



INSTITUTO POLITÉCNICO
DE VIANA DO CASTELO

ESTG

Paradigma do Digital Twin na Predição e na Assistência em
Fábricas Inteligentes

2025



INSTITUTO POLITÉCNICO
DE VIANA DO CASTELO

Paradigma do Digital Twin na Predição e na Assistência em Fábricas Inteligentes

André Filipe Ribeiro da Costa

Escola Superior de Tecnologia e Gestão

INSTITUTO POLITÉCNICO DE VIANA DO CASTELO

Paradigma do Digital Twin na Predição e na Assistência em Fábricas Inteligentes

André Filipe Ribeiro da Costa

TRABALHO DE DISSERTAÇÃO



**Mestrado em Engenharia informática
Escola Superior de Tecnologia e Gestão**

Orientador: Prof. Doutor Pedro Miguel Teixeira Faria.

Orientador: Prof. Doutor Luís Miguel Cabrita Romero

6 de agosto de 2025

Este trabalho foi financiado pelo projeto “TEXP@CT: Pacto de Inovação para a Digitalização do STV”, no âmbito do Plano de Recuperação e Resiliência-02-C05-i01.01-2022.PC644915249-00000025, integrado no subprojeto “WP 2.2 (PPS #8): Plataforma Digital Twin para a Indústria Têxtil”.



Resumo

A Indústria 5.0 está a provocar uma transformação profunda no sector industrial, impulsionada pela integração de tecnologias avançadas como a Internet das Coisas (IoT), a Inteligência Artificial (IA) e os sistemas ciber-físicos. Neste contexto, o conceito de Gémeo Digital emergiu como solução inovadora para a monitorização e optimização de processos, permitindo criar réplicas digitais de equipamentos físicos para predição e análise em tempo real. Esta dissertação explora o paradigma do Gémeo Digital aplicado à predição e à assistência em fábricas inteligentes, com especial enfoque no desenvolvimento de um Assistente Virtual Inteligente (AVI) de apoio à manutenção e à operação de equipamentos. O trabalho divide-se em duas fases: Fase 1, dedicada à validação experimental do Gémeo Digital em ambiente laboratorial; e Fase 2, centrada na criação do AVI integrado no Gémeo Digital numa unidade fabril real. Na Fase 1 foi construído um protótipo de Gémeo Digital recorrendo a tecnologias FIWARE, IoT, aprendizagem computacional e dashboards (painéis de controlo). Os testes confirmaram a viabilidade da solução e validaram a comunicação bidirecional entre os sistemas físico e digital, permitindo recolher dados em tempo real, prever anomalias e otimizar a manutenção. A Fase 2 introduziu um AVI capaz de interagir com operadores, fornecendo—em linguagem natural—suporte ao diagnóstico de falhas, consulta de documentação técnica e recomendações de manutenção baseadas em IA. Os resultados evidenciam que a integração de um Gémeo Digital com um AVI melhora significativamente a eficiência e a fiabilidade dos processos industriais, reduzindo tempos de paragem e facilitando a tomada de decisão. A abordagem proposta abre caminho a desenvolvimentos futuros, como o refinamento dos algoritmos preditivos e a extensão da solução a outros sectores industriais.

Palavras-chave: Gémeo Digital; Indústria 5.0; Manutenção Preditiva; Assistente Virtual Inteligente; IoT; Indústria Têxtil

Abstract

Industry 5.0 has brought about a profound transformation in the industrial sector, driven by the integration of advanced technologies such as the Internet of Things , Artificial Intelligence and Cyber-Physical Systems . In this context, the Digital Twin concept has emerged as an innovative solution for monitoring and optimizing industrial processes, enabling the creation of digital replicas of physical equipment for real-time analysis.

This dissertation explores the Digital Twin paradigm in prediction and assistance in smart factories, with a special focus on the development of an Intelligent Virtual Assistant (AVI) to support the maintenance and operation of industrial equipment. The work is divided into two phases: Phase 1, which consisted of experimental validation of the concept in a laboratory environment, and Phase 2, which transposes the solution to a real context in a textile factory.

In Phase 1, a Digital Twin prototype was developed, using technologies such as FIWARE, IoT, Machine Learning and interactive dashboards. The aim of this phase was to assess the feasibility of the solution and validate the two-way communication between the physical and digital systems. The tests carried out indicated that the proposed approach is effective in collecting and analyzing data in real time, making it possible to predict anomalies and optimize maintenance processes.

Phase 2 focused on the evolution of the system, introducing an Intelligent Virtual Assistant capable of interacting with industrial operators, providing AI-based support for diagnosing faults, consulting technical documentation and making maintenance recommendations.

The results of this study show that integrating Digital Twins with Intelligent Virtual Assistance can significantly improve the efficiency and reliability of industrial processes, reducing downtime and facilitating decision-making. The proposed approach paves the way for future improvements, such as refining the predictive algorithms and expanding the solution to different industry sectors.

Keywords: Digital Twin; Industry 5.0; Predictive Maintenance; Intelligent Virtual Assistant; IoT; Textile Industry

Agradecimentos

Em primeiro lugar, gostaria de expressar o meu sincero agradecimento aos meus orientadores, o Professor Doutor Pedro Miguel Faria e o Professor Doutor Luís Romero, pela sua orientação e apoio durante todo o desenvolvimento desta dissertação. Ao Professor Luís Romero, agradeço pela sua disponibilidade e pela forma como contribuiu com o seu conhecimento e visão crítica, ajudando a enriquecer este trabalho em várias fases importantes. Um agradecimento muito especial ao Professor Pedro Miguel Faria, que foi mais do que um orientador, foi o meu verdadeiro braço direito ao longo de todo este processo. A sua constante presença, os conselhos práticos, o acompanhamento atento e o incentivo genuíno foram determinantes para a realização deste projeto. A sua confiança nas minhas capacidades e a forma como esteve sempre disponível para colaborar, discutir ideias e ultrapassar obstáculos deixaram uma marca profunda em mim e neste percurso.

Quero também deixar uma palavra de apreço a todos os membros e ex-membros do Laboratório de Interação Audiovisual, onde tive o privilégio de trabalhar e aprender diariamente: Duarte Dias, Diogo Araújo, David Verde, Tânia Silva, João Santos, Valter Gomes e João Mirra. A vossa ajuda, espírito de equipa e boa disposição contribuíram imenso para tornar este trajeto mais leve e produtivo. Um agradecimento especial ao João Mirra, que é mais do que um colega, é um grande amigo de longa data com quem tive a sorte de partilhar muito mais do que apenas esta experiência académica.

Aos amigos que contribuíram diretamente para o desenvolvimento do projeto, o meu muito obrigado. Ao Duarte Xavier, ao Ricardo Araújo e à Mariana Veiga, agradeço pelo apoio técnico, pelas ideias, pela ajuda prática, e por todas as vezes que se disponibilizaram para colaborar.

À minha família, um obrigado profundo. O vosso apoio incondicional, a paciência, o incentivo constante e a confiança que sempre depositaram em mim foram fundamentais para que nunca desistisse, mesmo nos momentos mais difíceis. Saber que estavam sempre aí, mesmo à distância, deu-me força para continuar.

À Mariana, em particular, minha companheira nesta caminhada e na vida, deixo um agradecimento profundo por tudo o que deste ao projeto e a mim: desde o cuidado no design e na experiência do utilizador até ao apoio constante, emocional e prático, que me manteve motivado até ao fim. Este trabalho também tem muito de ti.

A todos os que, de alguma forma, estiveram ao meu lado e contribuíram para esta etapa: o meu sincero obrigado. Este percurso não teria sido o mesmo sem vocês.

*“You should be glad that bridge fell down.
I was planning to build thirteen more to that same design”*

Isambard Kingdom Brunel

Conteúdo

Resumo	ii
Abstract	iii
Agradecimentos	iv
1 Introdução	1
1.1 Contexto	1
1.2 Motivação e objetivos	2
1.2.1 Motivação	2
1.2.2 Objetivos	3
1.3 Metodologia de Investigação	3
1.3.1 Design Science Research	4
1.3.2 Justificação do Método para este Trabalho	4
1.3.3 Processo de Investigação Baseado em DSR	5
1.4 Estrutura da Dissertação	5
2 Tecnologias e Paradigmas Fundamentais	7
2.1 Indústria 4.0 e Indústria 5.0	7
2.1.1 Indústria 4.0	7
2.1.2 Indústria 5.0	8
2.1.3 Transição da Indústria 4.0 para a Indústria 5.0	8
2.1.4 Manutenção Preditiva	8
2.2 Internet das Coisas	9
2.3 Gémeo Digital	9
2.3.1 Níveis de maturidade do Gémeo Digital	11
2.3.2 Tecnologias Fundamentais	13
2.3.3 Aplicações e Benefícios	13
2.3.4 Integração com Outras Tecnologias	13
2.4 Inteligência Artificial	14
2.4.1 Processamento de Linguagem Natural (PLN)	15
2.4.2 Machine learning (ML)	15
2.4.3 Redes Neurais Artificiais	16
2.4.4 Modelos de Linguagem de Grande Escala	17
2.5 Assistência Virtual Inteligente	18

3	Trabalho Relacionado	19
3.1	Revisão Sistemática	19
3.2	Estudos Relacionados	20
3.2.1	Digital Twins na Indústria	21
3.2.2	IA na Indústria	26
3.2.3	Aplicações Industriais combinando IA e Digital Twin para manutenção preditiva	30
3.3	Reflexão sobre o levantamento efetuado	34
3.4	Conclusão	37
4	Arquitetura do Sistema e Desenvolvimento	38
4.1	Fase 1: Desenvolvimento e Validação Laboratorial	39
4.1.1	Requisitos e Objetivos	39
4.1.2	Arquitetura do Sistema	40
4.1.3	Tecnologias Implementadas na Fase 1	42
4.1.4	Descrição do Fluxo de Trabalho	50
4.1.5	Cálculo das Previsões	50
4.1.6	Integração e Aplicações Práticas	51
4.1.7	CoffeeTwin: expansão interativa do Digital Twin	52
4.2	Transição entre a Fase 1 e a Fase 2 do Projeto	55
4.3	Fase 2: Desenvolvimento de um Assistente Virtual Inteligente	56
4.3.1	Requisitos e Objetivos	56
4.3.2	Arquitetura do Sistema	57
4.3.3	Tecnologias Utilizadas na Fase 2	58
4.3.4	RIA	64
4.3.5	Classe Principal: Assistente Virtual	71
4.3.6	Implementação do Backend	73
4.3.7	Interface Gráfica	75
4.3.8	Integração da RIA com Aplicações de Realidade Aumentada e Realidade Virtual	77
5	Resultados e Discussão	79
5.1	Resultados	79
5.1.1	Resultados da Fase 1 – Validação Laboratorial	79
5.1.2	Resultados da Fase 2 – RIA	80
5.2	Discussão	81
6	Conclusões e Trabalho Futuro	84
6.1	Conclusões	84
6.2	Trabalho Futuro	85
	Referências	87
A	Trabalho Publicado	97
B	Pseudocódigo do AVI	102
B-1	Modo Manutenção	103
B-2	Modo Predição	104
B-3	Modo Informação	105

B-4 Classe Assistente Virtual	106
B-5 Backend Flask API	107

Lista de Figuras

2.1	Modelo de Gémeo Digital do processo de fabrico.	10
2.2	Curva de maturidade dos Gémeos Digitais segundo Metcalfe et al.[83]	12
3.1	Processo de pesquisa para seleção de estudos.	20
3.2	Arquitetura em camadas proposta por Tarek [128], composta pelas camadas Física, de Dados, Analítica e de Apresentação.	21
3.3	Framework proposta por Raza [106]	23
3.4	Arquitetura REPLICA proposta pelo autor Rossini [110]	28
3.5	Comparação entre o sinal de entrada (linha preta), a resposta do <i>Digital Twin</i> (linha azul) e a resposta do sistema físico em condição de falha (linha vermelha).	30
3.6	Arquitetura geral do assistente <i>Max</i> [74], baseada no modelo LTA-FIT	33
3.7	Interface principal do assistente virtual em RV, incluindo diálogo, lista de componentes e visualização 3D [131]	33
4.1	Arquitetura macro das duas fases do projeto.	39
4.2	Representação integrada do Gémeo Digital: a camada física à esquerda e a camada digital à direita, incluindo os fluxos de informação que as conectam.	40
4.3	Esquema geral da arquitetura do sistema em camadas.	41
4.4	Ligação do sensor DHT11 ao Raspberry Pi.	43
4.5	Arquitetura de contentores no Docker [63].	44
4.6	Estrutura do FIWARE do sistema.	45
4.7	Arquitetura do ecossistema FIWARE em Docker	45
4.8	Dashboard usando o Grafana recebendo dados do FIWARE.	46
4.9	Estrutura da base de dados do sistema da Fase 1.	47
4.10	Modelo de comunicação de uma REST API [11].	48
4.11	Representação das etapas do processo desde a recolha de dados até às ações preventivas.	50
4.12	Cálculo das previsões de temperatura futura.	51
4.13	Esquema geral do sistema CoffeeTwin	52
4.14	Ecrã da aplicação Web que permite ao utilizador escolher entre “café curto” e “café longo” através da voz.	53
4.15	Interface de Realidade Aumentada com dados em tempo real e comandos remotos.	54
4.16	Ambiente imersivo da aplicação VR com simulação completa da operação da máquina.	54
4.17	Esquema geral da arquitetura do sistema.	58
4.18	Fluxograma do <i>Modo Manutenção</i>	66
4.19	Fluxograma do <i>Modo Predição</i>	67
4.20	Fluxograma do <i>Modo Informação</i>	69

4.21	Fluxograma da classe <i>AssistenteVirtual</i>	72
4.22	Estrutura da base de dados do backend (diagrama de classes UML).	74
4.23	Interface da RIA.	76
4.24	Gráfico interativo de previsão baseado em dados operacionais	76
4.25	Interface de Realidade Aumentada integrada com a RIA.	77
4.26	Ambiente virtual com integração da RIA.	78
5.1	Resultados do questionário SUS.	80
A.1	Artigo publicado na conferência <i>CISTI 2024</i>	98
A.2	Artigo publicado na revista <i>Sensors 2025 - MDPI</i>	99
A.3	Artigo submetido para avaliação ao <i>Journal of Applied Intelligence - Springer</i> URL: https://link.springer.com/journal/10489	100
A.4	Artigo submetido para avaliação ao <i>Journal of Applied Sciences - MDPI</i> URL: https://www.mdpi.com/journal/applsci	101

