segurança e economia no setor.
35 Florian, Stadtmann., Adil, Rasheed. (2024). 8. Diagnostic Digital Twin for Anomaly Detection in Floating Offshore Wind Energy. doi: 10.48550/arxiv.2406.02775	Apresenta o conceito de <i>digital twins</i> Diagnósticos aplicados à manutenção preditiva e baseada em condições para turbinas eólicas flutuantes offshore.	O artigo sublinha a importância dos <i>digital twins</i> no contexto de engenharia offshore, especialmente para ativos de alto risco e valor em locais remotos. A abordagem proposta não apenas aumenta a vida útil das turbinas, mas também contribui para a sustentabilidade ao mitigar falhas inesperadas e otimizar a manutenção.
36 Haghshenas, A., Hasan, A., Osen, O. et al. <i>Digital twin</i> preditivo para parques eólicos offshore. Energy Inform 6 , 1 (2023). <a href="https://doi.org/10.1186/s42162-023-00257-4">https://doi.org/10.1186/s42162-023-00257-4</a>	O artigo apresenta uma abordagem inovadora para melhorar a operação e a manutenção de parques eólicos offshore por meio de <i>digital twins</i> preditivos.	A implementação de <i>digital twins</i> preditivos em parques eólicos offshore apresenta um grande potencial para revolucionar a manutenção e operação dessas instalações.
37 Palazzetti, C., e López Bertani, M. T. (2024, June 14). <i>Digital twin</i> project set to make offshore wind power more reliable and secure. Technical University of Denmark. <a href="https://www.icons.it/news/digital-twin-project-set-to-make-offshore-wind-power-more-reliable-and-secure">https://www.icons.it/news/digital-twin-project-set-to-make-offshore-wind-power-more-reliable-and-secure</a>	Aborda o desenvolvimento de um projeto de <i>digital twins</i> focado em tornar a energia eólica offshore mais confiável e segura.	A aplicação de <i>digital twins</i> em parques eólicos offshore representa um avanço crucial para a transição energética sustentável. A integração de ferramentas preditivas e de simulação em um ambiente digital facilita a antecipação de falhas e otimiza a operação, contribuindo para aumentar a segurança e a eficiência.
38 WindTwin Project. (n.d.). WindTwin press release. WindTwin. <a href="https://windtwinproject.eu/news/press-release/">https://windtwinproject.eu/news/press-release/</a>	O objetivo é criar uma plataforma de <i>digital twins</i> para prever de forma precisa a produção de energia e a demanda energética em parques eólicos.	O projeto WindTwin representa um avanço significativo no uso de tecnologias digitais no setor de energia renovável. Ao combinar previsão energética de alta precisão com gestão operacional, ele tem o potencial de tornar a energia eólica offshore mais eficiente e competitiva.

Tabela 2.14: Sumário dos artigos científicos mais citados - Parte 5

Referência	Resumo	Conclusões	
39	<p>TWI Ltd. (2017, September). WindTwin project aims to revolutionise wind turbine operation with <i>digital twin</i> technology. <a href="https://www.twi-global.com/media-and-events/press-releases/2017-09-windtwin-project-aims-to-revolutionise-wind-turbine-operation-with-digital-twin-technology">https://www.twi-global.com/media-and-events/press-releases/2017-09-windtwin-project-aims-to-revolutionise-wind-turbine-operation-with-digital-twin-technology</a></p>	<p>O projeto WindTwin, liderado pela TWI Ltd., visa transformar as operações de turbinas eólicas por meio da tecnologia de <i>digital twins</i>. Este sistema combina modelagem física, dados em tempo real e análise preditiva para monitorar, prever e otimizar o desempenho das turbinas.</p>	<p>O WindTwin é um marco na aplicação de <i>digital twins</i> em energia renovável, representando um avanço significativo na operação e manutenção de turbinas eólicas.</p>
40	<p>Saxena, A. (2023, Janeiro 31). Manutenção e reparo de aeronaves: caso de uso de blockchain.</p>	<p>O uso de blockchain na manutenção e reparo de aeronaves visa melhorar a rastreabilidade, segurança e transparência dos dados relacionados a peças e componentes de aeronaves.</p>	<p>O blockchain oferece um grande potencial para transformar a indústria de manutenção de aeronaves, trazendo mais eficiência e confiabilidade.</p>
41	<p>Lufthansa Group. (2023). Annual report: Combined management report – MRO business segment.</p>	<p>O relatório anual da Lufthansa Group de 2023 apresenta um panorama detalhado do segmento de negócios de Manutenção, Reparo e Revisão (MRO), destacando desempenhos financeiros, estratégias operacionais e inovações</p>	<p>O segmento MRO desempenha um papel crucial no fortalecimento operacional e financeiro da Lufthansa Group, com foco em soluções tecnológicas e eficiência para garantir a competitividade em um mercado global desafiador.</p>
42	<p>DTWO Project. (n.d.). Technologies. Recuperado de <a href="https://dtwo-project.eu/technologies/">https://dtwo-project.eu/technologies/</a></p>	<p>O site do projeto Dtwo apresenta uma visão geral das tecnologias avançadas aplicadas à gestão de recursos hídricos, destacando inovações como sensores inteligentes, plataformas digitais e análise de dados em tempo real para otimizar o uso sustentável da água.</p>	<p>As tecnologias abordadas pelo projeto Dtwo evidenciam a importância da integração de soluções digitais e inovadoras para melhorar a eficiência no gerenciamento de recursos hídricos, promovendo a sustentabilidade e a resiliência ambiental.</p>
43	<p>Mrzyk, P., Kubacki, J., Luttmer, J., Pluhna, R., &amp; Nagarajah, A. (2023). <i>Digital twins</i> for predictive maintenance: A case study for a flexible IT-architecture. <i>Procedia CIRP</i>, 119, 152-157. <a href="https://doi.org/10.1016/j.procir.2023.03.087">https://doi.org/10.1016/j.procir.2023.03.087</a></p>	<p>O artigo explora a aplicação de gêmeos digitais na manutenção preditiva, apresentando um estudo de caso sobre uma arquitetura de TI flexível. Os autores discutem como essas tecnologias podem melhorar a eficiência operacional e reduzir custos de manutenção.</p>	<p>A integração de gêmeos digitais com arquiteturas de TI flexíveis oferece um grande potencial para revolucionar a manutenção preditiva, permitindo uma gestão mais eficiente e proativa dos ativos industriais.</p>
44	<p>Liu, S., Ren, S., e Jiang, H. (2023). Predictive maintenance of wind turbines based on <i>digital twin</i> technology. <i>Energy Reports</i>, 9(Supplement 10), 1344-1352. <a href="https://doi.org/10.1016/j.egy.2023.05.052">https://doi.org/10.1016/j.egy.2023.05.052</a></p>	<p>O artigo apresenta o uso de gêmeos digitais para a manutenção preditiva de turbinas eólicas, detalhando como essa abordagem permite monitoramento em tempo real, análise de desempenho e previsão de falhas para otimizar a eficiência energética.</p>	<p>A tecnologia de gêmeos digitais demonstrou ser uma ferramenta eficaz na manutenção preditiva de turbinas eólicas, promovendo maior confiabilidade e sustentabilidade no setor de energia renovável.</p>
45	<p>Pacheco-Blazquez, R., Garcia-Espinosa, J., Di Capua, D., &amp; Pastor Sanchez, A. (2024). <i>A digital twin</i> for assessing the remaining useful life of offshore wind turbine structures. <i>Journal of Marine Science and Engineering</i>, 12(4), 573. <a href="https://doi.org/10.3390/jmse12040573">https://doi.org/10.3390/jmse12040573</a></p>	<p>O estudo investiga o uso de gêmeos digitais para avaliar a vida útil remanescente de estruturas de turbinas eólicas offshore, integrando modelos físicos e dados em tempo real para melhorar a manutenção e a tomada de decisões.</p>	<p>A aplicação de gêmeos digitais no setor offshore se mostra essencial para prever a vida útil remanescente de turbinas eólicas, garantindo maior eficiência operacional e redução de custos de manutenção em ambientes desafiadores.</p>
46	<p>XMPro. (n.d.). Wind power plant wind turbine DTDL models. GitHub. Recuperado de <a href="https://github.com/XMPro/Wind-Power-Plant-Wind-Turbine-DTDL-Models">https://github.com/XMPro/Wind-Power-Plant-Wind-Turbine-DTDL-Models</a></p>	<p>O repositório no GitHub da XMPro disponibiliza modelos baseados em <i>Digital Twins Definition Language</i> (DTDL) para turbinas eólicas, facilitando a criação de gêmeos digitais voltados ao monitoramento e gestão de plantas de energia eólica.</p>	<p>Os modelos DTDL fornecidos pela XMPro são fundamentais para a padronização e o desenvolvimento de gêmeos digitais em parques eólicos, permitindo integração eficiente e maior precisão no gerenciamento dessas instalações.</p>

Tabela 2.15: Sumário dos artigos científicos mais citados - Parte 6

## Implementação de Estratégias de Inovação na Gestão da Manutenção Industrial

Referência	Resumo	Conclusões
47 Johansen, S. S. (2018). On the development of a <i>digital twins</i> for fault detection in offshore wind turbine drivetrains (Master's thesis). Norwegian University of Science and Technology, Trondheim, Norway.	A dissertação investiga o desenvolvimento de um gêmeo digital para a detecção de falhas em sistemas de transmissão de turbinas eólicas offshore, com foco em aumentar a confiabilidade e eficiência na manutenção preventiva.	O uso de gêmeos digitais para monitorar sistemas de transmissão de turbinas eólicas offshore oferece avanços significativos na detecção precoce de falhas, reduzindo custos e aumentando a confiabilidade operacional no setor de energia renovável.
48 Karaoğlu, U., Mbah, O., & Zeeshan, Q. (2023). Applications of machine learning in aircraft maintenance. <i>Journal of Engineering Management and Systems Engineering</i> , 2(1), 76–95. <a href="https://doi.org/10.56578/jemse020105">https://doi.org/10.56578/jemse020105</a>	O artigo explora como o machine learning pode ser aplicado para otimizar processos de manutenção de aeronaves, aumentando a eficiência e reduzindo custos.	A integração de machine learning na manutenção de aeronaves representa um avanço significativo para a indústria aeronáutica, promovendo maior confiabilidade e segurança operacional.
49 Efthymiou, M., McCarthy, K., Markou, C., & O'Connell, J. F. (2022). Uma pesquisa exploratória sobre blockchain na aviação: O caso de organizações de manutenção, reparo e revisão (MRO). <i>Sustainability</i> , 14(5), 2643. <a href="https://doi.org/10.3390/su14052643">https://doi.org/10.3390/su14052643</a>	O artigo investiga o potencial do blockchain para melhorar a transparência e eficiência em organizações de manutenção, reparo e revisão (MRO) na aviação.	A adoção do blockchain pode transformar as operações MRO, promovendo sustentabilidade e confiança no setor.
50 Ahmed Abbasi. (n.d.). SkyLink: Blockchain-based solutions for aviation and aircraft management. GitHub. Retrieved March 16, 2025, from <a href="https://github.com/alcompilor/skylink">https://github.com/alcompilor/skylink</a>	O projeto SkyLink propõe soluções baseadas em blockchain para gestão de aviação e aeronaves, visando maior segurança e eficiência operacional.	A integração do blockchain na aviação pode revolucionar a gestão de dados e processos do setor.
51 Adil, R., Kvamsdal, T., Johannessen, K., San, O., Kölle, K., Giæver Tande, J. O., Barstad, I., Benhamou, A., Firlé, A.-L., Fjeldly, A., Froyd, L., Gleim, A., Meißner, C., Nygård, G., Rasmussen, T., & Rishoff, E. (2023). <i>Digital twins</i> in wind energy: Emerging technologies and industry-informed future directions. arXiv. <a href="https://doi.org/10.48550/arXiv.2304.11405">https://doi.org/10.48550/arXiv.2304.11405</a>	O estudo discute o uso de <i>digital twins</i> na energia eólica, destacando tecnologias emergentes e direções futuras para o setor.	<i>Digital twins</i> têm potencial para transformar a eficiência e a manutenção de turbinas eólicas.
52 Johansen, S. S. (2018). Development of a <i>digital twins</i> for fault detection in offshore wind turbine transmission systems [Master's thesis, Norwegian University of Science and Technology, Department of Marine Technology]	A tese aborda o desenvolvimento de um <i>digital twin</i> para detecção de falhas em sistemas de transmissão de turbinas eólicas offshore.	A tecnologia de <i>digital twins</i> pode melhorar a confiabilidade e manutenção de turbinas eólicas offshore.
53 Kjelland, M. B., & Hansen, M. R. (2015). Offshore wind payload transfer using flexible mobile crane. <i>Modeling, Identification and Control</i> , 36(1), 1–9. <a href="https://doi.org/10.4173/mic.2015.1.1">https://doi.org/10.4173/mic.2015.1.1</a>	O artigo estuda a transferência de cargas em parques eólicos offshore utilizando guindastes móveis flexíveis.	A abordagem proposta aumenta a eficiência e segurança nas operações de transferência de cargas.
54 Ozbek, M. (2022). An innovative structural damage detection system for preventive maintenance of wind turbines. <i>Arabian Journal for Science and Engineering</i> , 47(12), 13623–13637. <a href="https://doi.org/10.1007/s13369-022-07171-z">https://doi.org/10.1007/s13369-022-07171-z</a>	O estudo apresenta um sistema inovador para detecção de danos estruturais em turbinas eólicas, visando manutenção preventiva.	A tecnologia proposta pode prolongar a vida útil e melhorar a confiabilidade das turbinas eólicas.
55 Kandemir, E., Hasan, A., Kvamsdal, T., & Alaliyat, S. A. (2024). Predictive <i>digital twin</i> for wind energy systems: A literature review. <i>Energy Informatics</i> , 7, Article 3. <a href="https://doi.org/10.1186/s42162-024-00373-9">https://doi.org/10.1186/s42162-024-00373-9</a>	O artigo revisa o uso de <i>digital twin</i> preditivos para otimizar a operação e manutenção de sistemas de energia eólica.	<i>Digital twins</i> preditivos são ferramentas promissoras para aumentar a eficiência e confiabilidade na energia eólica.
56 Klarian. (n.d.). Intelligent turbines. Klarian. Retrieved November 1, 2023, from <a href="https://klarian.com/platform/intelligent-turbines">https://klarian.com/platform/intelligent-turbines</a>	A Klarian apresenta turbinas inteligentes que utilizam tecnologias avançadas para melhorar a eficiência e o desempenho energético.	As turbinas inteligentes representam um avanço significativo para a geração de energia sustentável e eficiente.

Tabela 2.16: Sumário dos artigos científicos mais citados- Parte 7

Referência	Resumo	Conclusões
57	Xu, X., Lu, Y., Vogel-Heuser, B., and Wang, L. (2021). Industry 4.0 and Industry 5.0—Inception, conception and perception. <i>Journal of manufacturing systems</i> , 61, 530-535.	Argumentam que a transição da Indústria 4.0 para a Indústria 5.0 apresenta uma evolução significativa que não apenas incorpora tecnologias avançadas, mas também prioriza a colaboração entre humanos e máquinas, visando um futuro mais sustentável e centrado no ser humano na manufatura.
58	Müller, J. (2020). Enabling Technologies for Industry 5.0: Results of a workshop with Europe’s technology leaders. Directorate-General for Research and Innovation.	Destaca as tecnologias essenciais identificadas por líderes da indústria europeia para impulsionar a Indústria 5.0, focando em como essas inovações podem promover a colaboração humano-máquina e a sustentabilidade no setor manufatureiro.
59	Drexel University, College of Computing and Informatics. (n.d.). Group-8 Aircraft Predictive Maintenance Project (INFO T780: Applied Machine Learning). <a href="https://github.com/archd3sai/Predictive-Maintenance-of-Aircraft-Engine">https://github.com/archd3sai/Predictive-Maintenance-of-Aircraft-Engine</a>	O projeto demonstra a viabilidade da análise preditiva para estender a vida útil dos motores, com resultados relevantes em ambientes educacionais e práticos.

Tabela 2.17: Sumário dos artigos científicos mais citados - Parte 8

## 2.4 Conceitos básicos de gestão da manutenção industrial

A palavra “manutenção” surgiu com uma procedência marcada pelo vocabulário com o sentido de “manter, nas unidades de combate, os efectivos e o material num nível constante.” Entretanto, apenas em cinco décadas as organizações começaram a aceitar a importância da manutenção como função independente e exata [25].

Em seguida, a mecanização das máquinas na Primeira Revolução Industrial fez aumentar cada vez mais a necessidade da reparação das máquinas, no qual eram os próprios operadores responsáveis por reparar as máquinas. Apenas a partir da Primeira Guerra Mundial, que a indústria estabeleceu os padrões mínimos de produção, o que levaram a constituição de equipas especializadas em consertar as máquinas que ocorriam falhas em menor tempo possível realizando as denominadas manutenções corretivas [25].

Na época que antecedeu a Segunda Guerra Mundial, a produção em massa e o cenário internacional forçaram uma produção cada vez maior, assim as organizações procuraram não apenas corrigir falhas, mas evitar a ocorrência delas. Assim abrangeu-se o tema sobre manutenção industrial, que passou a atuar na prevenção de anomalias [25].

A partir dos anos 40, a expansão do ramo da aviação trouxe mais desafios, no qual

obrigou a melhorar a prevenção de falhas e aumentou significativamente o problema da segurança de pessoas e bens [25].

Assim surge a Engenharia da Manutenção, no qual cria-se processos científicos de manutenção preventiva com objetivo em aumentar a fiabilidade dos equipamentos. Ao longo dos anos 60, desenvolve-se processos mais elaborados de análise e controle de fiabilidade, e adiciona-se modelos matemáticos e estatísticos para a análise da manutenção [25].

Em seguida, surge a área da microeletrônica, no qual permite a utilização de instrumentos digitais de alta precisão para medir parâmetros de funcionamento e realizar diagnósticos cada vez mais precisos e preditivos das possíveis avarias [25].

Assim, surgem os conceitos de “manutenção condicionada” e “manutenção preditiva” [25].

## 2.5 Definição da Manutenção

O uso da palavra manutenção, de acordo com o no Dicionário Merriam Webster Collegiate significa "manter em um estado existente (como de reparo, eficiência ou validade): preservar falhas ou declínio."Noutra definição diz "sustentar contra oposição ou perigo: sustentar e defender"[26].

Mas o termo manutenção é definido na [27] em Terminologia da Manutenção como a combinação das ações técnicas, administrativas e de gestão, durante o ciclo de vida de um bem, no qual é destinado a manter ou repor em um estado no qual ele possa desempenhar a sua função requerida.

O autor [28], descreve que o principal objetivo da manutenção é a otimização do ciclo de vida total dos ativos, o que significa maximizar a disponibilidade e a fiabilidade dos ativos e dos equipamentos, para produzir a quantidade desejada de produtos com as especificações e qualidades exigidas de uma maneira oportuna. Além disso, esse objetivo precisa ser alcançado de uma maneira rentável e que esteja de acordo com a segurança e a regulamentação ambiental.

De acordo com a Norma Portuguesa 13306 [27] em Terminologia da Manutenção, a gestão da manutenção são todas as atividades que determinam os requisitos da manutenção, os objetivos, estratégias e as responsabilidades, e a implementação destas por meios diversos, como o planeamento, o controle e a melhoria das atividades de manutenção e dos aspectos económicos.

Para satisfazer os clientes, uma organização deve responder rapidamente à manutenção dos seus produtos durante todo o seu ciclo de vida útil. Em ligação com isso, visualiza-se a gestão do ciclo de vida do produto como um novo conceito relacionada com a gestão da manutenção, mas focado na manutenção dos produtos vendidos aos

clientes. A mesma ideia transformou-se em gestão de ativos no que diz respeito aos nossos ativos físicos, que são utilizados para proporcionar valor às empresas [19].

É como objetivo expor a organização e aos clientes a riscos mínimos (sejam financeiros, de mercado, operacionais, ambientais ou de segurança), portanto segue-se teoricamente que gerenciar falhas e suas consequências resultam na entrega de tempo de atividade. O tempo de atividade permite um desempenho que atende ou excede os níveis desejados de produção, qualidade, velocidade, serviço, pontualidade e consumo de recursos [19].

A manutenção e a gestão de ativos são agora reconhecidas como disciplinas empresariais com “sociedades científicas” e programas educativos, vários deles ao nível de graus avançados, como os de outras profissões [19].

“A missão do departamento de manutenção é fornecer ativos físicos e ambientes confiáveis e seguros, além de excelente suporte para seus clientes, reduzindo e eventualmente eliminando a necessidade de serviços de manutenção” [26].

## 2.6 Tipos de manutenção

Há diversos tipos de manutenção e cada uma deve ser implementada de acordo com a estratégia ideal considerada e utilizada pelas organizações. De acordo com a Norma Portuguesa 13306 [27] em Terminologia da Manutenção, há um quadro para os diversos tipos de manutenção, apresentada na figura 2.3.

A manutenção é dividida em duas principais: A manutenção preventiva, que ocorre antes de detectar a falha e a manutenção corretiva, depois de detectar a falha [27].

Na manutenção preventiva é necessário tomar decisões para medidas específicas de forma a prolongar a vida útil do equipamento e detectar falhas iminentes. O foco é a investigação dos pontos críticos de desgaste para que as quebras sejam adiadas o máximo possível, e os reparos ou substituições sejam feitos antes que ocorram falhas [26].

A manutenção preventiva é efetuada de maneira que seja possível avaliar e finalizar a degradação, reduzindo a probabilidade de falha. Na manutenção preventiva, há ainda duas ocorrências, a manutenção condicionada e a manutenção sistemática [27].

Segundo a Norma Portuguesa 13306 [27], a manutenção condicionada ocorre com a avaliação das condições físicas, análises e com a possibilidade de ações de manutenção decorrentes, com a observação de degradação do equipamento. A condição da máquina pode ser avaliada através da observação do operador, de inspeção, teste ou monitorização dos parâmetros do sistema. Alguns autores abordam a manutenção condicionada como manutenção preditiva e que também será citado ao longo do tra-

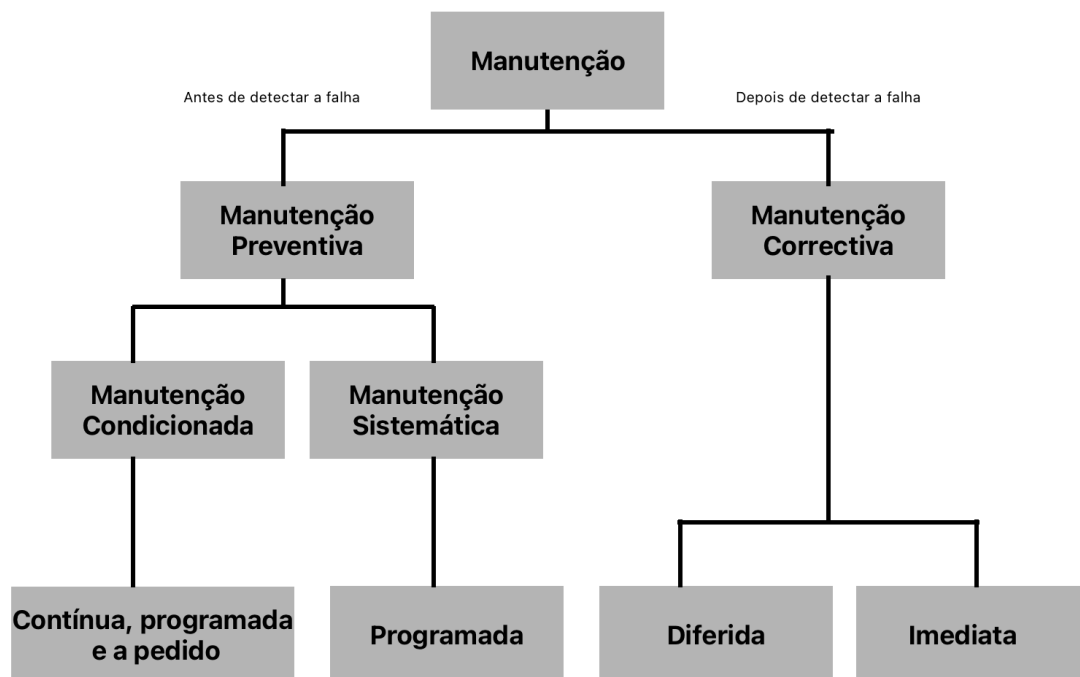


Figura 2.3: Tipos de manutenção. Fonte: [27]

balho.

Enquanto a manutenção sistemática ocorre sem a observação de degradação no equipamento, mas efetuada a intervalos de tempos preestabelecidos [27].

Além disso, há a manutenção corretiva que é efetuada após a detecção de avaria e ocorre de forma a repor um bem em um estado que ele pode realizar a função requerida [27].

Na manutenção diferida, não ocorre imediatamente quando é detectado a avaria, mas é feita de acordo com as regras específicas da organização [27].

Na manutenção imediata, ela é efetuada imediatamente após a detecção da avaria, de maneira que evite-se consequências à organização [27].

Em algumas indústrias, o cenário de falha com manutenção corretiva pode ser a melhor maneira de operar, caso o equipamento tenha baixo valor e pode ser substituído de forma barata e rápida, ou onde haja baixa necessidade de produção e baixo requisito de qualidade, assim torna-se uma alternativa de baixo custo [26].

Entretanto, o cenário de falhas tem consequências e normalmente o ambiente é caótico e cheio de perturbação para manter a produção. Além disso, o nível de segurança (incidentes por 100.000 horas de operação) pode ser maior do que em uma empresa com implementação da manutenção preventiva, seja do mesmo tipo e tamanho. Os funcionários tendem a se esgotar, mas frequentemente as organizações come-

çam nesse cenário quando são pequenas e infelizmente, a maioria permanece com essa curva enquanto reage ao que acontece. As falhas constantes nos equipamentos cria os cronogramas para a produção e a mão de obra para manutenção [26].

Segundo Levitt [26], o equipamento terá uma vida útil maior com a manutenção preventiva, mas exige dinheiro, reflexão e gestão. Muitas organizações não estão dispostas a comprometer o dinheiro ou o talento gerencial para tal objetivo. Outro fator importante a analisar é que tanto na manutenção preventiva quanto na manutenção preditiva é que eles exigem investimento constante de mão de obra e materiais.

A manutenção preditiva é basicamente uma forma de visualizar os dados e tomar decisões, isto significa que qualquer instrumento que pode ser utilizado para prever como equipamentos utilizados em inspeções como voltímetros, megômetros e instrumentos de medições são técnicas preditivas que devem ser listadas e controladas por um sistema de manutenção preventiva [26].

Entretanto, não é apenas utilizar o equipamento que evitará falhas, mas aplicar técnicas que seja possível identificar a curva de desgaste crítico e prever a vida útil do equipamento [26].

A manutenção preditiva tem uma tênue diferença com a manutenção preventiva. Na manutenção preditiva compara-se a leitura com algum limite ou com uma leitura da engenharia, como por exemplo, a instrução é "sempre relatar o ativo quando estiver 20 graus *Celsius* acima do ambiente, ou quando a velocidade da vibração exceder 0,3 IPS". Já na manutenção preventiva é relatado quando o ativo parece estar aquecendo demais ou vibrando muito [26].

A confiabilidade na manutenção preditiva é através da detecção da deterioração antecipada, mais cedo do que poderia ser detectada de maneira manual. Assim, os profissionais têm mais tempo para intervir antes de ocorrer a falha. Assim, se for necessário a ação corretiva, logo, pode-se incluir a encomenda de peças, materiais, ter o planejamento e agendamento do tempo de inatividade e da mão de obra necessária, indicando menores chances de um evento não programado acontecer [26].

A manutenção tem utilizado ferramentas de outras áreas como a medicina, química, física, automobilística, aeroespacial e outros. Nos quais são utilizados técnicas avançadas que incluem todos os tipos de análise de óleo, ferrografia, análise química, varredura de temperatura por infravermelho, magnaflux, análise de vibração, teste de motores, imagens ultrassônicas, medição de espessura ultrassônica, medidores de pulso de choque e inspeção visual avançada, e outros [26].

Essas tecnologias são inventadas ou melhoradas onde há riscos altos para os envolvidos. Algumas das fontes frequentes são o militar com análise de óleo e infravermelho, a medicina com o uso de ultrassom e câmeras miniaturas e usinas nucleares com todos os tipos de testes não destrutivos [26].

De acordo com o livro RCMII de John Moubray, publicado pela *Industrial Press* as tecnologias de manutenção preditiva são agrupadas em torno da detecção de deterioração nos seis efeitos: Dinâmico (vibração), partícula (ferrografia), químico (análise de água), físico (detecção de fissuras), temperatura (infravermelho) e elétrico (monitoramento de corrente)[26].

## 2.7 Indicadores de Desempenho

As métricas e indicadores de desempenho (em inglês, *Key Performance Indicators*, com sigla KPI) são utilizados para medir o desempenho de uma empresa, função ou até mesmo grupo de trabalho. Essas medidas devem refletir os objetivos gerais da organização e, geralmente, devem ser concretas e mensuráveis [26].

O objetivo básico do KPI é identificar qual o melhor indicador chave para medir o que está acontecendo em determinada área. Os KPI's podem ser com propósitos estratégicos como o lucro, operacionais para uma unidade de negócios como o tempo de inatividade de uma planta ou até mesmo pessoais como o tempo de atividade de uma máquina individual. As medidas são escolhidas para analisar e quantificar o desempenho de uma unidade para que possa ser medido, exibido e gerenciado [26].

Os indicadores podem ser quantitativos apresentados com números; os direcionais que especificam se uma organização está se desenvolvendo ou não, e normalmente são utilizados para sistema de manutenção preventiva ou implementação de CMMS; há também os indicadores acionáveis, no qual estão sob o controle de uma organização para realizar mudanças e os financeiros são utilizados ao analisar os índices operacionais [26].

Para verificar a qualidade dos KPI's, a Universidade da Califórnia e o Departamento de Energia dos Estados Unidos aplicaram o acrônimo SMART para desenvolver seus indicadores. Cada letra do SMART representa uma análise. A letra "S" é específica: a medida precisa ser clara e objetiva, para evitar suposições; "M" é mensurável: permitindo que seja quantificado e que permita análises estatísticas significativas; "A" é alcançável: precisam ser métricas que possam ser obtidas; "R" é relevante: a medida deve ser importante para a organização; T é oportuno, a tempo: deve ser coletada em um prazo que permita análises e ações significativas [26].

Além disso, eles avaliaram a qualidade das métricas e realizaram uma série de questionamentos sobre os indicadores, como:

- A métrica é mensurável?;
- Possui uma apresentação clara dos resultados esperados?;
- A métrica apoia os requisitos dos clientes, como questões de conformidade?;
- Foca na eficácia e/ou na eficiência do sistema que está sendo medido?;

- Permite uma análise estatística ou tendência?;
- Foram aplicados padrões industriais ou externos que são regularmente apropriados?;
- A métrica tem marcos e indicadores para apontar critérios qualitativos?;
- As métricas são desafiadoras, entretanto são alcançáveis?;
- As premissas e definições estão especificadas para obter um desempenho satisfatório?;
- Os responsáveis pelo desempenho foram envolvidos no desenvolvimento da métrica?;
- A métrica foi acordada por você e seus clientes?

De acordo com Levitt [26], há algumas medidas diretas que são recorrentes em atividades de manutenção preventiva, como:

- Conformidade com a manutenção preventiva: É analisado um gráfico de tendência que é gerado todo mês para acompanhar a degradação e a prioridade da manutenção;
- Número de tarefas de manutenção preventiva ou preditiva completas/ Número de tarefas de manutenção preventiva ou preditivas agendadas: É uma razão medida em ordens de serviços ou em tarefas de cada ordem de serviços realizadas;
- Medição bruta de manutenção preventiva: Mede quanto manutenção preventiva é feita em comparação com as horas totais.
- Razão das Horas de Manutenção Preventiva: É uma razão medida por horas padrão completas no período/ total de horas trabalhadas no período. Esse valor é igual a um porcentagem de manutenção preventiva.
- Relatório de falhas: É um documento que consta as falhas que ocorrem em determinado período, normalmente é calculado o MTBF (tempo médio entre falhas) com informações de MTTR (tempo médio para reparo).

Para [26] há também as medidas indiretas da manutenção preventiva, como:

- Trabalho Planejado/Programado versus Não Planejado/Fora do Cronograma: Uma análise feita normalmente para observar as ocorrências da manutenção preventiva. Normalmente são utilizados os seguintes indicadores em um gráfico de pizza para calcular as horas da manutenção preventiva: horas de emergência, horas DIN (quebra – faça agora), horas de reparo curto, horas de manutenção corretiva, horas de manutenção proativa.
- Trabalho planejado e programado versus o trabalho não programado (trabalho emergente): O trabalho planejado e programado é calculado com a somatória das horas da manutenção preventiva, horas da manutenção corretiva, horas de

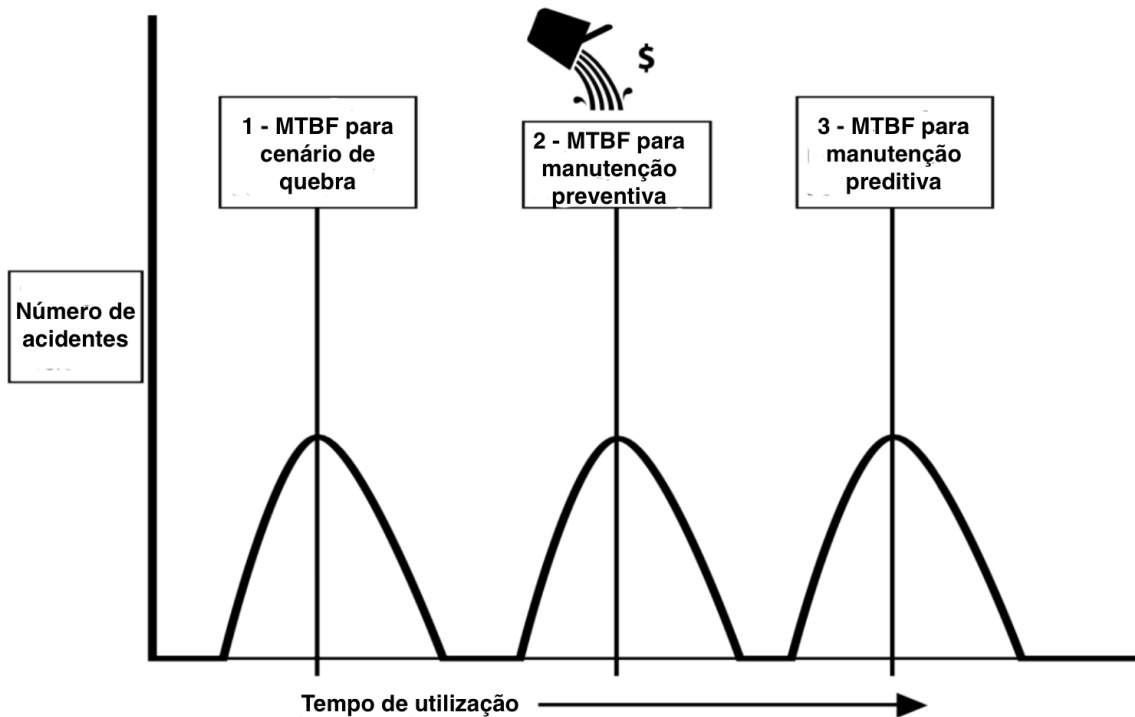


Figura 2.4: Gráfico de número de indidentes versus tempo de utilização [26].

reparo curto, horas da manutenção proativa e as horas do projeto. Enquanto o trabalho não programado é a somatória das horas DIN e das horas de emergência. Essa razão demonstra o quanto a organização é dominada por eventos não programados e as análises de tendências desses números fornecem uma noção se há melhoria.

- Total de Pendências por Ofício (em horas, semanas por pessoa): Os números de pendências são essenciais para executar um esforço de manutenção eficiente. Quando um programa de manutenção preventiva é instalado, o total de pendências normalmente deve disparar e, conforme as equipes lidam com itens adiados, as pendências caem semana a semana e se estabilizam em um nível mais baixo.
- O *Mean Time Between Failures (MTBF)* é um indicador de desempenho que representa o tempo médio entre falhas em um equipamento. É um indicador importante para a análise dos gestores da manutenção, porque com esta informação é possível acompanhar a saúde do equipamento e o seu ciclo de vida.

A figura 2.4 demonstra três maneiras de realizar o gerenciamento dos ativos físicos. O eixo x representa o tempo ou utilização do ativo, e à medida que você vai para a direita, mais tempo passou e mais o produto foi utilizado [26].

O eixo y ilustra o número de quebras ou falhas no equipamento. Quanto mais quebras acontecem, mais alta é a curva. A primeira falha está no lado esquerdo da curva, enquanto a última quebra está ao lado direito da curva [26].

Ao observar a figura 2.4, o primeiro cenário possui um tempo reduzido de utilização, no qual demonstra a primeira curva e identifica-se que ocorreram as primeiras falhas, normalmente ocorrem em manutenções corretivas. No segundo cenário tem-se o tempo médio entre as falhas após um maior período de utilização, portanto considera-se a implementação de manutenção preventiva. No caso do terceiro e último cenário, com o maior tempo de utilização do equipamento e maior MTBF, considera-se a implementação de manutenção preditiva.

Nenhuma melhoria permanente surgirá de uma orientação tradicional de manutenção preventiva. Quando reduz e a manutenção preventiva é adiada, a curva MTBF volta à sua antiga frequência de falhas. Portanto, a terceira curva (a curva de melhoria da manutenção) deve ser a prioridade do departamento de manutenção [26].

A melhoria contínua através da manutenção preditiva na prestação de serviços é o novo objetivo das organizações. A maior parte do tempo, dinheiro e esforço de gestão precisam ser direcionados para a reduzir a mão de obra, peças, utilidades e custos indiretos ou para o aumento do tempo de atividade [26].

## **2.8 Estratégias de melhorias para manutenção**

Gerir uma infraestrutura física de um negócio refere-se a execução na estratégia da gestão de ativos e a manutenção é apenas uma parte imprescindível dessa estratégia geral. As táticas são as escolhas que o gestor tomará para implementar a estratégia e gerenciar as pessoas, os processos e a infraestrutura de ativos que fazem parte do negócio [19].

As empresas que são bem-sucedidas em suas respectivas áreas normalmente aplicam os princípios de liderança e podem até alcançar um nível de excelência na execução das tarefas essenciais, constatando que de forma consistente aumenta significativamente o lucro. Essas organizações estão atentas a liderança e aspectos essenciais, colocando a excelência como prática diária. O sucesso na execução da manutenção depende em grande parte da organização em motivar seus colaboradores e este é um fator essencial para determinar o quão longe e com qual rapidez a empresa se desenvolve em busca da melhoria contínua e conseqüentemente da sua sustentação [19].

Líderes reconhecem que o segredo para o sucesso da organização está nas pessoas e na proatividade, compreendem que a mudança só será durável quando promovida por colaboradores motivados. Assim, essas pessoas implementaram estratégias bem aprimoradas quando tiveram participação na sua concepção, no desenvolvimento, se puderem trabalhar em um ambiente colaborativo para a execução e se os resultados ajudarem a alcançar os objetivos [19].

De acordo com Campbell [19], a Pirâmide da Excelência é uma das estratégias



Figura 2.5: A Pirâmide da Excelência. Fonte: [19].

gerais utilizadas em práticas de negócios bem sucedidos, como pode-se visualizar na figura 2.5. É uma abordagem para guiar as escolhas sobre a gestão da manutenção em uma organização.

É imprescindível abranger os dois níveis inferiores: Liderança e Essenciais. Ao obter no mínimo um nível de competências dessa pirâmide melhora a capacidade de sobrevivência como gestor da manutenção em um rigoroso ambiente empresarial e posiciona-se para a melhoria contínua no nível superior. Entretanto, se o objetivo for um desempenho superior, é adotar pelo menos um dos métodos no terceiro nível, adotando a excelência, a chave para a transição das competências [19].

Na área da gestão da manutenção, a estratégia normalmente estende-se às escolhas táticas das possibilidades em gerenciar ativos físicos específicos. Como por exemplo, a decisão de qual método de manutenção utilizar, a preventiva ou a preditiva, são estratégias de manutenção para um equipamento específico [19].

Segundo Campbell [19], para obter uma boa estratégia empresarial é importante ter alguns elementos, como: conhecer o negócio, seus produtos, serviços e os clientes; ter uma avaliação do ambiente regulatório/político, econômico, social, tecnológico e financeiro; descrição da visão futura do negócio, com metas apoiadas para motivar e estimular os colaboradores; possuir uma declaração de missão com o que quer fazer, os princípios orientadores, principais objetivos a serem alcançados e o plano de negócio para atingir os resultados; além da compreensão com o ambiente interno da empresa

com as restrições e facilitadores e como tratá-los.

De acordo com Karacharovskii [20], há três princípios básicos de gestão do conhecimento que são implementados para o desenvolvimento de produtos: Mídia e marketing para projetar o consumo dos grupos-alvo; A utilização de ferramentas e intermediação de inovação organizacional que permite um maior controle sob a oferta e demanda, para obter bens e serviços com alto potencial comercial e estrutura informacional e tecnológica dos sistemas de gestão que devem ser usados para planejar os recursos de uma empresa, gerenciar as cadeiras de abastecimento e interagir com os clientes.

De acordo com Campbell [19], a manutenção é baseada no modelo da estrutura apresentada a seguir na figura 2.6. No topo do plano de negócio estarão os objetivos dos clientes, acionistas e os *stakeholders*. Os objetivos-chave são elaborados com o foco neles. Para a implementação da manutenção em indústrias, de forma geral, as metas e alvos serão baseados nos seguintes padrões:

- Maximizar a taxa de produção de um produto por meio do aumento da confiabilidade, como elevar a disponibilidade de 93% para 96%.
- Reduzir os custos por unidade de produção ao realizar apenas a quantidade mínima necessária de manutenção segura, como diminuir os custos de manutenção por tonelada de concentrado de \$42 para \$35 de forma segura.
- Ampliar a capacidade produtiva de uma planta adicional fornecendo orientações à equipe de design, como aumentar a disponibilidade da linha de produção de 90% para 97%.
- Diminuir os estoques de armazém por meio de parcerias de inventário gerenciado pelo fornecedor, aumentando a manutenção preditiva e preventiva e reduzindo drasticamente o trabalho emergencial, como diminuir o valor do inventário de armazém em 25% enquanto mantém níveis de serviço de armazém de 95%.
- Incentivar a melhoria da qualidade através da aplicação de manutenção de precisão em todos os ativos de produção, como introduzir técnicas de alinhamento a laser para aumentar a confiabilidade dos equipamentos rotativos, eliminando todos os defeitos de qualidade causados por desalinhamento durante a instalação ou reparo.

As falhas que podem ocorrer em um projeto de inovação é devido a multiplicidade de riscos característicos ao processo do desenvolvimento do projeto, porque é um conjunto de etapas que acontecem muitas interações e dependências nos processos. Normalmente também pode haver a criação de produtos ou serviços que nunca foram realizados antes, e desta forma, se não for bem implementado, pode trazer prejuízos ao processo [29].

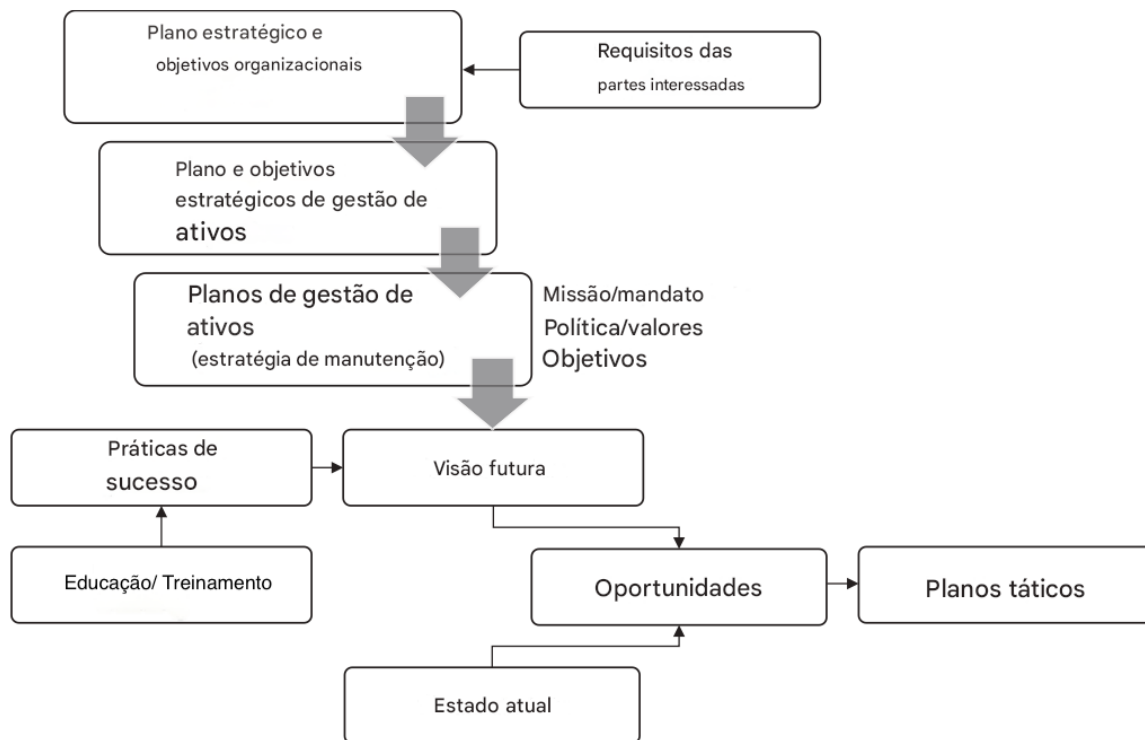


Figura 2.6: Estratégia de manutenção baseada no modelo de estrutura. Fonte: [19].

Uma estratégia de manutenção deve permanecer flexível. Se a situação da empresa mudar, a estratégia de manutenção também mudará. Por exemplo, se uma empresa fechar capacidade excedente, faz pouco sentido continuar a manter plantas que serão desativadas [19].

A estratégia de manutenção precisa ser flexível. Caso a situação da empresa mude, a estratégia também deve se ajustar. Um exemplo claro dessa situação é se uma empresa decide fechar a capacidade excedente, não faz sentido continuar mantendo instalações que serão desativadas [19].

Segundo Campbell [19] a estratégia é o fundamento para uma implementação tática, já que proporciona uma direção geral e clara. A estratégia é composta pelos seguintes componentes conforme a tabela 2.18:

Para desenvolver uma estratégia é necessário envolver equipes multifuncionais, com operações, cadeias de abastecimento, relações humanas, departamentos de treinamento, finanças, contabilidade, gerentes de plantas e outros. Além disso, é fundamental que a estratégia desenhada esteja vinculada à estratégia da corporação, caso contrário, é trabalhar em objetivos com esforços opostos [19].

É importante também integrar a pessoa que realiza a revisão da manutenção na estratégia, já que conhece os problemas e os objetivos. Após a revisão da manutenção ter sido realizada, é realizado o esforço para o desenvolvimento da estratégia [19].

Tabela 2.18: Componentes da estratégia para uma implementação tática

Componente	Interpretação	Exemplo
Missão	Uma declaração que explica a razão da finalidade, deve ser clara e ter um propósito comum para a organização.	Colaborar com a produção para assegurar a capacidade de produção requerida, de maneira estável e segura.
Visão	A declaração deve estar presente e explicando o que está tentando alcançar com a estratégia. Caso seja necessária a implementação de melhorias, é importante descrever o padrão que deseja alcançar.	“Ser reconhecido como o líder de mercado em inovação tecnológica e excelência em serviço ao cliente”.
Tática	O planejamento deve ser implementado para colocar em prática os processos.	Implementar RCM ou manutenção produtiva total (TPM).
Prazo-alvo	É preciso deixar claro quando precisa-se alcançar a visão. Uma data única e realista de conclusão para que as equipes trabalhem em direção aos resultados.	Os sistemas de produção críticos terão programas de manutenção de RCM em um prazo máximo de 2 anos.
Valores	Regras simples que deverão ser seguidas na implementação das táticas. Essas regras devem refletir os valores corporativos para o comportamento quando a visão for alcançada e como serão guiadas ao longo do caminho. As regras devem ser fáceis de serem lembradas.	Cuide de si mesmo. Cuide uns dos outros. Cuide do equipamento. Cuide dos negócios.

É indispensável ter planos de implementação para acompanhar a estratégia, entretanto, não é preciso incorporá-los à declaração estratégica. Eles devem ser gerenciados de forma independente, assim como qualquer outro projeto. Além disso, não desenvolver estratégias com planos de implementação muito longos, é recomendável planejar um por ano, realizar revisões anuais do projeto, determinar quais são as alterações do plano original e adicionar os detalhes para o próximo ano [19].

Uma das partes mais importantes para a implementação da estratégia é uma ligação clara da estratégia corporativa com a organização. Muitas vezes, os líderes dos departamentos precisarão agir onde tem controle e poderá ocorrer de não ter colaboração de outros departamentos, e geralmente iniciativas isoladas não são implementadas e corriqueiramente retornam aos mesmos hábitos anteriores [19].

Além do que, novas ideias nunca surgem dos colaboradores que estão na linha de frente porque não são consultados e frequentemente sentem-se intimidados para se destacarem. As energias não estão focadas em produzir uma nova ferramenta ou implementar novas formas de atender melhor aos requisitos do cliente, mas estão perdendo tempo, ocupadas competindo entre si ou para agradar os chefes de departamentos [19].

Assim, o ciclo vicioso permanece e novas crises surgem. Por isso, para implemen-

tar uma estratégia de forma consistente é necessário atingir os líderes corporativos até o chão de fábrica [19].

Iniciar uma mudança em uma organização com sucesso é necessário utilizar recursos adequados, sejam coisas ou pessoas. É importante ter um plano bem alinhado e acordado, para que tenha uma razão por trás das mudanças. Essas modificações precisam ser implementadas. As pessoas imaginam uma melhoria através de uma grande ideia, entretanto falham no momento de implementá-las, por isso, é importante que a organização sustente as transformações que ocorrem para ter resultados nas melhorias [30].

E um ponto essencial é a comunicação. Todos os passos do processo devem ser comunicados a todas as pessoas e devem estar de acordo para que seja bem sucedido. A comunicação eficiente envolve comunicar-se sempre, demonstrar as razões, explicar quem esteve envolvido nas mudanças e fornecer atualizações sobre os quais as mudanças ocorreram e os seus efeitos nos negócios [30].

Uma estratégia denominada por *Hoshin Kari* traduzida do japonês como gestão de direções, é um método utilizado para capturar e consolidar os objetivos estratégicos, aplicando *insights* sobre o futuro e desenvolvendo meios para tornar realidade, de modo que aconteça a cooperação entre as áreas funcionais e os membros da empresa [19].

Esse plano detalha os objetivos estratégicos e desdobra-se até o nível departamental. Assim, o *Hoshin Kari* direciona a estratégia para cada departamento específico.

De acordo com Campbell [19], o *Hoshin Kari* engloba o planejamento estratégico, gestão de mudanças e gestão de projetos com métodos de gestão de desempenho baseados nos resultados. Alguns subprocessos específicos incluem:

- Identificação de pressupostos críticos de negócios e áreas vulneráveis;
- Identificação de oportunidades específicas para melhorias;
- Ajustar metas de melhoria de desempenho para organização;
- Definir estratégias de gestão de mudança para objetivos empresariais;
- Desenvolver cartas de projeto para implementação de cada estratégia de mudança;
- Apresentar definições operacionais de medidas de desempenho para os processos;
- Conceituar medidas fundamentais de negócios desde os subprocessos até o nível operacional.
- Quando a estratégia estiver definida, o desafio é alinhar o trabalho da gestão diária com a direção estratégica.

*Hoshin Kari* é implementado através de um processo de oito etapas:

1. O primeiro passo é identificar os desafios fundamentais na gestão de ativos, considerar as estratégias empresariais de nível executivo e as anuais específicas da gestão de ativos e da manutenção.
2. Determinar quais são os objetivos empresariais e como irão lidar com os desafios e abordá-los para resolvê-los. É importante visualizar os objetivos que são mensuráveis para que a organização saiba o que deve alcançar.
3. Caracterizar a visão geral e as metas para os principais fluxos de valor da gestão de ativos.
4. Criar estratégias de suporte para seguir os objetivos. Na gestão da manutenção, essa estratégia precisa incluir projetos que compreendam o uso de métodos, técnicas e ferramentas da gestão de ativos.
5. Estabelecer táticas e objetivos que apoiam as estratégias. Em cada nível organizacional inferior, é importante que seja mais detalhado e tático, de maneira que considere o segmento específico ou elementos da gestão da manutenção que foram concebidos e implementados.
6. Elaborar medidas de desempenho (KPIs) para cada processo da gestão de ativos. Os KPIs devem ser claros, concisos, baseados no tempo, verificáveis, mensuráveis, fáceis de documentar e diagramar, com responsabilidade atribuída e compreendidos e adorados pelas partes interessadas.
7. Realizar medições, exibir e comunicar os resultados de forma visual através de gráficos ou outros meios para que a organização compreenda. Dessa forma, isso torna o progresso visível e incentiva a melhoria do desempenho.
8. Implementar o ciclo de Deming (Ciclo PDCA) com o objetivo de melhoria contínua. A etapa "Planejar (*Plan*)" consiste em estabelecer objetivos e processos para alcançar os resultados. Na etapa "Fazer (*Do*)" envolve a implementação dos processos. Na etapa de "Verificar (*Check*)", os processos são monitorados e avaliados em relação às especificações. Na quarta etapa, "Agir (*Act*)", ações são tomadas para melhorar o resultado e atender ou exceder as especificações. [19].

Como é um processo de melhoria, esse efeito é circular e deve ser aplicado em todos os processos no qual é importante acompanhar o efeito de melhoria contínua, os seus efeitos e resultados. Na figura 2.7, é possível visualizar o ciclo de Deming (Ciclo PDCA).

O processo de oito etapas do *Hoshin Kari* deve ser repetido de maneira cíclica usando o processo de *catchball*, a palavra remete a um jogo em que um círculo de crianças joga uma bola de beisebol ao redor de um círculo. Assim, descreve um processo participativo para responder questionamentos, esclarecer as prioridades, cons-

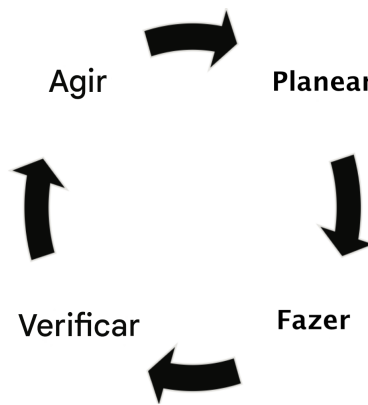


Figura 2.7: Ciclo de Deming ou ciclo PDCA. [19].

truir consenso entre os participantes e garantir que as estratégias sejam claras e realistas para alcançar os resultados [19].

Para ajudar na implementação do *Hoshin Kari*, na figura 2.8 é apresentado a Matriz de Hoshin Kanri.

O relacionamento da matriz é diferente, sendo importante equilibrar os esforços de melhoria. Entretanto, é importante vincular as estratégias que serão implementadas com os objetivos de melhorias relacionados aos objetivos principais. É imprescindível ter um fio condutor bem definido e claro. Garantindo que as estratégias de implementação vão impactar as áreas de foco de melhorias. Como por exemplo, uma estratégia de implementação que impacta apenas a qualidade, mas não resulta na segurança, entrega ou no custo, pode indicar falhas e que há estratégias mais eficientes [30].

Assim, muitas organizações priorizam estratégias de implementação que afetam diversas áreas de foco para obter melhorias significativas. No entanto, se ocorrer algum problema crítico de segurança, esta deve ser a prioridade e não deve impactar nenhuma outra área de foco de melhoria. As organizações pretendem impactar múltiplas áreas de foco porque investem tempo e dinheiro na melhoria desses processos [30].

O *Hoshin Kari* também tem como elemento essencial o *Balanced Scorecard*, é considerado um modelo de gestão estratégico que é baseado em metas de melhoria contínua, utilizando equipes multifuncionais para o desenvolvimento tático à medida que o método dissemina-se nas camadas organizacionais [19]. Na figura 2.9, pode-se visualizar um exemplo de *Balanced Scorecard*.

Em relação aos objetivos várias métricas podem estar relacionadas a um objetivo central. A organização necessita listar o objetivo central para corresponder as métricas que serão apropriadas. E essas métricas podem exigir uma estratégia de implementação diferente. Como por exemplo, se o objetivo principal é melhorar o retorno financeiro, isso pode ser medido através da produtividade da mão de obra ou de custos indiretos [30].

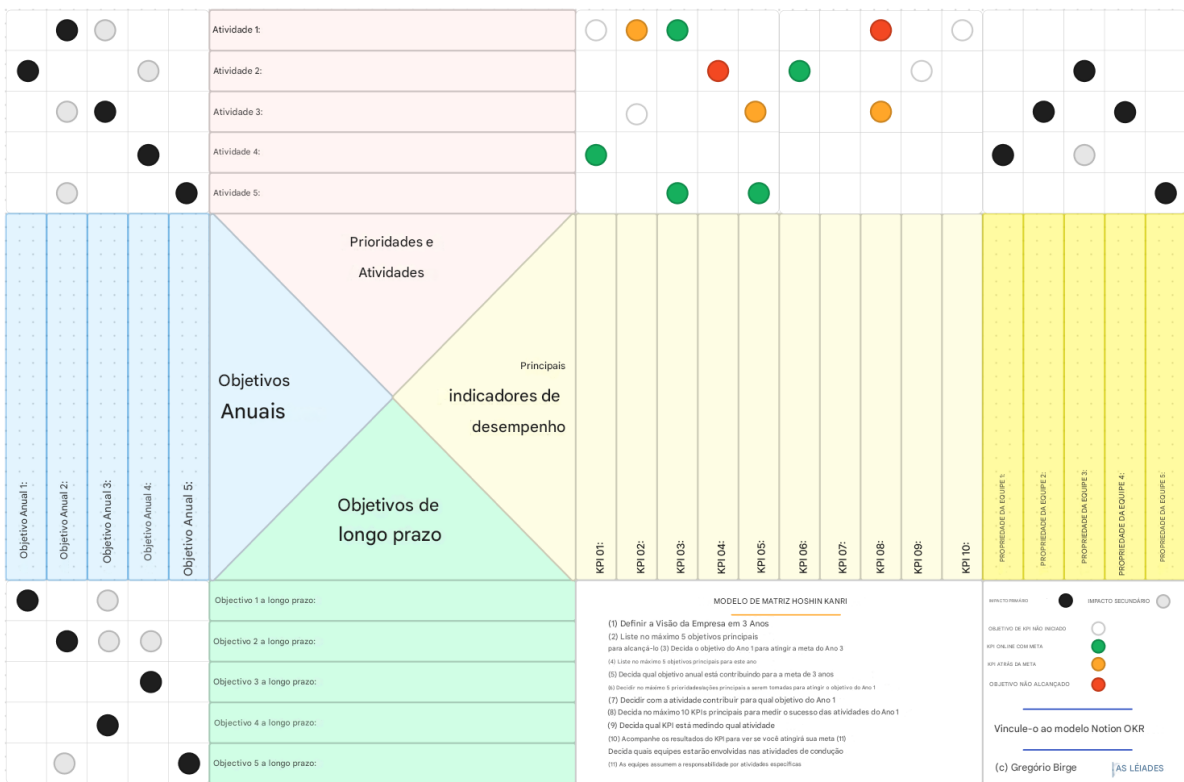


Figura 2.8: Matriz de *Hoshin Kari*. Fonte: [19].

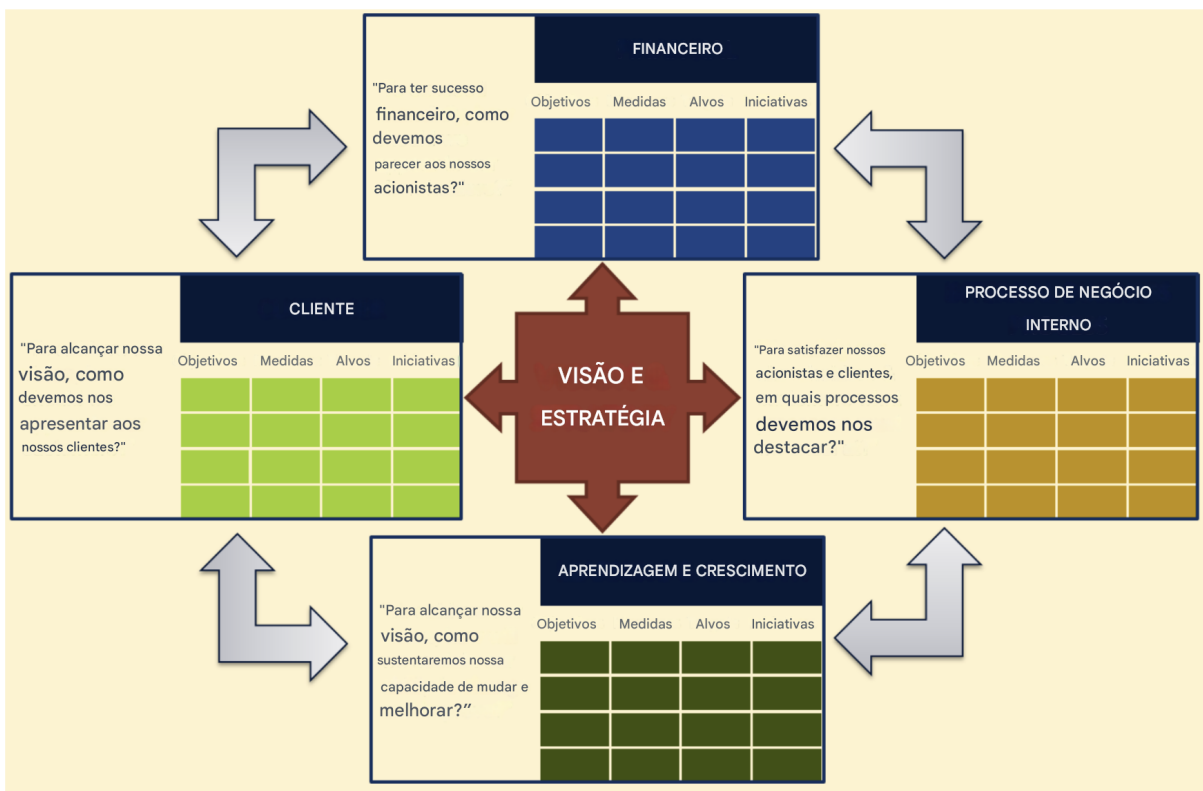


Figura 2.9: Modelo de *Balanced Scorecard*. Fonte: [19].

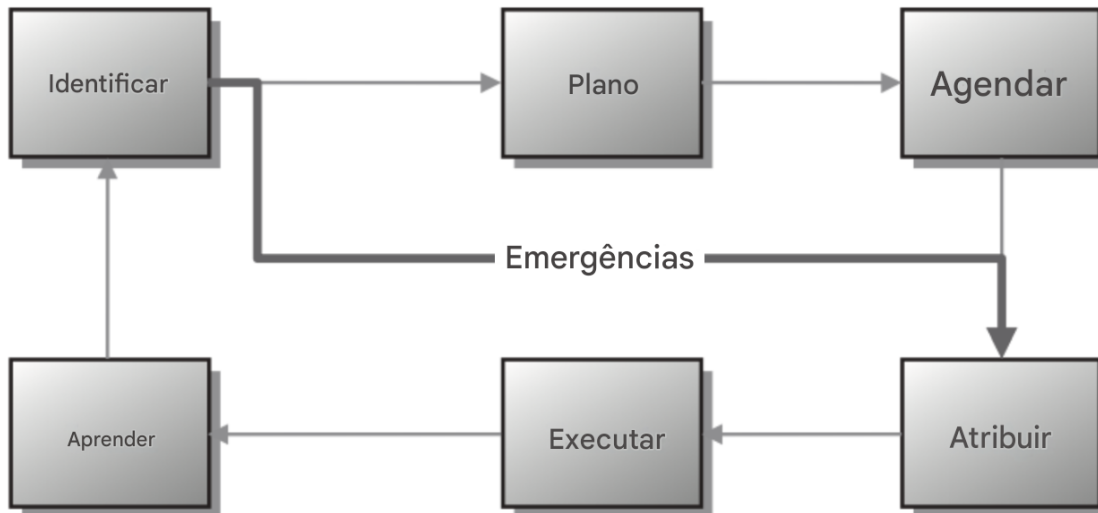


Figura 2.10: Ciclo da gestão do trabalho. Fonte: [19].

Assim, um departamento aborda a produtividade por um projeto de *Six Sigma* para melhorar a eficiência dos equipamentos (OEE) como estratégia de implementação e também utilizar da estratégia de implementação para melhorar a produtividade implementando um programa TPM. É importante que os líderes listem essas métricas para destacar que são métricas diferentes e com implementações diferentes [30].

Em [19], em organizações que têm um alto desempenho da manutenção, o principal foco é o planejamento do trabalho. Na figura 2.10, pode-se identificar o ciclo da gestão do trabalho.

Esse ciclo é formado por seis etapas:

1. Identificação: Essa é a etapa na qual geram-se ordens de serviços preventivas, preditivas ou de detecção de falhas, normalmente são identificadas nos cronogramas de manutenção ou através de relatos de operadores, como a ocorrência de falhas;
2. Planejamento: É a etapa que relata o que e como deve ser feito. Um documento é elaborado com um plano sequenciado, com descrições e desenhos, do que precisa ser feito para cada atividade. Os materiais precisam ser disponibilizados e os manuais de reparo são revisados para informações relevantes.
3. Agendamento: Após confirmar a disponibilidade de materiais e mão-de-obra, poderá ser colocado no cronograma o agendamento para o passo da execução. As atividades devem ser agendadas de modo que cause o menor impacto para o cliente. O planejador estabelece o cronograma semanal com uma demanda de trabalho com o objetivo de focar nos supervisores, enquanto este cria cronogramas diários normalmente um ou dois dias antes. Conforme a semana avança, é realizada demanda semanal e emergências que podem ocasionalmente aparecer.

O ideal é que não tenham trabalhos “inseridos” no cronograma semanal, para que o supervisor tenha flexibilidade para ajustar o cronograma. A definição de metas de um cronograma foca o time a realizar trabalhos completos mais do que o normal, além do foco da gestão para áreas que precisam de melhorias, porque identifica a lacuna entre a capacidade de trabalho e a realização do cronograma. Com um trabalho proativo, também reduz as situações de trabalho de emergências.

4. Atribuição: Os supervisores de manutenção são os responsáveis por atribuir os profissionais para as tarefas estabelecidas no cronograma. O supervisor faz um trabalho diariamente de transferir pessoas entre as tarefas, de acordo com as ausências, trabalhos de emergências ou que não podem esperar, além disso consegue ter considerações em fatores de risco ou de natureza humana, como quem trabalha bem junto ou quem trabalha melhor sozinho, quem é o mais habilidoso para determinada tarefa e outras. O supervisor tem um trabalho crítico ao determinar essas atribuições.
5. Execução: Em organizações eficientes, as equipes de trabalho realizam as tarefas com o melhor desempenho possível e por isso é importante reforçar as habilidades comerciais, a multiespecialização e o treinamento. Evitar contornar problemas apenas para cumprir cronograma, e sim fazer o trabalho da forma que precisa ser feito, para aprimorar cada vez mais a gestão da manutenção.
6. Aprendizado: Ao concluir o trabalho é imprescindível informar as operações. Quando a manutenção informa as operações que o trabalho foi concluído e o equipamento poderá ser operado. As equipes de trabalho precisam registrar o material usado, as peças utilizadas e outros dados relevantes na ordem de serviço, incluindo o feedback para os planejadores. Assim, podem encerrar a ordem de serviço fazendo qualquer melhoria necessária nos planos de trabalho para a confiabilidade. Quando encerra-se uma ordem de serviço, é uma etapa de aprendizado que a organização aprende em cada tarefa que foi executada, dessa forma, a próxima vez que for realizada, ela seja executada da melhor maneira.

A utilização dessas metodologias contribuíram com as empresas em se adaptar às transformações que ocorreram em seus ambientes, além de melhorar a competitividade e posicionar as empresas para um melhor planejamento. Entretanto, ocorrem situações que os resultados foram decepcionantes, como desperdício de recursos, perda de confiança dos gestores, frustração das equipes e o medo de realizar novas mudanças. As falhas ocorrem porque os gestores têm dificuldades em identificar, priorizar e organizar os recursos que produzem as transformações organizacionais [29].