Lista de Tabelas

2.1	Resumo dos níveis de maturidade de Gémeos Digitais.	12
3.1	Comparação entre abordagens de <i>Digital Twins</i> nos estudos analisados.	25
3.2	Tabela de Estudo de Trabalhos Relacionados.	36
4.1	Comparação de Modelos da OpenAI (valores de referência em fevereiro de 2025; sujeitos a alterações futuras)	60
4.2	Comparação dos modelos preditivos aplicados à velocidade real da máquina. . .	62
5.1	Análise comparativa de assistentes.	82

Abreviaturas e Símbolos

API	Application Programming Interface
AV	Assistência Virtual
AVI	Assistência Virtual Inteligente
BIM	Building Information Modeling
CPS	Cyber-Physical Systems (Sistemas Ciberfísicos)
CSV	Comma-Separated Values
DT	Digital Twin (Gémeo Digital)
DSR	Design Science Research
DTL	Digital Twin Layer
FFmpeg	Framework multimédia Fast Forward MPEG
FIWARE	Plataforma de código aberto para Soluções Inteligentes
gTTS	Google Text-to-Speech
GPU	Graphics Processing Unit
HTTP	Hypertext Transfer Protocol
IA	Inteligência Artificial
IIoT	Industrial Internet of Things
IoT	Internet of Things
JSON	JavaScript Object Notation
KPI	Key Performance Indicator
LLM	Large Language Model
ML	Machine Learning (Aprendizagem Automática)
MQTT	Message Queuing Telemetry Transport
NARX	Non-linear Autoregressive Network with Exogenous Inputs
NLP	Natural Language Processing (Processamento de Linguagem Natural)
PdM	Predictive Maintenance (Manutenção Preditiva)
PLC	Programmable Logic Controller
PLN	Processamento de Linguagem Natural
PWM	Pulse-Width Modulation
RA	Realidade Aumentada
REST	Representational State Transfer
REST API	RESTful Application Programming Interface
RV	Realidade Virtual
SARIMAX	Seasonal ARIMA with eXogenous Regressors
SUS	System Usability Scale
XR	Extended Reality (Realidade Estendida)

Capítulo 1

Introdução

1.1 Contexto

Nos últimos anos, a Quarta Revolução Industrial (Indústria 4.0) trouxe transformações significativas aos ambientes industriais integrando tecnologias avançadas como a Internet das Coisas, Inteligência Artificial (IA) e Sistemas Ciberfísicos (SC) para criar fábricas inteligentes. Neste cenário, o Gémeo Digital emergiu como uma das tecnologias mais promissoras, permitindo uma integração contínua entre o espaço físico e o virtual. Um Gémeo Digital representa uma réplica digital de um ativo físico, estabelecendo uma interação bidirecional que combina dados históricos, operacionais e em tempo real, otimizando processos e auxiliando na tomada de decisões estratégicas [127, 84].

O conceito de Gémeo Digital foi inicialmente introduzido em 2003 por Grieves no contexto do ciclo de vida do produto e, mais tarde, formalizado pela NASA, em 2012, como uma simulação multidisciplinar que integra dados de modelos físicos, históricos e sensores em tempo real representando o estado de ativos físicos ao longo do seu ciclo de vida [127, 18]. Esta integração permite que atuem como ferramentas ativas para monitorizar, prever e otimizar o desempenho de processos e ativos industriais, habilitando uma abordagem proativa na gestão de operações.

A aplicação do Gémeo Digital no contexto de fábricas inteligentes possibilita ganhos substanciais em termos de eficiência operacional e sustentabilidade. Especificamente, no domínio da manutenção preditiva (*Predictive Maintenance* - PdM), o Gémeo Digital é fundamental para prever falhas e otimizar a vida útil dos equipamentos. A PdM utiliza dados em tempo real, extraídos de sensores e modelos digitais, para identificar padrões e anomalias que antecipam falhas potenciais [18, 105]. Ao contrário das abordagens tradicionais de manutenção que reagem a falhas ou seguem cronogramas fixos, a PdM possibilita intervenções baseadas no estado real dos equipamentos, reduzindo significativamente o tempo de inatividade e os custos operacionais [18, 84].

Contudo, a implementação de uma arquitetura de Gémeo Digital enfrenta desafios substanciais. Entre estes, destacam-se a complexidade na recolha e integração de dados provenientes de fontes heterogêneas, como sensores, modelos físicos e plataformas de IoT, além da necessidade de modelos híbridos que combinem técnicas baseadas em dados e modelos físicos para aumentar

a precisão e robustez das previsões [127, 84]. Adicionalmente, questões relacionadas com a interoperabilidade de sistemas, segurança cibernética e elevados custos iniciais de implementação representam barreiras a serem superadas [127].

1.2 Motivação e objetivos

1.2.1 Motivação

1.2.1.1 Fase 1 – Desenvolvimento inicial do Gémeo Digital

Nesta fase, o objetivo inicial foi validar num ambiente laboratorial o conceito de Gémeo Digital aplicado ao controlo bidirecional e à integração de diversas tecnologias. As principais motivações foram:

- **Demonstrar a possibilidade do controlo bidirecional** entre um equipamento real (máquina de café) e o seu gémeo digital, permitindo a monitorização e controlo remoto eficiente em tempo real.
- **Avaliar a viabilidade de integração de diferentes plataformas tecnológicas** numa solução coesa e modular.
- **Implementar e testar algoritmos de manutenção preditiva** utilizando Aprendizagem computacional para antecipação de falhas e otimização de processos.
- **Criar uma base sólida e replicável**, capaz de ser adaptada futuramente a diferentes contextos industriais.

1.2.1.2 Fase 2 – Assistente Virtual Inteligente aplicado à Indústria

Após a apresentação da solução desenvolvida na Fase 1, surgiu o interesse concreto por parte da empresa RIOPELE, particularmente orientado às potencialidades da Inteligência Artificial na assistência aos operadores industriais. As motivações específicas desta segunda fase foram:

- **Desenvolver um Assistente Virtual Inteligente** focado em melhorar o suporte à manutenção industrial através de consultas facilitadas em linguagem natural.
- **Fornecer informação operacional crítica em tempo real**, garantindo que os operadores possam tomar decisões informadas e rápidas sobre o estado das máquinas e processos produtivos.
- **Implementar técnicas avançadas de predição de falhas**, contribuindo diretamente para a redução dos tempos de paragem não-planeados e aumento da eficiência produtiva.
- **Reforçar o papel central dos operadores humanos** através de ferramentas inteligentes que simplifiquem o acesso a documentos técnicos e dados operacionais complexos, alinhando-se com o conceito de Indústria 5.0.

1.2.2 Objetivos

1.2.2.1 Objetivo Geral

Pretende-se desenvolver e validar uma solução integrada baseada no paradigma do Digital Twin, integrando tecnologias para melhorar a eficiência, a fiabilidade e a sustentabilidade dos processos industriais. A solução proposta deverá permitir a monitorização contínua dos equipamentos, a predição de falhas e fornecer suporte em tempo real aos operadores industriais através de um assistente virtual interativo. Este sistema integrará dados provenientes de sensores, algoritmos avançados de IA para análise preditiva e uma plataforma de interação que facilite a tomada de decisões informadas em ambientes industriais.

1.2.2.2 Objetivos Específicos

Para alcançar o objetivo geral, foram definidos os seguintes objetivos específicos:

1. **Estudo aprofundado das tecnologias e conceitos relacionados como Gémeo Digital, IoT e IA na Indústria 5.0:** Analisar o estado da arte e as aplicações atuais de tecnologias como o Gémeo Digital e algoritmos de IA no domínio da manutenção preditiva, com especial enfoque na interação homem-máquina e nos desafios específicos das fábricas inteligentes.
2. **Desenho conceptual de uma arquitetura de Gémeo Digital Inteligente:** Conceber uma arquitetura capaz de ligar os sistemas físicos e digitais de uma fábrica inteligente, utilizando dados recolhidos de sensores e algoritmos de IA para criar modelos preditivos para prever valores e representações virtuais de equipamentos industriais.
3. **Implementação de um sistema que integre assistentes virtuais inteligentes:** Desenvolver um assistente virtual que utilize informações fornecidas pelo Gémeo Digital para oferecer suporte aos operadores, facilitando consultas técnicas e interações eficientes com o sistema.
4. **Desenvolvimento de funcionalidades para acesso a informações técnicas:** Criar um módulo para o assistente virtual que permita a consulta de manuais técnicos e documentos de manutenção, garantindo respostas precisas e personalizadas às necessidades dos operadores.
5. **Validação experimental do sistema em ambiente real:** Realizar testes em cenários industriais reais, avaliando a eficácia do sistema em termos de predição de falhas, redução de tempos de paragem e apoio à tomada de decisão operacional.

1.3 Metodologia de Investigação

A metodologia utilizada nesta tese segue o paradigma de *Design Science Research* (DSR) [23], uma abordagem amplamente adotada em pesquisas científicas que envolvem a criação e avaliação de artefactos para resolver problemas concretos. Este método oferece um enquadramento rigoroso e estruturado para o desenvolvimento de soluções inovadoras, combinando relevância prática com rigor científico.

1.3.1 Design Science Research

De acordo com [13], o DSR é uma abordagem metodológica centrada no desenvolvimento e avaliação de artefactos que resolvem problemas reais, promovendo avanços científicos através de processos de design iterativos e bem definidos. Abrange várias etapas, que incluem a identificação de um problema relevante, o desenvolvimento de soluções (artefactos), a sua validação em cenários práticos e a comunicação dos resultados.

A metodologia DSR visa criar conhecimento aplicável e transferível, através da produção de artefactos que podem assumir diferentes formas, como modelos, frameworks, algoritmos, sistemas ou metodologias. Uma das suas características principais é o um forte ênfase na integração entre teoria e prática, garantindo que os artefactos desenvolvidos sejam cientificamente sólidos e úteis para resolver problemas concretos.

Esta abordagem permite uma contribuição científica significativa ao envolver não apenas a construção de soluções, mas também a análise do impacto dessas soluções no ambiente onde são implementadas. Esta combinação de criação e avaliação torna o DSR particularmente relevante para contextos como o da Indústria 4.0 e 5.0, onde as tecnologias emergentes precisam ser constantemente validadas no campo.

1.3.2 Justificação do Método para este Trabalho

A escolha do *Design Science Research* como metodologia de investigação para esta tese deve-se à sua adequação ao desenvolvimento e validação de sistemas tecnológicos complexos, como o paradigma do Gémeo Digital no contexto das fábricas inteligentes. As principais razões para a adoção do DSR neste trabalho incluem:

- **Natureza prática do problema:** O problema abordado está diretamente relacionado com desafios reais enfrentados na otimização de manutenção preditiva e assistência operacional em fábricas têxteis. O DSR permite abordar este problema através da criação de soluções práticas, fundamentadas em conceitos científicos rigorosos.
- **Necessidade de artefactos inovadores:** Este trabalho propõe o desenvolvimento de uma solução integrada que combina tecnologias emergentes, como Gémeo Digital, IoT e a Inteligência Artificial. O DSR fornece um enquadramento robusto para a conceção e validação destes artefactos.
- **Integração Teórico-Prática:** A abordagem DSR assegura que o conhecimento teórico produzido seja aplicado e testado em cenários práticos, como a implementação e validação numa fábrica têxtil.
- **Ciclo iterativo de desenvolvimento e avaliação:** O DSR suporta ciclos iterativos de design, desenvolvimento e avaliação, permitindo ajustes contínuos com base nos resultados obtidos durante os testes de campo.

- **Contribuição científica e prática:** A metodologia DSR assegura que os resultados desta tese tenham impacto prático no ambiente industrial e contribuam para o avanço do conhecimento científico no campo do Digital Twin e da Indústria 5.0.

1.3.3 Processo de Investigação Baseado em DSR

O trabalho descrito nesta tese segue as etapas definidas no Design Science Research, que incluem:

1. **Identificação e Motivação do Problema:** O problema centra-se na necessidade de otimizar a manutenção e a operação em fábricas inteligentes através de soluções tecnológicas baseadas no Gémeo Digital e IA.
2. **Definição dos Objetivos da Solução:** Os objetivos incluem a conceção de uma arquitetura de Gémeo Digital que suporte manutenção preditiva e disponibilize assistência virtual aos operadores.
3. **Design e Desenvolvimento:** A fase de design e desenvolvimento envolve o desenho da arquitetura do sistema, a implementação das principais funcionalidades e a integração das tecnologias e algoritmos de inteligência artificial necessários.
4. **Demonstração:** A solução será aplicada numa fábrica têxtil de modo a procurar avaliar a sua funcionalidade em cenários reais.
5. **Avaliação:** A solução será avaliada com base em métricas de desempenho, como precisão preditiva, redução de tempos de inatividade e usabilidade do assistente virtual.
6. **Comunicação:** Os resultados serão disseminados através da publicação de artigos científicos e apresentações em conferências da área.

Esta abordagem assegura que o trabalho realizado combine rigor metodológico, inovação tecnológica e impacto prático, alinhando-se com os princípios fundamentais do Design Science Research.

1.4 Estrutura da Dissertação

Para além da introdução, esta dissertação contém mais cinco capítulos.

No Capítulo 2, são descritas as principais tecnologias e paradigmas fundamentais utilizados neste trabalho. São abordados conceitos como Indústria 4.0 e 5.0, IoT, Gémeo Digital, Manutenção Preditiva, Inteligência Artificial, aprendizagem computacional e Assistência Virtual Inteligente.

No Capítulo 3, é realizada uma revisão sistemática e discutidos os trabalhos relacionados com o tema da dissertação. São apresentados estudos recentes que abordam o uso de Gémeo Digital e Assistência Virtual na manutenção industrial, permitindo um enquadramento do estado da arte.

No Capítulo 4, é apresentada a arquitetura do sistema desenvolvido e os detalhes da sua implementação. Este capítulo encontra-se dividido em duas fases: a Fase 1, que se concentrou na validação laboratorial do Gémeo Digital e tecnologias associadas, e a Fase 2, que se dedicou ao desenvolvimento do Assistente Virtual Inteligente e sua integração num ambiente real de fábrica, nomeadamente uma fábrica têxtil.

No Capítulo 5, são apresentados os testes e os resultados obtidos com a implementação do sistema. É analisado o desempenho da solução proposta e a aceitação por parte dos utilizadores.

Por fim, no Capítulo 6, são apresentadas as conclusões da dissertação e discutidas as principais contribuições deste trabalho. São sugeridas possíveis direções para trabalho futuro, incluindo melhorias na integração do sistema com algoritmos preditivos mais avançados e a sua aplicação em diferentes contextos industriais.

Capítulo 2

Tecnologias e Paradigmas Fundamentais

Nesta secção são apresentados os principais conceitos e tecnologias que fundamentam o trabalho desenvolvido, com destaque para o paradigma do Gémeo Digital e os métodos associados à Indústria 4.0 e 5.0.