Segundo Vasile [31], é utilizada uma análise profunda do papel das atividades da manutenção industrial para obter os cinco objetivos da gestão operacional e são conhecidos como “Os cinco zeros olímpicos”:

1. Zero avarias;
2. Zero falhas;
3. Zero estoque;
4. Zero atrasos;
5. Zero papel.

Estes objetivos de melhoria são capazes de chegar em um local ideal, entretanto considerado inacessíveis em alguns aspectos. Um dos questionamentos de Deac é se é possível “Zero avarias” na manutenção [31].

O objetivo de “zero falhas” está diretamente ligada à gestão da qualidade e a manutenção, principalmente porque um produto depende das condições da ferramenta e dos equipamentos industriais [31].

Enquanto o “zero estoque” está envolvido no processo de manutenção no caso da organização “Just in time”, no qual os estoques são significativamente reduzidos, entretanto para chegar nesse resultado é necessário uma alta fiabilidade dos equipamentos [31].

O objetivo “zero atrasos” é relevante na área da manutenção quando relacionado a duração das intervenções, com a finalidade de reduzir o máximo o período de paragens [31].

O “zero papel” está relacionado ao uso de aplicações informáticas nas atividades da manutenção e que contribuem para a redução do uso de papéis [31].

Assim, a necessidade da manutenção industrial é um resultado da tendência dos equipamentos de falharem com o tempo e diversos fatores influenciam o risco da falha. Por isto, os meios pelos quais os objetivos são alcançados dependem de várias etapas anteriores [31].

## 2.9 Sistemas de Gestão e Apoio à Manutenção

Com a evolução da ciência e da tecnologia, a automação tornou-se fundamental para as empresas. Entretanto, com a automação presente nas organizações, com o aumento na quantidade de equipamentos, resultou em uma maior frequência de falhas e da reparação dos equipamentos. O processo de manutenção e de reparo, normalmente, é difícil para uma indústria, considerando longos tempos de espera e inconvenientes de produção. Além disso, há problemas também em posicionamento impreciso e falta de julgamento baseado em conhecimento [32].

De acordo com Levitt [26], o CMMS de denominação em inglês, *Computerized Maintenance Management Information System*, com tradução para português, Sistema de Informação Computadorizado de Gerenciamento de Manutenção. O CMMS é um sis-

tema integrado que apoia a liderança da manutenção a gerenciar as propriedades desse departamento, utilizados principalmente para manutenção preventiva e preditiva.

São *softwares* desenvolvidos para auxiliar o processo de manutenção industrial. Alguns desses sistemas são simples e outros mais complexos, nos quais os preços sempre vão variar de acordo com o nível de complexidade. Quando são implementados e utilizados da forma correta, contribuem significativamente para uma gestão eficaz e que traz resultados positivos para a organização. Independente de ser simples ou complexo, esses sistemas funcionam como ferramentas de apoio, no qual não resolvem o problema por si só, nem substituem pessoas ou processos [19].

Dessa forma as plataformas CMMS são focos centrais para as atuais práticas de manutenção, na qual é possível digitalizar e automatizar fluxos de trabalho, rastreamento e na gestão dos inventários. Além de integrar o agendamento da manutenção, a gestão de ordens de serviços, o rastreamento do histórico de ativos e a alocação de recursos em um banco de dados centralizado, que seja acessível às equipes da manutenção e das partes interessadas [33].

O resultado de uma implementação será a melhoria da eficiência organizacional ao permitir que os processos de manutenção sejam mais simples e a reduzir a sobrecarga administrativa dos registros e comunicação que eram realizados manualmente [33].

A equipe responsável pela manutenção ajuda diretamente no planejamento, na priorização e na execução de tarefas de maneira eficiente com a base de dados atualizada em tempo real e com análises fornecidas diretamente pelo CMMS. Além de facilitar o cumprimento de requisitos, regulamentações e padrões da indústria, mantendo uma base de dados precisa da manutenção e com um suporte mais eficiente para auditorias [33].

O uso desse sistema e ferramentas ajudam na gestão da manutenção, tornando-as mais fácil e eficiente, permitindo liberar um tempo precioso e mostrando falhas em desenvolvimento que podem ser corrigidas antes de causarem uma interrupção completa [19].

É importante ficar claro que os sistemas não são estratégias e não funcionam de maneira independente, para uma utilização bem sucedida é importante uma estruturação da gestão para que o sistema funcione em apoio e seja um facilitador nas tomadas de decisão das organizações [19].

Segundo Campbell [19], foi realizado uma pesquisa sobre os CMMS e 50 por cento dos participantes não consideraram o ROI (*Return on Investment*, em português, Retorno Sobre o Investimento) ao implementar um sistema. 28 por cento relataram que a utilização do CMMS não atingiu o ROI esperado, enquanto apenas 22 por cento descreveram que houve uma implementação bem sucedida.

Um destaque é que a maioria das organizações vão exigir um ROI antes de financiar um sistema, mas se não houver uma boa seleção do *software*, uma ineficiente implementação e objetivos mal definidos, normalmente podem não entregar o retorno esperado. Lembrando que, o CMMS é um facilitador na gestão da manutenção e não um gerador de receita. O software não poderá fornecer ROI diretamente, ele atua como suporte [19].

Uma das primeiras atitudes para configurar o CMMS é inserir as tarefas detalhadas, no qual será necessário colocar o escopo do trabalho, ferramentas e informações especializadas, além de habilidade necessária e horas padrão [26].

Outro ponto essencial é a coleta de dados em intervalos programados para permitir a comparação entre os equipamentos instalados, os dados de fábrica e as medições anteriores. Assim, é possível analisar os dados, revelar tendências e fornecer as situações sobre as condições reais do equipamento. Após os dados serem coletados e analisados, é possível realizar uma tomada de decisão informada para substituir ou manter um equipamento [34].

Após a instalação industrial obter o seu programa, é necessário garantir que tenha todas as peças e equipes para executar testes, a manutenção e para a substituir os equipamentos. Sem pessoal capacitado, acesso aos equipamentos de testes e peças de reposição, a implementação pode ser desafiadora [34].

É imprescindível buscar equipamentos compatíveis e padronizados sempre que possível. Instalações que são semelhantes serão mais acessíveis de se manter no sistema. A importância de padronizar os equipamentos deve ser considerada durante as atualizações e substituições do sistema [34].

### **2.10 Tecnologias emergentes na implementação da gestão da manutenção**

No momento que é dito que a *internet* está na indústria, isso significa que toda a planta operacional está digitalmente conectada, seja os fornecedores, distribuidores, plantas e até mesmo o produto final. Dessa maneira, proporciona uma cadeia de valor que é altamente incorporada no meio industrial, no qual todos os equipamentos e as máquinas são conectados em redes e fornecem informações de uma forma única [18].

Para isto funcionar, é imprescindível que exista uma infraestrutura tecnológica composta por sistemas físicos e virtuais, com o objetivo de criar um ambiente benéfico para que as novas tecnologias sejam disseminadas e incorporadas pela indústria, com o suporte da tecnologia da *Big Data Analytics*, robôs automatizados, simulações, manufatura avançada, realidade aumentada e IoT, monitorando as tendências tecnológicas, auxiliando os gestores em tomadas de decisão por toda a cadeia industrial [18].

### 2.10.1 Os sensores e a Internet das Coisas

A integração da IoT permite que os dispositivos interconectados comuniquem-se e compartilhem dados através da internet, assim dispositivos que possuem IoT conectam e transmitem informações em tempo real, métricas de desempenho, status da operação e as condições do ambiente [33].

Além disso, a integração da IoT possibilita a gestão de ativos por meio da manutenção preditiva. Ao monitorar as métricas de desempenho dos ativos, os sensores detectam anomalias ou sinais de falhas antes que se transformem em avarias onerosas. Dessa forma, a abordagem proativa minimiza o tempo de inatividade não planejada, reduzindo os custos de manutenção e prolonga a vida longa desses ativos. Assim, como os sistemas de gestão de ativos habilitados por IoT ajudam na tomada de decisão que serão baseada em dados, fornecendo análises abrangentes por meio de painéis de desempenho, colaborando com as organizações em otimizar os investimentos e na alocação de recursos [33].

A Internet das Coisas na indústria possui uma camada de IoT e IIoT, que gera um modelo prognóstico, e responde a perguntas sobre o que está acontecendo, o que aconteceu e por que aconteceu, considerando a integração dos dispositivos físicos, sistemas e plataformas [18].

A Internet Industrial das Coisas possui uma camada de IoT e IIoT na indústria, provocando um modelo prognóstico, uma vez que a automação, que em geral já existe, responde a perguntas sobre o que está acontecendo, o que aconteceu e por que aconteceu, considerando sua rede de dispositivos físicos (objetos e coisas, entre outros), sistemas, plataformas e sistemas [18].

A principal diferença entre o IoT e IIoT, é que a primeira relaciona-se com os sistemas que conectam as coisas, complementam as informações, produzem dados e podem ser usados em qualquer setor industrial, enquanto a segunda transforma a gestão dos ativos e analisa as tendências de manutenção [18].

A IIoT conecta diretamente com um fornecedor dos produtos em tempo real na linha de produção, o que permite analisar a qualidade e o uso do produto, e ainda conectar a cadeia logística na entrada e saída dos materiais, controlando a produção em tempo real [18].

A utilização de IoT e IIoT proporciona diversos benefícios para plantas produtivas, como a melhoria no uso do ativo, redução de operações ou custo do ciclo do ativo, melhora a produção, além de reduzir as falhas em máquinas industriais que funcionam automaticamente através sensores inteligentes que são altamente programáveis [18].

Na manutenção industrial, os sensores habilitados para IoT são instalados nos equipamentos com a responsabilidade de monitorar ininterruptamente diversos pa-

râmetros, incluindo temperatura, vibração, pressão e umidade. Os sensores coletam dados em tempo real que são transmitidos para sistemas centralizados para análise [35].

### 2.10.2 Inteligência Artificial e *Machine Learning*

Assim, surgem soluções, ferramentas e softwares com o uso da tecnologia da IA que possuem recursos integrados e que automatizam o processo da tomada de decisão do algoritmo [18].

A *Machine Learning* (Aprendizado de Máquina) é uma aplicação da IA, no qual ela tem acesso a um grande volume de dados e aprende automaticamente com eles, sem a necessidade da intervenção humana. A *Machine Learning* tem tecnologias de processamento da linguagem natural, com redes neurais, algoritmos de inferência e *deep learning*, com a meta de alcançar o raciocínio e desempenho similares aos dos seres humanos [18].

Na manutenção preditiva essa implementação é uma mudança de paradigma em relação às abordagens tradicionais da manutenção. Isto porque, a partir dos algoritmos de aprendizado da máquina, utiliza-se os dados em tempo real provenientes dos sensores e dispositivos IoT dos ativos para detectar padrões e erros no comportamento dos ativos, permitindo assim que as equipes de manutenção prevejam as falhas antes que ocorram [33].

Dessa forma, os sistemas de manutenção preditiva que são baseadas em IA aprendem continuamente a partir dos dados, métricas de desempenho e dos fatores ambientais para gerar relatórios com previsões precisas de desempenho dos ativos. Assim, as organizações conseguem agendar atividades de manutenção de forma proativa, otimizando os recursos de manutenção e priorizando tarefas com base na urgência e criticidade da situação, resultando na melhoria da eficiência operacional geral [33].

Assim, surgem soluções, ferramentas e softwares com o uso da tecnologia da IA que possuem recursos integrados e que automatizam o processo da tomada de decisão do algoritmo.

A *Machine Learning* é uma aplicação da IA, no qual ela tem acesso a um grande volume de dados e aprende automaticamente com eles, sem a necessidade da intervenção humana. A *Machine Learning* tem tecnologias de processamento da linguagem natural, com redes neurais, algoritmos de inferência e *deep learning*, com a meta de alcançar o raciocínio e desempenho similares aos dos seres humanos [33].

Na manutenção preditiva essa implementação é uma mudança de paradigma em relação às abordagens tradicionais da manutenção. Isto porque, a partir dos algoritmos de aprendizado da máquina, utiliza-se os dados em tempo real provenientes dos sensores e dispositivos IoT dos ativos para detectar padrões e erros no comportamento

dos ativos, permitindo assim que as equipes de manutenção prevejam as falhas antes que ocorram [33].

Dessa forma, os sistemas de manutenção preditiva que são baseadas em IA aprendem continuamente a partir dos dados, métricas de desempenho e dos fatores ambientais para gerar relatórios com previsões precisas de desempenho dos ativos. Assim, as organizações conseguem agendar atividades de manutenção de forma proativa, otimizando os recursos de manutenção e priorizando tarefas com base na urgência e criticidade da situação, resultando na melhoria da eficiência operacional geral [33].

### 2.10.3 *Digital Twins* na Manutenção Industrial

*Digital Twins*, em português, Gêmeos Digitais é uma das inovações significativas na área da manutenção industrial. Segundo Anaba [35], um gêmeo digital é uma réplica virtual idêntica de um ativo, de um sistema ou de um processo físico. Criado utilizando os dados simultâneos dos sensores e de outras fontes, que permitem o espelhamento do desempenho e das condições reais do correspondente físico.

Assim, os *digital twin* podem simular e analisar o desempenho dos equipamentos, como também as necessidades da manutenção. Dessa maneira é possível que as equipes de manutenção realizem simulações detalhadas para prever como o equipamento se comporta em diversas condições. Essa tecnologia permite identificar potenciais problemas e otimizar as atividades de manutenção. Um exemplo, o *digital twin* de uma turbina pode ser utilizada para simular as diferentes condições de carga e prever os padrões de desgaste, certificando os planos de manutenção como cronogramas, substituição de peças e reparos [35].

Uma outra vantagem dos *digital twins* é a possibilidade de monitorar e ter um diagnóstico remoto. Assim, especialistas da manutenção podem acessar os *digital twins* de qualquer local, proporcionando a realização de inspeções virtuais e solucionar problemas sem a necessidade de estar em local físico. Essa possibilidade é valiosa para a manutenção de ativos em ambientes que são remotos ou perigosos [35].

Para auxiliar os *digital twins* podem ser integrados com os algoritmos de IA e ML melhorando a manutenção preditiva, fornecendo uma solução para possíveis falhas, otimizando o desempenho e aumentando a fiabilidade dos equipamentos [35].

Segundo Stadtmann [36], os *digital twins* podem ser utilizados para rastrear e analisar o presente e o passado das condições do ativo, e a partir dessa informação, detectar anomalias no ativo. Entretanto, essas condições sempre dependem das capacidades do *digital twin*, como pode-se visualizar na figura 2.11.

A escala é baseada em seis níveis, do zero a cinco:

1. Quando o *digital twin* é apenas uma representação, mas que não está sincroni-



Figura 2.11: Escala de nível de capacidades dos *digital twins*. Fonte: [36].

zado com o ativo, sendo usado apenas para design, planejamento, visualização, comunicação e alcance é considerado um nível zero.

2. Quando o *digital twin* possui uma conexão em tempo real com o ativo para representações virtuais é denominado como descritivo ou nível 1, e pode ser utilizado para agregar dados e visualização.
3. O *digital twin* diagnóstico ou nível 2, pode ser utilizado para rastrear e realizar análises do presente e passado de acordo com as condições do ativo e já é possível detectar anomalias no ativo.
4. No nível 3 ou preditivo, já é necessário a utilização de algoritmos preditivos para obter estados futuros dos ativos.
5. A possibilidade de ter a capacidade diagnóstica e preditiva pode ser combinada com quantificação de incertezas, análises de hipóteses e estimativas de risco para recomendar ações aos usuários, nesse nível é conhecido como prescrito ou nível 4.
6. No nível 5 ou autônomo, o *digital twin* pode influenciar o ativo diretamente sem a intervenção de um usuário humano.

#### 2.10.4 Uso de Drones e Robôs Industriais

Na indústria, o uso de drones e robôs são cada vez mais utilizados para atividades de inspeção e manutenção. Os veículos aéreos não tripulados (UAVS) denominados de drones são usados para realizar a inspeção de grandes estruturas que são de difíceis acessos, como oleodutos, tanques de armazenamento e turbinas. Assim, com as câmeras e sensores de alta resolução, eles conseguem capturar imagens, dados detalhados e permitem que as equipes de manutenção identifiquem rachaduras, vazamentos e corrosão, sem a necessidade de equipamentos como andaimes e inspeções de forma manual [35].

A utilização de drones também reduz os tempos de inspeção e melhora a segurança do trabalho, evitando que o pessoal trabalhe em alturas ou condições perigosas. Além disso, os drones podem acessar espaços de difícil alcance e que são confinados para os seres humanos, abrangendo a cobertura da inspeção. Os dados que são coletados podem ser analisados utilizando algoritmos de IA e ML no processo de identificar padrões, anomalias e aperfeiçoando as capacidades da manutenção preditiva [35].

Os robôs industriais normalmente são utilizados para as atividades de manutenção de alta complexidade, que exigem precisão e constância. Os robôs possuem a capacidade de realizar tarefas como soldagem, pintura e substituição de componentes com uma alta precisão e de forma repetida. São principalmente úteis em ambientes perigosos e inadequados para os humanos, como nas usinas nucleares ou em plataformas

de petróleo [35].

Quando utiliza-se robôs automáticos, melhora a eficiência da manutenção, reduz o risco de acidentes e do tempo de trabalho. Além de outras aplicações com robôs colaborativos para auxiliar atividades, como levantar pesos, tarefas de precisão e atividades repetitivas. Com essa colaboração aumenta-se a produtividade e a segurança nas operações de manutenção [35].

### 2.10.5 Blockchain e Segurança das Informações

A tecnologia *blockchain* desempenha um papel significativo no aprimoramento da segurança e transparência dos sistemas de informação. O sistema de livro-razão descentralizado do *blockchain* garante que as transações e entradas de dados sejam imutáveis, o que significa que, uma vez que os dados são registrados, eles não podem ser alterados sem alertar a rede. Essa propriedade é crucial para manter a integridade de dados confidenciais, como registros financeiros ou informações de saúde, pois elimina o risco de adulteração ou alterações não autorizadas [37].

A segurança do *blockchain* é sustentada por funções de *hash* criptográficas e algoritmos de consenso, que exigem que os participantes da rede validem as transações. Os processos criptográficos garantem que, mesmo que atores maliciosos tentem modificar um bloco de dados, precisam alterar cada bloco subsequente em toda a rede, o que é computacionalmente inviável. Como tal, o *blockchain* fornece uma solução robusta para prevenir fraudes e garantir a precisão dos dados [37].

A capacidade do *blockchain* de fornecer rastreabilidade e auditabilidade é primordial, particularmente em setores como finanças, saúde e gerenciamento da cadeia de abastecimento. Ao oferecer uma plataforma transparente e resistente a violações, o *blockchain* oferece suporte ao compartilhamento seguro de dados entre organizações, aumentando a confiança e a colaboração entre sistemas distribuídos. A tecnologia não apenas protege as transações digitais, mas também garante que a integridade dos dados seja mantida, o que é vital para a fiabilidade dos sistemas de informação acadêmicos e profissionais [37].



## 3

### Estudo de Casos

#### 3.1 Tecnologias emergentes aplicada a Indústria da Energia Eólica

O consumo mundial de energia elétrica é uma demanda crescente, o que torna essencial o desenvolvimento de soluções para expansão da produção de energia. No entanto, ainda há desafios relacionados às emissões de gases de efeito estufa que geram o aquecimento global, e causam um impacto significativo no equilíbrio natural [38].

Paralelamente, a competitividade no setor aumenta, e os produtores são motivados à necessidade de aprimorarem a eficiência e diminuir os custos. Além das ameaças de desastres ambientais que são associadas e que impactam diretamente a operação segura e sustentável desse setor [38].

Os Sistemas de Energia (SE) são considerados elementos críticos por fornecer à sociedade um recurso essencial. Logo, sua segurança e proteção são fundamentais nesse ciclo e por este motivo todos esses fatores causaram o aumento da necessidade de tornar o SE sustentável e resiliente, e a indústria 4.0 possibilitou uma solução para garantir a sustentabilidade do SE [39].

Segundo Adil [38], tanto reduzir o custo quanto os problemas ambientais são fatores cruciais para um futuro movido a energia com zero emissões. E como resposta a esse problema, a energia eólica é uma das opções com baixas emissões e que tem um desempenho superior a outras fontes de energia elétrica.

À medida que o mundo foca cada vez mais na redução de CO<sub>2</sub> devido às mudanças climáticas, as tecnologias para recursos de energias renováveis amadurecem e se desenvolvem [40].

A energia eólica tem sido uma das fontes de energia com desenvolvimento mais rápido a nível mundial, com um aumento de cerca de 53 % no ano de 2020. Os autores estão otimistas e consideram que entre 51 a 56 % da produção de energia está previsto

que venha dos ventos em 2050, e 26 % em 2030 [38].

As turbinas eólicas aumentam em tamanho e capacidade, e são orientadas cada vez mais ao mar. Isso porque há benefícios quanto a velocidades de vento disponíveis à maior aceleração possível, além de menos ruídos, deslocamento de terra e impacto visual [40].

Com a expansão das turbinas eólicas, o maior segmento será *offshore* no qual as turbinas precisam de mais energia, menos impacto visual e menos deslocamento de terra. Entretanto, surgem desafios relativos a questões técnicas e custos. Há uma pressão crescente para reduzir custos sempre que seja possível [40].

No que diz respeito à operação, os parques eólicos são frequentemente localizados em locais remotos e perigosos, mais difíceis de acessar e inspecionar. Considerando principalmente que alguns dos parques eólicos flutuantes (*offshore*) se expandem para o mar, o tempo de respostas a falhas pode ser muito maior, por causa das condições climáticas e a disponibilidade de técnicos, embarcações de serviços e peças de reposição [36].

Diversos fatores adversos ocorrem para as falhas das pás, tais como descargas atmosféricas, congelamento, falhas de material ou do regulador de energia, danos causados por objetos externos e deficiências de projeto. Essas falhas resultam em reparos custosos e perda de receita devido à paralisação das turbinas. Além das pás, componentes como o gerador, a caixa de engrenagens e os rolamentos também são suscetíveis a falhas [41].

Uma abordagem amplamente citada por diversos autores é que a ampliação do tamanho das pás dos rotores, pode aumentar significativamente a geração de energia. Contudo, o aumento das dimensões das pás exige maior estresse estrutural sobre a turbina e seus componentes associados [41].

As principais causas de falhas em geradores podem ser atribuídas a cargas excessivas de vento, condições climáticas adversas, falhas de fabricação ou projeto, instalação elétrica insuficiente, poluição do abastecimento e isolamento elétrico insuficiente [41].

Com base em dados históricos e pesquisas, rolamentos e engrenagens são responsáveis pela maioria das falhas nas caixas de engrenagens. Fatores como transporte contaminado, ajustes imprecisos dos rolamentos, variações de temperatura e vibração, além da manutenção básica, são variáveis que podem precipitar falhas nesses componentes [41].

Como as turbinas eólicas estão sendo desenvolvidas com base em tecnologia *offshore* tanto fixa quanto flutuante, as demandas de operação e manutenção são cada vez maiores. Algumas chegam a ser localizadas a muitos quilômetros da costa e que em caso de falhas, é necessário ter um acesso imediato e confiável para colocar a turbina

em funcionamento novamente [42].

Falhas inesperadas ocasionam por vezes e geram meses de inatividade de turbinas, reduzindo assim a receita e a eficiência energética dessas turbinas. Para diminuir esses problemas, as organizações investem em estratégias de manutenção para evitar a inatividade [36].

Os operadores de turbinas eólicas evitam recorrer à manutenção corretiva devido ao custo total mais alto do que o custo residual de tempo de inatividade indesejado [40].

O monitoramento evita esse problema, porque detecta mudanças nas condições do sistema analisando falhas e tornando a manutenção baseada na condição potencialmente a mais econômica [40].

A detecção é feita por uma abordagem baseada em dados, sensores e outros sistemas de coleta e aquisição, que permite analisar a acústica, vibrações, medição de deformações ou partículas de óleo. Sendo, a estratégia mais utilizada para a indústria de turbinas eólicas [40].

Acompanhar a vida útil dos dos componentes também é um ponto importante, para que sejam estimados de acordo com base nas condições vivenciadas localmente e prever falhas a partir de pequenas anomalias. Assim a estratégia de manutenção poderá ser alterada de reativa e preventiva para baseada em condições e previsões [36].

Ao longo de uma vida útil de uma turbina eólica, é ainda esperado que resistam as condições extremas de carga, como ventos fortes, ondas e terremotos, e efeitos ambientais severos como gelo, umidade e alterações radicais de temperatura. Entretanto, a vibração contínua devido a essas cargas dinâmicas causam formações de rachaduras de fadigas nos componentes estruturais [43].

Se essas rachaduras não forem detectadas nos estágios iniciais, são capazes de se propagar e causar danos irreparáveis nas lâminas e na torre. Por isto, é imprescindível acompanhar a condição dessas estruturas e que devem ser monitoradas continuamente para garantir uma operação segura e confiável em condições operacionais que são desafiadoras [43].

Um dos principais desafios na pesquisa de previsão de energia eólica estão relacionados à falta de pontualidade e à baixa precisão dos resultados, decorrentes das variações em tempo real dos fatores ambientais [44].

Atualmente, costuma-se utilizar a média dos dados de um determinado período como entrada para o modelo de previsão, a fim de estimar a geração de energia eólica nesse intervalo. No entanto, como os fatores ambientais mudam constantemente, os dados coletados podem não refletir as condições atuais no momento da previsão [44].

Esse problema compromete a precisão das previsões e reduz a confiabilidade do

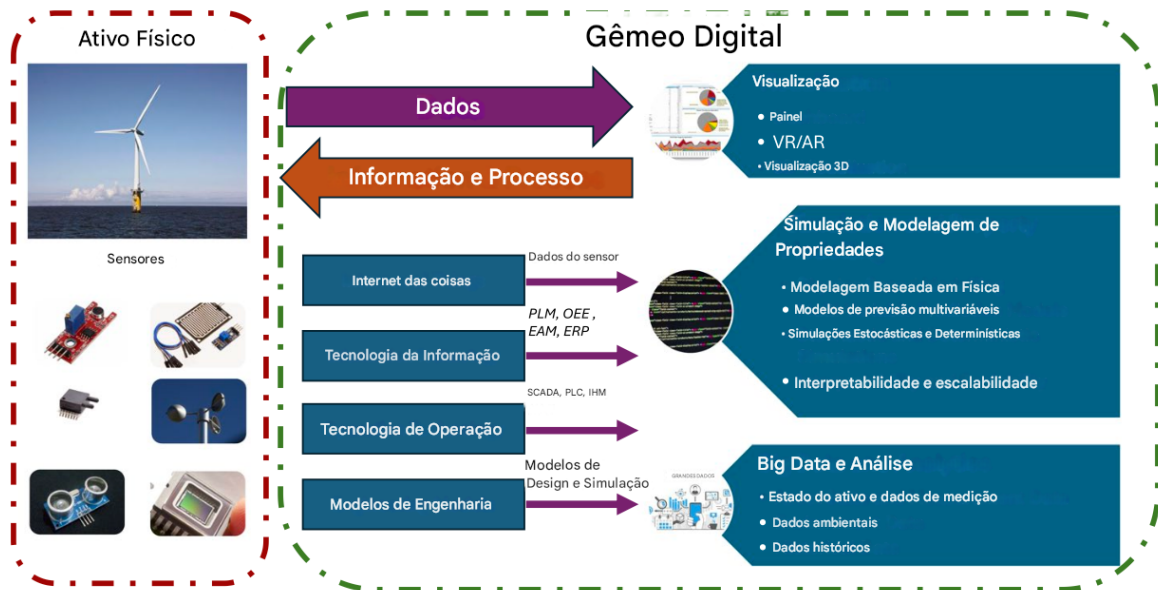


Figura 3.1: Estrutura conceitual do *digital twin* para uma turbina eólica. Fonte: [46].

sistema como um todo. Como consequência, torna-se difícil garantir tanto a pontualidade quanto a exatidão das previsões de energia eólica [44].

O conceito de *digital twin* têm demonstrado uma tecnologia de grande potencial para aprimorar a gestão de ativos industriais complexos. Considerando, o contexto da energia eólica *offshore*, essa inovação tecnológica ganha ainda mais relevância, analisando os desafios de operação e manutenção em ambientes adversos [45].

O *digital twin* é capaz de representar virtualmente o sistema com as informações disponíveis, isso significa que todas as informações são encontradas em um ambiente virtual e dinâmico que corresponde completamente ao sistema real [40].

O sistema utilizado na maioria dos parques eólicos é o *Supervisory Control and Data acquisition* (SCADA), entretanto surge a solução do *digital twins* para a predição e previsão. Os *digital twins* são implementados em um software que são escritos com base em *Machine Learning* (ML) ou Inteligência Artificial (IA) [41].

O *digital twin* opera em três principais frentes: *big data* e análise; em seguida, simulação; e a última é na modelagem de propriedades e visualização [46].

Dessa forma, o *digital twin* coleta, organiza e armazena as informações do sistema físico, no qual abrange um inventário da estrutura, dinâmica e da configuração do sistema. Os dados armazenados se tornam o bloco de construção fundamental no qual pode-se analisar, simular e visualizar o comportamento do sistema físico [46].

Na figura 3.1 é possível visualizar a representação visual do *digital twin*, destacando seus componentes: espaço real, espaço virtual e o *link* para dados e fluxos de informação do espaço real para o espaço virtual.

O sistema SCADA é uma arquitetura que faz a interface com a turbina, para o controle de supervisão e aquisição de dados. O conhecimento obtido com essa ferramenta no monitoramento em tempo real pode ser implementado posteriormente na plataforma para desenvolver as capacidades preditivas do *digital twin* [46].

O *digital twin* também é capaz de ser acessado remotamente, o que facilita a transferência global de dados com menos limitações. O caso ideal para cenários onde o acesso é limitado e a necessidade de monitoramento e o controle remoto de ativos são mais necessários [46].

A grande vantagem do *digital twin* para as turbinas eólicas *offshore*, é devido aos locais de difícil acesso e por ser um produto de alto valor. Produtos de alto valor são tecnologicamente intensivos, caros e críticos em termos de fiabilidade, o qual exige manutenção contínua durante todo o ciclo de vida [40].

A necessidade de manutenção preditiva e baseada nas condições está aumentando em todas as áreas, principalmente para ativos remotos, de alto valor e alto risco [36].

Por estes motivos há um grande interesse industrial no monitoramento das condições e manutenção preditiva, especialmente em *offshore* com ativos remotos. Nesse sentido surgem os *digital twins* como facilitador nas transformações das estratégias de análise, monitoramento, manutenção e condições dos ativos [36].

O setor de energia eólica tem demonstrado um esforço no desenvolvimento de *digital twin* e a motivação principal está nos benefícios que fornecem, como: comportamento preditivo do sistema, simulações de ambientes adversos, menos tempo de inatividade, menos horas de esforço humano para manutenção e maior vida útil para os seus sistemas. Todos esses fatores traz uma redução nos custos da manutenção [40].

O *digital twin* pode obter informações detalhadas sobre os componentes da turbina, como as especificações da pás do rotor, a saída da turbina, a configuração do gerador ou da caixa de engrenagens, além de parâmetros relacionados ao ambiente como velocidade e direção do vento [46].

Além disso, é possível armazenar dados sobre os perfis aerodinâmicos das pás, como a composição e a dimensão do material, assim como, documentar as especificações da caixa de engrenagens, com detalhes sobre as relações de transmissão e as capacidades de carga [46].

É possível obter também através dos sensores, os padrões históricos de vento e métricas de desempenho da turbina, como a saída de energia e eficiência. E esses dados podem ser usados como base para análises e simulações do comportamento da turbina [46].

A tecnologia *digital twin* pode combinar o modelo com as informações meteorolo-

lógicas, fortalecer a capacidade do sistema de previsão de trocar e armazenar informações, o que é propício para pesquisas futuras do SE [44].

Ao analisar e simular o ativo, os modelos computacionais e algoritmos são utilizados para examinar os dados armazenados no *digital twin*. Através de ferramentas analíticas avançadas e algoritmos de aprendizado da máquina, o *digital twin* consegue simular o comportamento do sistema físico em diversas condições. Essas simulações podem identificar como o ativo responde a diferentes entradas, fatores ambientais ou cenários operacionais, como problemas potenciais ou perdas de eficiência. No qual torna-se possível uma avaliação do sistema de forma abrangente [46].

Também é viável, com um *digital twin* o desenvolvimento de representações gráficas com as informações que sejam relevantes e atendam a necessidades específicas. Essas visualizações podem incluir métricas de desempenho, tendências e resultados críticos derivados das simulações analíticas. Com o principal objetivo de apresentar as informações claras e acessíveis facilitando a comunicação e tomada de decisões entre as partes interessadas [46].

Outro fator importante é a relevância em monitorar a saúde do sistema e detectar anomalias, sendo possível evitar consequências catastróficas. Com o diagnóstico da detecção de falha e a manutenção preditiva podem permitir uma operação mais econômica [46].

A aplicação dos *digital twins* na área da manutenção e operação das turbinas eólicas tem um impacto significativo na redução de custos. No entanto, os custos de manutenção e operação podem não ser os primários, mas contribuem de forma relevante para as despesas gerais [47].

Pesquisas mais atuais no campo de operação e manutenção, indicaram uma tendência de declínio nos custos médios nas últimas décadas. No relatório de 2022, sobre o mercado de energia eólica terrestre é demonstrada uma redução nos custos com base em duas curvas de ajustes utilizadas na previsão, com a informação de limite superior e o limite inferior, conforme se pode observar na figura 3.2 [47].

Segundo Pacheco [47], a probabilidade é que os custos permaneçam estáveis ou representem um suave aumento. Reduzir é menos provável porque os custos, na teoria, não podem chegar a zero. Dessa forma, segundo as tendências, há uma limitação no que diz a melhoria da eficiência em operação e manutenção.

Assim, Pacheco [47] destaca a relevância do *digital twin* para desenvolver modelos de alta fidelidade que, quando bem implementados, podem reduzir custos. No mesmo relatório sobre turbinas eólicas são fornecidos dados sobre os custos de operação e manutenção em turbinas eólicas, como pode-se visualizar na figura 3.3 abaixo.