2.1 Indústria 4.0 e Indústria 5.0

A evolução das revoluções industriais reflete as transformações tecnológicas, sociais e económicas ao longo do tempo. A transição da Indústria 4.0 para a Indústria 5.0 ilustra um avanço significativo que combina tecnologia avançada com a centralidade humana, respondendo aos desafios do presente e as necessidades futuras.

2.1.1 Indústria 4.0

A Indústria 4.0, também conhecida como a Quarta Revolução Industrial, é caracterizada pela integração de tecnologias digitais no ambiente fabril, permitindo a automação avançada, a conectividade e a otimização de processos em tempo real. O termo foi introduzido em 2011 por Wolfgang Wahlster na Feira de Hannover, na Alemanha, e está centrado na utilização de tecnologias como IoT, sistemas ciberfísicos, Inteligência Artificial, Big Data e Gémeo Digital [73]. Estas tecnologias possibilitam a criação de fábricas inteligentes, onde máquinas e processos comunicam e controlam-se mutuamente, promovendo alta eficiência e produtividade.

Entretanto, a Indústria 4.0 também trouxe desafios, como o aumento da desigualdade económica devido à substituição de mão de obra menos qualificada por sistemas automatizados e o impacto ambiental resultante de processos industriais otimizados para a eficiência, mas não necessariamente para a sustentabilidade [115]. Essas questões abriram caminho para discussões sobre a transição para a Indústria 5.0.

2.1.2 Indústria 5.0

A Indústria 5.0 surge como uma resposta às limitações da Indústria 4.0, introduzindo o conceito de centralidade humana e bem-estar no trabalho e sustentabilidade no cerne dos processos industriais. Este paradigma visa a colaboração harmoniosa entre humanos e máquinas, utilizando tecnologias avançadas como robôs colaborativos (cobots) e IA para promover processos mais resilientes e humanizados [73].

Enquanto a Indústria 4.0 prioriza a automação e a conectividade, a Indústria 5.0 concentra-se em como essas tecnologias podem melhorar a interação entre humanos e máquinas, garantindo bem-estar, criatividade e adaptabilidade. Procura práticas sustentáveis reduzindo o impacto ambiental e promovendo uma economia circular [115]. A Indústria 5.0 é vista como uma extensão lógica da Indústria 4.0, integrando avanços tecnológicos e sociais para criar um sistema industrial mais equilibrado.

2.1.3 Transição da Indústria 4.0 para a Indústria 5.0

A transição entre a Indústria 4.0 e a Indústria 5.0 é impulsionada pela necessidade de superar os desafios económicos, sociais e ambientais da Quarta Revolução Industrial. Essa transição é marcada por três pilares principais: centralidade humana, sustentabilidade e resiliência [73]. A Indústria 5.0 reintroduz o elemento humano na produção, valorizando as contribuições criativas dos trabalhadores enquanto utiliza máquinas para tarefas repetitivas e de alta precisão.

A transição envolve a adoção de práticas sustentáveis em toda a cadeia de valor, com o objetivo de equilibrar eficiência económica, responsabilidade ambiental e inclusão social [115]. Assim, a Indústria 5.0 não substitui a Indústria 4.0, mas complementa-a, colmatando as suas lacunas e promovendo um paradigma mais equilibrado e colaborativo.

2.1.4 Manutenção Preditiva

A manutenção preditiva é uma abordagem avançada, no âmbito da gestão de manutenção, que visa prever falhas em equipamentos antes que estas ocorram, permitindo a programação de intervenções de forma mais eficiente e reduzindo custos. Segundo o P.Nunes [91], esta estratégia combina tecnologias emergentes, como IoT e Sistemas Ciberfísicos, com técnicas de análise de dados para monitorizar continuamente o estado dos equipamentos e estimar a sua vida útil restante. Com isso, é possível planejar manutenções de forma precisa, minimizando paragens inesperadas e otimizando os recursos disponíveis. Esta depende de sensores para capturar dados sobre parâmetros físicos dos equipamentos, como vibrações, temperaturas e tensões, que são analisados por meio de algoritmos avançados incluindo modelos estatísticos e técnicas de aprendizagem computacional. Esses sistemas permitem a identificação de padrões anómalos e a previsão de degradações antes que causem falhas críticas nos equipamentos fabris.

2.2 Internet das Coisas

O conceito de Internet das Coisas pode ser entendido como a interconexão de objetos físicos por meio de sensores, dispositivos inteligentes e redes de comunicação, permitindo a recolha, troca e processamento de dados em tempo real. Manglani et al. [77] descrevem a IoT como um sistema capaz de integrar dispositivos com capacidade de comunicação, sensores e atuadores para criar um ecossistema digital. Esses dispositivos podem operar de forma autónoma, recebendo dados do ambiente físico e fornecendo informações para tomadas de decisão inteligentes em diferentes contextos, como saúde, transporte e fabrico.

Sanislav et al. [114] ampliam essa definição, associando a IoT a sistemas ciberfísicos, em que componentes físicos e digitais estão integrados para replicar processos reais no ambiente virtual. Esses sistemas utilizam sensores para monitorar variáveis, como temperatura, pressão e vibração, e transmitem dados em tempo real para o espaço virtual. A IoT desempenha um papel central na criação de Gémeos Digitais, uma vez que possibilita a recolha e análise de dados necessários para modelar e simular processos industriais e urbanos em tempo real.

2.3 Gémeo Digital

O conceito de Gémeo Digital é amplamente reconhecido como uma representação virtual de um sistema ou objeto físico, que permite uma integração bidirecional de dados entre o mundo físico e o digital. Segundo Fuller [43], esta tecnologia emergente tem vindo a ganhar destaque no contexto da Indústria 4.0, tirando partido da conectividade proporcionada pela IoT e dos avanços em análise de dados para criar um Gémeo Digital que reflete, em tempo real, o estado e o funcionamento de um ativo físico. Mais do que uma mera simulação, os Gémeos Digitais envolvem uma troca contínua e integrada de dados, permitindo atualizações automáticas tanto no modelo digital como no físico, promovendo assim capacidades de análise preditiva e manutenção preventiva. Desde a sua introdução formal, em 2003, por Michael Grieves, no âmbito de um curso de gestão do ciclo de vida do produto, o conceito de Gémeo Digital tem evoluído significativamente. Grieves definiu-o como a combinação de três elementos essenciais: o produto físico, a sua representação virtual e as conexões bidirecionais entre ambos [49]. Estas conexões asseguram uma sincronização constante entre os dois domínios, permitindo que alterações num sejam refletidas de forma imediata e fiável no outro.

Jones et al. [66] salientam que o Gémeo Digital não é uma réplica estática, mas sim um sistema dinâmico que permite simular, otimizar e prever comportamentos. Para Attaran e Celik [6], a sua aplicação transcende o ciclo de vida do produto, abrangendo desde a fase de conceção até à desativação, permitindo uma análise histórica e contínua dos dados recolhidos ao longo do tempo.

Inspirada no modelo publicado pela Deloitte University Press [24], a Figura 2.1 apresenta, numa estrutura hexagonal tridimensional, a orquestração do ciclo de vida de um Gémeo Digital aplicado a processos industriais. O lado esquerdo (a verde) representa o domínio físico—máquinas, sensores e atuadores—, enquanto o lado direito (a azul) representa o domínio digital—dados,




Figura 2.1: Modelo de Gémeo Digital do processo de fabrico.

análises e visualizações. Ao centro, a aresta vertical em ciano simboliza a Camada de Integração, que atua como elo fundamental entre os dois domínios, assegurando a normalização, filtragem e distribuição bidirecional de informação com coerência temporal e semântica. Cada aresta do hexágono representa uma função macro que descreve o fluxo de dados e de conhecimento entre os dois mundos:

- **Create** — criação do ativo físico e do respetivo gémeo digital, incorporando especificações de engenharia, listas de materiais (*Bill of Materials*, BOM) e requisitos funcionais.
- **Act** — execução de ações no ambiente físico por meio de atuadores, com base em decisões geradas digitalmente, encerrando o ciclo de controlo.
- **Communicate** — recolha de dados por sensores e transmissão em tempo real, através de redes industriais de IoT (*Industrial IoT*), para a camada de integração.
- **Aggregate** — consolidação, limpeza e normalização dos dados no domínio digital, utilizando *data lakes*, sistemas de gestão de bases de dados temporais (*Database Management Systems*, DBMS) e técnicas de processamento em fluxo (*stream processing*).
- **Analyse** — aplicação de métodos analíticos, como estatística, *machine learning* e simulação, para deteção de padrões, previsão de falhas e otimização do desempenho dos sistemas.
- **Insight** — transformação do conhecimento gerado em recomendações acionáveis, direcionadas a operadores humanos ou a mecanismos de atuação automática.

A Camada de Integração desempenha um papel central, sendo responsável por garantir a sincronização bidirecional necessária para que o gémeo digital funcione em tempo real e com fiabilidade. É nesta camada que se resolvem latências, se harmonizam modelos de dados heterogéneos e se assegura a coerência entre versões digitais. Sem esta infraestrutura, o sistema corre o risco de se tornar num simples *Digital Shadow* [71], onde os dados fluem apenas num sentido, comprometendo a capacidade de reação e a eficácia das decisões.

Relação entre Building Information Modeling (BIM) e Gémeo Digital

O BIM pode ser visto como o antecessor conceptual dos Gémeos Digitais no sector da Arquitetura, Engenharia e Construção (AEC). De acordo com Eastman *et al.* [32], o BIM corresponde a um modelo tridimensional paramétrico que agrega informação geométrica e semântica ao longo de todo o ciclo de vida do edifício, desde o projeto até à demolição. Contudo, o BIM opera maioritariamente como um *Digital Model* estático ou, no máximo, como um *Digital Shadow*—isto é, com fluxo de dados unidirecional (físico $\rightarrow$ digital). Para evoluir para um verdadeiro Gémeo Digital é necessário integrar fontes de dados em tempo-real e estabelecer um canal bidirecional que permita não só monitorizar, mas também atuar sobre o ativo físico. Uma revisão sistemática recente [104] identifica quatro posições na literatura ($BIM \subset DT(DigitalTwin)$, $DT \subset BIM$, $BIM \equiv DT$, ou sem relação) e conclui que a diferença chave reside precisamente na capacidade de ciclo fechado com análise preditiva e otimização.

Em síntese, o BIM fornece a base geométrica e informacional, enquanto o Gémeo Digital adiciona conectividade IoT, analítica avançada e mecanismos de decisão.

2.3.1 Níveis de maturidade do Gémeo Digital

Para avaliar o grau de evolução do protótipo desenvolvido, adota-se o modelo de Metcalfe *et al.* [83], que define cinco níveis de maturidade (ML1–ML5). A Tabela 2.1 resume as características de cada nível, enquanto a Figura 2.2 ilustra graficamente a progressão.




Figura 2.2: Curva de maturidade dos Gémeos Digitais segundo Metcalfe et al.[83]

Posicionamento do protótipo. A implementação laboratorial descrita no Capítulo 4 na Fase 1, cumpre os critérios de *Predictive Gémeo Digital* (ML3), pois:

1. Recolhe dados em tempo-real de múltiplos sensores (*Communicate* e *Aggregate*) e armazena histórico.
2. Incorpora modelos de regressão linear para manutenção preditiva (*Analyse*) que geram alertas antecipados.
3. Permite controlo remoto *ad-hoc* (start/stop) mas ainda depende da decisão humana, não fechando o ciclo *Insight*→*Act* de forma autónoma.

Tabela 2.1: Resumo dos níveis de maturidade de Gémeos Digitais.

Nível	Tipo	Descrição resumida
ML1	Status	Captura e visualização de dados em tempo-real.
ML2	Informative	Integra dados históricos e de referência.
ML3	Predictive	Acrescenta modelos preditivos (ML ou baseados em física) para antecipar falhas e tendências.
ML4	Optimisation	Explora cenários <i>what-if</i> e recomenda ações .
ML5	Autonomous	Atua autonomamente com aprendizagem contínua.

Consequentemente, o próximo passo lógico para evoluir para o nível ML4 passa por integrar um módulo de simulação em tempo-real que compare cenários alternativos (*what-if*) e proponha — ou aplique — configurações ótimas de operação.

2.3.2 Tecnologias Fundamentais

De acordo com Attaran e Celik [6], as tecnologias fundamentais que permitem o funcionamento dos Gémeo Digitais incluem:

- **IoT:** Utilização de sensores para recolher dados do mundo físico e transmiti-los para o modelo digital em tempo real.
- **Computação em Nuvem:** Armazenamento e processamento de grandes volumes de dados, permitindo o acesso remoto e análises em tempo real.
- **Análise de Dados:** Ferramentas analíticas avançadas que processam os dados recolhidos para gerar previsões.

2.3.3 Aplicações e Benefícios

Os Gémeos Digitais têm transformado vários setores industriais. No setor fabril, são usados para otimizar processos produtivos, prever falhas e melhorar a eficiência operacional [66]. Na agricultura, permitem a gestão de recursos de forma sustentável, enquanto na saúde, possibilitam o desenvolvimento de modelos personalizados de pacientes, contribuindo para diagnósticos mais precisos [6].

Os benefícios incluem a redução de custos operacionais, maior previsibilidade de falhas, e a possibilidade de testar cenários no ambiente virtual antes de os implementar no ambiente físico, mitigando riscos e acelerando inovações.

2.3.4 Integração com Outras Tecnologias

Uma das características centrais do Gémeo Digital é a sua capacidade de integrar-se com outras tecnologias avançadas, criando um sistema coeso e inteligente. Esta integração permite que o Gémeo Digital vá além da mera representação digital, atuando como um elemento central para a otimização de operações industriais.

- **Manutenção Preditiva (MP):** Com base nos dados recolhidos em tempo real, o Gémeo Digital permite prever falhas em máquinas e equipamentos, antecipando intervenções de manutenção antes que ocorram problemas. Esta capacidade melhora significativamente a eficiência operacional e reduz o tempo de inatividade não planeado.
- **Assistência Virtual Inteligente (AVI):** A integração do Gémeo Digital com sistemas de assistentes virtuais fornece aos operadores uma interface avançada para consultar o estado das máquinas e receber alertas em tempo real. O AVI pode ajudar no diagnóstico de problemas e na consulta de manuais, tudo suportado por IA.
- **Inteligência Artificial :** A IA é uma peça chave para transformar os dados recolhidos pelo Gémeo Digital em informação acionável. Por exemplo, algoritmos de aprendizagem

computacional podem ser usados para identificar padrões ocultos nos dados, prever comportamentos e otimizar processos industriais de forma contínua.

2.4 Inteligência Artificial

A Inteligência Artificial é um campo interdisciplinar da ciência computacional que visa criar sistemas capazes de realizar tarefas que normalmente exigiriam inteligência humana, como reconhecer padrões, tomar decisões e compreender a linguagem natural. De acordo com a definição fornecida pela IBM [60], a IA simula a cognição humana, permitindo que máquinas analisem dados, aprendam com eles e ajustem o seu comportamento com base na experiência acumulada. Esta tecnologia está na base de diversas aplicações, desde sistemas de recomendação em plataformas digitais até ferramentas de diagnóstico médico.

A Universidade de Illinois em Chicago complementa esta definição ao enfatizar que a IA não se limita à automação de tarefas, mas sim ao desenvolvimento de sistemas que aprendem, adaptam-se e colaboram com humanos para resolver problemas complexos [92]. Este avanço é possibilitado pela combinação de algoritmos avançados, grandes volumes de dados e capacidades computacionais robustas, permitindo que os sistemas de IA não só executem tarefas específicas, mas também otimizem processos de forma contínua.

A ISO (International Organization for Standardization) [35], também oferece uma perspectiva importante ao sublinhar que a IA engloba ML, DL, Supervised Learning, Unsupervised Learning, Self-supervised learning, reinforcement learning, etc. Estas áreas capacitam sistemas para interpretar o mundo, aprender com interações e tomar decisões de forma autônoma, o que torna a IA uma tecnologia central na transformação digital da sociedade.

2.4.0.1 Abordagens e Aplicações

A Inteligência Artificial pode ser abordada de várias formas, dependendo do tipo de problema e do objetivo a ser alcançado. Segundo Russell e Norvig [111], as principais abordagens incluem sistemas baseados em regras, busca e otimização, raciocínio probabilístico e aprendizagem computacional. Os sistemas baseados em regras utilizam lógica simbólica para representar conhecimento e tomar decisões, sendo amplamente usados em sistemas especialistas, como diagnósticos médicos. Já a busca e otimização modelam problemas como espaços de estados, permitindo que algoritmos, encontrem soluções eficientes, especialmente em planejamento e navegação. O raciocínio probabilístico lida com incertezas através de técnicas como redes bayesianas [9] e modelos Markov ocultos [12], fundamentais em diagnósticos e previsões. O aprendizagem computacional, por sua vez, é atualmente a abordagem mais dominante, capacitando sistemas a identificar padrões e tomar decisões com base em dados, sendo aplicada em áreas como classificação de imagens e análise preditiva. Estas abordagens têm transformado diversos setores. Na saúde, são usadas para diagnósticos assistidos e sistemas de apoio clínico. Na indústria, otimizam processos e implementam manutenção preditiva. Na área dos transportes, os algoritmos de IA são fundamentais para o desenvolvimento de veículos autônomos.

2.4.1 Processamento de Linguagem Natural (PLN)

O Processamento de Linguagem Natural é uma subárea da Inteligência Artificial que permite aos computadores compreender, interpretar e gerar linguagem humana, tanto escrita quanto falada. O objetivo principal do PLN é criar sistemas que interajam de maneira eficiente e intuitiva com seres humanos, aproximando a comunicação máquina-homem do comportamento natural humano. De acordo com Dr. Chandrika G [44], o PLN é amplamente utilizado em assistentes virtuais como Alexa [4] e Siri [62], que interpretam comandos de voz e geram respostas adequadas em linguagem natural. No contexto da gestão, como destacado por Kang et al. [67], o PLN tem sido aplicado para analisar grandes volumes de dados textuais, como relatórios anuais, comentários em redes sociais e documentos legislativos. Este campo oferece ferramentas poderosas para a análise de sentimentos, compreensão de tendências de mercado e previsão de comportamentos de consumo. A importância do PLN reside na sua capacidade de automatizar tarefas linguísticas complexas, reduzindo esforços manuais e aumentando a eficiência em vários setores.

2.4.1.1 Técnicas e Algoritmos de PLN

As técnicas e algoritmos de PLN evoluíram significativamente ao longo dos anos, passando de métodos baseados em regras para abordagens modernas baseadas em aprendizagem computacional e redes neurais profundas. Dr. Chandrika G [44] destaca técnicas fundamentais, como análise lexical, análise sintática e análise semântica. Estas técnicas permitem que sistemas identifiquem estruturas gramaticais, extraiam significados de frases e compreendam contextos mais amplos. Exemplos incluem ferramentas como Named Entity Recognition (NER) [130] para identificar entidades específicas e análise de sentimentos para medir opiniões positivas ou negativas.

Por outro lado, Kang et al. [67] exploram algoritmos mais avançados, como Bag-of-Words (BOW) [55], Term Frequency-Inverse Document Frequency (TF-IDF) [112] e Word2Vec [85], usados para representar texto de maneira vetorial. Modelos modernos como redes neurais convolucionais (CNN) [70] e redes neurais recorrentes (RNN) [33] têm revolucionado o campo, permitindo avanços em tradução automática, resumo de textos e classificação de documentos. Estas técnicas são amplamente utilizadas em setores como marketing, finanças e operações, ajudando as organizações a extrair conhecimento valioso a partir de grandes volumes de dados.

2.4.2 Machine learning (ML)

Machine learning, ou aprendizagem automática, é uma subárea da Inteligência Artificial que se foca em criar sistemas que aprendem a partir de dados. Em vez de serem explicitamente programados para realizar cada tarefa, os modelos de ML utilizam algoritmos que identificam padrões em grandes volumes de dados e usam esses padrões para tomar decisões ou fazer previsões [123]. Esta abordagem diferencia-se da programação tradicional, na qual todas as regras são definidas manualmente, permitindo que as máquinas se adaptem a novos cenários e problemas.

A relação entre IA e ML é estreita: enquanto a IA engloba um conjunto mais amplo de tecnologias que simulam a inteligência humana, o ML é a técnica principal que permite que os

sistemas de IA aprendam e melhorem automaticamente. Como destacado por Sarker [117], o ML tem um papel essencial em aplicações modernas de IA, sendo utilizado em sistemas como reconhecimento de voz, análise preditiva e condução autónoma. Para simplificar, podemos pensar no ML como o "motor" que alimenta muitas das funcionalidades práticas da IA. Um exemplo comum é o de assistentes virtuais, que utilizam algoritmos de ML para interpretar comandos de voz, aprender preferências do utilizador e melhorar a sua precisão ao longo do tempo.

2.4.2.1 Aprendizagem Supervisionada

Na aprendizagem supervisionada, os modelos são treinados com dados rotulados, ou seja, onde cada entrada está associada a uma saída conhecida. Esta abordagem pode ser vista como ensinar uma máquina a "resolver problemas", fornecendo-lhe exemplos específicos. Singh [123] explica que este método é amplamente utilizado em tarefas como classificação (ex.: identificar e-mails como spam ou não) e regressão (ex.: prever preços de imóveis com base em características como localização e tamanho). Os algoritmos supervisionados são amplamente aplicados em áreas como a saúde, onde sistemas preditivos ajudam no diagnóstico de doenças, e no setor financeiro, para prever o comportamento do mercado. Entre os métodos mais comuns estão árvores de decisão, máquinas de vetores de suporte (SVM) e redes neuronais. Segundo Sarker [117], a eficácia da aprendizagem supervisionada depende da qualidade dos dados e da capacidade do modelo de generalizar para novos exemplos.

2.4.2.2 Aprendizagem Não Supervisionada

Aprendizagem não supervisionada, por outro lado, lida com dados que não possuem rótulos ou categorias predefinidas. Em vez de aprender a associar entradas e saídas específicas, os modelos exploram os dados para identificar padrões e estruturas ocultas [123]. Esta abordagem é frequentemente utilizada para tarefas como agrupamento (ex.: segmentação de clientes) e redução de dimensionalidade (ex.: simplificação de grandes volumes de dados para facilitar a análise).

Sarker [117] destaca que a aprendizagem não supervisionada é essencial em áreas como segurança cibernética, onde algoritmos podem detetar anomalias que indicam possíveis ataques, e na análise de redes sociais, para identificar tendências e agrupamentos de utilizadores.

2.4.3 Redes Neuronais Artificiais

As *Redes Neuronais Artificiais* são modelos computacionais inspirados no funcionamento dos neurónios biológicos. A sua estrutura é composta por nós (neurónios) organizados em camadas, ligados entre si por pesos sinápticos que regulam a influência entre as unidades [46]. Durante o processo de aprendizagem, esses pesos são ajustados iterativamente, recorrendo a algoritmos como o *back-propagation* e a descida do gradiente, com o objetivo de minimizar uma função de perda.

Do *perceptron*(perceptrão) às arquiteturas profundas O *perceptrão* de Rosenblatt (1958) demonstrou capacidade para resolver problemas de classificação linear. No entanto, foi a introdução

das redes *Multi-Layer Perceptron* (MLP), com uma ou mais camadas ocultas não lineares, que permitiu aproximar funções complexas e não lineares [58]. Nas últimas duas décadas, o aumento do poder computacional e o acesso a grandes volumes de dados permitiram o desenvolvimento do chamado *aprendizado profundo* (*deep learning*), onde redes com dezenas de camadas são treinadas para resolver tarefas altamente complexas [72, 118].

Alguns dos principais tipos de redes neurais incluem:

- **Redes Convolucionais (CNN)** — particularmente eficazes no processamento de dados com estrutura espacial, como imagens ou padrões captados por sensores. Utilizam filtros convolucionais para extrair automaticamente características relevantes de forma local.
- **Redes Recorrentes (RNN, LSTM, GRU)** — ideais para dados sequenciais, como séries temporais e texto. Estas redes mantêm uma memória interna que lhes permite capturar dependências temporais, sendo muito úteis na previsão de degradação de equipamentos com base em dados históricos [56].
- **Transformers** — arquiteturas modernas baseadas em mecanismos de atenção, que facilitam a paralelização do treino. Têm vindo a ser exploradas em aplicações industriais complexas, como prognóstico multivariável [133].

Em ambientes industriais inteligentes, as RNA têm um impacto significativo, permitindo:

1. **Manutenção preditiva:** deteção precoce de anomalias em sensores de vibração, temperatura ou consumo energético, contribuindo para a redução de paragens não planeadas.
2. **Otimização de processos:** ajustamento dinâmico de parâmetros operacionais (por exemplo, a velocidade de teares ou a temperatura em processos de tingimento), com vista a maximizar a eficiência e a qualidade.
3. **Integração com Gémeo Digitais:** os modelos neurais podem ser integrados no Gémeo Digital para atualizar, em tempo real, a representação do ativo físico e fornecer previsões que alimentam mecanismos de controlo automático.

2.4.4 Modelos de Linguagem de Grande Escala

Os Modelos de Linguagem de Grande Escala, do inglês (*Large Language Models*-LLM) constituem uma classe de modelos de rede neuronal profunda treinados com técnicas de aprendizagem auto-supervisionada sobre corpora massivos de texto não rotulado. O objetivo do treino passa por prever a próxima palavra em sequência, tarefa simples que, quando realizada em largas escalas de dados e parâmetros, dota o modelo de capacidades de geração coerente de texto, compreensão de contexto e raciocínio tácito. A literatura identifica três pilares fundamentais: a utilização de arquiteturas *transformer* com mecanismos de auto-atenção, que permitem ao modelo ponderar, em paralelo, a relevância de cada palavra no contexto; o dimensionamento — quer em volume de dados, quer em número de parâmetros — que conduz a fenómenos de

capacidades “emergentes”, isto é, competências não observadas em modelos de menor porte; e afinação (*fine-tuning*) ou *instruction tuning* sobre subconjuntos curados de dados, para alinhar o comportamento do modelo com objectivos específicos ou princípios de segurança. Entre as aplicações mais comuns contam-se motores de busca conversacionais, sistemas de resumo automático, tradução, programação assistida e suporte ao utilizador em tempo real. Apesar do seu potencial, os LLMs colocam desafios relevantes, tais como o elevado custo computacional do treino, a necessidade de hardware especializado (GPUs ou TPUs), a tendência para gerar factos incorretos (*hallucinations*) e a propagação de enviesamentos presentes nos dados de origem, tornando imprescindível a avaliação cuidadosa da fiabilidade das respostas e a implementação de camadas adicionais de verificação humana [14, 134, 137].

2.5 Assistência Virtual Inteligente

A Assistência Virtual Inteligente refere-se a sistemas baseados em inteligência artificial que interagem com os utilizadores de forma natural e intuitiva, simulando diálogos humanos para executar tarefas ou fornecer serviços personalizados. Estes sistemas, têm evoluído significativamente nos últimos anos, tornando-se ferramentas indispensáveis na gestão de tarefas quotidianas, como configurar lembretes, controlar dispositivos conectados ou obter informações em tempo real.

De acordo com Saifeddin Alimamy [3], as AVIs destacam-se pela sua capacidade de personalização e autenticidade, características que aumentam o envolvimento e a confiança dos utilizadores. Estes sistemas não apenas respondem a comandos, mas também aprendem com as interações anteriores, adaptando as respostas às preferências individuais de cada utilizador. A personalização pode incluir, por exemplo, ajustes com base em rotinas ou preferências, como fornecer atualizações de trânsito ou lembretes de eventos específicos, contribuindo para uma experiência mais fluida e satisfatória.

O design de AVIs promove uma sensação de autenticidade, especialmente através da humanização da voz e do comportamento, o que incentiva os utilizadores a estabelecerem uma ligação emocional com o sistema.

Capítulo 3

Trabalho Relacionado

3.1 Revisão Sistemática

Para caracterizar o estado da arte em *Digital Twins*, Assistência Virtual Inteligente e Manutenção Preditiva na evolução da Indústria 4.0 para a Indústria 5.0, realizou-se uma revisão sistemática em conformidade com as recomendações *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA) 2020 [96].

A pesquisa incidiu sobre duas bases de dados complementares. Na IEEE Xplore [61] realizou-se, num primeiro momento, uma consulta ampla aos metadados, combinando os termos “Industry 4.0”, “Digital Twin” e conceitos relacionados com previsão de falhas, manutenção e assistência inteligente, tendo sido obtidos 290 registos. De seguida, aplicou-se uma pesquisa mais restrita, limitada às *Author Keywords*, que exigia ainda a presença de termos como “Artificial Intelligence”, “Virtual Assistant” ou “Predictive Maintenance”. Este segundo filtro reduziu o conjunto a 22 artigos, mais próximos dos objetivos desta investigação.

Para assegurar uma cobertura mais alargada, recorreu-se também ao Google Scholar [48], utilizando uma expressão de pesquisa composta com os termos “Digital Twin”, “predictive maintenance”, “industry 4.0” ou “smart factory” e “artificial intelligence”, limitada ao intervalo 2018–2025, para obter estudos mais atuais. Foram inicialmente identificados 218 registos, dos quais 42 artigos foram seleccionados após triagem por título e resumo, removendo-se os que eram manifestamente irrelevantes ou duplicados.