Na Figura 3.3, fica claro que o custo médio para operação e manutenção é maior nas turbinas eólicas mais antigas, enquanto nas turbinas mais recentes permanecem

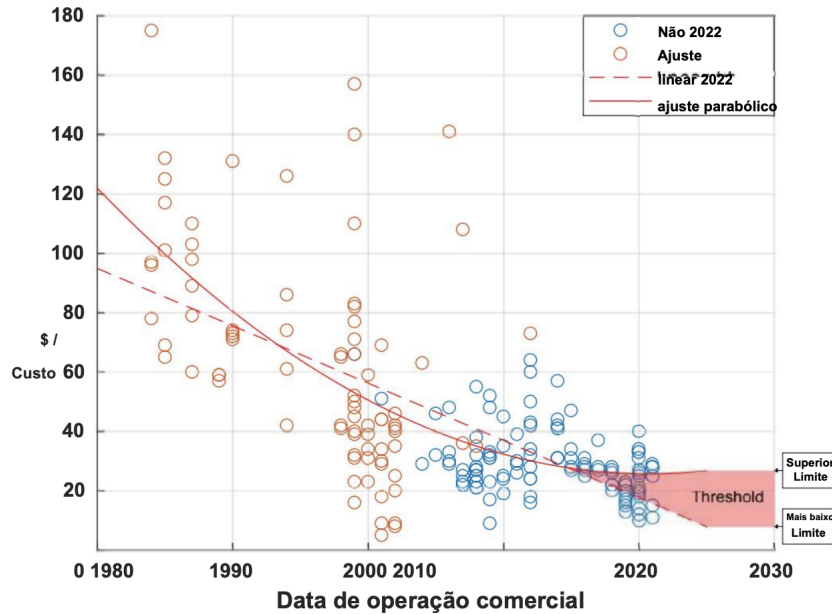


Figura 3.2: Custo médio de O&M versus idade do projeto e impacto combinado com *digital twin* e turbinas eólicas. Fonte: [47].

similar. Isto porque, as novas tecnologias envolvem um custo mais alto de aquisição, entretanto diminuem conforme a tecnologia amadurece. Além disso, a geração de energia nas turbinas eólicas aumentaram nos últimos anos, o que está correlacionado com tamanhos maiores e, conseqüentemente, custos maiores [47].

Além das questões de redução de custos, a transição rumo a um sistema energético sustentável e com baixas emissões de carbono consolida a energia eólica como um elemento principal da estratégia da União Européia. A UE definiu que o intuito é ampliar a capacidade para 150GW até o ano de 2050. Iniciativas políticas como o Acordo Verde Europeu, o pacote *Fit-for-5S* e a Estratégia de Energia Renovável *Offshore* são projetadas para acelerar a adoção de energia renováveis [45].

A energia eólica deverá suprir cerca de 31% da geração total de energia da Europa até 2030. Adicionalmente, conforme o Plano de Ação da UE para Digitalização do Sistema Energético, as tecnologias digitais como o *digital twins*, desempenham um papel essencial ao Acordo Verde Europeu e no alcance dos objetivos estabelecidos para a Década Digital 2030 [45].

O novo projeto da União Europeia, *Federated Digital Twins for Wind-Offshore*, que teve início em junho de 2024 e terá a duração de três anos, visa desenvolver uma plataforma personalizável e federada de *digital twins* para parques eólicos *offshore* [45].

O projeto DTWO busca melhorar a fiabilidade e a segurança energética, integrando modelos de simulação avançados e dados em tempo real para monitorar e prever o desempenho das turbinas e das adversidades das condições climáticas [45].

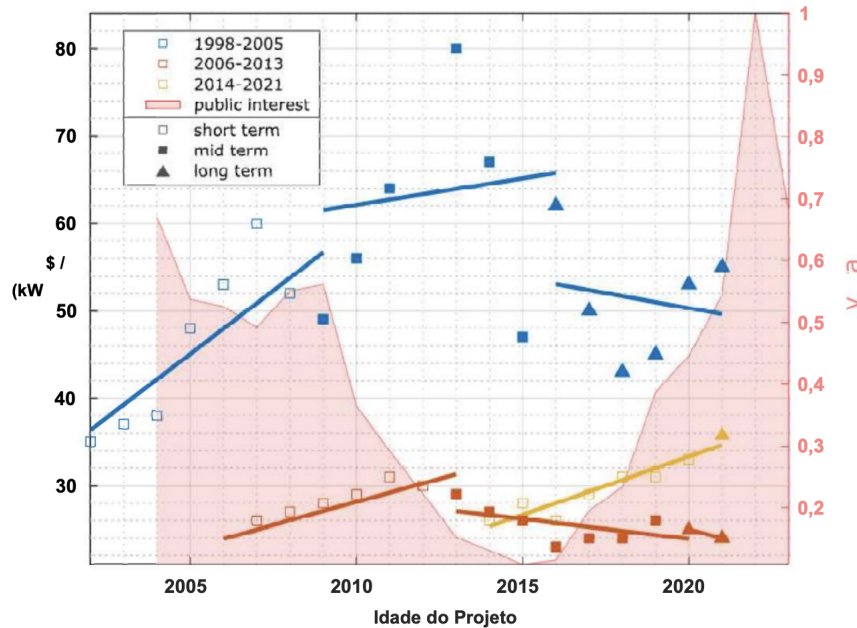


Figura 3.3: Custo médio da O&M versus idade do projeto e o impacto do *digital twin* em turbinas eólicas. Fonte: [47].

O *digital twin* desenvolvido no âmbito do DTWO permitirá a simulação de parques eólicos inteiros, proporcionando uma avaliação coordenada de fatores críticos como o rendimento energético, o estado de saúde das turbinas eólicas e a interconectividade dos sistemas de energia [45].

Diferentemente de outras iniciativas comerciais, o DTWO é pioneiro ao oferecer uma solução que mantém a confidencialidade dos dados comerciais, ao mesmo tempo em que integra módulos de análise climática, esteiras de vento inter e intra-fazendas, turbulência e previsões de fiabilidade [45].

Esse projeto conta com a participação de grandes players da indústria eólica, a Siemens Energy (neste caso, sua divisão Siemens Gamesa) e do maior desenvolvedor de projetos eólicos *offshore* do mundo, a Ørsted, com a colaboração de grandes centros de pesquisas; parceria de consultoria de TI e provedor de serviços digitais; centros de pesquisas acadêmicos como Universidade Técnica da Dinamarca e Universidade de Tecnologia de Gdańsk, além de instituição de comunicação científica, um previsor de energias e centros meteorológicos [45].

O DTWO está desenhando uma arquitetura de software modular, com *hubs* de dados e ferramentas de fácil uso. Através dessa plataforma, espera-se uma maior capacidade de resposta a eventos extremos e um planejamento mais eficaz de manutenção preventiva, otimizando a operação e reduzindo custos [48].

Para coordenar os ativos digitais, a arquitetura do DTWO é desenvolvida para integrar cinco módulos, assim é possível oferecer capacidades prescritivas, além de satisfazer as necessidades transversais da tecnologia de informação, como acessibili-



Figura 3.4: Metodologia para o DTWO. Fonte: [48].

dade, computação, segurança, gerenciamento e monitoramento citeDTWO. É possível visualizar a metodologia usada no DTWO na figura 3.4:

Na metodologia para o DTWO [48], é mostrado os cinco módulos e como vai funcionar a arquitetura utilizada para esse modelo:

- No módulo Terra incluirá a modelagem climática e meteorológica avançada especificadamente para energia eólica *offshore*, usado para quantificar incertezas em previsões e dados históricos utilizando modelagem de conjunto, será capaz de capturar e simular eventos climáticos extremos, garantindo a melhor preparação e operações mais eficientes em ambientes *offshore* que são desafiadores;
- No módulo Esteira Aerodinâmica são os efeitos que o fluxo de ar atrás de uma turbina eólica tem sobre as outras turbinas mais próximas. Essas interações podem impactar a eficiência e a produção de energia do parque eólico. Essa modelagem é crucial para otimizar o posicionamento da turbina, reduzir perdas e melhorar o desempenho geral para turbinas fixas e flutuantes;
- O módulo de Localização será focado na criação de um modelo eficiente que ajuda avaliar o potencial de energia eólica e a produção para parques eólicos. Otimizando o *design* e a modelação de turbinas para cada local para garantir o melhor desempenho. Além de avaliar a relação custo-eficiência de locais dos parques eólicos com base nas condições ambientais;

- O módulo de Turbina ajudará a verificar como as turbinas estão, como as condições afetam os custos e os lucros, como medir riscos e incertezas relacionadas ao tempo de inatividade para a manutenção e quanto tempo as peças da turbina ainda irão durar. Isso permite ter suporte ao planejamento, tempo de inatividade e os custos de operação e manutenção, além de perda de receita, disponibilidade e efeito da degradação relacionada à fadiga;
- O módulo de Rede criará ferramentas para dar suporte tanto ao planejamento de investimentos ao longo prazo quanto às operações diárias, isso porque ele fará previsões de cenários futuros de energia e preços quando ocorrer interconectividade. Permitindo assim planejar mudanças de mercado, além de garantir um fornecimento de energia mais eficiente e confiável.




Figura 3.5: Cenários de teste no âmbito do DTWO. Fonte: [48].

A arquitetura federada da plataforma será desenvolvida utilizando uma abordagem de *design* especializada que seja focada em recursos-chave e vai oferecer uma estrutura flexível e de código aberto, para funcionar com diferentes tipos de módulo, incluindo sistemas terrestres, de esteiras eólicas, redes e turbinas [48].

Para mais, terá integração científica que combinará e testará a plataforma federada com modelos já existentes para garantir que eles funcionem perfeitamente juntos, assim aumenta a precisão e a capacidade do sistema de medir e gerenciar incertezas

[48].

Na integração final da DTWO, o objetivo é ter uma plataforma totalmente funcional, sob medida para proprietários de ativos eólicos, dessa forma vai ajudar a gerenciar e otimizar seus ativos eólicos *offshore* [48].

Os módulos do *digital twins* serão validados utilizando dados do mundo real com diferentes cenários de teste, como pode-se visualizar na figura 3.5.

Os cenários de teste segundo a DTWO [48] são divididos em cinco etapas:

- Cenário de teste 1: Medições de pesquisa com controle de supervisão e aquisição de dados;
- Cenário de teste 2: Medições de pesquisa sem controle de supervisão e aquisição de dados;
- Cenário de teste 3: Zonas de desenvolvimento como Ilhas de Energia do Mar do Norte e do Mar Báltico e Zona Econômica Alemã, com medições esparsas de domínio público;
- Cenário de teste 4: Fazenda flutuante com medidas limitadas;
- Cenário de teste 5: Regional, todo o Mar do Norte e todo o Mar Báltico.

Como resultado esperado, é necessário ao final do projeto que, possuam uma arquitetura *digital twin* com cinco módulos acoplados, um design de alta segurança cibernética, um centro de dados e que sejam condicionalmente abertos, um centro de ferramentas condicionalmente abertas e implementação de módulos do *digital twin* em casos de uso industriais [48].

Um outro exemplo de caso de estudo da implementação de tecnologias do *digital twins* na energia eólica é sobre o projeto WinDTwin, que é uma iniciativa que envolve diversas empresas de energia e tecnologia, bem como instituições acadêmicas e tem como principal objetivo desenvolver os *digital twins* para melhorar a operação e a manutenção de turbinas eólicas em parques eólicos [49].

WinDTwin é um projeto para criar um *digital twins* para parques eólicos *offshore*, e que é financiado por um investimento europeu de seis milhões de euros, esta iniciativa de três anos reúne uma equipe composta por treze organizações de sete diferentes estados-membros da UE [50].

Iniciou com a criação de modelos físicos detalhados das turbinas eólicas, incluindo informações sobre o design, as pás, os geradores eólicos, os sistemas de controle e as condições de vento [50]. Esses modelos são como base para *odigital twin*, que permite simulações em tempo real e a geração de variação de desempenho, como observado na figura 3.6 abaixo.

Além disso, o projeto WindTwin incorpora uma coleta em tempo real de dados de



Figura 3.6: Visualização 3D para o projeto WindTwin. Fonte: Klarian, SD

sensores instalados nas turbinas eólicas. Isso inclui dados sobre vibração, temperatura, velocidade do vento, consumo de energia e outros parâmetros relevantes. Esses dados são integrados ao *digital twin*, que possibilita o monitoramento contínuo do estado das turbinas [51].

Um aspecto inovador do projeto é a aplicação de técnicas de aprendizado de máquina e aprendizado profundo para analisar os dados em tempo real. Os algoritmos de aprendizado de máquina identificam padrões e anomalias no funcionamento das turbinas, permitindo a detecção precoce de problemas e a previsão de falhas potenciais [50].

Como resultado esperado, o projeto WindTwin proporciona várias melhorias nas turbinas que foram analisadas, como o sistema ser capaz de prever a necessidade de manutenção com base em dados em tempo real e específico de desempenho, reduzir os tempos de inatividade não planejados e os custos de manutenção [50].

Além da otimização de desempenho, permitindo o ajuste fino do ângulo das pás e outros parâmetros operacionais para maximizar a eficiência energética. A detecção precoce de problemas e a manutenção proativa também resultarão em economia de custos operacionais e conseqüentemente aumento da vida útil, com isto permite ampliar a vida útil das turbinas eólicas, reduzindo o investimento em substituições [51].

Para explorar sobre a implementação de *digital twin* em turbinas eólicas foi analisado a *Digital Twin Definition Language* (DTD), uma linguagem de modelagem desenvolvida pela Microsoft para representar ativos físicos com o intuito de integrar em modelos em soluções como o *Azure Digital Twin* [52].

A metodologia com DTD para turbinas e parques eólicos com base no padrão IEC 61400-25 (norma que especifica o modelo de informação de dispositivos e funções relacionadas a aplicações em usinas eólicas), foi dividida em três etapas principais: a primeira é a modelagem com o DTD, posteriormente, a integração dos dados e a terceira etapa é a parte de análise e otimização dos cenários [52].

Na primeira etapa de modelagem, é necessário definir o modelo da turbina e no mesmo código apresentado, é descrito as propriedades e telemetrias da turbina como energia gerada, potência ativa e reativa, e outros. Na figura 3.7 é possível visualizar parte do código implementado.

O modelo utilizado para representação da turbina eólica foi criado na *Azure Digital Twin*. Após criado, você tem um modelo digital da turbina que pode ser monitorado e manipulado [52].

A partir do momento que já existe o modelo digital, o próximo passo é integrar os dados reais vindo da turbina. Os dados dos sensores das turbinas são enviados em tempo real para a plataforma. Assim, a turbina envia as medições de velocidade do vento, energia gerada e temperatura para o sistema de nuvem. Esses dados são

```

{
  "@id": "dtmi:com:xmpro:WindFarm:WTUR;1",
  "@type": "Interface",
  "@context": [
    "dtmi:dtdl:context;2"
  ],
  "displayName": "Wind Turbine General Information",
  "description": "-",
  "contents": [
    {
      "@type": "Property",
      "name": "StrCnt",
      "schema": "integer"
    },
    {
      "@type": "Property",
      "name": "StopCnt",
      "schema": "integer"
    },
    {
      "@type": ["Telemetry", "Power"],
      "name": "TotWh",
      "schema": "double",
      "unit": "megawatt"
    },
    {
      "@type": "Telemetry",
      "name": "TotVARh",
      "schema": "double"
    },
    {
      "@type": ["Telemetry", "Power"],
      "name": "DmdWh",
      "schema": "double",
      "unit": "megawatt"
    },
    {
      "@type": "Telemetry",
      "name": "DmdVARh",
      "schema": "double"
    },
    {
      "@type": ["Telemetry", "Power"],
      "name": "SupWh",
      "schema": "double",
      "unit": "megawatt"
    }
  ],
}

```

Figura 3.7: Código de definição de modelo e das propriedades da turbina. Fonte: [52].

utilizados para atualizar a instância do *digital twin* no *Azure Digital Twin* . [52].

No código apresentado na figura 3.8 é especificamente relacionado à transmissão de informações, inclui os estados operacionais, os dados dos sensores e o relacionamento, que se conecta a outros componentes no sistema.

Nesse código é possível ter as telemetrias com dados dinâmicos ou em tempo real, através das medições dos sensores. Algumas telemetrias específicas utilizadas:

- BrkOpSt: Estado de operação do freio, representado por um Enum com valores;
- ShfBrgTmp: Temperatura do mancal do eixo;
- GbxOilTmp: Temperatura do óleo da caixa de engrenagens;
- ShftBrkTmp: Temperatura do freio do eixo;
- GbxVbr: Vibração da caixa de engrenagens;
- GsLev: Nível de óleo da caixa de engrenagens;
- GbxOilLev: Nível de óleo da caixa de engrenagens;
- GbxOilPres: Pressão do óleo da caixa de engrenagens;
- BrkHyPres: Pressão hidráulica do freio;
- ShftBrkTmp: Temperatura do freio do eixo;
- OfFil: Estado do filtro de óleo;
- InlFil: Estado do filtro de entrada.

A próxima etapa é realizar a análise e otimização com base nos dados coletados. O objetivo dos dados é para tomar decisões mais informadas sobre o desempenho da turbina e otimizar a sua operação. No código apresentado na Figura 3.12 é possível observar o registro de estados e *logs* da operação da turbina.

As propriedades específicas representam os atributos estáticos ou de estado do *digital twin* e são apresentados da seguinte forma no código:

- TurCmdLog: Representa um log de comandos enviados para a turbina;
- TurStLog: Representa um log de estados da turbina;
- HiUrgAlm: Representa um contador de alarmes de alta urgência;
- LoUrgAlm: Representa um contador de alarmes de baixa urgência;
- TurCntLog: Representa um contador de eventos relacionados à turbina;
- TurTmLog: Representa um log de tempo de operação da turbina.

Nesse modelo DTDL é possível que as propriedades possam armazenar informações sobre comandos, estados, alarmes e tempos de operação das turbinas, sendo que as propriedades HiUrgAlm e LoUrgAlm podem ser usadas para monitorar e contar

```

{
  "@id": "dtmi:com:xmpro:WindFarm:WTRM;1",
  "@type": "Interface",
  "@context": [
    "dtmi:dtdl:context;2"
  ],
  "displayName": "Transmission information",
  "description": "-",
  "contents": [
    {
      "@type": "Telemetry",
      "name": "BrkOpSt",
      "schema": {
        "@type": "Enum",
        "valueSchema": "integer",
        "enumValues": [
          {
            "name": "Brk",
            "displayName": "Shaft has stopped by brake",
            "enumValue": 1
          },
          {
            "name": "Rdy",
            "displayName": "Brake is ready",
            "enumValue": 2
          },
          {
            "name": "OvHt",
            "displayName": "Brake disk is overheated",
            "enumValue": 3
          },
          {
            "name": "Flt",
            "displayName": "Brake system is faulty",
            "enumValue": 4
          }
        ]
      }
    },
    {
      "@type": "Property",
      "name": "LuSt",
      "schema": {
        "@type": "Enum",
        "valueSchema": "integer",
        "enumValues": [
          {
            "name": "On",
            "displayName": "System is operating",
            "enumValue": 1
          }
        ]
      }
    }
  ]
}

```

Figura 3.8: Código referente a transmissão de informações. Fonte: [52].

```
{
  "@id": "dtmi:com:xmpro:WindFarm:WSLG;1",
  "@type": "Interface",
  "@context": [
    "dtmi:dtdl:context;2"
  ],
  "displayName": "State log information",
  "description": "-",
  "contents": [
    {
      "@type": "Property",
      "name": "TurCmdLog",
      "schema": "integer"
    },
    {
      "@type": "Property",
      "name": "TurStLog",
      "schema": "integer"
    },
    {
      "@type": "Property",
      "name": "HiUrgAlm",
      "schema": "integer"
    },
    {
      "@type": "Property",
      "name": "LoUrgAlm",
      "schema": "integer"
    },
    {
      "@type": "Property",
      "name": "TurCntLog",
      "schema": "integer"
    },
    {
      "@type": "Property",
      "name": "TurTmLog",
      "schema": "integer"
    },
    {
      "@type": "Relationship",
      "name": "isPartOf",
      "target": "dtmi:com:xmpro:WindFarm:WPPD;1",
      "maxMultiplicity": 1
    }
  ]
}
```

Figura 3.9: Código referente ao registro de estados e *logs* da operação da turbina. Fonte: [52].

alarmes de alta e baixa urgência [52].

Além das análises de desempenho TurCmdLog, TurStLog e TurTmLog são usados para analisar o desempenho das turbinas e e identificar padrões ou problemas [52].

Através da função isPartOf é possível conectar esse *digital twin* a outros, criando uma hierarquia ou rede de *twins* que representem o parque eólico como um todo [52].

A interface também gerada pelo modelo DTDL é relacionada a relatórios de operação em um parque eólico, como pode-se visualizar o código na Figura 3.13.

```
{
  "@id": "dtmi:com:xmpro:WindFarm:WREP;1",
  "@type": "Interface",
  "@context": [
    "dtmi:dtdl:context;2"
  ],
  "displayName": "Report information",
  "description": "-",
  "contents": [
    {
      "@type": "Property",
      "name": "TurChrRp",
      "schema": "integer"
    },
    {
      "@type": "Property",
      "name": "TurTmRp",
      "schema": "integer"
    },
    {
      "@type": "Property",
      "name": "TurCntRp",
      "schema": "integer"
    }
  ],
  {"@type": "Relationship",
   "name": "isPartOf",
   "target": "dtmi:com:xmpro:WindFarm:WPPD;1",
   "maxMultiplicity": 1
  }
} ] }
```

Figura 3.10: Código referente aos relatórios de operação do parque eólica. Fonte: [52].

Nos códigos utilizados podem representar um relatório de carga, relatório de tempo de operação ou de contagem de eventos ou operações da turbina [52].

- TurChrRp: Pode representar um relatório de carga ou característica da turbina;
- TurTmRp: Pode representar um relatório de tempo de operação da turbina;
- TurCntRp: Pode representar um relatório de contagem de eventos ou operações da turbina.

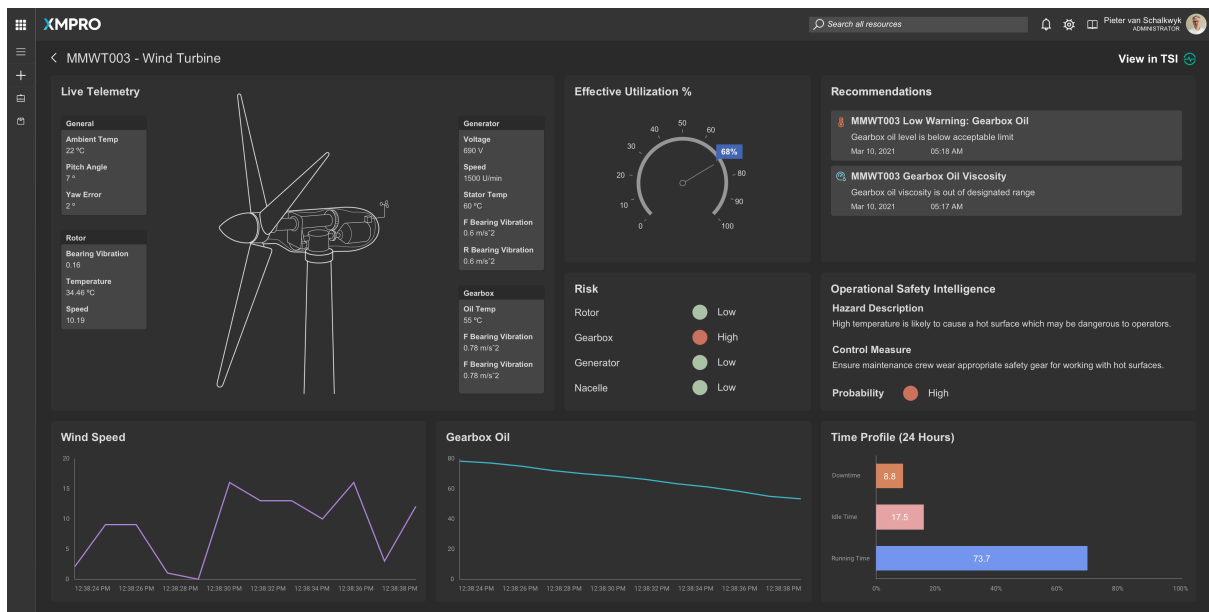


Figura 3.11: Exemplo de turbina eólica *Digital Twins* no XMPRO usando os modelos DTDL de código aberto e dados dos Azure *Digital Twins*. Fonte: [52].

Após ter todos os códigos implementados e associado a turbina eólica, é sempre importante o relacionamento com outros componentes ou dispositivos, e que pode também está associada a uma única planta de energia eólica ou várias [52].

Na Figura 3.14 é possível visualizar um exemplo de turbina eólica *digital twins* utilizando os dados no *Azure Digital Twins*.

Este modelo DTDL é uma representação detalhada de uma turbina eólica, onde as propriedades, telemetrias, comandos e relacionamentos são definidos para integração na plataforma *Azure Digital Twins*. Assim é possível, monitorar a turbina, enviar comandos e analisar o desempenho, aproveitando a visualização e análise em tempo real [52].

Destaca-se que os *digital twins* tem um potencial significativo no setor da energia renovável e que a utilização de modelagens permitem a identificação de falhas, capacidades preditivas aprimoradas e processos de decisão informados [46].

Entretanto, uma implementação bem sucedida em SE requer vários desafios, como aquisição de dados de alta fidelidade para garantir a precisão e ter uma tomada de decisão confiável, redes de comunicação padronizadas garantindo a segurança dos dados, integração de diversas fontes de dados e garantir que os relatórios gerados pelos *digital twins* sejam efetivamente percebidos pelos operadores e tomadores de decisão [46].

## 3.2 Tecnologias emergentes aplicadas na Indústria Aeroespacial

É importante avaliar que para a implementação de estratégias de inovação na gestão da manutenção industrial, principalmente para a adoção de tecnologias, é necessário justificativa plausível por parte das organizações, e um dos princípios dos gestores é analisar a viabilidade de uma implementação, principalmente quando trata-se de investimentos.

Por este motivo, um dos setores que mais desenvolvem tecnologias de ponta é a área da aviação, justificado pela redução de danos e pela necessidade de proporcionar segurança, além de ser uma manutenção dispendiosa ao abordar sobre aeronaves e por isto recorrer a investimentos em tecnologia para a manutenção preditiva.

Através da manutenção preditiva as companhias aéreas podem prever quando as suas aeronaves precisam de manutenção, desenvolvendo a eficiência operacional e com redução no tempo de inatividade. O uso das tecnologias emergentes além de facilitar as tomadas de decisões, também colaboram na realização de procedimentos com maior precisão, sendo extremamente útil para tarefas complexas e críticas, no qual o erro humano pode resultar em consequências expressivas [53].

No cenário tradicional da aviação, os diários de manutenção são armazenados em diário de bordo físico, normalmente na aeronave e/ou na posse do proprietário. No qual vários riscos são associados à manutenção em um diário físico, como: perder, danificar ou ter a documentação roubada da aeronave, no qual impede de ser navegável. Caso esse livro seja extraviado é necessário reconstruir os registros, ocorrendo atrasos e aumento de custos. Além disso, essa reconstrução não é fiável, justamente porque à medida que a aeronave envelhece, a responsabilidade da manutenção que realizou o trabalho pode não estar mais em atividade, e assim não há registros dessa aeronave [54].

Quando ocorrem esses casos é necessário que o proprietário da aeronave faça uma declaração autenticada que justifique a perda de registros e estimar o tempo que a aeronave esteve em uso de acordo com a Administração Federal de Aviação (FAA). Nesse processo ainda é possível falsificações por meio das assinaturas de diários de bordo físicos. [54].

Na aviação quase 90 % de todos os registros de manutenção de aeronaves comerciais são realizados em papel. Segundo Efthymiou [54], a média de proprietários são de cinco a seis, desde a entrega e a aposentadoria da aeronave. É desafiador manter toda a documentação, devido ao alto volume e a atividade durante toda a vida útil da aeronave. Considerando a quantidade de documentos, é possível que o histórico de manutenção de uma aeronave não seja completo.

Em 2016, a FAA emitiu uma declaração na qual constatava-se que 273 peças falsificadas da China foram instaladas em spoilers de asa do Boeing 777, no qual provocou uma desaceleração durante o pouso. As peças e fuselagens são importadas e a cadeia de abastecimento é monitorada em níveis individuais, há um risco de peças de reposição que podem ser réplicas ou de qualidade inferior que são vendidos no mercado negro. As estratégias de falsificação se tornam cada vez mais sofisticadas e tem afetado a legitimidade das peças [54].

Uma das prioridades da indústria da aviação é a segurança, e por este motivo é imprescindível detectar produtos falsificados na cadeia de abastecimento das peças de aeronaves. Um pequeno número de peças falsificadas ou sem registros pode ter um resultado catastrófico, caso não sejam fabricadas de acordo com os padrões reguladores [54].

O processo de desenvolver, projetar e introduzir as tecnologias avançadas na aviação pode se estender por um longo trajeto a fim de garantir a segurança e manter a eficiência, sem aumentar a pressão sobre os trabalhadores. Outro aspecto fundamental é melhorar a segurança e o treinamento de forma que sejam adequados a equipe da aviação e que estejam adaptáveis às tecnologias implementadas [53].

Há um termo conhecido como “Manutenção de Aviação 4.0”, no qual as companhias aéreas aprimoram os processo de Manutenção, Reparo e Revisão (MRO), utilizando plataformas digitais integradas na coleta dos dados e no uso de informações para obter maior flexibilidade operacional, redução de custos e melhorar a segurança. Com a captação dos dados obtidos através de várias fontes por meio de conectividade sem fio permite o monitoramento eficaz do desempenho de todo o processo [53].

Segundo Korba [53], há quatro principais problemas na otimização no setor aéreo: o planejamento de voo, o gerenciamento da frota, planejamento da tripulação e a manutenção das aeronaves. O problema da manutenção é o que mais destaca-se, justamente por causa dos seus impactos diretos na redução dos custos operacionais. Assim, as atividades de MRO é que representa o maior núcleo de custos de uma companhia área e representa cerca de 10% dos custos operacionais totais.

A grande questão da manutenção básica das aeronaves é que após um determinado número de ciclos de voo, a aeronave é levada para uma estação ou centro de manutenção, no qual o MRO é realizado de acordo com as recomendações que foram descritas pelo fabricante, do regulamento das autoridades da aviação e de diretrizes internas da companhia área [53].

A MRO é complexa, porque possui diversas políticas imigratórias, portfólio de variados clientes, além da forte dependência de cadeias de abastecimento das peças, a dependência de humanos no processo e cronogramas que são desafiadores para gerenciar e captar as informações de forma eficaz [54].

O processo é complexo por fatores diários como atrasos de voo, diversas opções de frotas, utilização da aeronave ou a capacidade disponível em estações de manutenção individuais, além do fato de que a produção de peças de reposição para aviação é uma demanda de alta tecnologia e baixo volume, isso significa que a entrega de grandes quantidades de produtos devem ter especificações precisas e são feitas especialmente sob encomenda [53].

Além das milhões de peças que possuem as aeronaves e que necessitam ser rastreadas com os programas de manutenção, porque cada movimento, mudança de propriedade e condição das peças de reposição, por motivos de modificação, manutenção, arrendamento e troca precisa ser relatado para garantir a aeronavegabilidade. Assim como o rastreamento das peças, manutenção, boletins de serviços e diretrizes que uma aeronave precisa cumprir e que são gerados uma infinidade de dados [55].

Os dados que são gerados e que estão relacionados a manutenção e a reposição das peças são armazenados em diversos sistemas que podem variar de acordo com a organização. Esses sistemas são necessários para rastrear e relatar com eficiência o movimento, a modificação e a manutenção de peças de reposição e que devem ser comunicados durante toda a cadeia de abastecimento. No processo tradicional, o provedor do MRO não tem acesso às informações da manutenção, normalmente ocasionados devido à falta de registros históricos de componentes e a solicitação dessas informações levam aumento no tempo de resposta e conseqüentemente o aumento dos custos [55].

A tecnologia mais recente utilizada no campo da aviação é a tecnologia *blockchain*, na qual é considerada uma das influentes e inovadoras atualmente. A *blockchain* é descrita por Efthymiou [54] como uma cadeia de blocos, usada em ordem cronológica e na qual cada bloco possui o seu registro de atividades que ocorreram na rede desde que o último bloco foi adicionado.

Para compreender algumas dessas questões e como estão sendo implementadas tecnologias emergentes para melhorar o setor da aviação, é realizado um estudo de caso com o grupo Lufthansa, uma empresa alemã de aviação que opera com o transporte aéreo de passageiros, logística de manutenção, reparo e operação, além de fornecer serviços de tecnologia da informação.

A Lufthansa afirma que as três forças motrizes da aviação são: Tecnologia, dados e pessoas. Isso porque acreditam que esses impulsionadores não são capazes de atingir o seu máximo potencial de forma isolada um do outro e que através dessa conexão é possível realizar uma revolução genuína [56].

A comunicação homem-máquina ou máquina-máquina, robótica e a inteligência artificial são as tecnologias que estão transformando todos os aspectos em escala mundial e impulsionando novos desenvolvimentos [56].

No entanto, a tecnologia não trabalha sozinha e por isso a Lufthansa colabora com

instituto de pesquisas, indústrias, companhias aéreas ou concorrentes. Através do *Center of Applied Aeronautical Research* (ZAL), realizou-se mais de cem projetos científicos, com uma variedade de provedores de serviços e institutos de pesquisas para produzir as soluções no setor da aviação [56].

Como solução dos questionamentos abordados anteriormente, a Lufthansa apresenta o AVIATAR, uma plataforma holística que é aberta, modular e neutra, no qual oferece uma variedade de produtos e serviços digitais para as operações de MRO, que combina os vários aplicativos em um único lugar [56].

Assim como recepcionar a grande quantidade de dados, com o AVIATAR é possível conectar os sistemas para analisar dados, prever requisitos de manutenção e atender as necessidades, além de implementar a manutenção preditiva, realizar análises de falhas sem precedentes e monitorar as condições para os sistemas e componentes [56].

Uma das tecnologias apresentadas pela Lufthansa também é a iniciativa do *Blockchain for Aviation* (BC4A), um banco de dados descentralizado que armazena informações permanentemente e impede que sejam editadas ou alteradas, permitindo o rastreamento desde seguro de bens valiosos à verificação de peças originais. O *blockchain* retira a necessidade um terceiro confiável e desempenha a função que é executada pelos bancos, trazendo como principal diferencial a confiança digital. Cada link no *blockchain* possui uma cópia completa de todas as informações, assim a tecnologia proporciona a transparência e promove a confiança [56].