Critérios de inclusão

- Artigos revistos por pares publicados entre 2020 e 2025;
- Referência explícita a *Digital Twins*, manutenção preditiva ou assistentes virtuais em contexto industrial;
- Contributo prático ou teórico relevante para a transição Indústria 4.0 para 5.0.

Critérios de exclusão

- Texto integral indisponível;

- Duplicados entre bases de dados;
- Estudos fora da manufatura ou sem relação direta com os objetivos da investigação.

Após a remoção de duplicados (38 registos) e a triagem inicial por título e resumo (194 exclusões), foram avaliados em texto integral 80 artigos. Destes, 64 foram excluídos por não cumprirem os critérios definidos (falta de contributo prático, contexto não industrial, ou ausência de dados originais). O processo culminou com a inclusão de 16 estudos na síntese qualitativa que serve de base ao trabalho relacionado apresentado. O processo completo é apresentado na Figura 3.1 .

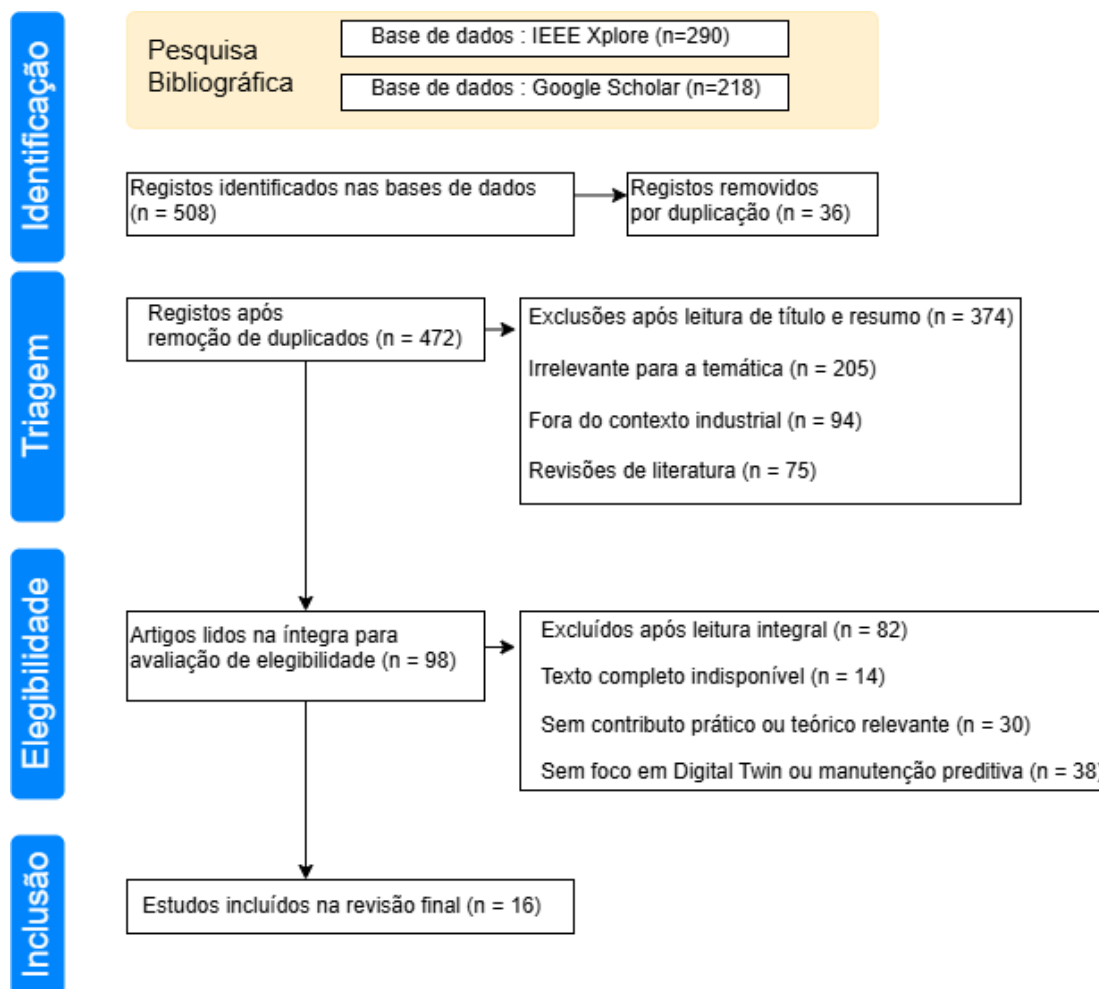


Figura 3.1: Processo de pesquisa para seleção de estudos.

3.2 Estudos Relacionados

Os avanços na integração de tecnologias emergentes, como *Digital Twins*, IoT, Big Data e Inteligência Artificial, têm transformado profundamente os sistemas industriais e os processos operacionais. Arquiteturas flexíveis e modelos em camadas têm vindo a ser desenvolvidos para

conectar os mundos físico e virtual, promovendo eficiência e adaptabilidade em ambientes de manufatura [132]. Paralelamente, a manutenção preditiva ganha destaque ao utilizar algoritmos de *machine learning* e frameworks inovadores para prever falhas, otimizar intervenções e reduzir custos operacionais. A inteligência artificial expande a sua aplicação em contextos industriais, permitindo a análise avançada de dados, personalização de sistemas e automação de decisões, evidenciando o potencial dessas tecnologias para impulsionar a inovação e a resiliência em cenários dinâmicos e complexos [76].

3.2.1 Digital Twins na Indústria

Tarek et al. [128] apresentam uma arquitetura flexível de *Digital Twin* projetada para otimizar processos numa fábrica de ração avícola. O modelo adota uma estrutura de quatro camadas (ver Figura 3.2), começando com sensores IoT para coleta de dados em tempo real transmitidos através do protocolo MQTT(Message Queuing Telemetry Transport) [103]. Os dados são armazenados no InfluxDB [65], especializado em dados temporais e no Neo4j [88], uma base de dados de grafos de conhecimento, usada para modelar o processo de manufatura, representando ativos, organização e fluxo de produção.




Figura 3.2: Arquitetura em camadas proposta por Tarek [128], composta pelas camadas Física, de Dados, Analítica e de Apresentação.

O sistema inclui uma camada de processamento que utiliza grafos de conhecimento para análises avançadas e simulações, permitindo prever impactos de mudanças nos processos e adaptar-se em tempo real. A camada final oferece uma interface gráfica interativa, que permite monitorizar o estado da fábrica e realizar ajustes remotos. Para integração, o sistema utiliza Apache Kafka [5] para gerir eventos e uma API RESTful desenvolvida com Flask [97], assegurando comunicação eficiente entre os módulos. Embora eficaz em ambientes controlados, o estudo não explora a implementação em sistemas industriais mais complexos, onde seria necessário interligar-se com sistemas legados — ou seja, plataformas e equipamentos existentes, muitas vezes baseados em tecnologias antigas

mas críticas para a operação diária — nem discute os desafios adicionais de cibersegurança que tal integração acarreta. Rosen et al. [109] exploram o papel central dos *Digital Twins* como elementos fundamentais para alcançar sistemas de manufatura mais autônomos e interconectados, alinhados com os princípios da Indústria 4.0. O estudo destaca que os DTs permitem uma representação virtual precisa dos processos físicos, possibilitando um fluxo contínuo e bidirecional de dados entre o mundo real e o digital. Essa integração não apenas viabiliza a monitorização em tempo real, mas também facilita simulações avançadas que otimizam processos ao longo de todo o ciclo de vida do produto. Um dos principais pontos enfatizados no artigo é a capacidade dos DTs em promoverem modularidade e conectividade nos sistemas de manufatura, permitindo que fábricas reajam de forma dinâmica a mudanças no ambiente operacional. Por exemplo, alterações na procura ou falhas inesperadas em máquinas podem ser rapidamente identificadas e resolvidas por meio das análises e simulações oferecidas pelos DTs eliminando a necessidade de reconfigurações manuais demoradas. Essa flexibilidade operacional representa um avanço significativo na eficiência e na resiliência dos sistemas industriais. Os autores detalham como os DTs, ao serem combinados com tecnologias como sensores IoT e algoritmos de inteligência artificial, permitem a realização de diagnósticos preditivos e a antecipação de problemas antes que esses ocorram. As simulações baseadas em DTs, por sua vez, são amplamente utilizadas para testar cenários, validar processos e identificar oportunidades de melhoria sem riscos para a operação real. Essas capacidades tornam os DTs numa ferramenta indispensável para a evolução de sistemas produtivos cada vez mais autônomos e inteligentes.

Enquanto Tarek et al. [128] se concentram na arquitetura modular e na organização dos dados com grafos de conhecimento, Rosen et al. [109] ampliam essa visão ao explorar o impacto da modularidade e da conectividade para alcançar autonomia industrial e adaptar-se a ambientes operacionais dinâmicos, ao expandir a discussão sobre a autonomia industrial, indo além da organização de dados e grafos de conhecimento para abordar a adaptabilidade e a inteligência operacional em ambientes altamente dinâmicos. Dessa forma, o trabalho de Rosen et al. reforça a visão de que os DTs são a base para uma manufatura resiliente e eficiente, onde a conectividade e a análise avançada de dados desempenham papéis cruciais no futuro das fábricas inteligentes. Amplificando o estudo de Rosen et al. [109] na autonomia e conectividade, Raza et al. [106] demonstram a aplicação prática desses princípios por meio de um framework de *Digital Twin* projetado para simular e otimizar uma linha de produção industrial em tempo real. Raza et al. [106] propõem um framework de *Digital Twin* especificamente desenvolvido para replicar e otimizar uma linha de produção real, utilizando a Festo Cyber Physical Factory [1] como caso de estudo. O trabalho apresenta uma réplica digital que permite simular e monitorizar processos de montagem industrial, integrando tecnologias como IoT, Big Data Analytics e sistemas ciberfísicos.

A estrutura proposta por Raza et al. [106], Figura 3.3, é composta por módulos que interligam o sistema físico e a instância digital para fornecer serviços estendidos, incluindo diagnósticos em tempo real e manutenção preditiva. O framework recolhe dados de sensores durante todas as fases do ciclo de vida do produto, desde o design e a fabricação, até à distribuição e manutenção utilizando dispositivos para adquirir informações operacionais e de manutenção em tempo real.




Figura 3.3: Framework proposta por Raza [106]

Esses dados são analisados por ferramentas de Big Data, gerando previsões que são enviados de volta ao sistema físico para otimizar o desempenho e a manutenção.

O estudo também destaca a implementação de uma réplica gráfica e animada das estações de montagem, que simula as operações das primeiras três estações da linha de produção. Este simulador não apenas oferece uma representação visual dos processos, como também utiliza algoritmos inteligentes para identificar falhas, devolver produtos às estações necessárias para corrigir problemas e priorizar operações pendentes com base nos dados recolhidos. A comunicação eficiente entre os componentes físicos e os digitais é facilitada por uma integração contínua de sensores, leitores de RFID e mecanismos de controlo baseados em localização. Os autores realçam o uso de animações contínuas para demonstrar a interação dinâmica entre o sistema físico e o digital. A implementação permite operações como a inspeção de qualidade, ajustes baseados em feedback em tempo real e a adaptação de processos às especificações de produção. Essas capacidades tornam o DT proposto numa ferramenta eficaz para testar e validar operações industriais sem interromper as atividades no chão de fábrica — isto é, a área física onde se encontram as linhas de produção, as máquinas e os operadores, e onde decorrem todas as atividades essenciais da manufatura.

Attaran et al. [7] salientam que a combinação entre *Digital Twins* e o *Industrial Internet of Things* (IIoT) constitui a base fundamental para a transformação dos processos industriais no contexto da Indústria 4.0. O estudo aborda como o IIoT possibilita a recolha e análise de dados em tempo real de sistemas físicos, os quais são então utilizados para alimentar as réplicas digitais. Essas réplicas digitais não apenas otimizam operações industriais, mas também permitem prever falhas e simular condições específicas, oferecendo suporte a decisões baseadas em dados e promovendo eficiência e agilidade operacionais. A aplicação prática dos DTs, segundo os autores, abrange desde a gestão de cadeias de suprimentos até a manutenção preditiva e o controlo de processos

industriais. O artigo ressalta as tecnologias fundamentais que viabilizam os DTs, incluindo IoT, computação em nuvem, inteligência artificial, realidade aumentada e blockchain. Essas tecnologias trabalham em conjunto para criar um ambiente interconectado, onde a troca contínua de dados entre o físico e o digital é a chave para alcançar operações industriais mais inteligentes e resilientes. A computação em nuvem, por exemplo, oferece a infraestrutura necessária para lidar com os altos volumes de dados gerados por dispositivos IoT, enquanto a IA permite analisar esses dados de forma avançada, detectando padrões e propondo melhorias em tempo real. Esse trabalho complementa e expande as ideias exploradas por Raza et al. [106], que demonstraram a viabilidade de um framework de DT em ambientes industriais ciberfísicos, com foco na otimização de linhas de produção. No entanto, Attaran et al. aprofundam a discussão ao explorar o papel estratégico do IIoT como base para conectar o mundo físico ao digital, destacando como a integração de tecnologias emergentes amplia o âmbito e a funcionalidade dos DTs. Da mesma forma, enquanto Rosen et al. [109] destacaram a capacidade dos DTs de proporcionar autonomia e modularidade em sistemas industriais, Attaran enfatiza o potencial de transformação no controle e na análise operacional, particularmente em cenários complexos onde a tomada de decisão rápida e baseada em dados é essencial.

Gu et al. [50] apresentam oD-RODS (*Digital Twin Framework for Dynamic and Robust Distributed Systems*), um framework inovador que aborda os principais desafios na implementação de gêmeos digitais em sistemas industriais complexos e distribuídos. Este framework adota uma abordagem em camadas que integra aprendizagem de máquinas e mecanismos de verificação e validação (V&V), assegurando a robustez e resiliência dos sistemas digitais. A arquitetura proposta é projetada para melhorar a integração com sistemas legados, otimizar a eficiência energética e lidar com grandes volumes de dados operacionais.

O D-RODS organiza-se em diferentes contextos funcionais, destacando-se:

- **Contexto Físico :** Representa os processos e ativos físicos, funcionando como a base para recolha de dados.
- **Contexto de aprendizagem :** Concentra-se na criação de modelos digitais por meio de aprendizagem de máquina. Este contexto realiza filtragem de dados, seleção de características e construção de modelos preditivos com base em séries temporais, utilizando redes neurais avançadas, como a arquitetura NARX (Nonlinear Autoregressive Network with Exogenous Inputs) [10].
- **Contexto Funcional e Contexto de Infraestrutura :** Incorporam algoritmos de IA e ferramentas para supervisionar e otimizar o desempenho dos DTs. Estes blocos asseguram que os gêmeos digitais não apenas refletem com precisão os sistemas físicos, mas também sejam adaptáveis às mudanças no ambiente operacional.

Um ponto inovador do D-RODS é o uso de técnicas de verificação e validação para garantir a fidelidade dos modelos digitais. O framework aborda questões como a fragmentação de dados, a regressão a partir de valores-alvo esparsos e a definição de atrasos temporais, desafios comuns na

modelação de sistemas complexos. Além de usar ferramentas como o **Simulink** [2] para simular e validar modelos em ambientes controlados, testando cenários como falhas operacionais e limitações de recursos. Comparado com os estudos anteriores, como o de Attaran et al. [7], que enfatizam a sinergia entre DTs e IIoT, o D-RODS avança ao fornecer uma solução abrangente para a criação de DTs em sistemas distribuídos. Ele destaca a importância da escalabilidade e da robustez em cenários industriais, integrando aprendizagem contínua e técnicas de V&V para enfrentar as incertezas e complexidades dos ambientes industriais. Este trabalho complementa as abordagens exploradas por Rosen et al. [109] ao reforçar a necessidade de modularidade e adaptabilidade em sistemas distribuídos e autônomos.

Tabela 3.1: Comparação entre abordagens de *Digital Twins* nos estudos analisados.

Estudo	Tecnologias Envolvidas	Arquitetura / Camadas	Objetivo Principal	Limitações / Desafios
[128]Nehal Tarek	MQTT, InfluxDB, Neo4j, Apache Kafka, Flask, grafos de conhecimento	Quatro camadas: sensores, dados, processamento e visualização	Desenvolver um DT flexível para uma fábrica de ração com modelação baseada em grafos	Escalabilidade e integração com sistemas industriais reais não abordadas
[109] Roland Rosen	Simulação baseada em modelos, sensores IoT, conectividade digital	Visão modular e conectada com comunicação bidirecional entre físico e virtual	Explorar DTs como facilitadores de modularidade, conectividade e autonomia industrial	Abordagem conceitual, sem aplicação prática detalhada
[106] Mohsin Raza	IoT, Big Data, RFID, simulação gráfica em tempo real	Módulos integrados com comunicação contínua entre <i>Digital Twin</i> e físico	Replicar e otimizar uma linha de produção com feedback automático	Limitações na escalabilidade e abrangência do modelo físico
[7] Sharmin Attaran	IIoT, IA, Blockchain, Cloud, Big Data, AR/VR	Integração tecnológica com foco em eficiência e tomada de decisão baseada em dados	Destacar o papel do IIoT como base dos DTs e mostrar aplicações em Indústria 4.0	Abordagem ampla e teórica; sem validação experimental concreta
[50] Rong Gu	IA, NARX, <i>machine learning</i> , Verificação e Validação (V&V), Simulink	Quatro contextos: Físico, aprendizagem, Funcionalidade e Infraestrutura	Criar um framework robusto e escalável para DTs em sistemas distribuídos industriais	Alta complexidade na modelação e na integração em cenários reais

A análise comparativa evidencia três tendências transversais. Primeiro, verifica-se uma aposta crescente em arquiteturas em camadas: tanto Tarek et al. [128] como Gu et al. [50] recorrem expressamente a estruturas de quatro níveis, embora com ênfase distintas (sensores → dados → processamento → visualização versus Físico → Aprendizagem → Funcional → Infra-estrutura). Esta modularidade facilita a substituição de componentes e a evolução incremental do sistema, mas levanta desafios de integração quando estão presentes equipamentos legados — ou seja, máquinas ou sistemas mais antigos, ainda em operação, que não foram concebidos para comunicar com tecnologias digitais modernas —, bem como quando existem requisitos de cibersegurança mais exigentes.

Em segundo lugar, as tecnologias de apoio divergem consoante a maturidade do estudo. Trabalhos conceituais, como o de Rosen et al. [109], limitam-se a sensores IoT e simulação, ao passo que abordagens mais recentes já integram conjuntos tecnológicos interligados, como Big Data, blockchain e computação em nuvem (Attaran et al. [7]). Mesmo assim, apenas Gu et al. [50] tratam explicitamente a verificação e validação, sublinhando que a fiabilidade do *Digital Twin* continua pouco explorada.

Por fim, nota-se um desalinhamento entre o objetivo declarado e a avaliação empírica: apenas dois dos cinco estudos apresentam casos de utilização em ambiente fabril real (Tarek et al. e Raza et al.) e, ainda assim, com limitações de escala. Isto confirma a lacuna identificada na revisão sistemática: há necessidade de validar frameworks de *Digital Twins* em contextos industriais complexos, com sistemas legados e requisitos de segurança rigorosos — precisamente o espaço de contribuição desta tese.

3.2.2 IA na Indústria

O paradigma do *Digital Twin* emergiu como uma solução inovadora para a monitorização e predição de falhas em sistemas industriais, promovendo uma manutenção preditiva mais eficiente e reduzindo custos operacionais. Com foco nesse potencial, Cardoso e Ferreira [15] investigam como ferramentas de Inteligência Artificial, especificamente algoritmos de *machine learning*, podem ser aplicados a dados recolhidos via IoT para prever falhas e otimizar intervenções de manutenção.

No estudo, os autores utilizam um conjunto de dados reais que inclui telemetria, logs de erro, histórico de manutenção e registos de falhas. A análise concentra-se em combinar dados históricos de sensores — como tensão, rotação, pressão e vibração — com técnicas avançadas, criando novas variáveis que melhor representam os padrões de falhas. Este processo permite que algoritmos de aprendizagem supervisionada sejam treinados para prever falhas iminentes com base em intervalos temporais definidos. Uma abordagem destacada no artigo é a categorização das condições de operação em “estável” ou “pré-instável”, permitindo que os modelos detetem anomalias antes de estas resultarem em falhas críticas. Os autores sublinham a dificuldade associada ao desbalanceamento das classes — um problema típico na manutenção preditiva, dado que os eventos de falha ocorrem com muito menor frequência do que os períodos de operação normal. Nessa situação privilegiam-se métricas como Recall (taxa de deteção de falhas reais) e Precision (proporção de alertas que correspondem efetivamente a falhas), pois diminuem a probabilidade de falsos negativos, algo crucial em ambientes industriais. Este trabalho não apenas demonstra o potencial do uso de *machine learning* na manutenção preditiva, mas também reforça a conexão natural entre *Digital Twins* e predição de falhas, estabelecendo uma base metodológica robusta para aplicações industriais. Em conjunto com estudos anteriores, como os de Rosen et al. [109], que enfatizam a modularidade e conectividade e Raza et al. [106], que exploram a integração de Big Data, o trabalho de Cardoso e Ferreira adiciona uma camada prática ao demonstrar como dados reais podem ser usados para alcançar melhores resultados em cenários de manutenção preditiva.

Por outro lado, Guc e Chen [52] apresentam um framework inovador para Manutenção Preditiva Inteligente, alavancado por *Digital Twins* e Smart Big Data. O modelo proposto não se limita à simulação do comportamento físico das máquinas, mas utiliza os DTs para gerar dados sintéticos de alta fidelidade, uma abordagem essencial para superar a limitação de conjuntos de dados reais insuficientes. Esses dados sintéticos permitem expandir a capacidade analítica de sistemas preditivos, garantindo uma visão mais abrangente do estado operacional das máquinas, mesmo em condições de dados esparsos ou ausentes. O framework incorpora tecnologias como Edge Computing e Análise Avançada de Dados para processar grandes volumes de informação em tempo

real, extraída de sensores integrados nos sistemas físicos. O uso de algoritmos de *machine learning* permite não apenas identificar falhas iminentes, mas também prever a vida útil remanescente dos componentes, otimizando o planejamento de manutenção e reduzindo o tempo de inatividade não programado. Uma contribuição notável deste estudo é a aplicação de Big Data de forma inteligente, explorando dinâmicas subjacentes e físicas dos sistemas para enriquecer os modelos preditivos. O framework cria dados sintéticos ao simular cenários de falha sob diferentes condições, como variações no ambiente de operação (exemplo: mudanças na carga ou interferências de ruído). Esses dados simulados refletem com precisão situações reais, ajudando a treinar os modelos preditivos de forma mais eficaz. Esse método permite que o framework aborde falhas críticas de forma proativa, melhorando significativamente a eficiência operacional.

Rossini et al. [110] apresentam a arquitetura REPLICA (Figura 3.4) como uma solução inovadora para O diagnóstico de falhas e a manutenção preditiva em sistemas industriais, focando em flexibilidade e escalabilidade. A arquitetura incorpora uma rede sensorial adaptativa capaz de recolher dados em tempo real, integrando-se perfeitamente com módulos de Inteligência Artificial numa abordagem plug-and-play. Essa modularidade facilita a rápida adaptação às mudanças do ambiente industrial, permitindo que as empresas ajustem os seus sistemas de forma eficiente pde modo a enfrentar desafios operacionais emergentes.

O REPLICA também utiliza simulações distribuídas e uma coordenação eficaz dos seus componentes para prever falhas e otimizar processos, demonstrando como uma arquitetura bem projetada pode transformar a gestão industrial. A capacidade de interoperar com diferentes tecnologias e sistemas torna o REPLICA uma ferramenta indispensável para cenários industriais complexos, onde a personalização e a integração são essenciais para o sucesso. Çınar et al. [138] complementam essa discussão ao explorarem o uso de algoritmos de *machine learning* em manutenção preditiva no contexto da Indústria 4.0. Este estudo fornece uma visão abrangente de como tecnologias emergentes, como redes neuronais artificiais ou máquinas de vetores de suporte podem ser aplicadas para identificar falhas e prever a vida útil remanescente de componentes industriais com alta precisão. O trabalho destaca o potencial transformador de algoritmos de ML ao lidar com grandes volumes de dados operacionais, frequentemente multivariados e dinâmicos, recebidos por sensores inteligentes integrados em sistemas de IoT. Essa abordagem é essencial para capacitar sistemas industriais para diagnosticarem e resolverem problemas em tempo real, minimizando interrupções e custos. Diferentemente do REPLICA, que prioriza a modularidade e a escalabilidade, o foco de Çınar et al. está na seleção criteriosa de algoritmos que possam lidar com a complexidade dos dados, ampliando as possibilidades de integração com sistemas preexistentes e promovendo uma manufatura mais sustentável e eficiente. Esses dois estudos, embora complementares nas suas abordagens, ilustram diferentes facetas do potencial da manutenção preditiva habilitada por *Digital Twins* e tecnologias de aprendizagem de máquina. Ambos reforçam a ideia de que a inovação tecnológica, quando aplicada de maneira estratégica, pode redefinir a forma como sistemas industriais operam, promovendo maior resiliência, eficiência e sustentabilidade num cenário de crescente complexidade.

Khneyzer et al. [68] mostram que a inteligência artificial está a mudar profundamente a forma




Figura 3.4: Arquitetura REPLICA proposta pelo autor Rossini [110]

como as empresas gerem a relação com os clientes. Ao recorrer a algoritmos de aprendizagem automática e aprendizagem profunda, é possível personalizar as interações e antecipar tendências de consumo. O estudo foca-se na integração de chatbots alimentados por IA que, graças a técnicas avançadas de processamento de linguagem natural e análise preditiva, automatizam o atendimento e proporcionam uma experiência mais fluida e eficaz. Além de reduzirem custos operacionais, estes sistemas ajustam-se em tempo real às necessidades dos utilizadores e geram informações úteis para otimizar recursos e melhorar o serviço, sobretudo em setores como o retalho e o turismo. A investigação sublinha, assim, a flexibilidade destas soluções e a sua capacidade de responder rapidamente às mudanças no comportamento do consumidor, tornando-as ferramentas essenciais para uma gestão personalizada e eficiente. Complementando este contexto, Siddiqui et al. [121] exploram o papel da Inteligência Artificial no desenvolvimento de gémeos digitais aplicados à manutenção preditiva em sistemas de automação industrial. O estudo propõe um modelo baseado em redes neurais recorrentes dinâmicas, como a NARX (Nonlinear Autoregressive Network with Exogenous Inputs), que combina dados em tempo real de sensores com entradas externas para prever anomalias e evitar falhas catastróficas. Esta abordagem permite capturar a complexidade dos sistemas industriais, que muitas vezes são não lineares e altamente dinâmicos. Para validar a eficácia do modelo proposto, os autores realizaram uma série de experiências em que compararam a resposta do sistema físico com a do *Digital Twin*, usando como sinal de entrada a variação de frequência de um sinal PWM — (Pulse-Width Modulation), um tipo de onda retangular cujo ciclo útil (percentagem de tempo em que permanece no nível alto) é modulado para regular potência ou velocidade em motores e atuadores. Foram recolhidos dados reais tanto em condições normais como em cenários com falhas induzidas. A mesma entrada foi aplicada, em malha fechada, ao sistema físico e ao *Digital Twin*. A Figura 3.5 mostra um desses ensaios, comparando a resposta do sistema físico com falha (linha vermelha) e a do *Digital Twin* (linha azul); o sinal PWM de excitação é representado a preto. A precisão da predição é quantificada através do Erro Quadrático Médio (MSE – Mean Squared Error), uma métrica estatística que mede a diferença entre os valores reais (observados) e os valores previstos por um modelo. Quanto menor o valor do MSE, maior a proximidade entre as duas respostas, o que indica um melhor desempenho do modelo.

Os resultados demonstraram que o MSE entre a resposta do *Digital Twin* e o sistema físico em condições saudáveis foi de apenas 2.05, enquanto em condição de falha o MSE subiu para 5.07. Considerando que o limiar de alarme foi definido em 2.15, o sistema foi capaz de detetar anomalias com elevada sensibilidade: o valor de 2.05 (ligeiramente abaixo do limite) confirmou a normalidade, enquanto o valor de 5.07 (substancialmente acima) sinalizou corretamente a condição de falha. Estes resultados validam o modelo como uma ferramenta eficaz para deteção automática de anomalias em tempo real, demonstrando o potencial da combinação entre IA e gémeos digitais em ambientes industriais complexos e exigentes.

Samatas et al. [113], por sua vez, oferecem uma visão abrangente sobre como a IA, em conjunto com a Internet das Coisas, está a redefinir o panorama da manutenção preditiva. O estudo analisa a eficácia de diferentes algoritmos de IA, incluindo Redes neurais Artificiais, Máquinas de Vetores de Suporte e Random Forest, na análise de dados provenientes de sensores industriais.