Para uma melhor compreensão da tecnologia *blockchain*, ao implementar os MROs em *blockchain*, eles podem ser inseridos manualmente por funcionários autorizados ou automaticamente por sistemas de gerenciamento de manutenção. Uma vez que esse bloco é inserido no sistema, ele é compartilhado com todos os participantes do *blockchain* e este bloco de dados não pode ser alterado [54].

Quando eles são implementados em MROs, os blocos contém os dados sobre as peças da aeronave e de como vieram, qual companhia aérea operou, quantas horas foram utilizadas, quando, onde e o que falhou. Assim como, quem, quando e onde foram reparados. Na aviação isso é conhecido como Back-to-Birth (ou BtB), mas no *blockchain* utiliza-se a criptografia ao invés de assinaturas para garantir a segurança e a confiabilidade dos dados [54].

Segundo Efthymiou [54] os ganhos de eficiência provados pelo uso da *blockchain* podem aumentar a receita da indústria aeroespacial em até 4 %, isto significa, 40 bilhões de dólares, enquanto a redução de custos utilizando a MRO pode chegar em aproximadamente 5 %, ou seja, 3,5 bilhões de dólares.

Entretanto, segundo Bernhard Kube, Vice-presidente de consultoria de tecnologia, pesquisa e padrões da Lufthansa Industry Solutions, ainda levará de cinco a dez anos para que a tecnologia *blockchain* se torne popular, mas que é importante testar a

tecnologia para que ela libere o potencial [56].

Uma das grandes barreiras para a implementação do *blockchain* é o compartilhamento de informações, porque há partes interessadas na indústria da aviação que não compartilham dados ou registros com empresas nas quais não estão diretamente envolvidas. Ainda há uma falta de confiança entre as partes, sendo um grande desafio ter a indústria na mesma transparência e rastreabilidade [54].

Outro problema identificado é o custo de implementação, já que alguns pequenos distribuidores de peças de reposição e agências de reparos do setor aeroespacial podem ser uma barreira significativa, considerando a estrutura de custos e para a inclusão eficaz do *blockchain* [54].

Alguns dos benefícios da tecnologia *blockchain* em resumo é a automação de terceiros confiáveis, a criação da transparência e do consenso, obter dados históricos imutáveis, ter a visibilidade em tempo real para todos os envolvidos, além do rastreamento entre processos e entre organizações, e uma barreira maior para a fraude e a manipulação [56].

Com a *Blockchain for Aviation* (BC4A), a Lufthansa pretende compilar potenciais aplicações de *blockchain* no campo da aviação e criar padrões conjuntos para seu uso. Com o objetivo de reunir todos os campos de especialização e sondar coletivamente os potenciais da tecnologia *blockchain*, os participantes potenciais incluem, por exemplo, desenvolvedores de software, fabricantes de aeronaves, provedores de serviços de MRO, provedores de logística, locadores e reguladores [56].

Dessa forma as informações são armazenadas em blocos e cada um tem o seu próprio histórico. Cada bloco é verificado e selado, assim as informações contidas não podem ser alteradas e salvas de forma que seja visível para todos. Assim, se torna difícil corromper e manipular as informações de forma benéfica se diferentes empresas estiverem trabalhando juntas utilizando os mesmos dados, como na manutenção das aeronaves [56].

Para o futuro, os componentes deverão ser registrados em um *blockchain* depois de serem fabricados junto com todos os dados relevantes como os códigos seriais. Se um componente for instalado em um avião, essas informações poderão ser salvas novamente em outro *blockchain*. Se a peça apresentar falha ou mau funcionamento, os técnicos de manutenção poderão utilizar as informações armazenadas para revisar o número exato de horas de voo e decidir se devem substituir ou consertar a peça. Se for consertada, essas informações poderão ser salvas em um *blockchain* separado para o componente em questão [56].

Assim torna-se possível armazenar a documentação em diferentes empresas, sejam de fabricantes a companhias aéreas e provedores de serviços de MRO. Isso significa que todo o ciclo de manutenção de um único componente pode ser revisado em sua

totalidade. Ele reduz o risco para provedores de serviços de MRO em particular, pois agora eles podem usar a tecnologia *blockchain* para fornecer documentação verificável sobre as peças que instalaram a qualquer momento. Outros cenários de aplicação de *blockchain* na aviação incluem o gerenciamento seguro de certificação de autoridades de aviação e cartões de trabalho de técnicos [56].

A Lufthansa é a principal fornecedora mundial de MRO para aeronaves civis do mundo, no qual compreende 30 plantas que oferecem serviços para aviação em todo mundo, atendendo mais de 800 clientes, incluindo OEMs, empresas de leasing de aeronaves, operadores de jatos, governos e forças armadas, além das companhias aéreas [57].

A Lufthansa tem desempenhado um papel fundamental na transformação digital das operações técnicas de aeronaves através do desenvolvimento e implementação do ecossistema Digital Tech Ops. Esse ecossistema é formado por três principais elementos: o AVIATAR, plataforma voltada para soluções analíticas baseadas em dados; o flydocs, que é uma solução digital para gestão de ativos e registros; e o software de manutenção e engenharia/MRO AMOS [57].

No final do ano do relatório de 2023, a plataforma AVIATAR já estava conectado em 3.300 aeronaves, representando 23 % a mais que no ano anterior. Essa expansão reflete o impacto significativo do ecossistema Digital Tech Ops para a digitalização e otimização dos processos de manutenção e gestão técnica na aviação [57].

Além disso, o segmento do desenvolvimento da MRO da Lufthansa apresentou um desempenho sólido em 2023, refletindo a expansão da demanda por serviços técnicos de aviação. A receita no segmento de MRO totalizou €6.547 milhões, um crescimento de 18 % em relação ao ano anterior, com uma contribuição significativa de €2.158 milhões provenientes apenas do Grupo Lufthansa, representando um aumento de 40 %. O desempenho foi impulsionado pelas unidades MRO Engine Services e Aircraft Component Services em particular. A receita operacional aumentou em 18% alcançando €7.028 milhões [57].

As despesas operacionais aumentaram 19 %, atingindo €6.383 milhões, acompanhando o aumento da receita. O EBIT (Earning Before Interest and Taxes), um indicador financeiro utilizado para avaliar o lucro operacional de uma empresa desconsiderando os efeitos dos juros e da carga tributária, foi de €628 milhões, representando 13 % de crescimento em relação a 2022. Isso reflete melhorias na eficiência operacional e na capacidade de gerar lucro. Além disso, houve um aumento significativo no EBIT global, com mais de 26 %, refletindo o fortalecimento de MRO no mercado de aviação [57].

No balanço do segmento da MRO da Lufthansa Technik, o ROCE (Return on Capital Employed) que é uma métrica financeira utilizada para avaliar a rentabilidade e

## Segmento de negócios MRO

### T041 NÚMEROS-CHAVE MRO

		2023	2022	Mudança em %
Receita	€m	6.547	5.550	18
dos quais com empresas do Grupo Lufthansa	€m	2.158	1.546	40
Lucro operacional	€m	7.028	5.951	18
Despesas operacionais	€m	6.383	5.383	19
EBITDA Ajustado 1)	€m	785	732	7
EBIT ajustado 1)	€m	628	554	13
EBIT 1)	€m	628	498	26
Margem EBIT ajustada 1)	%	9.6	10.0	-0,4 pontos
ROCE ajustado 1)	%	12.0	11.4	0,6 pontos
Despesas de capital do segmento	€m	137	99	38
Funcionários em 31 de dezembro	número	22.870	20.411	12
Número médio de funcionários	número	21.925	20.116	9
Empresas totalmente consolidadas	número	25	25	-

1) Os resultados dos investimentos de capital da empresa associada "Ameco" são relatados em Negócios Adicionais e Funções do Grupo devido à mudança de responsabilidade na gestão do Grupo; os números do ano anterior foram ajustados de acordo.

Figura 3.12: Balanço com indicadores financeiros no segmento de MRO. Fonte: [57].

a eficácia da gestão dos recursos em relação ao investimento, foi ajustado em 12 % em 2023, representado um aumento de 0,6 pontos percentuais em relação ao ano anterior. O resultado positivo e crescente indica uma capacidade do segmentos de MRO em gerar valor para seus acionistas e outros stakeholders, destacando sua gestão eficaz dos recursos, mesmo no contexto de aumento de despesas de capital superior a 38 % [57].

O segmento de MRO também registrou um aumento de 12 % no número de funcionários em 31 de dezembro de 2023, passando de 20.411 em 2022 para 22.870 em 2023,

destacando o crescimento na capacidade operacional [57].

O balanço em segmentação de MRO pode ser visualizado na figura 3.12 e demonstram o impacto positivo das estratégias operacionais com o avanço das tecnologias, refletindo o compromisso com a inovação. Através desses indicadores demonstram a expansão e a consolidação da Lufthansa no segmento de MRO, reforçando sua posição como líder global em soluções de manutenção e reparação para a aviação [57].

Outra tecnologia utilizada pelo Grupo Lufthansa é a IA generativa, com o modelo de linguagem ChatGPT (Chat Generative Pre-trained Transformer) em diversos segmentos como no processo de linguagem natural para a substituição, manutenção ou reparo da aeronave [57].

Com a IA generativa é possível um desenvolvimento de um protótipo de NLP como o manual de manutenção das aeronaves da Lufthansa Technik para resolver os problemas causados por referenciais manuais no próprio Manual de Manutenção de Aeronaves (AMM) e nos relatórios de defeitos. A referência manual automatizada entre tarefas do AMM torna a manutenção do motor mais rápida e eficiente [57].

Ao comparar documentos, as capacidades do processamento de linguagem podem ir além das de um mecanismo de busca. Como a abordagem também entende trechos de texto, ela até torna possível descobrir seções totalmente reformuladas com conteúdo correspondente. Os usos potenciais incluem pesquisas automatizadas de patentes, consulta à legislação e categorização de manuais de reparo, o que facilita no processo das manutenções das aeronaves [56].

O avanço na análise de Big Data e as técnicas de inteligência artificial revolucionam as operações da manutenção preditiva e que estão desenvolvendo-se rapidamente no setor aeroespacial. Além do Grupo Lufthansa, diversas outras companhias aéreas estão implementando tecnologias como algoritmos de inteligência artificial para otimizar aeronaves, sistemas e operações de manutenção, além da análise e investigação para aplicações de análise de dados baseada em Inteligência Artificial, Aprendizado de Máquina e Aprendizado Profundo para manutenção preditiva de sistemas, subsistemas e componentes de aeronaves [58].

Para compreender como funciona um protocolo de gerenciamento de aeronaves usando um *blockchain*, é analisado o Protocolo *SkyLink* (SKLP), uma infraestrutura descentralizada desenvolvida para garantir a integridade, rastreabilidade e segurança em processos críticos de manutenção de aeronaves. O SKLP detalha a implementação, funcionalidade e aplicações, utilizando o código fornecido e validado através de testes automatizados [59].

O Protocolo *SkyLink* (SKLP) selecionou a empresa Boeing para apresentar uma solução baseada em *blockchain*. A Boeing passou por uma crise que tem afetado sua reputação de uma forma negativa, com inúmeras acusações e processos judiciais, in-

cluindo ações, multas e acordos relacionados a incidentes fatais ligados à suas aeronaves. O principal problema da Boeing foi relacionado à falha de projeto do sistema de controle de voo, com esses incidentes gerou um desgaste na confiança de clientes devido a falta de transparência em relação às suas aeronaves [59].

Como solução para Boeing, o SKLP propõe a implementação de contratos inteligentes em um *blockchain EVM* (*Ethereum Virtual Machine*) público como Ethereum, que pode ser conectado para trabalhar com vários *blockchain* em simultâneo [59].

A solução utiliza contratos inteligentes para fornecer registros de manutenção imutáveis, com datas, detalhes das partes substituídas e informações sobre os prestadores de serviços; permite o rastreamento da cadeia de abastecimento com a implementação de *tokens* não fungíveis (NFTs) para monitorar a propriedade e a localização dos componentes. Além de ser possível a integração com agregadores de tarifas de viagem, como a Skyscanner, com a exibição de informações sobre a manutenção das aeronaves antes dos voos [59].

Através do protocolo SKPL é possível aumentar a segurança na manutenção de aeronaves ao introduzir a rastreabilidade, com controle imutável e registrado em *blockchain*; a descentralização, a partir da governança compartilhada por meio de consenso e restrições baseadas de acordo com as hierarquias, com permissões definidas para cada entidade envolvida no processo [59].

O SKPL tem como arquitetura de acesso ao SKPL, uma hierarquia que implementa quatro papéis principais no controle de acesso:

- O SUPER (Root Owner) que possui o controle total e tem a capacidade de gerenciar todos os outros papéis;
- O MANUFACTURER que gerencia todas as operações específicas, como adicionar ou revogar as MROs;
- O MRO (Maintenance, Repair, Overhaul) executa as funções que são relacionadas a manutenção;
- E a THIRD PARTY, no qual possui permissões limitadas apenas para funções específicas.

Cada papel possui restrições quanto ao limite de uso, para evitar que entidades abusem das suas permissões. Essa implementação é realizada através de contratos inteligentes que são escritos em Solidity Código demonstrativo de método para controle de acessos e permissões [59].

No código que se apresenta seguidamente pode-se verificar o gerenciamento de controle de acesso e permissões para várias funções dentro do Protocolo SkyLink, incluindo os métodos para conceder e/ou revogar as funções de acessos [59].

```
5 describe("SkyLink Access Control Contract Testing", () => {
6   ✓ async function deploySkyLink() {
7     const SkyLink = await ethers.getContractFactory("SkyLink");
8     const SkyLinkContract = await SkyLink.deploy(1, 1, 1);
9     const [owner, addr1, addr2, addr3, addr4, addr5] =
10      await ethers.getSigners();
11     await SkyLinkContract.waitForDeployment();
12     return { SkyLinkContract, owner, addr1, addr2, addr3, addr4, addr5 };
13   }
14   it("Should give Root Owner SUPER access", async () => {
15     const { SkyLinkContract, owner } = await loadFixture(deploySkyLink);
16     expect(await SkyLinkContract.hasPermission(owner, 0)).to.equal(true);
17   });
18   it("Should NOT allow Root Owner to revoke its own access", async () => {
19     const { SkyLinkContract, owner } = await loadFixture(deploySkyLink);
20     await expect(SkyLinkContract.revokeSkyLink(owner)).to.be.reverted;
21   });
22   it("Should allow Root Owner / SUPER to Add All Types of Access Roles", async () => {
23     const { SkyLinkContract, owner, addr1, addr2, addr3, addr4 } =
24     await loadFixture(deploySkyLink);
25     await expect(SkyLinkContract.addManufacturer(addr1)).to.not.be.reverted;
26     await expect(SkyLinkContract.addSkyLink(addr2)).to.not.be.reverted;
27     await expect(SkyLinkContract.addMRO(addr3, "MRO Example")).to.not.be
28     .reverted;
29     await expect(SkyLinkContract.addThirdParty(addr4)).to.not.be.reverted;
30     expect(await SkyLinkContract.hasPermission(addr1, 1)).to.equal(true);
31   });
```

Figura 3.13: Código demonstrativo de método para controle de acessos e permissões. Fonte: [59].

Além disso, o SKPL também define a estrutura de dados e realiza o mapeamento para gerenciar as aeronaves, os componentes e os registros de serviços [59].

Para compreender o código utilizado, na estrutura tem-se as seguintes condições:

- Aircraft: Representa uma entidade aeronáutica.
- currentOwner: Endereço do proprietário atual.
- previousOwners: Conjunto de endereços representando proprietários anteriores.
- regNumber: Número de registro da aeronave.
- manufacturer: Fabricante da aeronave.
- model: Modelo da aeronave.
- productionDate: Data de produção da aeronave.
- seatCapacity: Capacidade de assentos da aeronave.
- inService: Status que indica se a aeronave está em serviço.
- AirComponent: Representa uma entidade componente da aeronave.
- identifier: Identificador do componente de ar.
- name: Nome do componente de ar (por exemplo, Motor).
- manufacturer: Fabricante do componente de ar.

- `productionDate`: Data de produção do componente de ar.
- `inService`: Status que indica se o componente de ar está em serviço.
- `ServiceRecord`: Representa uma entidade de registro de serviço.
- `performer`: Endereço do executor (MRO) do registro de serviço.
- `date`: Data do registro de serviço.
- `result`: Resultado do registro de serviço.
- `description`: Descrição do registro de serviço.
- `servicedComponents`: Matriz de identificadores de componentes aéreos atendidos no registro.

Enquanto para mapeamentos, utiliza-se as seguintes funções:

- `regNumberToAircraft`: Armazena informações da aeronave com base nos números de registro.
- `flightNumberToAircraft`: Associa números de voo a entidades de aeronaves.
- `regNumberToServiceRecords`: Armazena registros de serviço associados aos números de registro de aeronaves.
- `regNumberToAirComponents`: Armazena componentes de aeronaves categorizados por status de serviço.
- `componentIdentifierExists`: Rastreia a existência de identificadores de componentes.

A seguir na figura 3.14 é demonstrado uma parte do código que é criado uma instância da aeronave e adicionados todos os seus atributos.

Segundo Abbasi [59], no SKPL também é possível gerenciar taxas e pagamentos, assim é permitido definir taxas para diferentes tipos de classes, sacar saldos de contrato e incluir modificadores para garantir a inicialização do pagamento e o controle do acesso. Como funções principais, temos:

- `FeeClass`: Define classes de taxas (A, B, C).
- `feeHashMap`: Armazena valores de taxas para cada classe de taxa (em WEI).
- `constructor(uint _classAFee, uint _classBFee, uint _classCFee)`: Inicializa o contrato com valores de taxas para as classes de taxas A, B e C.
- `setFee(...)`: define o valor da taxa para uma classe de taxa específica.
- `getFee(...)`: Recupera o valor da taxa para uma classe de taxa específica.
- `withdraw(...)`: Permite que os proprietários do contrato retirem o saldo do contrato.

## Implementação de Estratégias de Inovação na Gestão da Manutenção Industrial

```
14     it("Should create AirCraft instance + Fetch all its attributes correctly", async () => {
15         const { SkyLinkContract, owner } = await loadFixture(deploySkyLink);
16         await expect(
17             SkyLinkContract.addAirCraft(
18                 "XYZ123",
19                 "Boeing",
20                 "737MAX",
21                 169999999,
22                 400,
23                 owner.address,
24                 { value: ethers.parseEther("1.2334") }
25             )
26         ).to.not.be.reverted;
27         expect(await SkyLinkContract.getAirCraftStatus("XYZ123")).to.equal(
28             false
29         );
30         expect(await SkyLinkContract.getAirCraftInfo("XYZ123")).to.deep.equal([
31             "Boeing",|
32             "737MAX",
33             "169999999",
34             "400",
35         ]);
36         expect(
37             await SkyLinkContract.getAirCraftCurrentOwner("XYZ123")
38         ).to.equal(owner.address);
39         /*expect(
40             await SkyLinkContract.getActiveAirCraftComponents("XYZ123")
41         ).to.deep.equal([
42             ["Component1", "X1"],
43             ["Component2", "X2"],
44             ["Component3", "X3"],
45         ]);*/
46     });
47     it("Should NOT allow an AirCraft instance to spawn when it has <4 components", async () => {
48         const { SkyLinkContract, owner } = await loadFixture(deploySkyLink);
49         await SkyLinkContract.addAirCraft(
50             "XYZ123",
51             "Boeing",
52             "737MAX",
53             169999999,
54             400,
55             owner.address,
56             { value: ethers.parseEther("1.2334") }
```

Figura 3.14: Código demonstrativo da instância da aeronave e seus atributos. [59].

Na figura 3.15 abaixo, é possível observar o código em uso para gerenciamento das taxas e pagamentos.

Para realizar os testes e cobertura dos diretórios de códigos implementados, é necessário ter os pacotes de npm instalados executando um `npm install`. Para executar os contratos, basta utilizar os seguintes comandos:

- Executar testes: `npx hardhat test`
- Gerar relatórios de cobertura: `npx hardhat coverage`

O Protocolo SKPL passou por testes unitários que garantiu 100% de cobertura, o que validou com sucesso os pacotes destinados a execução dentro dos contratos. Esses contratos estão abertos e são fornecidos para um ponto inicial para as soluções

```

17     constructor(
18         uint _classAFee,
19         uint _classBFee,
20         uint _classCFee
21     ) SkyLinkAccessControl() {
22         setFee(FeeClass.A, _classAFee);
23         setFee(FeeClass.B, _classBFee);
24         setFee(FeeClass.C, _classCFee);
25     }
26
27     // Enum defining fee classes.
28     enum FeeClass {
29         A,
30         B,
31         C
32     }
33
34     // Mapping to store fee amounts for each fee class (WEI).
35     mapping(FeeClass => uint) private feeHashMap;
36
37     /**
38      * @dev Sets the fee amount for a specific fee class.
39      * @param _class The fee class to set the fee for.
40      * @param _feeAmount The fee amount to set (WEI).
41      */
42     function setFee(FeeClass _class, uint _feeAmount) public onlySkyLink {
43         feeHashMap[_class] = _feeAmount;
44     }
45
46     /**
47      * @dev Retrieves the fee amount for a specific fee class.
48      * @param _class The fee class to query.
49      * @return The fee amount for the specified fee class.
50      */
51     function getFee(FeeClass _class) public view returns (uint) {
52         return feeHashMap[_class];
53     }
54
55     /**
56      * @dev Allows the contract owners to withdraw the contract's balance.
57      */
58     function withdraw() external onlySkyLink {
59         payable(msg.sender).transfer(address(this).balance);
60     }

```

Figura 3.15: Código demonstrativo para gerenciamento das taxas e pagamentos. Fonte: [59].

baseadas em *blockchain* na área da aviação e do gerenciamento de aeronaves. Pode ser utilizado para exploração ou adoção de indivíduos ou organizações que estão interessadas em desenvolver suas próprias soluções em *blockchain* [59].

O SkyLink se destaca principalmente pelo foco em componentes críticos com a implementação de NFTs para rastrear as peças, a compatibilidade de integração com múltiplos *blockchain* EVM e o acesso público aos registros, o grande diferencial, já que outros sistemas priorizam apenas o uso interno [59].

A solução proposta pelo SKPL tem diversos benefícios na implementação em aeronaves, pelo aumento da eficiência operacional com a redução de trabalho manual e o rastreamento acontecendo de forma automática; a transparência com o acesso público a esses registros, o que aumenta a confiança do consumidor que pode verificar diretamente a segurança da aeronave antes do embarque e o aumento da segurança, com a redução dos riscos que são associados à falta de manutenção ou uso de componentes

com defeitos ou falsificados [59].

### 3.3 Aplicação prática de Manutenção Preditiva em Aeronaves

A Gestão de Prognósticos e Saúde, conhecida como PHM (*Prognostics and Health Management*) desempenha um papel essencial na manutenção preditiva baseada em condição, especialmente para sistemas críticos como é o caso dos motores de aeronaves.

No momento que o PHM consegue prever falhas potenciais, ajuda a minimizar o tempo de inatividade e otimizar o planejamento de manutenções, aumentando a segurança, a confiabilidade e a eficiência dos custos.

Para analisar o uso de PHM em manutenções preditivas em aeronaves, foi analisado em Python um Projeto de Manutenção Preditiva em Aeronaves da Drexel University e o conjunto de dados utilizado foi do Repositório de Dados de Prognósticos da Nasa usando o CMAPSS (*Commercial Modular Aero-Propulsion System Simulation*) .

Para implementar o modelo de aprendizado de máquina para a modelagem de propagação de dados foi usado a simulação de falha total (*run-to-failure*) de motores de aeronaves, com o objetivo de antecipar as falhas de componentes e garantir que as ações de manutenção sejam planejadas antes de ocorrerem falhas críticas.

O maior desafio é prever a Vida Útil Remanescente (RUL - *Remainin Useful Life*) do motor de uma aeronave, isto significa, obter o número de ciclos antes de ocorrer a falha, utilizando dados coletados ao longo do tempo em formato de séries temporais.

Para a implementação de manutenção preditiva, esse tipo de previsão é essencial porque permite que as intervenções de manutenção sejam planejadas com antecedência, garantindo a eficiência e a economia de recursos, além de reduzir os riscos de falhas inesperadas.

Para o caso analisado, foi tratado como um problema de regressão, no qual o modelo aprende a prever um valor contínuo, com a quantidade de ciclos restantes até a falha. Entretanto, esse mesmo problema pode ser abordado usando uma classificação binária, para saber em quantos ciclos vai falhar ou multiclass para categorizar a RUL em faixas, que podem ser curto, médio ou longo prazo.

Ao usar a regressão, o objetivo é ter a possibilidade de obter estimativas precisas da RUL, sendo necessária estar alinhada com os princípios do PHM.

Para essa análise o conjunto de dados usados é o FD001, proveniente do repositório C-MAPSS da NASA, no qual contém simulações de degradação de motores de aeronaves em condições controladas. Nesses dados constam as seguintes informações:

- Trajetórias de treino: 100 motores simulados até a falha (*run-to-failure*);

- Trajetórias de teste: 100 motores com tempo de operação parcial;
- Condições operacionais: Uma (nível do mar);
- Modo de falha: Um (degradação do compressor de alta pressão - HPC).

Cada linha do *dataset* representa o estado de um motor em um determinado ciclo de operação com as seguintes variáveis:

- *engine\_id*: identificação do motor de 1 a 100;
- *cycle*: ciclo de operação (tempo, em unidades de ciclo);
- *op\_setting1*, *op\_setting2*, *op\_setting3*: parâmetros operacionais como altitude, velocidade, etc;
- *sensor measurement 1 a 26 (s1 a s26)*: leituras de sensores que monitoram diferentes aspectos do motor (temperatura, pressão e vibração).

O primeiro passo é preparar a análise de dados com a modelagem Python. Portanto, na figura está acontecendo a leitura e o pré-processamento do *dataset*.

Tabela 3.1: Identificação do motor, configurações operacionais e sensores s1 a s5. Fonte: [60].

engine id	cycle	op setting1	op setting2	op setting3	s1	s2	s3	s4	s5
1	1	-0,0007	-0,0004	100,00	518,67	641,82	1589,70	1400,60	14,62
1	2	0,0019	-0,0003	100,0	518,67	642,15	1591,82	1403,14	14,62
1	3	-0,0043	0,0003	100,0	518,67	642,35	1587,99	1404,20	14,62
1	4	0,0007	0,0000	100,0	518,67	642,35	1582,79	1401,87	14,62
1	5	-0,0019	-0,0002	100,0	518,67	642,37	1582,85	1406,22	14,62

Tabela 3.2: Leitura dos sensores s6 a s21. Fonte: [60].

(...)	s12	s13	s14	s15	s16	s17	s18	s19	s20	s21
...	521,66	2388,02	8138,62	8,4195	0,03	392	2388	100,0	39,06	23,4190
...	522,28	2388,07	8131,49	8,4318	0,03	392	2388	100,0	39,00	23,4236
...	522,42	2388,03	8133,23	8,4178	0,03	390	2388	100,0	38,95	23,3442
...	522,86	2388,08	8133,83	8,3682	0,03	392	2388	100,0	38,88	23,3739
...	522,19	2388,04	8133,80	8,4294	0,03	393	2388	100,0	38,90	23,4044

O arquivo original tem 28 colunas, mas as últimas duas colunas (índices 26 e 27) são preenchidas com valores ausentes. Assim, elas são eliminadas para evitar inconsistências nos dados.

Em seguida, carrega-se os dados de vida útil remanescente (RUL) para o conjunto de testes, para que seja possível comparar as previsões feitas pelo modelo com o valor real, pode-se visualizar na figura 3.16. A coluna é renomeada para *time-to-failure* para representar claramente que contém o valor de RUL de cada motor.

```
# reading the truth data. this provides us test set of 100 engines with their actual time to failure.
aircraft_rul_df = pd.read_csv('CMAPSSData/RUL_FD001.txt', sep = ' ', header=None)
aircraft_rul_df = aircraft_rul_df.drop([1], 1)
aircraft_rul_df.columns = ['time-to-failure']
aircraft_rul_df.head()
```

Figura 3.16: RUL para os dados de teste. Fonte: [60].

É importante analisar os detalhes do conjunto de dados para obter mais informações. No conjunto de dados apresentados existem 3 configurações operacionais e 21 medições de sensores para cada motor. Com o código na figuras, é apresentado variáveis numéricas que incluem:

- count: número de valores não nulos;
- mean: média;
- std: desvio padrão;
- min: valor mínimo;
- 25%: primeiro quartil;
- 50%: mediana;
- 75%: terceiro quartil;
- max: valor máximo.

Tabela 3.3: Estatísticas descritivas: identificação do motor, configurações operacionais e sensores s1 a s4. Fonte: [60].

	engine cycle		setting1	setting2	setting3	s1	s2	s3	s4
count	20631	20631	20631	20631	20631	20631	20631	20631	20631
mean	51,51	108,87	-0,0001	0,0000	100,00	518,67	642,88	1590,52	1408,94
std	29,23	68,88	0,0022	0,0003	0,00	6,54e-11	0,50	6,13	9,00
min	1	1	-0,0087	-0,0006	100,00	518,67	641,21	1571,04	1382,52
25%	26	52	-0,0015	-0,0002	100,00	518,67	642,33	1586,62	1402,36
50%	52	104	0,0000	0,0000	100,00	518,67	642,64	1590,16	1408,44
75%	77	156	0,0015	0,0002	100,00	518,67	643,00	1594,38	1414,56
max	100	362	0,0087	0,0006	100,00	518,67	644,53	1616,91	1414,49

Tabela 3.4: Estatísticas descritivas dos sensores s5 a s21. Fonte: [60].

s5	(...)	s12	s13	s14	s15	s16	s17	s18	s19	s20	s21
20631	...	20631	20631	20631	20631	20631	20631	20631	20631	20631	20631
14,62	...	521,41	2388,10	8143,75	8,4421	0,03	393,21	2388,0	100,0	38,82	23,29
0,00	...	0,74	0,07	19,08	0,0375	0,00	1,55	0,0	0,0	0,18	0,11
14,62	...	518,69	2387,88	8099,94	8,3249	0,03	388,0	2388,0	100,0	38,14	22,89
14,62	...	520,96	2388,04	8133,25	8,4149	0,03	392,0	2388,0	100,0	38,70	23,22
14,62	...	521,48	2388,09	8140,54	8,4389	0,03	393,0	2388,0	100,0	38,83	23,30
14,62	...	521,95	2388,14	8148,31	8,4656	0,03	394,0	2388,0	100,0	38,95	23,37
14,62	...	523,38	2388,56	8293,72	8,5848	0,03	400,0	2388,0	100,0	39,43	23,62

Logo, a partir da descrição do conjunto de dados pode-se observar que contém 100 motores, com uma média de 108 ciclos por motor e com o tempo de cada motor que desenvolve uma condição de falha e o último ciclo de cada motor que representa a condição de falha. Assim, é possível prever as interrupções a partir das leituras dos sensores.

O passo seguinte é observar o histograma da fig 3.17 que as todas as variáveis são numéricas e contínuas e apenas a `op_setting2` e `S17` são variáveis discretas nos dados, ou seja, mudam em graus, o que pode indicar que são registradas em categorias ou níveis definidos. Além disso, nota-se que alguns sensores e configurações operacionais não mudam com o tempo, e como eles são constantes, podem ser removidos da análise.

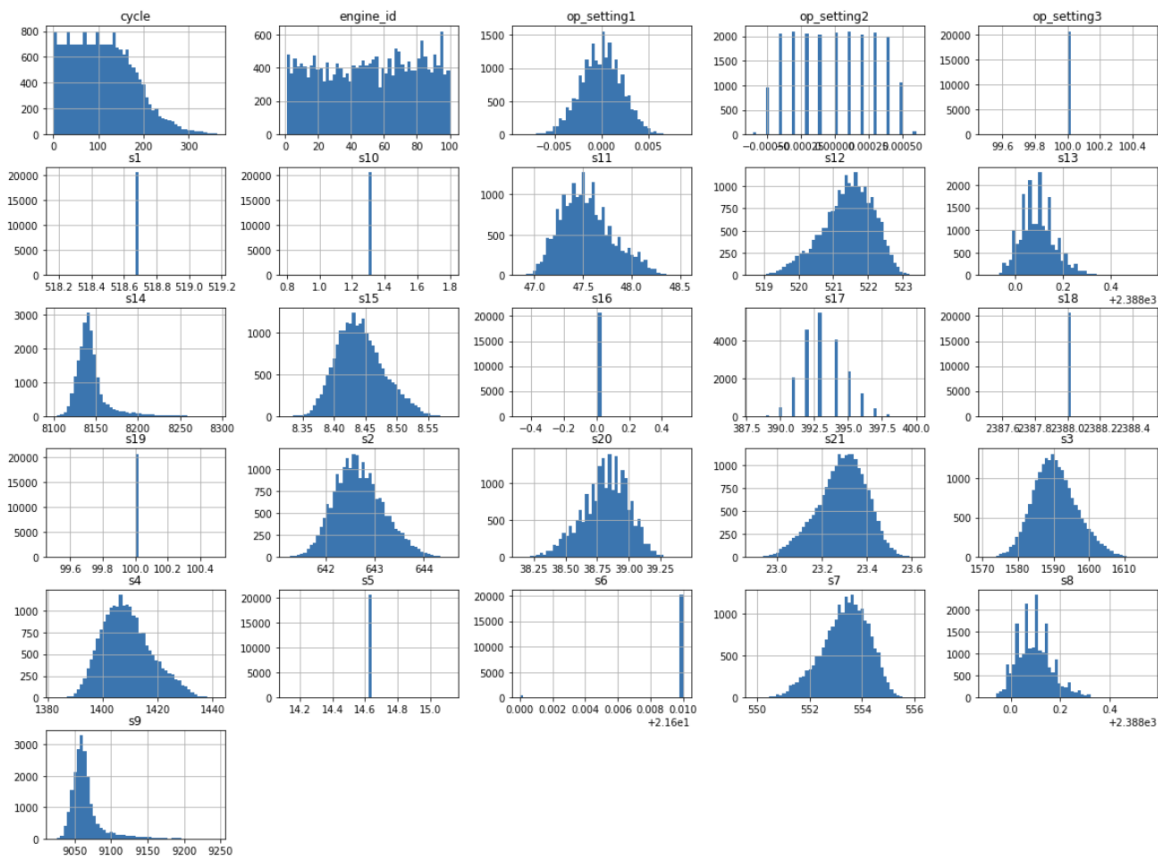


Figura 3.17: Histograma com as variáveis do conjunto de dados. Fonte: [60].

As variáveis que são constantes com o tempo são `op_setting3`, `s1`, `s5`, `s6`, `s10`, `s16`, `s18`, `s19`, essas variáveis podem ser removidas da análise durante a modelagem porque são praticamente constantes e não carregam informações úteis para prever falhas, podendo ser removidas do modelo para reduzir a dimensionalidade, melhorar a performance e evitar ruído desnecessário.

A próxima análise é através do gráfico de barra com a média de todas as colunas do conjunto de dados, como observado na figura 3.18.

O gráfico confirma visualmente que certas variáveis tem valores médios que são




Figura 3.18: Média de todas as colunas do conjunto de dados. Fonte: [60].

extremamente altos (s9, s14, s15), enquanto outras tem médias próximas de zero (op\_setting1, s6, s10, s16, s18, s19), que aparecem barras bem estreitas ou quase nulas, o que reforça a baixa variabilidade ou constância desses atributos.

Isso reflete escaladas diferentes entre sensores e configurações operacionais, e esse tipo de variação reforça a importância da normalização ou padronização dos dados antes de utilizar o algoritmos de aprendizado de máquina.

Outra análise realizada é da figura 3.19 abaixo, no qual mostra o desvio padrão de todas as colunas, usando escala logarítmica no eixo y. Isso permite destacar as diferenças em variabilidade, mesmo que algumas sejam extremamente pequenas.

Variáveis com desvio padrão próximo de zero são praticamente constantes e não agregam nenhuma informação para os modelos de machine learning. Essas colunas são removidas do *dataset* sem perda de desempenho.

As variáveis do gráfico praticamente constantes são op\_setting3, s1, s5, s6, s10, s16, s18 e s19.

O próximo trecho do código cria um mapa de calor *heatmap* para visualizar a matriz de correlação entre os parâmetros operacionais e os sensores do conjunto de dados, como pode-se visualizar na figura 3.20.




Figura 3.19: Desvio padrão de todas as colunas do conjunto de dados. Fonte: [60].

Na fig pode-se observar que o `op_setting1` e `op_setting2` tem correlação forte entre si (1.00), o que indica colinearidade entre os dados, isso significa que elas contêm informações semelhantes. Quando isso ocorre os modelos de machine learning ou regressão linear podem ter dificuldade em estimar os coeficientes de forma correta, isso pode gerar instabilidade nos modelos e dificultar a interpretação.

No *heatmap* da fig, visualiza-se que o `op_setting1` e `op_setting2` tem uma correlação de 1.0, o que significa que tem fortíssima colinearidade, são quase idênticas e que manter as duas pode ser redundante. A `s9` e `s14` tem correlação de 0.96 que são duas variáveis que fornecem quase a mesma informação. A `s8`, `s9` e `s14` são fortemente correlacionadas entre si, acima de 0.83, o que sugere um grupo de sensores alinhados, o que pode ser útil usar apenas um deles. E `s12` e `s13` tem correlação de 0.79, o que também apresenta colinearidade bastante significativa.

Enquanto as variáveis `op_setting3`, `s1`, `s5`, `s6`, `s10`, `s16`, `s18` e `s19` possuem baixa ou nenhuma correlação com qualquer outra, o que pode ser um indicativo de ser quase constante ao longo do tempo ou ter uma baixa variância, o que não contribui significativamente para o modelo.

O próximo passo é o pré-processamento dos dados e a extração de características




Figura 3.20: Matriz de correlação do conjunto de dados. Fonte: [60].

da vida útil restante da base de dados. A vida útil do motor é a diferença entre o ciclo máximo de cada motor e o ciclo atual, sendo a RUL a variável destaque para a tarefa de regressão. O código treino utilizado é apresentado na figura 3.21.

Esse código treino descobre até que ponto cada motor foi operado (ciclo final), calcula quantos ciclos faltam para chegar ao fim (RUL) e cria essa informação como variável-alvo na base de dados. O resultado é demonstrado nas tabelas 3.5 - 3.6.

Tabela 3.5: Resultado do conjunto de dados treino calculando o RUL - Parte 1. Fonte: [60].

engine id	cycle	op setting1	op setting2	op setting3	s1	s2	s3	s4	s5	(...)
1	1	-0,0007	-0,0004	100,00	518,67	641,82	1589,70	1400,60	14,62	(...)
1	2	0,0019	-0,0003	100,00	518,67	642,15	1591,82	1403,14	14,62	(...)
1	3	-0,0043	0,0003	100,00	518,67	642,35	1587,99	1404,20	14,62	(...)
1	4	0,0007	0,0000	100,00	518,67	642,35	1582,79	1401,87	14,62	(...)
1	5	-0,0019	-0,0002	100,00	518,67	642,37	1582,85	1406,22	14,62	(...)

```
# Remaining useful life feature creation for train dataset
data_RUL = pd.DataFrame(aircraft_train_df.groupby('engine_id')['cycle'].max()).reset_index()
data_RUL.columns = ['engine_id', 'max_cycle']
aircraft_train_df = aircraft_train_df.merge(data_RUL, on='engine_id', how='left')
aircraft_train_df['RUL'] = aircraft_train_df['max_cycle'] - aircraft_train_df['cycle']
aircraft_train_df = aircraft_train_df.drop('max_cycle', 1)
aircraft_train_df.head()
```

Figura 3.21: Código treino do conjunto de dados. Fonte: [60].

Tabela 3.6: Resultado do conjunto de dados treino calculando o RUL - Parte 2. Fonte: [60].

s13	s14	s15	s16	s17	s18	s19	s20	s21	RUL
2388,02	8138,62	8,4195	0,03	392	2388	100,0	39,06	23,4190	191
2388,07	8131,49	8,4318	0,03	392	2388	100,0	39,00	23,4236	190
2388,03	8133,23	8,4178	0,03	390	2388	100,0	38,95	23,3442	189
2388,08	8133,83	8,3682	0,03	392	2388	100,0	38,88	23,3739	188
2388,04	8133,80	8,4294	0,03	393	2388	100,0	38,90	23,4044	187

Em seguida, é extrair a RUL de um motor para todas as instâncias e utilizar no conjunto de teste. No conjunto de treino a falha aumenta em uma magnitude até ocorrer a falha total do sistema, já no conjunto de teste as séries temporais terminam um tempo antes da falha no sistema.

Esse processo prepara o conjunto de teste para que os modelos de regressão possam ser avaliados corretamente, comparando a RUL predita pelo modelo com a RUL real, que foi fornecida externamente. No código da figura 3.22, está tratando o conjunto de teste para calcular e anexar a variável RUL com base nos valores reais fornecidos.

O objetivo é estimar o número de ciclos operacionais restantes antes da falha no conjunto de teste, ou seja, no número de ciclos que o motor ainda vai operar após o último ciclo observado no teste. O conjunto de teste final é exibido nas tabelas 3.7 e 3.8.

Posteriormente, é feito uma análise de correlação entre as variáveis e a variável-alvo RUL no *dataset* de treino, como pode-se visualizar em figura 3.23.

O código apresentado calcula a matriz de correlação entre todas as variáveis, e em seguida seleciona a coluna de correlação com o RUL e ordena da maior para a menor, como visto na tabela 3.9.

```
valid_data = pd.DataFrame(aircraft_test_df.groupby('engine_id')['cycle'].max()).reset_index()
valid_data.columns = ['engine_id', 'last_cycle']
df_truth_data = pd.merge(aircraft_test_df, valid_data, on='engine_id')
df_truth_data[df_truth_data['cycle'] == df_truth_data['last_cycle']]
df_truth_data = df_truth_data.drop(['last_cycle'], 1)
df_truth_data.reset_index(drop=True, inplace=True)
df_truth_data = pd.concat([df_truth_data, aircraft_rul_df], axis=1)
df_test_data = df_truth_data.rename(columns={'time-to-failure': 'RUL'})
```

Figura 3.22: Código teste para calcular RUL. Fonte: [60].

Tabela 3.7: Resultado do conjunto de dados teste calculando o RUL - Parte 1. Fonte: [60].

engine id	cycle	op setting1	op setting2	op setting3	s1	s2	s3	s4	s5	(...)
1	31	-0,0006	0,0004	100,00	518,67	642,58	1581,22	1398,91	14,62	(...)
2	49	0,0018	-0,0001	100,00	518,67	642,55	1586,59	1410,84	14,62	(...)
3	126	-0,0016	0,0004	100,00	518,67	642,88	1589,75	1418,89	14,62	(...)
4	106	0,0012	0,0004	100,00	518,67	642,78	1594,53	1406,88	14,62	(...)
5	98	-0,0013	-0,0004	100,00	518,67	642,27	1589,94	1419,36	14,62	(...)

Tabela 3.8: Resultado do conjunto de dados teste calculando o RUL - Parte 2. Fonte: [60].

s13	s14	s15	s16	s17	s18	s19	s20	s21	RUL
2388,06	8130,11	8,4024	0,03	393	2388	100,0	38,81	23,3552	112
2388,09	8126,90	8,4505	0,03	391	2388	100,0	38,81	23,2618	98
2388,14	8131,46	8,4119	0,03	395	2388	100,0	38,93	23,2740	69
2388,11	8133,64	8,4634	0,03	395	2388	100,0	38,58	23,2581	82
2388,15	8125,74	8,4362	0,03	394	2388	100,0	38,75	23,4117	91

Na interpretação dos resultados temos que correlação forte e positiva da RUL são observadas em s12, s7, s21 e s20, porque apresentam alta correlação positiva com a vida útil, essas variáveis são boas candidatas para o modelo, porque possuem uma alta RUL, isto significa que elas crescem quando o motor ainda está em boas condições.

Em cycle, s11, s4, s15, s17, s2, s3 tem correlação negativa forte com a RUL, demonstrando que têm relação forte com a redução da RUL, e também são boas para modelos preditivos e identifica quando os motores estão perto da falha.

Entretanto, também há variáveis irrelevantes com correlação próxima a zero como s1, s5, s10, op\_setting1, op\_setting2, op\_setting3, s18 e s19. Essas variáveis podem ser descartadas para reduzir o ruído e a dimensionalidade.

Assim, a matriz de correlação, mostra a relação entre cada par de variáveis numéricas, os valores vão de -1 a 1:

- +1: correlação perfeitamente positiva;
- -1: correlação perfeitamente negativa;

```
# correlation of the all features with the RUL variable.
for col in aircraft_train_df.columns:
    aircraft_train_df[col] = pd.to_numeric(aircraft_train_df[col], errors='coerce')
corr_m = aircraft_train_df.corr()
corr_m['RUL'].sort_values(ascending=False)
```

Figura 3.23: Código para análise de correlação no conjunto de dados treino. Fonte: [60].

Tabela 3.9: Correlação entre as variáveis com o RUL. Fonte: [60].

Variável	Correlação com RUL
RUL	1,000000
s12	0,671983
s7	0,657227
s21	0,635662
s20	0,629423
engine_id	0,078753
s5	0,000000
s1	0,000000
s10	0,000000
s16	-0,003800
op_setting2	-0,001948
op_setting1	-0,003195
s6	-0,128844
s14	-0,030675
s9	-0,039011
s13	-0,562568
s8	-0,563964
s3	-0,584520
s17	-0,066135
s2	-0,664840
s15	-0,642670
s4	-0,789482
s11	-0,696221
cycle	-0,736240
op_setting3	NaN
s18	NaN
s19	NaN

```
attributes = ['op_setting1', 'op_setting2', 's2', 's3', 's4', 's7', 's8', 's9', 's11',
              's12', 's13', 's14', 's15', 's17', 's20', 's21']
for i in range(len(attributes)):
    sns.relplot(x=attributes[i], y="RUL", data=aircraft_train_df)
```

Figura 3.24: Código para gerar gráficos de dispersão entre as variáveis e o RUL. Fonte: [60].

- 0: nenhuma correlação linear.

Logo, é importante selecionar variáveis com maior correlação absoluta com RUL para obter um modelo mais eficiente e descartar as que tem correlação próxima a zero, pois não contribuem com a previsão.

Depois, será implementado o código para analisar os gráficos de dispersão para visualizar como cada variável relaciona-se com a variável-alvo RUL, visualizado na 3.24.

Na figura 3.25 abaixo, mostra uma grade de gráficos de dispersão entre as variáveis e a variável alvo RUL.

Para a interpretação do gráfico, será importante observar o padrão visual.

## Implementação de Estratégias de Inovação na Gestão da Manutenção Industrial

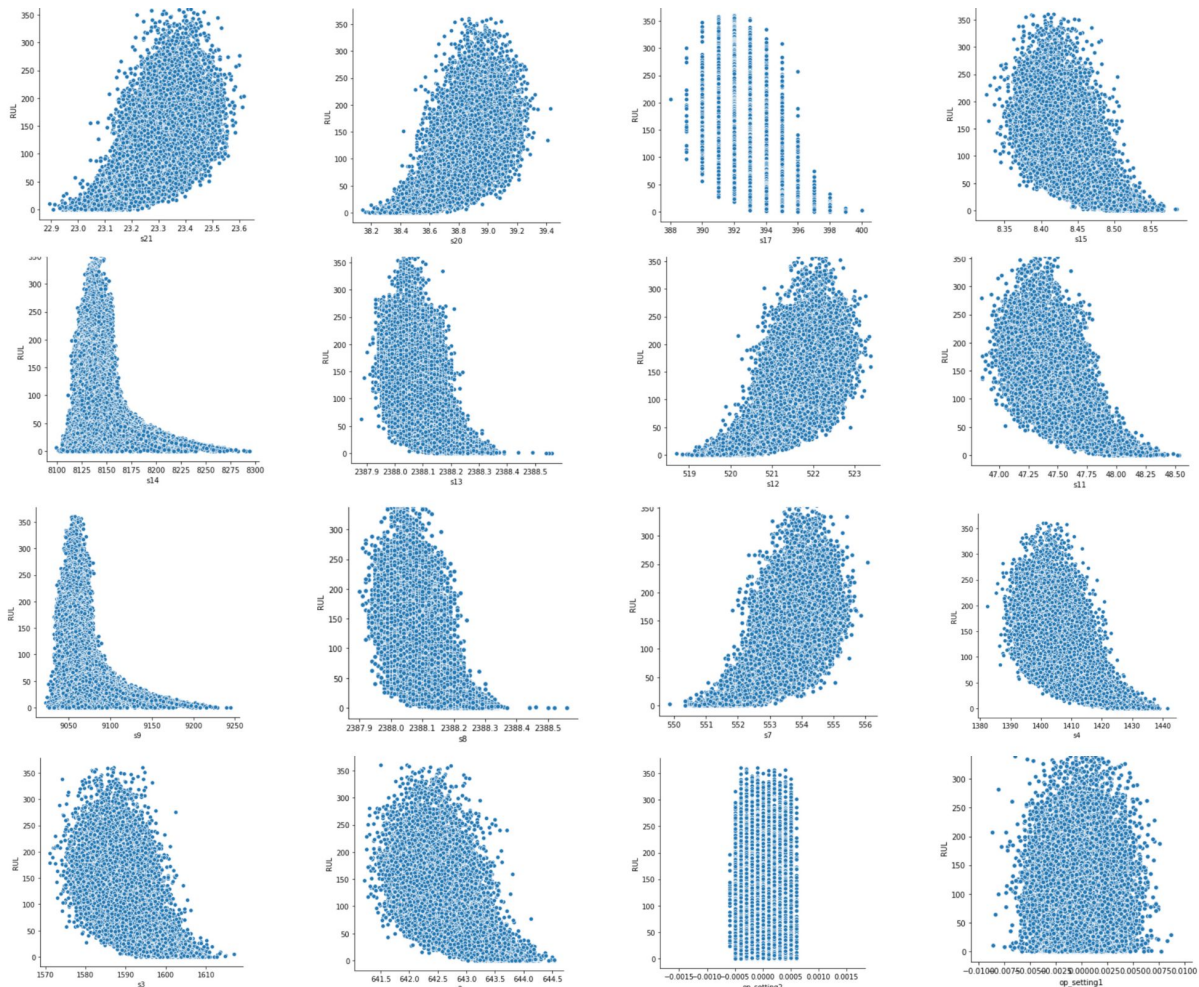


Figura 3.25: Gráficos de dispersão entre as variáveis e o RUL. Fonte: [60].

- Linha decrescente: Correlação negativa, o valor da variável aumenta conforme a RUL diminui, sinal de falha se aproximando;
- Linha crescente: Correlação positiva, valor cresce com RUL, apresenta bom estado do motor;
- Nuvem sem padrão: Pouca ou nenhuma correlação.

Na análise virtual por padrão temos que o s2, s7, s12, s21 e s20 mostram um padrão crescente suave, no qual quanto maior o valor do sensor, maior tende ser a RUL. No s3, s4, s11, s14, s15, s16, s17 demonstram padrões decrescentes bem definidos, com valores altos de sensor associados a menor RUL, indicando desgaste ou falha eminente.

No caso de op\_setting1, op\_setting2 possuem uma distribuição aleatória, sem padrão encontrado. E nas variáveis s13 e s16, estão densamente agrupadas, mas não seguem um padrão de regressão linear claro.

Agora utilizando o método `scatter_matrix` do `pandas` será usado um código para criar a matriz de dispersão entre os múltiplos atributos e a variável alvo RUL. O código é mostrado na figura 3.26

```
## Scatter Plot
from pandas.plotting import scatter_matrix
attributes = ['op_setting1', 'op_setting2', 's2', 's3', 's4', 's7', 's8', 's9', 's11',
            's12', 's13', 's14', 's15', 's17', 's20', 's21', 'RUL']
fig = scatter_matrix(aircraft_train_df[attributes], alpha=0.2, figsize=(15, 15))
plt.show()
```

Figura 3.26: Código para gerar gráfico de dispersão entre as variáveis. Fonte: [60].

O resultado da matriz de dispersão das variáveis é apresentado na figura 3.27 abaixo:




Figura 3.27: Gráfico de dispersão entre as variáveis. Fonte: [60].

A interpretação utilizada é que as variáveis com dispersões curvadas ou inclinadas mostram uma boa correlação com RUL, como s2, s3, s4, s7, s11, s12, s15, s20, s21 e variáveis com nuvem amorfa ou dispersa não trazem informações úteis, como op\_setting1, op\_setting2, s13 e s17.

Enquanto há pares com colineariedade entre as variáveis, com padrões de linhas clara, como s8 e s13, s9 e s14, s7 e s11, s4 e s12. Esses pares apresentam forte correlação entre si, ou seja, informação redundante.

```
#for random engine num 21
engine_id_21 = aircraft_train_df[aircraft_train_df['engine_id'] == 21]

# few sensor values are ignores since they don't change with time
feature_col = ['op_setting1', 'op_setting2', 's2', 's3', 's4', 's7', 's8', 's9', 's11', 's12', 's13', 's14', 's15', 's17', 's20', 's21']
engine_id_21 = engine_id_21[feature_col]
engine_id_21_plot = engine_id_21.plot(subplots=True, sharex=True, figsize=(20,20))
```

Figura 3.28: Código para representar gráficos com curvas temporais dos sensores para o motor 21. Fonte: [60].

A partir da matriz de dispersão, observa-se que a maioria das variáveis possui distribuições próximas da normalidade, embora algumas apresentem distorções. A relação entre as variáveis independentes e a variável alvo RUL não é majoritariamente linear, evidenciado através de padrões não lineares como curvaturas e distribuições em formato de cone ou funil.

O próximo código da figura 3.28, utilizado representa os gráficos com as curvas temporais dos sensores para o motor específico engine\_id=21 ao longo do tempo (ciclos).

Para interpretar os padrões do gráfico na figura 3.29 é utilizado a validação visual. É observado que o op\_setting1 e op\_setting2 apresentam variação leve ou ruído, mas sem uma tendência clara ao longo do tempo, assim confirma-se que os parâmetros não mudam muito com o desgaste do motor, isto é, são pouco úteis para prever falhar, assim como foi visto nas análises anteriores.

O s2, s3, s4, s7, s11 e s21 mostram uma queda gradual ou flutuação descendente, o que pode indicar deterioração do motor. Excelente para prever vida útil restante já que diminuem conforme o motor se aproxima do fim da vida.

O s9, s14, s17 e s20 são sensores com tendência crescente, eles aumentam de forma consistente com o tempo, podem indicar acúmulo de pressão ou desgaste e são inversamente relacionados à RUL.

O s8, s13 e s15 possuem flutuações mais aleatórias, mas ainda assim podem ter relação com falha em combinação com outros sensores.

O mesmo foi feito para o motor número 61, e no qual resultou no gráfico de dispersão da figura 3.30.

Os padrões de comportamento do motor 61 indica que as variáveis s2, s11, s12, s20 e s21 mostram uma queda suave ou contínua, o que é normal para sensores que diminuem conforme o motor se desgasta. Demonstrando uma tendência ligada à proximidade de falha.

Os sensores com comportamento ascendentes demonstram crescimento ao longo do tempo e no qual podemos visualizar o s3, s8, s14 e o s17, indicando possível acúmulo de vibração, temperatura ou outra variável associada ao desgaste.




Figura 3.29: Gráficos com curvas temporais dos sensores para o motor 21. Fonte: [60].

Enquanto o `op_setting1`, `op_setting2`, `s13` e `s15` variam pouco ou apenas oscilam, sem um padrão consistente e aparecem de forma aleatória.

Ao analisar o motor 21 com 61, percebe-se que há padrões similares nas variáveis `s3`, `s8` e `s14` de crescimento e `s2`, `s12` e `s21` de redução. Isso reforça que certos sensores tem comportamento consistente entre os motores, o que torna bons preditores da RUL.

Os modelos de similaridade são utilizados para a estimativa RUL, no qual a previsão de uma máquina teste é feita com base no comportamento conhecido de máquinas semelhantes a partir de um histórico de banco de dados. Esses modelos comparam uma tendência nos dados de teste ou valores do indicador de condição com as mesmas informações extraídas de um sistema semelhante.

A próxima etapa é utilizar análises de regressão para prever o RUL, essas estimativas são expressas em unidades de tempo (ciclos/horas/quilometragem). Nas análises de regressão são utilizados modelos lineares e não lineares:

- Regressão linear: Estima uma relação linear entre variáveis por meio do método dos mínimos quadrados;




Figura 3.30: Gráficos com curvas temporais dos sensores para o motor 61. Fonte: [60].

- **Árvore de decisão:** Divide os dados em ramos com base em regras, retornando a média das observações nos nós terminais;
- **Regressão polinomial:** Modela relações não lineares como polinômios de grau  $n$ ;
- **Lasso:** Variante da regressão linear com penalização L1, que ajuda na seleção de variáveis e redução do overfitting;
- **Random Forest:** Conjunto de árvores de regressão que trabalham em paralelo e retornam a média das previsões;
- **LightGBM:** Algoritmo de gradient boosting rápido, eficiente e leve, ideal para grandes volumes de dados;
- **XGBoost:** Algoritmo otimizado de boosting por gradiente, altamente preciso e utilizado em problemas supervisionados;
- **CatBoost:** Variante de boosting que lida bem com dados categóricos e evita overfitting com parada antecipada.

Em seguida, também é importante compreender as métricas de avaliação dos

modelos:

- R2\_score: Mede o quanto da variabilidade dos dados é explicada pelo modelo (0 a 100%)
- RMSE: Avalia a precisão das previsões. Quanto menor, melhor.
- MAE: Mede o erro médio absoluto entre as previsões e os valores reais.
- MSE: Calcula o erro quadrático médio, penalizando os erros grandes.

Para o modelo do sistema, a figura 3.31 abaixo mostra os indicadores de condição identificados sendo avaliados e fornecidos como entrada para o modelo.

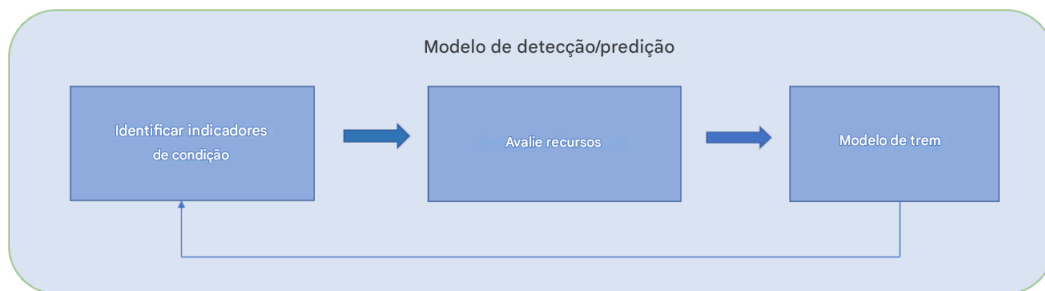


Figura 3.31: Modelo de predição. Fonte: [60].

Ao identificar os indicadores de condição nas medições de valor do sensor e nas condições operacionais, avaliamos a importância das variáveis. Com as variáveis identificadas, treinamos o modelo e a variável-alvo RUL é prevista. No código da figura 3.32 abaixo mostra a importação das bibliotecas necessárias para treinar, validar e avaliar modelos de regressão aplicados à estimativa RUL.

A etapa seguinte é a seleção de variáveis para o modelo como pode-se observar na figura 3.33. As variáveis escolhidas foram selecionadas porque estão correlacionadas com a variável alvo RUL.

```

from sklearn import model_selection
from sklearn.linear_model import LinearRegression
from sklearn.tree import DecisionTreeRegressor
from sklearn.model_selection import RepeatedKFold
from sklearn.ensemble import RandomForestRegressor
from sklearn import metrics
from sklearn.model_selection import cross_val_score
from matplotlib import pyplot
from numpy import mean
from numpy import std
from sklearn.metrics import r2_score, mean_absolute_error, mean_squared_error
  
```

Figura 3.32: Código para importação de bibliotecas necessárias para estimar RUL. Fonte: [60].

```
features = ['op_setting1', 'op_setting2', 's2', 's3', 's4', 's7', 's8', 's9', 's11', 's12', 's13', 's14', 's15', 's17', 's20', 's21']  
  
#Features which are constant with time are not considered for modelling  
# features_orig = ['op_setting1', 'op_setting2', 'op_setting3', 's1', 's2', 's3', 's4', 's5', 's6', 's7', 's8', 's9', 's10', 's11', 's12', 's13', 's14', 's15',  
# 's17', 's18', 's19', 's20', 's21']  
# features = features_orig
```

Figura 3.33: Variáveis selecionadas para correlacionar com RUL. Fonte: [60].

O próximo código da figura 3.34 é a divisão de dados de treinamento e teste. Lembrando que os dados de treinamento são usados para treinar o modelo de aprendizado de máquina, e os dados de teste são usados para a validação.

```
X_train = aircraft_train_df[features]  
y_train = aircraft_train_df['RUL']  
  
X_test = df_test_data[features]  
y_test = df_test_data['RUL']  
  
#Selecting numerical dataframe in train set  
x_train_num = X_train.select_dtypes(include=np.number)  
  
#Selecting categorical dataframe in train set  
x_train_cat = X_train.select_dtypes(exclude=['number'])
```

Figura 3.34: Código de divisão de dados de treinamento e teste. Fonte: [60].

Como tem apenas variáveis numéricas nos dados, o pipeline é construído com os dados numéricos. Se houver muitos valores discrepantes nos dados, eles influenciarão a média e o valor máximo ou mínimo. Utiliza-se o `RobustScaler` para remover a mediana dos dados e dimensiona pelo Intervalo Interquartil (IQR), tornando-o robusto contra outliers.

O *pipeline* é útil para encadear as transformações e facilita a integração com os modelos de machine learning.

No código apresentado abaixo nas figura 3.35 e 3.36 é demonstrado o passo-a-passo para preparar os dados de treino e teste para um modelo *machine learning*.

Para a construção de um *pipeline* robusto é necessário os seguintes passos:

- O primeiro passo é importar as bibliotecas necessárias;
- Em seguida, definir as pipelines para os dados numéricos e para os dados categóricos;
- Separa e cria os nomes das colunas numéricas e categóricas;
- Depois, combina os dois pipelines em um único transformador;
- Transforma os dados de treino e de teste;
- Verifica as dimensões do resultado;
- Tentativa de obter os nomes das variáveis transformadas.

O primeiro modelo aplicado será a regressão linear, incluindo a modelagem, avaliação e visualização. Na figura fig:imgs28, tem o código para criar o modelo de regres-

```

from sklearn.impute import SimpleImputer
from sklearn.pipeline import Pipeline
from sklearn.preprocessing import OneHotEncoder
from sklearn.preprocessing import RobustScaler, StandardScaler

num_pipeline = Pipeline([('imputer', SimpleImputer(strategy='constant', fill_value=0)), ('robust_scaler', RobustScaler())])
cat_pipeline = Pipeline([('imputer', SimpleImputer(strategy='most_frequent', fill_value=0)), ('onehot', OneHotEncoder(handle_unknown='ignore'))])

from sklearn.compose import ColumnTransformer
from sklearn.preprocessing import OneHotEncoder

num_attribs = list(x_train_num.columns)
cat_attribs = list(x_train_cat.columns)

#full pipeline of numeric attributes
full_pipeline = ColumnTransformer([("num", num_pipeline, num_attribs), ("cat", cat_pipeline, cat_attribs)])

#Using full_pipeline perform fit and transform on training data
x_train_prepared = full_pipeline.fit_transform(X_train)

x_test_prepared = full_pipeline.transform(X_test)

x_train_prepared.shape

x_test_prepared.shape

full_pipeline.get_feature_names

```

Figura 3.35: Código com passo-a-passo para preparar os dados de treino e teste - Parte 1. Fonte: [60].

```

<bound method ColumnTransformer.get_feature_names of ColumnTransformer(n_jobs=None, remainder='drop', sparse_threshold=0.3,
transformer_weights=None,
transformers=[('num',
Pipeline(memory=None,
steps=[('imputer',
SimpleImputer(add_indicator=False,
copy=True,
fill_value=0,
missing_values=nan,
strategy='constant',
verbose=0)),
('robust_scaler',
RobustScaler(copy=True,
quantile_range=(25.0,
75.0),
with_centering=True,
wi...
's4', 's7', 's8', 's9', 's11', 's12', 's13',
's14', 's15', 's17', 's20', 's21')),
('cat',
Pipeline(memory=None,
steps=[('imputer',
SimpleImputer(add_indicator=False,
copy=True,
fill_value=0,
missing_values=nan,
strategy='most_frequent',
verbose=0)),
('onehot',
OneHotEncoder(categories='auto',
drop=None,
dtype=<class 'numpy.float64'>,
handle_unknown='ignore',
sparse=True))],
verbose=False),
[]]),
verbose=False]>

```

Figura 3.36: Código com passo-a-passo para preparar os dados de treino e teste - Parte 2. Fonte: [60].

## Implementação de Estratégias de Inovação na Gestão da Manutenção Industrial

```
model_linear = LinearRegression(fit_intercept=True, normalize=False, copy_X=True, n_jobs=None)
model_linear.fit(x_train_prepared, y_train)
model_linear_train_predictions = model_linear.predict(x_train_prepared)
model_linear_test_predictions = model_linear.predict(x_test_prepared)

print('Root Mean Squared Error:', (metrics.mean_squared_error(y_test, model_linear_test_predictions)**0.5))
print('Mean Absolute Error:', (metrics.mean_absolute_error(y_test, model_linear_test_predictions)))

print("r2_score on Train data :", r2_score(y_train, model_linear_train_predictions))
print("r2_score on Test data :", r2_score(y_test, model_linear_test_predictions))
print(' ')
print("Cross Validation on Training Data")
cv = RepeatedKFold(n_splits=10, n_repeats=3, random_state=1)
n_scores = cross_val_score(model_linear, x_train_prepared, y_train, scoring='neg_mean_absolute_error', cv=cv, n_jobs=-1, error_score='raise')
print('MAE: %.3f (%.3f)' % (mean(n_scores), std(n_scores)))
print("Cross validation score:", cross_val_score(model_linear, x_train_prepared, y_train, cv=cv))
```

Figura 3.37: Código com aplicação de modelo de regressão linear. Fonte: [60].

```
from yellowbrick.regressor import ResidualsPlot
visualizer = ResidualsPlot(model_linear, hist=False)

visualizer.fit(x_train_prepared, y_train) # Fit the training data to the visualizer
visualizer.score(x_test_prepared, y_test) # Evaluate the model on the test data
visualizer.show()
```

Figura 3.38: Código para gerar gráfico de resíduos da regressão linear. Fonte: [60].

são linear.

O resultado é apresentado abaixo na tabela 3.10.

Tabela 3.10: Resultados do Modelo de Regressão Linear

Métrica	Valor	Interpretação
Erro Quadrático Médio (RMSE)	32,04 ciclos	Erro médio de 32 ciclos; penaliza mais os erros grandes
Erro Absoluto Médio (MAE)	25,59 ciclos	Em média, o modelo erra por cerca de 25 ciclos
Coeficiente de Determinação (R <sup>2</sup> ) – Treino	0,579	O modelo explica 57,9% da variância nos dados de treino
Coeficiente de Determinação (R <sup>2</sup> ) – Teste	0,405	O modelo explica 40,5% da variância nos dados de teste
MAE (Validação Cruzada)	-34,14 ± 0,72	Erro médio de 34 ciclos nos 30 folds (valor negativo é convenção do sklearn)
R <sup>2</sup> nos folds da Validação Cruzada	~0,55 a ~0,60	Estável entre as repetições, sem grandes variações — boa generalização

Em seguida, é solicitado um código da 3.38 para gerar um gráfico de resíduos. Esse gráfico mostra se o modelo está cometendo erros sistemáticos, que indica problemas como falta de linearidade, variância não constante e outros.

O gráfico gerado é representado em Fig 38, no qual os pontos azuis são resíduos do conjunto de treinamento e os pontos verdes são resíduos do conjunto de teste.