Figura 3.5: Comparação entre o sinal de entrada (linha preta), a resposta do *Digital Twin* (linha azul) e a resposta do sistema físico em condição de falha (linha vermelha).

Um aspeto importante abordado é o desafio de lidar com dados desbalanceados, frequentemente encontrados em contextos industriais, onde eventos de falha são raros mas críticos. O trabalho apresenta soluções para melhorar o desempenho dos modelos em tais condições, reforçando a ideia de que a seleção criteriosa de algoritmos é essencial para garantir resultados robustos e confiáveis. A capacidade dos modelos de IA de se adaptarem a diferentes volumes e tipos de dados torna-os indispensáveis para o futuro da indústria.

Ao ligar estes estudos, percebe-se como a IA tem desempenhado um papel central em diversas áreas, desde a personalização de experiências no CRM (Customer Relationship Management) — ou gestão da relação com o cliente, isto é, o conjunto de estratégias, processos e plataformas digitais que recolhem e analisam dados de vendas, marketing e apoio ao cliente para oferecer interações mais relevantes e oportunas — até à otimização de sistemas industriais complexos. Enquanto Khneyzer et al. focam o seu trabalho no estudo do impacto da IA em ambientes orientados para o cliente, Siddiqui et al. e Samatas et al. ampliam o escopo, demonstrando como as tecnologias de IA e DTs podem ser aplicadas para criar operações industriais mais inteligentes e resilientes.

3.2.3 Aplicações Industriais combinando IA e Digital Twin para manutenção preditiva

Os assistentes virtuais têm vindo a assumir um papel relevante na Indústria 5.0, sobretudo no apoio técnico e na automatização de operações. Segundo Pereira et al. [99], estes sistemas destacam-se pela sua capacidade de fornecer informações em tempo real, apoiar diagnósticos e facilitar a execução de tarefas complexas. Ao contrário dos chatbots, apresentam um maior grau de autonomia, sendo aplicados em cenários como o suporte a operadores, a manutenção preditiva e a

integração com sistemas robóticos, contribuindo assim para ambientes industriais mais eficientes e seguros.

Apesar dos avanços, Pereira et al. identificam desafios significativos na implementação desses sistemas, como a dificuldade em operar em ambientes ruidosos, a integração com sistemas legados e a garantia de segurança e privacidade dos dados. No entanto, os autores argumentam que os contínuos avanços em inteligência artificial e tecnologias de interface natural, como o processamento de linguagem natural, abrirão novas possibilidades para os assistentes virtuais, ampliando ainda mais sua aplicabilidade no setor industrial. Este trabalho sublinha a importância estratégica dos assistentes virtuais no contexto da digitalização das fábricas inteligentes, enfatizando a sua capacidade de atuar como mediadores entre os operadores humanos e as tecnologias digitais. A abordagem proposta reforça a visão de que os assistentes virtuais são elementos-chave para alcançar maior eficiência, flexibilidade e sustentabilidade nas operações industriais, alinhando-se com os objetivos centrais da Indústria 4.0.

Guachun-Arias e Serpa-Andrade [51] propõem um ambiente assente na Internet das Coisas para controlar processos industriais através de comandos de voz emitidos por assistentes virtuais, reduzindo o tempo de interação face a botões e ecrãs tátil. A arquitetura recorre a uma Raspberry Pi ligado a um Controlador Lógico Programável Siemens PLC - um PLC amplamente adotado em automação industrial pela sua fiabilidade e facilidade de programação [122]. A troca de dados entre os dispositivos é realizada via Modbus TCP/IP, protocolo aberto e amplamente suportado que permite comunicação mestre-escravo sobre redes Ethernet industriais [95]. Para expor os serviços locais da Raspberry Pi na Internet de forma segura, os autores utilizam o Ngrok, ferramenta de tunelização que cria ligações HTTPS seguras e evita configurações complexas de encaminhamento de portas [90]. Uma característica central deste trabalho é a criação de "skills" personalizadas para o assistente de voz Alexa, permitindo que operadores emitam comandos simples, como iniciar ou parar um motor, ajustar frequências, ou monitorizar variáveis do sistema. O uso de uma interface de voz oferece maior mobilidade e eficiência aos operadores, eliminando a necessidade de interações manuais constantes. Durante a fase de validação, os autores analisaram o desempenho do sistema em diferentes condições, incluindo ambientes industriais ruidosos. Os resultados indicaram que o sistema funciona bem em níveis de ruído moderados (50 a 80 dB), mas apresenta limitações em níveis de ruído elevados (>80 dB), destacando a importância de integrar tecnologias de cancelamento de ruído em implementações futuras. O estudo também enfatiza os benefícios de reduzir tempos operacionais ao comparar a interface proposta com métodos tradicionais. A implementação de comandos de voz mostrou-se mais eficiente em cenários onde a interação com botões exigiria maior esforço e tempo.

Os assistentes virtuais desempenham um papel cada vez mais relevante na automação de tarefas e na melhoria da interação homem-máquina, com impacto significativo em ambientes de trabalho e no quotidiano. Haghighat et al. [54] investigaram a eficácia dos AVIs em escritórios, analisando de que modo as variáveis como ruído de fundo e complexidade das tarefas influenciam o desempenho e a carga cognitiva dos utilizadores. Os resultados mostram que, em condições silenciosas, os AVIs proporcionam ganhos consideráveis de eficiência, especialmente em tarefas simples, como

configurar notificações ou enviar e-mails. No entanto, o estudo destaca os desafios enfrentados em ambientes ruidosos, particularmente com ruídos verbais, que comprometem a precisão do reconhecimento de comandos e aumentam a frustração dos utilizadores, evidenciando limitações técnicas que ainda necessitam de ser superadas. Kumaran et al. [87] apresentam um framework detalhado para a implementação de assistentes pessoais inteligentes baseados em voz, com foco em promover interações fluidas e seguras através do uso de tecnologias como reconhecimento de voz, sintetizadores de fala e um parser semântico designado SURR (Semantic Unifier for Resolving Requests). O SURR funciona como um unificador de intenções: recebe a transcrição da fala, aplica desambiguação semântica e converte o pedido do utilizador num formato estruturado que o sistema pode executar. O framework destaca-se pela sua arquitetura modular, dividida em três componentes principais: comandos sociais, web e shell, cada um projetado para atender a diferentes categorias de interação com o utilizador. A inovação central deste trabalho reside na capacidade do sistema em interpretar comandos complexos utilizando o parser SURR, que unifica semântica e contexto para gerar respostas precisas e adequadas às solicitações dos utilizadores. Os autores enfatizam a importância da privacidade e a segurança dos dados, implementando uma abordagem baseada em base de dados locais para armazenar informações pessoais, eliminando a dependência de servidores externos para processar dados sensíveis. O estudo também explora o potencial dos assistentes inteligentes em diversos cenários práticos, com aplicações que incluem interação social (como consultas a eventos e notificações), e integração com a web para fornecer informações em tempo real. Essa versatilidade torna o framework adaptável a diferentes ambientes, incluindo os industriais, onde o uso de comandos de voz pode reduzir a necessidade de interações manuais e otimizar fluxos de trabalho. Este trabalho complementa abordagens anteriores, como a de Guachun-Arias e Serpa-Andrade [51], ao oferecer uma visão mais técnica e detalhada sobre como assistentes virtuais podem ser implementados de maneira eficiente e segura.

Dando continuidade aos contributos já discutidos, investigações recentes mostram que os assistentes virtuais estão a evoluir, passando de simples interfaces conversacionais para verdadeiros auxiliares ativos da produção. Li et al. [74] apresentaram o *Max*, um assistente virtual integrado num robot móvel industrial que utiliza um modelo denominado LTA-FIT. Este modelo recorre ao algoritmo BERT, uma técnica avançada de processamento de linguagem natural que permite ao sistema compreender a intenção dos utilizadores, juntamente com um grafo de conhecimento, uma estrutura que armazena informação de forma interligada para respostas mais precisas. Em cenários práticos de aprendizagem, treino e assistência direta aos operadores, o sistema demonstrou bons tempos de resposta e uma boa capacidade de adaptação às diferentes necessidades dos utilizadores, reforçando que comandos por voz tornam a colaboração entre humanos e robots mais natural e intuitiva. A arquitetura detalhada do assistente *Max* pode ser observada na Figura 3.6.




Figura 3.6: Arquitetura geral do assistente *Max* [74], baseada no modelo LTA-FIT .

Na área de consultoria técnica, Trappey et al. [131] desenvolveram um assistente virtual integrado num ambiente interativo de Realidade Virtual para apoiar a conceção de transformadores de potência. Este assistente foi treinado com um vasto conjunto de documentos técnicos, permitindo atingir uma precisão superior a 91% nas respostas fornecidas. Através da visualização tridimensional, os utilizadores conseguem avaliar melhor as implicações das decisões técnicas, reduzindo significativamente o tempo necessário para o desenvolvimento colaborativo entre clientes e fabricantes, como ilustrado na Figura 3.7.




Figura 3.7: Interface principal do assistente virtual em RV, incluindo diálogo, lista de componentes e visualização 3D [131] .

Complementando esta abordagem, Pavlov et al. [98] demonstraram as vantagens da utilização combinada de Realidade Virtual e Realidade Aumentada em serviços analíticos para monitorização industrial. As soluções denominadas *Centro de Situação* e *Assistente Virtual* permitiram uma identificação mais rápida e eficiente de problemas em linhas de produção do setor metalomecânico, comparativamente às abordagens tradicionais de painéis bidimensionais. Estes sistemas tornam mais fácil a análise e atuação em indicadores-chave de desempenho diretamente no ambiente

industrial. No domínio da formação profissional, Casillo et al. [16] propuseram um assistente virtual capaz de guiar trabalhadores recém-admitidos durante tarefas industriais complexas.

Num estudo realizado com trinta participantes, aqueles que utilizaram o assistente virtual obtiveram resultados superiores em cinco das sete áreas avaliadas. Este sucesso deveu-se à implementação de tutoriais personalizados e disponibilizados exatamente no momento necessário, facilitando a retenção do conhecimento e reduzindo significativamente o tempo necessário para a integração dos novos colaboradores. Por fim, Mantravadi et al. [78] desenvolveram um assistente virtual concebido especificamente para facilitar o acesso a informações críticas nos sistemas de execução da produção (MES - Manufacturing Execution System). Este assistente permite aos utilizadores consultarem rapidamente, através de linguagem natural, informações sobre encomendas, gestão de inventários e alertas técnicos. Os resultados do estudo demonstraram que esta abordagem reduz consideravelmente o esforço e o tempo necessários para obter dados importantes, provando que interfaces conversacionais podem simplificar o acesso à informação e apoiar eficazmente a tomada de decisões no chão de fábrica.

Em resumo, estes estudos recentes destacam três tendências essenciais no desenvolvimento dos assistentes virtuais industriais: a utilização de técnicas avançadas de linguagem natural e bases de conhecimento estruturadas para respostas mais precisas; a combinação de tecnologias imersivas como RV e RA para aumentar a perceção do contexto industrial por parte dos operadores e a inclusão de ferramentas preditivas e analíticas que tornam os assistentes participantes ativos na tomada de decisões. Contudo, permanecem desafios importantes, como a organização rigorosa dos dados industriais, a compatibilidade com sistemas mais antigos e a garantia da privacidade dos utilizadores. Ainda assim, os benefícios observados apontam claramente para um impacto positivo significativo na eficiência, flexibilidade e aprendizagem contínua, refletindo os princípios fundamentais da Indústria 5.0 centrada nas pessoas.

3.3 Reflexão sobre o levantamento efetuado

A análise dos estudos revela que os avanços tecnológicos têm transformado profundamente os sistemas industriais e os processos operacionais. Os *Digital Twins* emergiram como uma ferramenta indispensável para ligar os mundos físico e digital, promovendo eficiência, adaptabilidade e autonomia operacional. Essas tecnologias evoluíram de simples réplicas digitais para sistemas inteligentes e interconectados, capazes de monitorizar, simular e otimizar operações em tempo real. O uso de arquiteturas modulares, aliadas a camadas bem definidas para recolha, armazenamento e processamento de dados, tem-se mostrado eficaz na gestão de fluxos de trabalho industriais. Desafios como a integração com sistemas existentes, a segurança cibernética e a escalabilidade continuam a ser pontos críticos que necessitam de soluções mais robustas.

Os *Digital Twins* também se destacam pela capacidade de prever falhas e otimizar intervenções de manutenção, proporcionando economias significativas nos custos operacionais. Soluções baseadas em algoritmos de inteligência artificial, como *machine learning*, têm demonstrado grande eficácia na análise de dados complexos e multivariados, permitindo prever anomalias e antecipar

falhas críticas. Adicionalmente, a geração de dados sintéticos de alta fidelidade tem-se mostrado uma alternativa promissora para superar limitações de conjuntos de dados reais enriquecendo os modelos preditivos e tornando-os mais robustos em cenários industriais. A integração de sensores inteligentes e algoritmos avançados também tem sido fundamental para transformar a manutenção preditiva otimizando os processos em tempo real e promovendo maior eficiência e resiliência operacional.

No campo da interação homem-máquina, os assistentes virtuais têm desempenhado um papel essencial tanto na automação de tarefas como no apoio técnico a operadores. Estas interfaces inteligentes oferecem a capacidade de fornecer informações contextualizadas em tempo real e de facilitar interações com sistemas complexos. Tecnologias de comandos de voz têm-se mostrado promissoras para aumentar a eficiência e a mobilidade dos operadores reduzindo a necessidade de interações manuais. No entanto, ainda enfrentam limitações em ambientes ruidosos e na integração com infraestruturas preexistentes o que reforça a necessidade de avanços em tecnologias de interface natural como o processamento de linguagem natural e o cancelamento de ruído.

Conforme evidenciado na Tabela 3.2, de forma geral, os resultados analisados apontam para uma convergência clara entre *Digital Twins*, inteligência artificial e assistentes virtuais na transformação do ambiente industrial. Enquanto os *Digital Twins* asseguram a conectividade e a autonomia, a inteligência artificial oferece ferramentas analíticas avançadas para otimizar processos. Os assistentes virtuais estabelecem uma ponte eficiente entre os operadores humanos e os sistemas digitais. Apesar dos desafios, como a integração de sistemas, segurança de dados e limitações técnicas, os contínuos avanços nessas áreas prometem expandir ainda mais a sua aplicabilidade, promovendo maior eficiência, sustentabilidade e resiliência nas operações industriais.

Tabela 3.2: Tabela de Estudo de Trabalhos Relacionados.