Como interpretação visual, tem-se que o modelo comete erros para cima e para

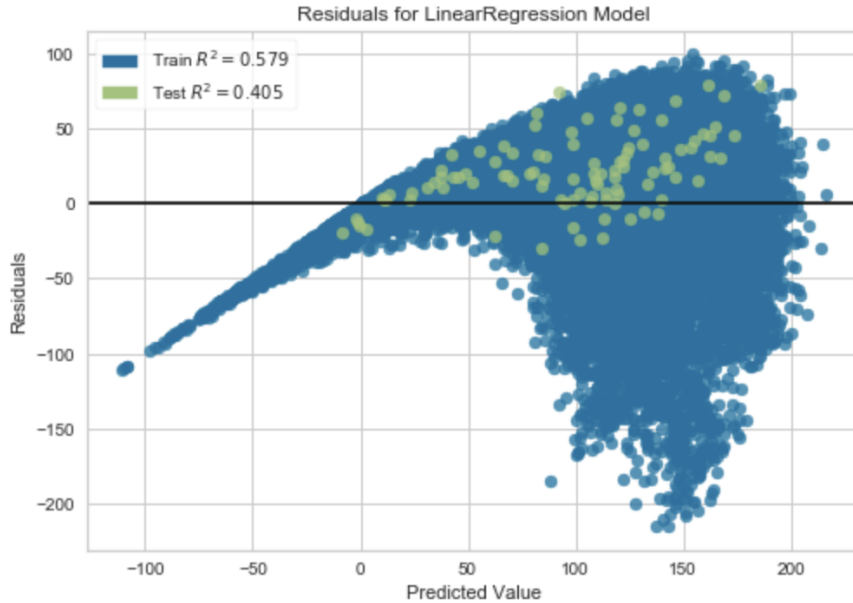


Figura 3.39: Gráfico de resíduos da regressão linear. Fonte: [60].

baixo, como esperado. Entretanto, o modelo funciona melhor para valores menores de RUL e piora com valores maiores. Além disso, não há padrão evidente de erro sistemático, o que é desejável.

O próximo passo é buscar o erro de predição, no qual, representa o desempenho do modelo na hora de prever a variável de resposta. Para avaliar, calcula-se os modelos previstos e comparamos com os valores reais, gerando um gráfico que relaciona as previsões com os resultados observados. O código usado é citado na 3.40 abaixo:

```
from yellowbrick.regressor import prediction_error
visualizer = prediction_error(model_linear, x_train_prepared, y_train, x_test_prepared, y_test)
```

Figura 3.40: Código para gerar gráfico com erro da predição da regressão linear. Fonte: [60].

No gráfico da figura 3.41 a seguir, é apresentada a curva de regressão ajustada e a distribuição dos erros de predição para o conjunto de teste. O coeficiente de determinação ( $R^2$ ) obtido foi de 0,405, no qual indica que o modelo é capaz de explicar aproximadamente 40,5% da variância dos dados de teste.

Em seguida, o código aplicado na figura 3.42 gera um gráfico de comparação entre valores reais e valores previstos da variável alvo RUL, com os números dos motores representados no eixo X.

Na figura 3.43, a linha azul representa os valores reais observados no conjunto de teste, enquanto a linha verde mostra as previsões geradas pelo modelo de regressão. Quanto mais próximo os valores entre os previstos e os reais, pode-se identificar que o modelo consegue capturar adequadamente a tendência dos dados. A linha preta




Figura 3.41: Gráfico de erro da predição da regressão linear. Fonte: [60].

```
fig = plt.figure(figsize=(10, 5))
plt.plot(y_test, color="blue")
plt.plot(model_linear_test_predictions, color="green")
plt.title('prediction')
plt.ylabel('Cycles')
plt.xlabel('Engines')
plt.legend(['Actual', 'Prediction'], loc='upper right')
plt.show()
```

Figura 3.42: Código para o gráfico de comparação entre valores reais e valores previstos da variável RUL na regressão linear. Fonte: [60].

horizontal em zero representa o erro ideal, sem resíduo.

Uma boa sobreposição entre as duas curvas indica um bom desempenho preditivo. Divergências maiores podem indicar limitações do modelo ou a necessidade de ajustes.

A próxima análise é utilizar a regressão polinomial. Os mesmos passos aplicados para a regressão linear, foi aplicada na regressão polinomial, incluindo a modelagem, avaliação e visualização.

Os códigos implementados na regressão polinomial podem ser observados na figura 3.44:

Os resultados do modelo de regressão polinomial são demonstrado na tabela 3.11 a seguir:

O gráfico de resíduos da regressão polinomial pode ser avaliado na figura 3.45.




Figura 3.43: Gráfico de comparação entre valores reais e valores previstos da variável RUL na regressão linear. Fonte: [60].

```

from sklearn.preprocessing import PolynomialFeatures

poly_features = PolynomialFeatures(degree=2, include_bias=False)

x_train_prepared_poly = poly_features.fit_transform(x_train_prepared)
x_test_prepared_poly = poly_features.fit_transform(x_test_prepared)

poly_reg = LinearRegression()
poly_reg.fit(x_train_prepared_poly, y_train)

poly_reg_train_predict = poly_reg.predict(x_train_prepared_poly)
poly_reg_test_predict = poly_reg.predict(x_test_prepared_poly)

print('Root Mean Squared Error:', (metrics.mean_squared_error(y_test, poly_reg_test_predict)**0.5))
print('Mean Absolute Error:', (metrics.mean_absolute_error(y_test, poly_reg_test_predict)))
print("r2_score on Train data :", r2_score(y_train, poly_reg_train_predict))
print("r2_score on Test data :", r2_score(y_test, poly_reg_test_predict))
print(' ')
print("Cross Validation on Training Data")
cv = RepeatedKFold(n_splits=10, n_repeats=3, random_state=1)
n_scores = cross_val_score(poly_reg, x_train_prepared, y_train, scoring='neg_mean_absolute_error', cv=cv, n_jobs=-1, error_score='raise')
print('MAE: %.3f (%.3f)' % (mean(n_scores), std(n_scores)))
print("Cross validation score:", cross_val_score(poly_reg, x_train_prepared_poly, y_train, cv=cv))

```

Figura 3.44: Código de implementação da regressão polinomial. Fonte: [60].

No gráfico de dispersão através da regressão polinomial observa-se que há uma distribuição mais concentrada em torno da linha zero, principalmente nos dados de teste, quando comparado ao modelo de regressão linear simples. Isso sugere que o modelo polinomial é mais eficiente nas relações não-lineares, como também refletido na melhoria do coeficiente de terminação  $R^2 = 0,433$ .

Em seguida é gerado o gráfico de erro de predição, no qual o coeficiente de determinação indica que o modelo explica cerca de 43,3% da variância dos dados de teste, um resultado superior ao obtido pela regressão linear simples.

Agora, ocorre a comparação entre os valores reais e previstos na regressão polinomial. No gráfico de linha da fig abaixo, pode-se visualizar os valores reais em linha azul e os valores previstos em linha verde da variável alvo.

Tabela 3.11: Resultados do Modelo de Regressão Polinomial (grau 2)

Métrica	Valor	Interpretação
Erro Quadrático Médio (RMSE)	31,28 ciclos	O erro médio das previsões foi de 31 ciclos, menor que o do modelo linear
Erro Absoluto Médio (MAE)	23,85 ciclos	Em média, o modelo erra por cerca de 23 ciclos, indicando melhora nas previsões
Coeficiente de Determinação (R <sup>2</sup> ) – Treino	0,627	O modelo explica 62,7% da variância dos dados de treino
Coeficiente de Determinação (R <sup>2</sup> ) – Teste	0,433	O modelo explica 43,3% da variância nos dados de teste, superior à regressão linear
MAE (Validação Cruzada)	-34,14 ± 0,72	Erro médio nos 30 folds da validação cruzada; valor negativo por convenção do sklearn
R <sup>2</sup> nos folds da Validação Cruzada	~0,60 a ~0,65	O modelo apresentou R <sup>2</sup> estável entre os folds, com boa capacidade preditiva




Figura 3.45: Gráfico de resíduos da regressão polinomial. Fonte: [60].

Apesar de alguma variação entre os valores reais e os previstos, observa-se uma tendência comum nas curvas, o que sugere que o modelo consegue captar parte importante do comportamento da variável alvo.

O próximo modelo para análise é regressão com árvores de decisão. Esse modelo é não linear baseado em aprendizado por partições em estruturas de árvores. Abaixo pode-se visualizar o código utilizado para o estudo na figura 3.48.

O resultado encontrado é demonstrado com as interpretações na tabela 3.12.

Em seguida é aplicado uma técnica de otimização de hiperparâmetros para um modelo de árvore de decisão. Foram testados 10 combinações de parâmetros em 5

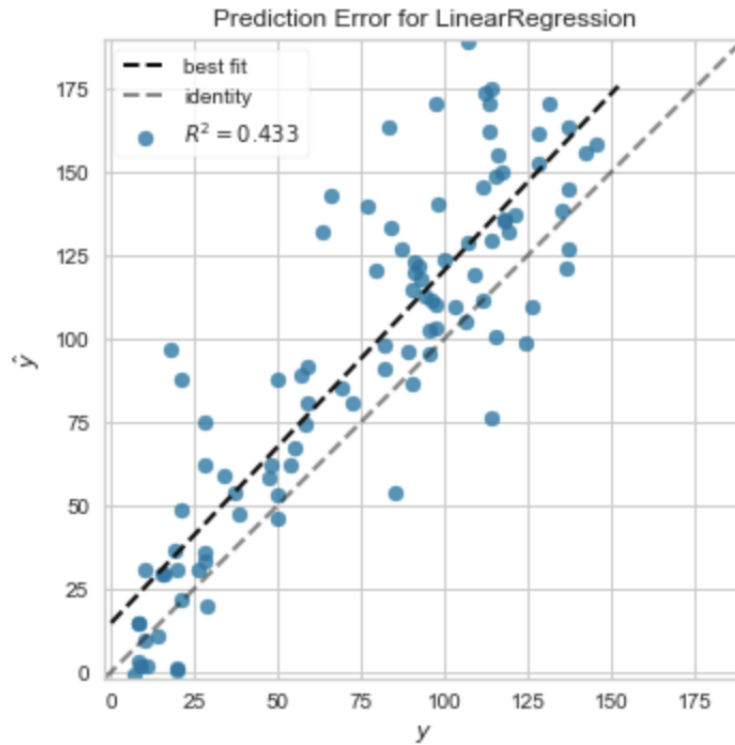


Figura 3.46: Gráfico de erro de predição da regressão polinomial. Fonte: [60].




Figura 3.47: Gráfico de comparação entre os valores reais e previstos na regressão polinomial. Fonte: [60].

divisões de validação cruzada cada, totalizando 50 execuções. O código implementado está descrito nas figuras 3.48 e na 3.50.

Os resultados encontrados foram descritos na tabela 3.13.

Após implementar o código para o gráfico de resíduos, observa-se na figura ?? que há uma concentração maior dos resíduos abaixo da linha de zero, especialmente

```

model_dt = DecisionTreeRegressor(max_depth=7)
# fit the model on the whole dataset
model_dt.fit(x_train_prepared, y_train)
model_dt_train_predictions = model_dt.predict(x_train_prepared)
model_dt_test_predictions = model_dt.predict(x_test_prepared)

print('Root Mean Squared Error:', (metrics.mean_squared_error(y_test, model_dt_test_predictions)**0.5))
print('Mean Absolute Error:', (metrics.mean_absolute_error(y_test, model_dt_test_predictions)))

print("r2_score on Train data :", r2_score(y_train,model_dt_train_predictions))
print("r2_score on Test data :", r2_score(y_test,model_dt_test_predictions))
print(' ')
cv = RepeatedKFold(n_splits=10, n_repeats=3, random_state=1)
n_scores = cross_val_score(model_dt, x_train_prepared, y_train, scoring='neg_mean_absolute_error', cv=cv, n_jobs=-1, error_score='raise')
print('MAE: %.3f (%.3f)' % (mean(n_scores), std(n_scores)))
print("Cross validation score:", cross_val_score(model_dt, x_train_prepared, y_train, cv=cv))

```

Figura 3.48: Código para implementação da regressão com árvores de decisão. Fonte: [60].

```

from sklearn.model_selection import RandomizedSearchCV
model_dt = DecisionTreeRegressor()

parametr = {"criterion": ["mse", "mae"],
            "min_samples_split": [2, 4, 6, 8, 10],
            "max_depth": [2, 3, 4, 5, 6, 7, 8],
            "min_samples_leaf": [1, 2, 3, 4, 5],}

dt_model= RandomizedSearchCV(model_dt, parametr, verbose=2, random_state=42, n_jobs = -1)
dt_model.fit(x_train_prepared, y_train)

Fitting 5 folds for each of 10 candidates, totalling 50 fits
[Parallel(n_jobs=-1)]: Using backend LokyBackend with 12 concurrent workers.
[Parallel(n_jobs=-1)]: Done 17 tasks | elapsed: 47.3s
[Parallel(n_jobs=-1)]: Done 50 out of 50 | elapsed: 2.4min finished

RandomizedSearchCV(cv=None, error_score=nan,
                  estimator=DecisionTreeRegressor(ccp_alpha=0.0,
                                                    criterion='mse',
                                                    max_depth=None,
                                                    max_features=None,
                                                    max_leaf_nodes=None,
                                                    min_impurity_decrease=0.0,
                                                    min_impurity_split=None,
                                                    min_samples_leaf=1,
                                                    min_samples_split=2,
                                                    min_weight_fraction_leaf=0.0,
                                                    presort='deprecated',
                                                    random_state=None,
                                                    splitter='best'),

```

Figura 3.49: Código para implementação de técnica de otimização de hiperparâmetros em árvores de decisão - Parte 1. Fonte: [60].

Tabela 3.12: Resultados do Modelo de Regressão com Árvore de Decisão (profundidade = 7)

Métrica	Valor	Interpretação
Erro Quadrático Médio (RMSE)	32,10 ciclos	O modelo erra em média 32 ciclos, desempenho comparável à regressão linear
Erro Absoluto Médio (MAE)	24,32 ciclos	Previsões com menor erro absoluto médio que a regressão linear
Coefficiente de Determinação ( $R^2$ ) – Treino	0,625	Explica 62,5% da variância no conjunto de treino
Coefficiente de Determinação ( $R^2$ ) – Teste	0,403	Explica 40,3% da variância no conjunto de teste
MAE (Validação Cruzada)	$-31,62 \pm 0,68$	Média do erro absoluto nos 30 folds da validação cruzada; negativo por convenção do sklearn
$R^2$ nos folds da Validação Cruzada	$\sim 0,57$ a $\sim 0,62$	Scores consistentes entre os folds, com boa generalização

Tabela 3.13: Resultados do Modelo de Regressão com Árvore de Decisão após Otimização de Hiperparâmetros

Métrica	Valor	Interpretação
Erro Quadrático Médio (RMSE)	30,81 ciclos	Erro médio reduzido após otimização dos hiperparâmetros
Erro Absoluto Médio (MAE)	23,60 ciclos	Previsões com erro absoluto médio menor que o modelo anterior
Coefficiente de Determinação ( $R^2$ ) – Treino	0,608	Modelo explica 60,8% da variância nos dados de treino
Coefficiente de Determinação ( $R^2$ ) – Teste	0,450	Explica 45,0% da variância nos dados de teste; melhora em relação ao modelo base

para valores previstos mais altos, indicando uma tendência do modelo em subestimar o RUL em algumas faixas.

Ainda assim, a dispersão dos pontos é mais homogênea do que nos modelos anteriores, e o coeficiente de determinação  $R^2=0,450$  no conjunto teste mostra uma melhora em relação ao modelo sem afinação.

Em seguida, temos o gráfico de erro de predição, como pode ser visualizado na figura 3.52.

O coeficiente de determinação  $R^2=0,450$  mostra uma melhoria significativa em relação aos modelos anteriores. A proximidade da linha de melhor ajuste com a linha de identidade indica que o modelo apresenta uma boa capacidade de generalização.

A dispersão ainda existe ao redor da linha revela que, embora o modelo tenha melhorado, ainda há casos em que a previsão não é tão precisa, especialmente em va-

```

        splitter='best'),

iid='deprecated', n_iter=10, n_jobs=-1,
param_distributions={'criterion': ['mse', 'mae'],
                    'max_depth': [2, 3, 4, 5, 6, 7, 8],
                    'min_samples_leaf': [1, 2, 3, 4, 5],
                    'min_samples_split': [2, 4, 6, 8, 10]},
pre_dispatch='2*n_jobs', random_state=42, refit=True,
return_train_score=False, scoring=None, verbose=2)

dt_model.best_params_

{'min_samples_split': 10,
 'min_samples_leaf': 1,
 'max_depth': 7,
 'criterion': 'mae'}

dt_model_train_predictions = dt_model.predict(x_train_prepared)
dt_model_test_predictions = dt_model.predict(x_test_prepared)

print("r2_score on Train data :", r2_score(y_train,dt_model_train_predictions))
print("r2_score on Test data :", r2_score(y_test,dt_model_test_predictions))

print('Root Mean Squared Error:', (metrics.mean_squared_error(y_test, dt_model_test_predictions)**0.5))
print('Mean Absolute Error:', (metrics.mean_absolute_error(y_test, dt_model_test_predictions)))

```

Figura 3.50: Código para implementação de técnica de otimização de hiperparâmetros em árvores de decisão - Parte 2. Fonte: [60].

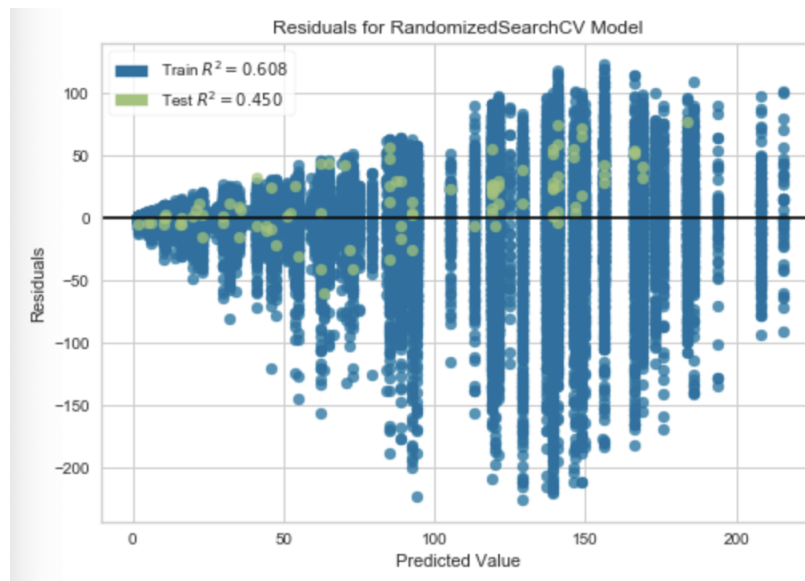


Figura 3.51: Gráfico de resíduos com técnica de otimização de hiperparâmetros em árvores de decisão. Fonte: [60].

lores médios de RUL.

Na figura 3.53, mostra a comparação entre os valores reais e previstos pelo modelo de árvore de decisão com hiperparâmetros otimizados ao longo dos motores no conjunto do teste.

Observa-se que as curvas seguem padrões semelhantes, com o modelo conseguindo acompanhar variações abruptas de forma razoável. Apesar de alguns desvios,




Figura 3.52: Gráfico de erro de predição com técnica de otimização de hiperparâmetros em árvores de decisão. Fonte: [60].

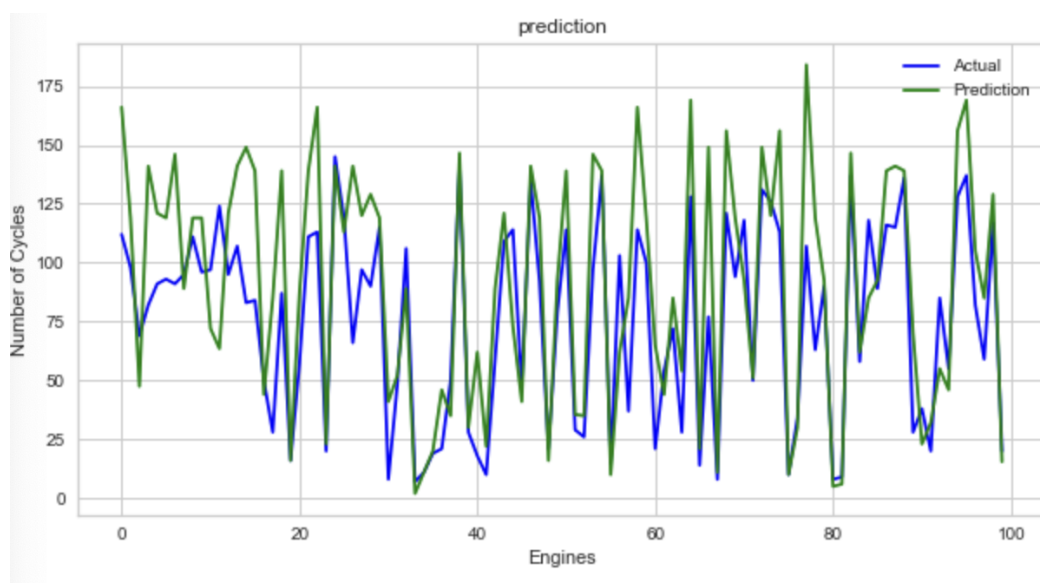


Figura 3.53: Gráfico de comparação entre os valores reais e previstos pelo modelo de árvore de decisão com hiperparâmetros otimizado. Fonte: [60].

principalmente em valores mais altos, o modelo otimizado consegue aproximar-se da tendência real.

Essa visualização evidencia a melhoria do modelo após a otimização dos hiperparâmetros, tornando mais confiável na predição da vida útil das aeronaves.

```

from sklearn.linear_model import Lasso

model_lasso = Lasso(alpha=0.01)

model_lasso.fit(x_train_prepared, y_train)
model_lasso_train_predictions = model_lasso.predict(x_train_prepared)
model_lasso_test_predictions = model_lasso.predict(x_test_prepared)

print('Root Mean Squared Error:', (metrics.mean_squared_error(y_test, model_lasso_test_predictions)**0.5))
print('Mean Absolute Error:', (metrics.mean_absolute_error(y_test, model_lasso_test_predictions)))

print("r2_score on Train data :", r2_score(y_train, model_lasso_train_predictions))
print("r2_score on Test data :", r2_score(y_test, model_lasso_test_predictions))
print(' ')
cv = RepeatedKFold(n_splits=10, n_repeats=3, random_state=1)
n_scores = cross_val_score(model_lasso, x_train_prepared, y_train, scoring='neg_mean_absolute_error', cv=cv, n_jobs=-1, error_score='raise')
print('MAE: %.3f (%.3f)' % (mean(n_scores), std(n_scores)))
print("Cross validation score:", cross_val_score(model_lasso, x_train_prepared, y_train, cv=cv))

```

Figura 3.54: Código para implementação da regressão da Lasso. Fonte: [60].

O próximo modelo é a regressão Lasso, uma técnica de regressão que utiliza simultaneamente a seleção de variáveis e a regularização do modelo. Isso é feito através da aplicação que força alguns coeficientes da regressão ser tornarem exatamente zero, tornando o modelo mais simples e fácil de interpretar.

No estudo foi aplicada a regressão Lasso com o parâmetro de regularização  $\alpha = 0.01$ . A influência do parâmetro de regularização é conhecida, à medida que  $\alpha$  aumenta, ocorre maior viés e menor variância (modelo mais simples); e quando o  $\alpha$  diminui, o viés reduz e a variância aumenta (modelo mais flexível).

Abaixo o código apresentado com a regressão de Lasso na figura 3.54

Como resultado, tem apresentação da tabela 3.14:

Tabela 3.14: Resultados do Modelo de Regressão Lasso ( $\alpha = 0,01$ )

Métrica	Valor	Interpretação
Erro Quadrático Médio (RMSE)	32,04 ciclos	Desempenho praticamente idêntico ao da regressão linear
Erro Absoluto Médio (MAE)	25,59 ciclos	Penalização não afetou os coeficientes de forma significativa
Coeficiente de Determinação ( $R^2$ ) – Treino	0,579	O modelo explica 57,9% da variância nos dados de treino
Coeficiente de Determinação ( $R^2$ ) – Teste	0,406	O modelo explica 40,6% da variância nos dados de teste
MAE (Validação Cruzada)	-34,14 ± 0,72	Valor compatível com os dados de teste; valida a estabilidade do modelo
$R^2$ nos folds da Validação Cruzada	~0,55 a ~0,60	Desempenho estável e consistente nos folds da validação cruzada

O gráfico de resíduos da figura 3.54 apresenta visualmente a performance do modelo com  $\alpha = 0,01$  e confirma o que foi observado nas métricas.

Observa-se uma distribuição semelhante à do modelo de regressão linear, com maior dispersão dos resíduos para os valores previstos mais altos. Isso reforça o fato

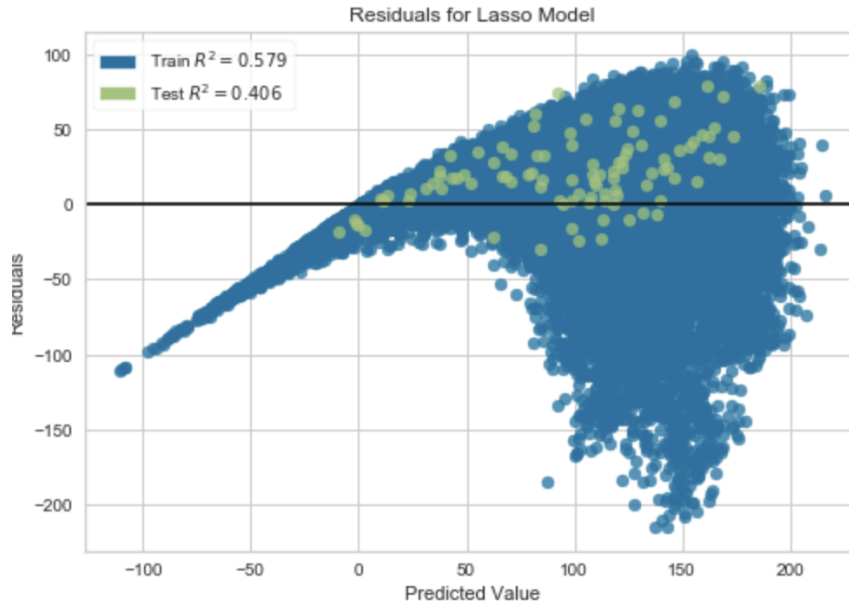


Figura 3.55: Gráfico de resíduos da regressão de Lasso. Fonte: [60].

de que, com o valor de penalização aplicado, o modelo não apresentou alterações significativas.

O coeficiente de determinação  $R^2=0,406$  no teste confirma que o modelo mantém a capacidade preditiva moderada, mas sem vantagem significativa sobre a regressão linear simples.

O modelo apresentou um coeficiente de determinação  $R^2=0,406$ , o que significa que ele é capaz de explicar aproximadamente 40,6% da variância nos dados de teste.

Na figura 3.56, a dispersão em torno da linha de identidade mostra que há tendência e ruído nos dados que o modelo não capturou totalmente, mas ainda assim mantém um desempenho consistente com a regressão linear, sem ganho significativo de regularização.

O gráfico da figura 3.57 demonstra a comparação entre os valores reais e previstos pelo modelo de regressão de Lasso, ao longo das 100 instâncias do conjunto de teste.

Observa-se uma boa sobreposição entre as curvas, embora existam desvios notáveis em casos extremos. Isso indica que o modelo de regressão de lasso, mesmo com regularização leve, conseguiu capturar a tendência geral dos dados, mantendo desempenho muito semelhante ao da regressão linear.

A próxima análise é realizada na regressão com Random Forest, é uma técnica de aprendizado de máquina, na qual ela constrói múltiplas árvores de decisão independentes, cada uma treinada sobre subconjuntos aleatórios dos dados e das variáveis, e combina as predições para gerar o resultado final.

O código de implementação do Random Forest pode ser visualizado na figura




Figura 3.56: Gráfico de erro de predição da regressão de Lasso. Fonte: [60].




Figura 3.57: Gráfico da comparação entre os valores reais e previstos pelo modelo de regressão de Lasso. Fonte: [60].

3.58.

Na tabela 3.15 podemos visualizar o resultado do código implementado.

Em uma segunda etapa, foi realizada a otimização de hiperparâmetros utilizando a técnica de busca aleatória (RandomizedSearchCV), o que resultou em melhorias significativas no desempenho. O modelo com *tuning* obteve o melhor desempenho entre

```

from sklearn.ensemble import RandomForestRegressor
randf = RandomForestRegressor(max_depth=7)
randf.fit(x_train_prepared, y_train)
model_random_train_predictions = randf.predict(x_train_prepared)
model_random_test_predictions = randf.predict(x_test_prepared)

print("r2_score on Train data :", r2_score(y_train,model_random_train_predictions))
print("r2_score on Test data :", r2_score(y_test,model_random_test_predictions))

print('Root Mean Squared Error:', (metrics.mean_squared_error(y_test, model_random_test_predictions)**0.5))
print('Mean Absolute Error:', (metrics.mean_absolute_error(y_test, model_random_test_predictions)))

print("Cross validation score:", cross_val_score(randf, x_train_prepared, y_train, cv=10))

```

Figura 3.58: Código de implementação do Random Forest. Fonte: [60].

Tabela 3.15: Resultados do Modelo de Regressão com Random Forest (com *tuning*)

Métrica	Valor	Interpretação
Erro Quadrático Médio (RMSE)	31,76 ciclos	Melhor desempenho que o modelo linear e Lasso; próximo ao da árvore de decisão otimizada
Erro Absoluto Médio (MAE)	23,88 ciclos	Previsões com erro absoluto similar ao modelo polinomial e árvore com afinação
Coefficiente de Determinação ( $R^2$ ) – Treino	0,651	O modelo explica 65,1% da variância nos dados de treino
Coefficiente de Determinação ( $R^2$ ) – Teste	0,416	O modelo explica 41,6% da variância nos dados de teste
Validação Cruzada ( $R^2$ )	~0,41 a ~0,73	Scores com variação moderada; generalização razoável

todos os avaliados, com um  $R^2$  de 0,494 no conjunto de teste, superando inclusive a árvore de decisão individual otimizada.

O código pode ser visualizado na figura 3.59.

Os novos resultados indicam que rodou uma nova versão da Random Forest com melhores hiperparâmetros e pode-se visualizar os resultados na tabela 3.17.

Tabela 3.16: Resultados do Modelo de Regressão com Random Forest com otimização

Métrica	Valor	Interpretação
Erro Quadrático Médio (RMSE)	31,51 ciclos	Melhor desempenho entre todos os modelos testados
Erro Absoluto Médio (MAE)	22,52 ciclos	Modelo com menor erro absoluto médio até o momento
Coefficiente de Determinação ( $R^2$ ) – Treino	0,873	Excelente ajuste ao conjunto de treino; risco moderado de sobreajuste
Coefficiente de Determinação ( $R^2$ ) – Teste	0,425	O modelo explica 42,5% da variância no conjunto de teste — maior poder preditivo

Após fornecer no código da figura 3.60, dez combinações diferentes de hiperpa-

```

from sklearn.ensemble import RandomForestRegressor
from sklearn.model_selection import GridSearchCV
model_rf = RandomForestRegressor()
param_grid = {
    "n_estimators"      : [10, 30, 50, 70, 100],
    "max_features"      : [1, 2, 3, 4, 5],
    "min_samples_split" : [2,3, 5, 7, 9],
    "bootstrap": [True, False],
}
grid = GridSearchCV(model_rf, param_grid, n_jobs=-1, cv=5)

grid.fit(x_train_prepared, y_train)
model_random_train_predictions = grid.predict(x_train_prepared)
model_random_test_predictions = grid.predict(x_test_prepared)

print("r2_score on Train data :", r2_score(y_train,model_random_train_predictions))
print("r2_score on Test data :", r2_score(y_test,model_random_test_predictions))

print('Root Mean Squared Error:', (metrics.mean_squared_error(y_test, model_random_test_predictions)**0.5))
print('Mean Absolute Error:', (metrics.mean_absolute_error(y_test, model_random_test_predictions)))

```

Figura 3.59: Código de implementação do Random Forest com a otimização de hiperparâmetros. Fonte: [60].

râmetros a serem testadas, o processo de validação cruzada foi configurada com cinco divisões e isso gerou cinquenta ajustes do modelo.

```

from sklearn.ensemble import RandomForestRegressor
from sklearn.model_selection import RandomizedSearchCV

randf = RandomForestRegressor(random_state = 42)
n_estimators = [10, 50, 75, 100]
max_features = [1, 2, 3, 4]
max_depth = [1, 2, 3, 4, 5]
min_samples_split = [1, 2, 3, 4, 5]
bootstrap = [True, False]
random_grid = {'n_estimators': n_estimators,
               'max_features': max_features,
               'max_depth': max_depth,
               'min_samples_split': min_samples_split,
               'bootstrap': bootstrap}

rf_random = RandomizedSearchCV(randf,random_grid, verbose=2, random_state=42, n_jobs = -1)
rf_random.fit(x_train_prepared, y_train)
rf_random_train_predictions = rf_random.predict(x_train_prepared)
rf_random_test_predictions = rf_random.predict(x_test_prepared)

print("r2_score on Train data :", r2_score(y_train,rf_random_train_predictions))
print("r2_score on Test data :", r2_score(y_test,rf_random_test_predictions))

print('Root Mean Squared Error:', (metrics.mean_squared_error(y_test, rf_random_test_predictions)**0.5))
print('Mean Absolute Error:', (metrics.mean_absolute_error(y_test, rf_random_test_predictions)))

print(' ')
cv = RepeatedKFold(n_splits=10, n_repeats=3, random_state=1)
n_scores = cross_val_score(rf_random, x_train_prepared, y_train, scoring='neg_mean_absolute_error', cv=cv, n_jobs=-1,
print('MAE: %.3f (%.3f)' % (mean(n_scores), std(n_scores)))

```

Figura 3.60: Código do Random Forest com dez combinações de hiperparâmetros. Fonte: [60].

Gerou-se resultados apresentado na 3.17 com o modelo de Random Forest com hiperparâmetros otimizados no qual gerou o melhor desempenho até o momento.

Na análise de resíduos, o modelo da figura 3.61 apresenta uma distribuição de resíduos centrada ao redor de zero, com dispersão menor em comparação aos mode-

Tabela 3.17: Resultados do Modelo de Regressão com Random Forest (melhor configuração)

Métrica	Valor	Interpretação
Erro Quadrático Médio (RMSE)	28,93 ciclos	Menor erro médio entre todos os modelos testados
Erro Absoluto Médio (MAE)	22,81 ciclos	Alta precisão preditiva, com um dos menores erros absolutos
Coefficiente de Determinação ( $R^2$ ) – Treino	0,612	Modelo ajustado com boa capacidade de generalização
Coefficiente de Determinação ( $R^2$ ) – Teste	0,515	Melhor desempenho explicativo do conjunto de teste entre todos os modelos
MAE (Validação Cruzada)	$-31,81 \pm 0,66$	Validação cruzada estável, com desempenho consistente

los anteriores. A forma triangular invertida (com menor variação para valores baixos e maior dispersão para valores altos) indica que o modelo mantém boa precisão preditiva, mas ainda enfrenta desafios ao prever valores mais elevados de RUL.




Figura 3.61: Gráfico de resíduos do Random Forest com a otimização de hiperparâmetros. Fonte: [60].

No gráfico de erro de predição - Random Forest otimizado da figura 3.62, temos que o coeficiente de determinação  $R^2=0,515$  indica que o modelo explica mais de 51% da variância nos dados de teste.

A boa proximidade da reta preta com a linha de identidade mostra a alta correlação entre predição e realidade, e os pontos relativamente agrupados validam a capacidade de generalização do modelo.

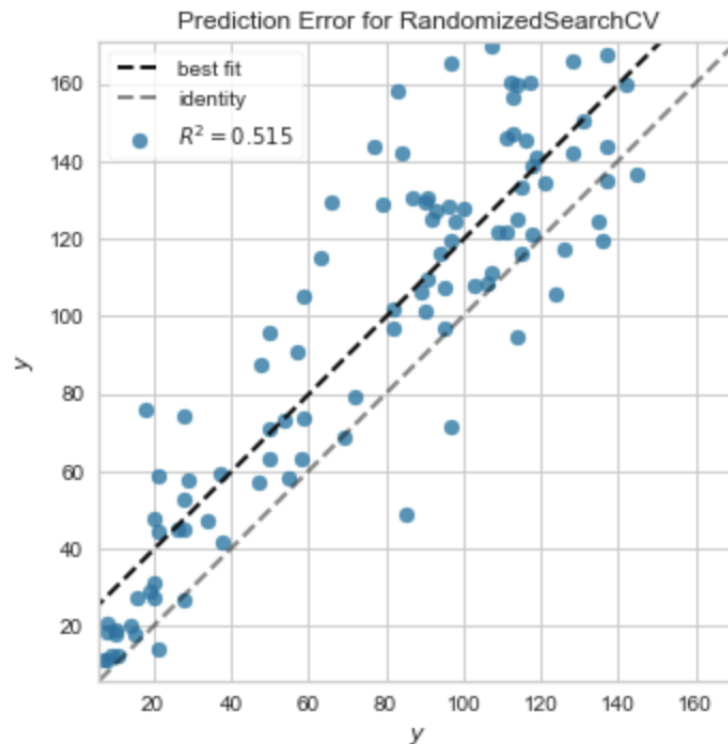


Figura 3.62: Gráfico de erro de predição do Random Forest com a otimização de hiperparâmetros. Fonte: [60].

No gráfico de valores reais vs previstos da figura 3.63, é possível observar que o modelo acompanha bem as variações nos dados reais, principalmente em alguns intermédios. Apesar de desvios pontuais em valores extremos, a curva prevista segue de maneira próxima a realidade, evidenciando a capacidade do modelo em capturar padrões complexos.

O próximo modelo a ser analisado é a regressão LGBM, utilizado para tarefas com grandes volumes de dados e estruturas complexas, tende a superar modelos lineares e até árvores de decisões simples, especialmente quando bem ajustados. O código dessa modelagem é apresentado na figura 3.64 abaixo.

O resultado da regressão LGBM é encontrado na tabela 3.18 com a interpretação para cada métrica.

O gráfico de resíduos apresentado na figura 3.65 demonstra a concentração dos pontos em torno da linha zero e indica que o modelo teve um desempenho razoável, com erros relativamente distribuídos, embora seja possível notar maior dispersão negativa para valores previstos mais altos.

O modelo alcançou  $R^2 = 0.615$  no treino e  $R^2 = 0.409$  no teste, revelando um ajuste moderado, inferior ao Random Forest ajustado, mas superior aos modelos lineares.

O gráfico de erros de predição da figura 3.66, observa-se que muitos pontos estão próximos da linha ideal, indicando boa precisão. Contudo, existe uma certa dispersão,




Figura 3.63: Gráfico valores reais vs previstos do Random Forest com a otimização de hiperparâmetros. Fonte: [60].

```

from lightgbm import LGBMRegressor
model_lgbm = LGBMRegressor(max_depth=7, num_leaves = 2)
# fit the model on the whole dataset
model_lgbm.fit(x_train_prepared, y_train)
model_lgbm_train_predictions = model_lgbm.predict(x_train_prepared)
model_lgbm_test_predictions = model_lgbm.predict(x_test_prepared)

print('Root Mean Squared Error:', (metrics.mean_squared_error(y_test, model_lgbm_test_predictions)**0.5))
print('Mean Absolute Error:', (metrics.mean_absolute_error(y_test, model_lgbm_test_predictions)))

print("Accuracy on Train data :", r2_score(y_train,model_lgbm_train_predictions))
print("Accuracy on Test data :", r2_score(y_test,model_lgbm_test_predictions))
print(' ')
cv = RepeatedKFold(n_splits=10, n_repeats=3, random_state=1)
n_scores = cross_val_score(model_lgbm, x_train_prepared, y_train, scoring='neg_mean_absolute_error', cv=cv, n_jobs=-1, error_score='raise')
print('MAE: %.3f (%.3f)' % (mean(n_scores), std(n_scores)))
print("Cross validation accuracy:", cross_val_score(model_lgbm, x_train_prepared, y_train, cv=10))

```

Figura 3.64: Código para a implementação da regressão LGBM. Fonte: [60].

especialmente em valores médios e altos, explicando o resultado de  $R^2=0.409$ . Ainda assim o desempenho do modelo é superior ao da regressão linear simples e comparável ao Lasso, sendo um candidato competitivo para previsões não lineares.

A regressão XGBoost com Ajuste de Parâmetros é um algoritmo de aprendizado supervisionado baseado em árvores de decisão, que utiliza a técnica de boosting por gradiente, é conhecido por sua eficiência computacional, flexibilidade e capacidade de ser paralelo, sendo bastante utilizado em competições de machine learning. O código a ser implementando é visualizado na figura 3.67.

O resultado e a interpretação do modelo XGBoost com ajuste de parâmetro pode ser visualizado na tabela 3.19.

O gráfico de análise dos resíduos da figura 3.68, o modelo obteve um coeficiente de determinação  $R^2=0.775$  no treino, o que demonstra um forte aprendizado dos padrões nos dados. Contudo, o desempenho caiu no teste com  $R^2=0.342$ , indicando que

Tabela 3.18: Resultados do Modelo de Regressão com LightGBM (ajuste de parâmetros)

Métrica	Valor	Interpretação
Raiz do Erro Quadrático Médio (RMSE)	31,94 ciclos	Leve melhora em relação à regressão linear; desempenho inferior ao Random Forest
Erro Absoluto Médio (MAE)	25,15 ciclos	Erro médio moderado nas previsões, semelhante ao modelo linear e Lasso
Coefficiente de Determinação ( $R^2$ ) – Treino	0,615	O modelo explica 61,5% da variância nos dados de treino
Coefficiente de Determinação ( $R^2$ ) – Teste	0,409	Explica 40,9% da variância nos dados de teste
MAE (Validação Cruzada)	$-32,01 \pm 0,67$ ciclos	Estabilidade razoável nas previsões ao longo dos subconjuntos
$R^2$ na Validação Cruzada	$\sim 0,42$ a $\sim 0,68$	Resultados consistentes, competitivos com os demais modelos não lineares




Figura 3.65: Gráfico de resíduos da regressão LGBM. Fonte: [60].

o modelo teve dificuldade em generalizar.

É visível uma dispersão maior dos resíduos negativos para valores de previsão mais altos, o que sugere subestimação de alguns valores altos.

No gráfico de erro de predição apresentado em figura 3.69, o valor de  $R^2=0.342$  indica um desempenho modesto, com diversos pontos distantes da linha ideal, o que demonstra um erro de predição mais acentuado, principalmente com valores altos. O modelo acerta tendência geral, mas com menor precisão do que outros modelos não lineares.

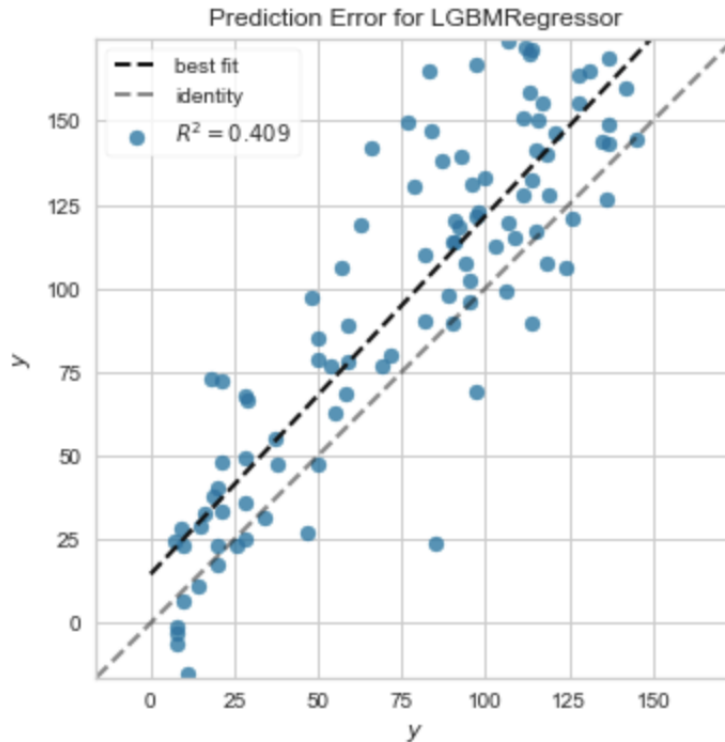


Figura 3.66: Gráfico de erro de predição da regressão LGBM. Fonte: [60].

```

from xgboost import XGBRegressor
model_xgb = XGBRegressor(learning_rate =0.1, n_estimators=100, max_depth=7, min_child_weight=1, gamma=0, subsample=0.8, colsample_bytree=0.8)
model_xgb.fit(x_train_prepared, y_train)
model_xgb_train_predictions = model_xgb.predict(x_train_prepared)
model_xgb_test_predictions = model_xgb.predict(x_test_prepared)

print('Root Mean Squared Error:', (metrics.mean_squared_error(y_test, model_xgb_test_predictions)**0.5))
print('Mean Absolute Error:', (metrics.mean_absolute_error(y_test, model_xgb_test_predictions)))

print("Accuracy on Train data :", r2_score(y_train,model_xgb_train_predictions))
print("Accuracy on Test data :", r2_score(y_test,model_xgb_test_predictions))
print("Cross validation accuracy:", cross_val_score(model_xgb, x_train_prepared, y_train, cv=10))

```

Figura 3.67: Código para a implementação da regressão XGBoost. Fonte: [60].

A próxima análise de regressão é do CatBoost com ajuste de parâmetros. O CatBoost é um algoritmo de aprendizado baseado em boosting por gradiente em árvore de decisão, com excelente desempenho quando há variáveis categóricas. Na figura 3.70 é possível visualizar o código processado para a modelagem analisada.

Na tabela 3.20 a seguir é apresentados os resultados e as interpretações para os indicadores.

Após apresentar diversos modelos de regressão, para observar qual o melhor modelo de regressão para prever a vida útil remanescentes de um motor com base em dados de sensores sob diferentes condições operacionais, foi realizado a análise exploratória dos dados e assim concluir que o conjunto de dados apresenta atributos suficientes e relevantes para a predição da variável-alvo RUL.

Durante o trabalho, foram realizadas diversas visualizações que evidenciam a

Tabela 3.19: Resultados do Modelo de Regressão com XGBoost (ajuste de parâmetros)

Métrica	Valor	Interpretação
Raiz do Erro Quadrático Médio (RMSE)	33,70 ciclos	Maior erro quadrático entre os modelos de regressão não linear testados
Erro Absoluto Médio (MAE)	24,17 ciclos	Erro médio comparável ao da regressão por árvore de decisão; previsões razoáveis
Coefficiente de Determinação (R <sup>2</sup> ) – Treino	0,775	Modelo com ótimo ajuste aos dados de treino, capturando bem os padrões internos
Coefficiente de Determinação (R <sup>2</sup> ) – Teste	0,342	Desempenho inferior aos demais modelos não lineares na generalização dos dados
R <sup>2</sup> na Validação Cruzada	~0,39 a ~0,72	Variação significativa entre os subconjuntos de validação; menor estabilidade preditiva




Figura 3.68: Gráfico da análise de resíduos da regressão XGBoost. Fonte: [60].

relação entre as variáveis que contribuíram para a compreensão do comportamento dos dados.

Com base nas variáveis conhecidas, foi realizado um processo de seleção de variáveis e essas foram utilizadas para treinar os modelos apresentados.

Entre os algoritmos testados, foram considerados modelos lineares e modelos não lineares. A seguir a lista dos modelos de regressão implementados:

- Regressão linear
- Árvore de Decisão
- Regressão polinomial




Figura 3.69: Gráfico de dispersão da regressão XGBoost. Fonte: [60].

```

from catboost import CatBoostRegressor
model_cat = CatBoostRegressor(verbose=0, n_estimators=100, max_depth=7, learning_rate =0.1)
model_cat.fit(x_train_prepared, y_train)
model_cat_train_predictions = model_cat.predict(x_train_prepared)
model_cat_test_predictions = model_cat.predict(x_test_prepared)

print('Root Mean Squared Error:', (metrics.mean_squared_error(y_test, model_cat_test_predictions)**0.5))
print('Mean Absolute Error:', (metrics.mean_absolute_error(y_test, model_cat_test_predictions)))

print("Accuracy on Train data :", r2_score(y_train,model_cat_train_predictions))
print("Accuracy on Test data :", r2_score(y_test,model_cat_test_predictions))
print("Cross validation accuracy:", cross_val_score(model_cat, x_train_prepared, y_train, cv=10))

```

Figura 3.70: Código de implementação para a regressão de CatBoost. Fonte: [60].

- Regressão Lasso
- Regressão com Random Forest
- Regressão com LGBM
- Regressão com XGBoost
- Regressão com CatBoost

Abaixo na tabela 3.21 é realizada a comparação com o desempenho dos modelos de regressão.

O modelo que obteve o melhor desempenho foi o Random Forest, com os seguintes hiperparâmetros:

Tabela 3.20: Resultados do Modelo de Regressão com CatBoost (ajuste de parâmetros)

Métrica	Valor	Interpretação
Raiz do Erro Quadrático Médio (RMSE)	31,25 ciclos	Desempenho preditivo sólido; menor erro que a regressão linear e o XGBoost
Erro Absoluto Médio (MAE)	22,82 ciclos	Erro médio competitivo; entre os melhores modelos testados
Coefficiente de Determinação ( $R^2$ ) – Treino	0,668	Modelo bem ajustado aos dados de treino
Coefficiente de Determinação ( $R^2$ ) – Teste	0,434	Boa generalização, desempenho acima da média geral
$R^2$ na Validação Cruzada	~0,39 a ~0,75	Variação moderada entre os subconjuntos; estabilidade aceitável

Tabela 3.21: Comparação do desempenho dos modelos de regressão

Modelo	$R^2$ (Treino)	$R^2$ (Teste)	RMSE (ciclos)	MAE (ciclos)
Regressão Linear	0,5794	0,4054	32,04	25,59
Regressão Polinomial	0,6269	0,4332	31,28	23,84
Árvore de Decisão	0,6076	0,4502	30,84	23,60
Regressão Lasso	0,5794	0,4054	32,04	25,59
Random Forest	0,6117	<b>0,5154</b>	<b>28,96</b>	23,66
LightGBM	0,6146	0,4135	31,82	25,11
XGBoost	<b>0,7756</b>	0,3685	33,02	24,09
CatBoost	0,6679	0,4343	31,25	<b>22,82</b>

- Número de estimadores (n\_estimators): 75 árvores
- Profundidade máxima das árvores (max\_depth): 5 níveis
- Coeficiente de Determinação ( $R^2$ ): 0,515
- Erro Quadrático Médio (RMSE): ~28,96 ciclos

O modelo apresentado alcançou coeficiente de determinação  $R^2=0.515$  e erro quadrático médio (RMSE) de aproximadamente 28,96 ciclos. Estes resultados indicam que o Random Forest foi o mais eficaz na previsão da RUL.

No presente trabalho, propõe-se compreender uma solução destinada à estimar o tempo até a falha de aeronaves com base em um conjunto de dados simulados. Essa abordagem pode ser aplicadas em indústrias aeronáuticas e de defesa, contribuindo para o desenvolvimento de estratégias de manutenção mais eficientes e otimizadas.



## 4

### Conclusão

A implementação de estratégias inovadoras na gestão da manutenção industrial, como explorado nos estudos de casos da dissertação, é cada vez mais necessária para as empresas que desejam acompanhar o ritmo acelerado das transformações tecnológicas. O uso de tecnologias, como a *Machine Learning*, Inteligência Artificial, *Blockchain*, *Digital Twins*, entre outras, permite monitoramento em tempo real, maior previsibilidade e uma manutenção mais eficiente, com base em dados. Essas ferramentas contribuem diretamente para a redução de custos, aumento da produtividade e melhoria da qualidade dos produtos.

Durante o desenvolvimento do trabalho, ficou evidente que essas inovações não são apenas tendências, mas uma realidade que impacta diretamente os resultados das organizações. Ao mesmo tempo, surgem desafios como o custo de implementação, a necessidade de infraestrutura adequada e, principalmente, a capacitação das equipes. Não adianta adotar a tecnologia se as pessoas não estão preparadas para lidar com ela no dia a dia. A cultura organizacional precisa acompanhar essa mudança.

Vale destacar que mesmo utilizando um conjunto de dados do setor aeronáutico para o desenvolvimento dos modelos preditivos, esta dissertação foi realizada no âmbito do curso de Engenharia e Gestão Industrial. A escolha do estudo se deu pelo seu caráter técnico e por ser uma base amplamente utilizada em pesquisas sobre manutenção preditiva.

Assim, é fundamental que o engenheiro de gestão industrial mantenha-se atento às inovações que possam ser adaptadas e aplicadas em diferentes contextos da indústria. O conhecimento adquirido na engenharia aeroespacial não apenas possibilita a aplicação de modelos prontos, mas também fornece uma base sólida para o desenvolvimento de soluções específicas que podem ser replicadas e ajustadas a outros desafios da engenharia industrial. Essa possibilidade é essencial para ampliar o impacto estratégico dessas tecnologias e contribuir para a evolução contínua do setor.

Um aspecto importante e que merece atenção é o potencial de integração en-

tre manutenção preditiva e sustentabilidade. A redução de falhas inesperadas, o uso racional de matérias-primas e a melhoria do ciclo de vida dos ativos contribuem diretamente para a eficiência energética e redução do desperdício. A manutenção pode se tornar uma aliada das metas do futuro para melhorar os impactos ambientais, sociais e econômicos.

Com a transição digital da Indústria 4.0 para a Indústria 5.0, a manutenção industrial deixa de ser uma função isolada e passa a ter um papel mais estratégico, com foco não só em eficiência, mas também no bem-estar das pessoas e na sustentabilidade. Empresas que souberem integrar tecnologia, pessoas e processos terão mais chances de se destacar em um mercado cada vez mais competitivo e exigente.

Além disso, observa-se cada vez questões de cibersegurança através do *blockchain* e que ganham mais relevância à medida que os sistemas industriais se tornarem mais interconectados, destacando a necessidade de estratégias de segurança robustas para proteger dados sensíveis e garantir a integridade operacional.

A segurança é uma preocupação diante de ameaças como *phishing* e fraudes. É recomendável adotar medidas preventivas para reduzir esses riscos, como o uso de chaves privadas mantidas offline, o que torna os dados inacessíveis a tentativas de *hacking*, disponibilizando-os online apenas quando necessário. Além disso, atualizações regulares de *software* são essenciais para corrigir vulnerabilidades conhecidas, garantindo maior proteção. Também é fundamental realizar *backups* de chaves privadas, implementar uma eliminação segura e progressiva de cópias desnecessárias, e utilizar métodos de autenticação robustos.

A natureza descentralizada e a consequente ausência de supervisão centralizada das tecnologias *blockchain* representam um grande desafio, especialmente no que diz respeito à segurança do *software* e ao armazenamento de ativos digitais.

De forma semelhante, os *digital twins* têm se mostrado tecnologias relevantes para monitoramento e análise de sistemas industriais em tempo real. No entanto, sua implementação também traz desafios críticos relacionados à segurança e à privacidade. A interconexão contínua entre o modelo virtual e o sistema físico expõe ambos a vulnerabilidades, como acesso não autorizado e manipulação de dados sensíveis.

Apesar desses desafios, a aplicação da tecnologia *blockchain* na gestão de equipes demonstra um potencial significativo, com uso crescente em diversas empresas, como explorado nesta dissertação. A *blockchain* oferece vantagens como segurança, transparência, credibilidade e descentralização. No entanto, esses benefícios não estão isentos de riscos que podem comprometer sua estabilidade e confiabilidade. Entre as vulnerabilidades identificadas estão questões de escalabilidade, devido às limitações tecnológicas no número de transações processáveis, o que pode ocasionar atrasos. Há também riscos de manipulação de transações que merecem atenção.

No que diz respeito à privacidade das operações e dados, a *blockchain* se baseia no anonimato. Embora as transações possam ser rastreadas, os dados armazenados não podem ser removidos ou alterados, garantindo integridade.

Portanto, sugere-se que futuras pesquisas ampliem essa discussão com estudos aplicados em diferentes setores, testando novos algoritmos, avaliando a integração com sistemas, e explorando indicadores de desempenho específicos para cada tipo de processo industrial. A inovação na manutenção é um caminho sem volta e quanto mais preparada estiver a organização, melhores serão os seus resultados.



## Referências bibliográficas

- [1] H. Günther, “Pesquisa qualitativa versus pesquisa quantitativa: esta é a questão?” *Psicologia: Teoria e Pesquisa*, vol. 22, no. 2, 2006.
- [2] M. C. B. Galvão, P. Pluye, and I. L. M. Ricarte, “Métodos de pesquisa mistos e revisões de literatura mistas: conceitos, construção e critérios de avaliação,” *InCID: Revista De Ciência Da Informação E Documentação*, vol. 8, no. 2, pp. 4–24, 2017.
- [3] K. Schwab, *A Quarta Revolução Industrial*. Porter, 2016.
- [4] L. S. Santos and R. B. D. Araújo, *A revolução industrial*. História Econômica e Geral, 2018.
- [5] A. Mathur, A. Dabas, and N. Sharma, “Evolution from industry 1.0 to industry 5.0,” in *2022 4th International Conference on Advances in Computing, Communication Control and Networking (ICAC3N)*, 2022, pp. 1390–1394.
- [6] P. Poór, D. Ženíšek, and J. Basl, “Historical overview of maintenance management strategies development from breakdown maintenance to predictive maintenance in accordance with four industrial revolutions,” 2019. [Online]. Available: <https://www.researchgate.net/publication/335444202>
- [7] T. L. Barboza, “Um histórico da manutenção e conceitos sobre sua função,” *Revista Marítima Brasileira*, vol. 138, no. 4, pp. 84–88, 2018. [Online]. Available: <https://www.portaldeperiodicos.marinha.mil.br>
- [8] A. Atkeson and P. J. Kehoe, “The transition to a new economy after the second industrial revolution,” National Bureau of Economic Research, Working Paper 8676, 2001.
- [9] J. Mokyr, “The second industrial revolution, 1870-1914,” Northwestern University, Tech. Rep., 1998.
- [10] N. Omri, Z. Al Masry, N. Mairot, S. Giampiccolo, and N. Zerhouni, “Industrial data management strategy towards an sme-oriented phm,” *Journal of Manufacturing Systems*, 2020.
- [11] H. Mohajan, “Third industrial revolution brings global development,” *Journal of Social Sciences and Humanities*, vol. 7, no. 4, pp. 239–251, 2021. [Online]. Available:

<http://www.aiscience.org/journal/jssh>

- [12] V. Deac, G. Cârstea, C. Bâgu, and F. Pârvu, "The modern approach to industrial maintenance management," *Informatica Economică*, vol. 14, no. 2, p. 133–140, 2010. [Online]. Available: <https://revistaie.ase.ro/content/54/13%20Deac.pdf>
- [13] J. S. Hwang, "The fourth industrial revolution (industry 4.0): intelligent manufacturing," *SMT Magazine*, vol. 3, pp. 616–630, 2016.
- [14] C. Klingenberg and J. Antunes, "Industry 4.0: what makes it a revolution," in *EurOMA 2017*, 2017, pp. 1–11.
- [15] M. Brettel, N. Friederichsen, M. Keller, and M. Rosenberg, "How virtualization, decentralization and network building change the manufacturing landscape: An industry 4.0 perspective," *International Journal of Mechanical, Industrial Science and Engineering*, vol. 8, no. 1, pp. 37–44, 2014.
- [16] X. Xu, Y. Lu, B. Vogel-Heuser, and L. Wang, "Industry 4.0 and industry 5.0—inception, conception and perception," *Journal of Manufacturing Systems*, vol. 61, pp. 530–535, 2021.
- [17] J. Müller, "Enabling technologies for industry 5.0: Results of a workshop with europe's technology leaders," 2020.
- [18] R. Anandan, S. Gopalakrishnan, S. Pal, and N. Zaman, Eds., *The Industrial Internet of Things (IIoT): Intelligent analytics for predictive maintenance*. John Wiley & Sons, Inc. and Scrivener Publishing LLC, 2022.
- [19] J. D. Campbell and J. V. Reyes-Picknell, *Uptime: Strategies for Excellence in Maintenance Management*, 3rd ed. Taylor & Francis, 2016.
- [20] K. V., "Innovation management in industrial production," *Problems of Economic Transition*, 2011.
- [21] V. Rozsa, A. F. G. Vieira, and M. Dutra, "Aplicação de tecnologias da web semântica em motores de busca na internet," *Investigación Bibliotecológica*, vol. 33, no. 78, pp. 165–191, 2019.
- [22] A. M. Aljaser, "Which is more effective: A mind map or a concept map learning strategy?" *ResearchGate*, 2021. [Online]. Available: [https://www.researchgate.net/publication/352678732\\_which\\_is\\_more\\_effective\\_a\\_mind\\_map\\_or\\_a\\_concept\\_map\\_learning\\_strategy](https://www.researchgate.net/publication/352678732_which_is_more_effective_a_mind_map_or_a_concept_map_learning_strategy)
- [23] M. A. Moreira. (2012) Mapas conceituais e aprendizagem significativa. Instituto de Física - UFRGS. [Online]. Available: <https://www.if.ufrgs.br/moreira/mapasport.pdf>
- [24] M. S. A. E. . L. E. Correa, J., "Using scada data for wind turbine condition monitoring: A systematic literature review." *Energies*, vol. 13, no. 12, 2020.

- [25] J. M. T. Farinha, *Uma abordagem terológica da manutenção dos equipamentos hospitalares*, 1994.
- [26] J. Levitt, *The complete guide to preventive and predictive maintenance*, 2nd ed. Industrial Press, 2011.
- [27] *Gestão de ativos - Terminologia*, Std., 2021.
- [28] A. Rastegari and A. Salonen, "Strategic maintenance management: Formulating maintenance strategy," *International Journal of Condition Monitoring and Diagnostic Engineering Management*, vol. 18, pp. 5–14, 2015.
- [29] F. F. Espinosa, A. Dias, and G. E. Salinas, "Un procedimiento para evaluar el riesgo de la innovación en la gestión del mantenimiento industrial," *A procedure for assessing the risks of innovation in the management of industrial maintenance*, 2011.
- [30] T. Agustiady and E. A. Cudney, *Total productive maintenance strategies and implementation guide*, 2024.
- [31] V. Deac, G. Carstea, C. Bagu, and F. Parvu, "The modern approach to industrial maintenance management," 2010.
- [32] Y. Liu, W. Yao, X. Li, and X. Liu, "Intelligent industrial device maintenance management system," 2017.
- [33] P. P. Okpeke, J. O. Ogugua, and N. L. Eyo-Udo, "Innovations in fixed asset management: Enhancing efficiency through advanced tracking and maintenance systems," *International Journal of Research Archive in Science and Technology*, vol. 7, no. 1, pp. 19–26, 2024.
- [34] R. Malhotra, T. Alzahawi, and E. McLeod, "Management and maintenance of electrical equipment in industrial facilities," in *ICPS*, 2019.
- [35] D. C. Anaba, A. J. Kess-Momoh, and S. A. Ayodeji, "Innovative maintenance strategies for industrial equipment: A review of current practices and future directions," *Open Access Research Journal of Science and Technology*, vol. 11, no. 2, pp. 29–37, 2024.
- [36] F. Stadtmann and A. Rasheed, "Diagnostic digital twin for anomaly detection in floating offshore wind energy," 2024.
- [37] A. N. Sari and T. Gelar, "Blockchain: Teknologi dan implementasinya," *Jurnal MNEMONIC*, vol. 7, no. 1, pp. 63–70, 2024.
- [38] R. Adil, T. Kvamsdal, K. Johannessen, O. San, K. Kölle, J. O. Giæver Tande, I. Barstad, A. Benhamou, A.-L. Firlé, A. Fjeldly, L. Froyd, A. Gleim, C. Meißner, G. Nygård, T. Rasmussen, and E. Rishoff, "Digital twins in wind energy: Emerging technologies and industry-informed future directions," *arXiv*, 2023.

- [39] A. A. Ali, A. Longo, and A. Ficarella, "Digital twin (dt) in smart energy systems - systematic literature review of dt as a growing solution for energy internet of the things (eiot)," in *E3S Web of Conferences*, vol. 312, 2021.
- [40] S. S. Johansen, "Development of a digital twin for fault detection in offshore wind turbine transmission systems," Master's thesis, Norwegian University of Science and Technology, Department of Marine Technology, 2018.
- [41] A. Haghshenas, A. Hasan, and O. Osen, "Gêmeo digital preditivo para parques eólicos offshore," *Energy Informatics*, vol. 6, no. 1, 2023.
- [42] M. B. Kjelland and M. R. Hansen, "Offshore wind payload transfer using flexible mobile crane," *Modeling, Identification and Control*, vol. 36, no. 1, pp. 1–9, 2015.
- [43] M. Ozbek, "An innovative structural damage detection system for preventive maintenance of wind turbines," *Arabian Journal for Science and Engineering*, vol. 47, no. 12, pp. 13 623–13 637, 2022.
- [44] S. Liu, S. Ren, and H. Jiang, "Predictive maintenance of wind turbines based on digital twin technology," *Energy Reports*, vol. 9, no. Supplement 10, pp. 1344–1352, 2023.
- [45] C. Palazzetti and M. T. López Bertani. (2024) Digital twin project set to make offshore wind power more reliable and secure. Technical University of Denmark. [Online]. Available: <https://www.icons.it/news/digital-twin-project-set-to-make-offshore-wind-power-more-reliable-and-secure>
- [46] E. Kandemir, A. Hasan, T. Kvamsdal, and S. A. Alaliyat, "Predictive digital twin for wind energy systems: A literature review," *Energy Informatics*, vol. 7, p. Article 3, 2024.
- [47] R. Pacheco-Blazquez, J. Garcia-Espinosa, D. Di Capua, and A. Pastor Sanchez, "A digital twin for assessing the remaining useful life of offshore wind turbine structures," *Journal of Marine Science and Engineering*, vol. 12, no. 4, p. 573, 2024.
- [48] DTWO Project, "Technologies," n.d. [Online]. Available: <https://dtwo-project.eu/technologies/>
- [49] T. Ltd. (2017) Windtwin project aims to revolutionise wind turbine operation with digital twin technology. [Online]. Available: <https://www.twi-global.com/media-and-events/press-releases/2017-09-windtwin-project-aims-to-revolutionise-wind-turbine-operation-with-digital-twin-technology>
- [50] W. Project. Windtwin press release. [Online]. Available: <https://windtwinproject.eu/news/press-release/>
- [51] Klarian, "Intelligent turbines," <https://klarian.com/platform/intelligent-turbines>, n.d., accessed: November 1, 2023.

- [52] XMPro, “Wind power plant wind turbine dtld models,” GitHub, n.d. [Online]. Available: <https://github.com/XMPro/Wind-Power-Plant-Wind-Turbine-DTDL-Models>
- [53] P. Korba, P. Šváb, M. Vereš, and J. Lukáč, “Optimizing aviation maintenance through algorithmic approach of real-life data,” *Applied Sciences*, vol. 13, p. 3824, 2023.
- [54] M. Efthymiou, K. McCarthy, C. Markou, and J. F. O’Connell, “Uma pesquisa exploratória sobre blockchain na aviação: O caso de organizações de manutenção, reparo e revisão (mro),” *Sustentabilidade*, vol. 14, p. 2643, 2022.
- [55] A. Saxena. (2023) Manutenção e reparo de aeronaves: caso de uso de blockchain. [Online]. Available: <https://medium.com/@aarti.saxena21/aeronave-minha-e-reparar-bl-uso-caso-3cfb>
- [56] L. Technik. Innovation & digitalization. Lufthansa Technik. [Online]. Available: <https://www.lufthansa-technik.com/en/innovation-digitalization>
- [57] Lufthansa Group, “Annual report: Combined management report – mro business segment,” 2023. [Online]. Available: <https://report.lufthansagroup.com/2023/annual-report/en/combined-management-report/business-segments/mro-business-segment/>
- [58] U. Karaoğlu, O. Mbah, and Q. Zeeshan, “Applications of machine learning in aircraft maintenance,” *Journal of Engineering Management and Systems Engineering*, vol. 2, no. 1, pp. 76–95, 2023.
- [59] A. Abbasi, “Skylink: Blockchain-based solutions for aviation and aircraft management,” <https://github.com/alcompilor/skylink>, n.d., retrieved March 16, 2025.
- [60] Drexel University, College of Computing and Informatics, “Group-8 aircraft predictive maintenance project,” <https://github.com/archd3sai/Predictive-Maintenance-of-Aircraft-Engine>, n.d., iNFO T780: Applied Machine Learning. [Online]. Available: <https://github.com/archd3sai/Predictive-Maintenance-of-Aircraft-Engine>





**Instituto Superior  
de Engenharia**

Politécnico de Coimbra