Estudo	Tecnologia	Contexto	Objetivo	Limitações
[128] Tarek	<i>Digital Twin</i> , IoT, Grafos de Conhecimento	Manufatura	Monitorização e otimização de processos	Integração com sistemas legados e ciber-segurança
[109] Rosen	<i>Digital Twin</i> , IoT, Big Data	Fábricas Inteligentes	Simulação e otimização do ciclo de vida do produto	Limitação na integração modular e com novas tecnologias
[106] Raza	<i>Digital Twin</i> , IoT, Big Data	Linha de Produção	Simulação e manutenção preditiva em tempo real	Escalabilidade em linhas mais complexas
[7] Attaran	<i>Digital Twin</i> , IIoT, Cloud	Gestão de Processos Industriais	Análise preditiva e eficiência operacional	Integração com <i>blockchain</i> ainda em fase inicial
[50] Gu	<i>Digital Twin</i> , ML, V&V	Sistemas Distribuídos	Robustez, integração com sistemas legados	Complexidade na modelação
[15] Cardoso	<i>machine learning</i> , IoT	Manutenção Preditiva	Previsão de falhas e otimização de manutenção	Limitação de dados reais
[52] Guc	Smart Big Data, Dados Sintéticos	Manutenção Diagnóstico	e Expansão analítica com dados sintéticos	Efetividade em cenários de dados reais
[110] Rossini	Inteligência Artificial, Modularidade	Diagnóstico Falhas	de Diagnóstico e manutenção em sistemas escaláveis	Integração com dados preexistentes
[138] Çınar	<i>machine learning</i> , IoT	Manutenção Preditiva	Previsão da vida útil de componentes	Desafios em contextos multivariados
[99] Rodrigo Pereira	Assistentes Virtuais, IoT, AI	Fábricas Inteligentes	Diagnósticos e automação de processos	Eficiência reduzida em ambientes ruidosos
[51] John Guachun	IoT, Comandos de Voz	Operações Industriais	Otimização de interações por voz	Baixa eficácia em ambientes ruidosos
[54] Parian Haghighat	Assistentes Inteligentes	Virtuais Escritórios e Ambientes Ruidosos	Melhoria da interação homem-máquina	Precisão comprometida pelo ruído verbal
[87] Kumaran	Reconhecimento de Voz, NLP	Interação Homem-Máquina	Interações fluídas e seguras	Dependência de hardware de alta precisão

A análise dos trabalhos evidencia três linhas de força. Primeiro, vários estudos adotam arquiteturas modulares em camadas, o que facilita evoluções graduais mas expõe dificuldades recorrentes: integrar equipamentos antigos ainda ativos na fábrica e garantir ciber-segurança robusta. Segundo, a qualidade e a quantidade de dados determinam a estratégia preditiva: quando há histórico suficiente, privilegia-se aprendizagem supervisionada; quando faltam registros, recorre-se ao *Digital Twin* para simular cenários de falha e enriquecer o conjunto de treino. Por fim, as soluções que incluem interfaces de voz mostram que a usabilidade já pesa tanto quanto a precisão dos modelos; contudo, o ruído do ambiente fabril e as exigências de privacidade continuam a limitar a adoção plena destas interfaces.

No conjunto, percebe-se que a convergência entre *Digital Twin*, inteligência artificial e assistência virtual está a transformar a manutenção preditiva, mas a integração de sistemas antigos, a disponibilidade de dados fiáveis e a robustez das interfaces ainda constituem desafios que esta tese procura ultrapassar.

3.4 Conclusão

Nesta secção analisaram-se os avanços e aplicações de tecnologias emergentes, como *Digital Twin*, inteligência artificial, IoT e assistentes virtuais, no contexto da transformação industrial. Os estudos revisados demonstraram como essas ferramentas têm revolucionado a forma como processos e sistemas industriais são concebidos e geridos, proporcionando melhorias significativas em eficiência operacional, adaptabilidade e resiliência. Os *Digital Twins* destacaram-se como uma solução central para integrar o mundo físico e digital, permitindo a monitorização em tempo real, simulações avançadas e a optimização de processos, contribuindo directamente para a autonomia e a modularidade das operações.

A inteligência artificial, por sua vez, mostrou-se indispensável na análise de grandes volumes de dados multivariados, possibilitando a previsão de falhas e a tomada de decisões mais informadas especialmente em cenários de manutenção preditiva. O uso de algoritmos avançados reforçam a robustez e a aplicabilidade desses sistemas, mesmo em condições adversas ou com dados limitados. Da mesma forma, os assistentes virtuais revelaram-se ferramentas valiosas para aumentar a eficiência, reduzir a carga cognitiva dos operadores e facilitar a interação homem-máquina, especialmente por meio de comandos de voz e interfaces inteligentes, embora ainda enfrentem desafios em ambientes ruidosos e na integração com infraestruturas preexistentes.

De forma geral, a convergência entre essas tecnologias aponta para um futuro industrial mais conectado, sustentável e resiliente. Embora existam desafios relacionados, a integração, segurança de dados e escalabilidade, os avanços contínuos nessas áreas prometem ampliar ainda mais o impacto positivo dessas soluções redefinindo as práticas e os paradigmas da Indústria 4.0 e contribuindo para uma transição em direcção aos objetivos da Indústria 5.0.

Capítulo 4

Arquitetura do Sistema e Desenvolvimento

Este capítulo apresenta o processo de concepção e implementação do sistema desenvolvido no âmbito deste trabalho, detalhando a arquitetura e os principais avanços alcançados em cada uma das fases do projeto. O objetivo é descrever de forma clara e estruturada o percurso desde a fase inicial de prototipagem e validação até à integração em contexto real destacando os desafios enfrentados e as soluções implementadas.

O desenvolvimento do sistema foi dividido em duas fases distintas, cada uma com objetivos específicos e complementares. Na Fase 1, o foco esteve na prototipagem e validação de tecnologias fundamentais para a criação de um Gémeo Digital num ambiente laboratorial controlado. Esta etapa foi essencial para explorar a viabilidade técnica das ferramentas e soluções propostas, garantindo uma base sólida para o avanço do projeto. Tecnologias como FIWARE, APIs REST e algoritmos de *machine learning* foram testadas e integradas validando conceitos como a comunicação bidirecional e a análise preditiva em tempo real.

Já na Fase 2, o projeto evoluiu para um contexto industrial real na área de fiação da fábrica têxtil da empresa RIOPELE. Nesta etapa, a base tecnológica foi expandida com a integração de um Assistente Virtual Inteligente projetado para operar sobre um Gémeo Digital já existente desenvolvido pela própria empresa. O objetivo principal desta fase é proporcionar uma solução que amplie as capacidades do sistema, adicionando funcionalidades como suporte à manutenção, predição de falhas e acesso a dados em tempo real, tudo de forma mais interativa e eficiente. Figura 4.1 ilustra de forma resumida a organização das duas fases, destacando os objetivos centrais de cada uma e a ponte entre o desenvolvimento laboratorial e a sua aplicação em contexto industrial.




Figura 4.1: Arquitetura macro das duas fases do projeto.

4.1 Fase 1: Desenvolvimento e Validação Laboratorial

O desenvolvimento inicial do sistema, denominado de Fase 1, foi realizado num ambiente laboratorial controlado, com o objetivo de validar as tecnologias e os conceitos fundamentais necessários para a criação de um Gémeo Digital. Esta fase permitiu explorar de forma segura e iterativa, os principais componentes do sistema desde a recolha de dados em tempo real até à análise preditiva.

4.1.1 Requisitos e Objetivos

Um dos requisitos centrais desta fase consistiu na recolha e gestão eficiente de dados em tempo real. Para validar a arquitetura de Gémeo Digital, optou-se por utilizar uma máquina de café como caso de estudo simplificado. Sensores de temperatura e humidade foram instalados na máquina física, enquanto o respetivo Gémeo Digital foi modelado em 3D. A Figura 4.2 apresenta, num único esquema, a camada física (máquina de café real) e a respetiva camada digital, evidenciando os principais fluxos de dados — historial operacional, histórico de manutenções, métricas em tempo real e contexto espacial — que alimentam o Gémeo Digital.

Esta representação facilita a compreensão do fluxo de informação: do lado esquerdo, a máquina física gera dados operacionais que são transmitidos em tempo real; do lado direito, o modelo 3D recebe-os, atualiza o seu estado e disponibiliza previsões agregadas, como a probabilidade de falha do sistema de infusão. A ligação bidirecional permite igualmente enviar comandos a partir do Gémeo Digital para a máquina física, exemplificando as capacidades de controlo remoto.




Figura 4.2: Representação integrada do Gémeo Digital: a camada física à esquerda e a camada digital à direita, incluindo os fluxos de informação que as conectam.

Outro aspeto crucial foi a integração de tecnologias modulares e escaláveis. Para responder a este desafio, utilizou-se a plataforma FIWARE [39] que proporcionou uma infraestrutura aberta e flexível para a gestão de dados contextuais em tempo real. A visualização dos dados foi também considerada uma prioridade, com a criação de dashboards interativos que simplificavam a análise e suportavam a tomada de decisões.

O objetivo central desta etapa foi validar a viabilidade tecnológica do sistema. Pretendia-se demonstrar que as tecnologias escolhidas – como FIWARE, sensores IoT, APIs REST e algoritmos de *machine learning* – podiam ser integradas de forma eficaz para dar vida a um protótipo funcional.

4.1.2 Arquitetura do Sistema

A arquitetura do sistema desenvolvido está organizada em quatro camadas principais, conforme ilustrado na Figura 4.3. Cada camada desempenha um papel específico no funcionamento do sistema, garantindo a integração e a eficiência necessárias para a implementação de um Gémeo Digital, esta abordagem modular permite uma separação clara das responsabilidades, facilitando o desenvolvimento a manutenção e futuras expansões do sistema.




Figura 4.3: Esquema geral da arquitetura do sistema em camadas.

A Camada Física (*Physical Layer*) representa o nível mais básico do sistema e é composta por sensores e dispositivos físicos instalados nos equipamentos. Sensores como o DHT11 são responsáveis pela monitorização de variáveis como temperatura e humidade recolhendo dados diretamente do ambiente físico. Esses dados são transmitidos para as camadas superiores por meio de dispositivos de computação, como o *Raspberry Pi*, que atuam como intermediários e asseguram uma integração fluida entre os dados recolhidos e o sistema digital.

A Camada de Integração (*Integration Layer*) tem como principal função garantir a comunicação eficiente entre os diferentes componentes do sistema. Para isso, utiliza-se uma infraestrutura baseada em Docker, que possibilita a criação de um ambiente de desenvolvimento e produção consistente e escalável, a utilização do Docker também simplifica a integração de inteligência artificial, permitindo a incorporação de modelos preditivos e análises de desempenho. Esta camada facilita a interação entre serviços e aplicações, assegurando que os dados recolhidos são processados e entregues de forma eficiente às camadas superiores.

A Camada Digital (*Digital Layer*) constitui o núcleo central da arquitetura sendo responsável pela organização e armazenamento dos dados recolhidos na camada física. Esses dados são armazenados em bases de dados estruturadas, como o SQL, e processados em tempo real utilizando ferramentas como o FIWARE.

Esta camada garante a gestão de dados históricos, permitindo análises aprofundadas e suportando funcionalidades preditivas, que são exploradas na camada superior.

Por último, a Camada Cibernética (*Cyber Layer*) é o nível mais avançado do sistema onde os dados processados são utilizados para análises preditivas e para a criação de modelos digitais detalhados. Nesta camada algoritmos de *machine learning*, como a Regressão Linear são aplicados para identificar padrões nos dados e prever potenciais falhas ou necessidades de manutenção. Isso permite a tomada de decisões proativas, otimizando as operações e reduzindo o tempo de inatividade dos equipamentos. Esta camada também suporta a simulação e monitorização em tempo real, consolidando a integração entre o Gémeo Digital e o ambiente físico.

A estrutura modular desta arquitetura assegura que cada camada desempenhe um papel específico e complementar, possibilitando a implementação de funcionalidades avançadas como predição, suporte à manutenção e análise em tempo real, alinhadas com os objetivos globais do sistema.

4.1.3 Tecnologias Implementadas na Fase 1

4.1.3.1 IoT e Raspberry Pi

Os sensores desempenham um papel fundamental na recolha de dados físicos para sistemas digitais. Neste projeto, foi utilizado o sensor DHT11, conhecido pela sua simplicidade e eficácia na monitorização de temperatura e humidade. O DHT11 é um sensor digital capaz de medir temperaturas entre 0°C e 50°C com uma precisão de $\pm 2^\circ\text{C}$, e níveis de humidade entre 20% e 90% com uma precisão de $\pm 5\%$ [19]. Este sensor é amplamente utilizado devido ao seu baixo custo, tamanho compacto e facilidade de integração com dispositivos computacionais como o Raspberry Pi 3 B+ [42].

O Raspberry Pi 3 B+ é um microcomputador compacto e poderoso, ideal para atuar como intermediário na comunicação entre sensores físicos e sistemas digitais. Com um processador quad-core de 1.4 GHz, suporte para conectividade Wi-Fi e Bluetooth, e uma gama completa de pinos GPIO (General Purpose Input/Output), o Raspberry Pi oferece uma plataforma robusta para aplicações de IoT. No contexto deste projeto, o Raspberry Pi 3 B+ foi utilizado para recolher os dados gerados pelo sensor, armazená-los e transmiti-los para as camadas superiores do sistema, assegurando uma integração eficiente e em tempo real.

Para a comunicação entre o DHT11 e o Raspberry Pi, foi utilizada uma biblioteca Python dedicada, que simplifica a leitura dos dados de temperatura e humidade do sensor. Esta biblioteca configura automaticamente o pino GPIO definido para receber os sinais do DHT11 e traduz os dados digitais em valores numéricos que podem ser processados e utilizados pelo sistema [28]. Podemos ver na imagem 4.4 a ligação entre este sensor e o Raspberry Pi.




Figura 4.4: Ligação do sensor DHT11 ao Raspberry Pi.

4.1.3.2 Ambiente em Docker integrando o FIWARE e a Visualização de Dados com o Grafana

O ambiente de desenvolvimento deste sistema utilizou o Docker, uma plataforma amplamente utilizada para criar, implementar e executar aplicações em contentores. Os contentores são unidades leves e portáteis que incluem todos os elementos necessários para executar uma aplicação, como bibliotecas, dependências e o próprio código da aplicação. O Docker simplifica o processo de desenvolvimento ao fornecer um ambiente isolado, que garante a consistência entre desenvolvimento, teste e produção [81].

A utilização do Docker neste projeto foi essencial para a modularidade e escalabilidade do sistema. Com o Docker, foi possível isolar os diferentes componentes do sistema em contentores separados garantindo que cada serviço pudesse ser gerido e escalado independentemente. A Figura 4.5 apresenta uma visão geral do funcionamento de contentores em Docker, destacando como cada aplicação contentorizada opera de forma isolada sobre uma infraestrutura partilhada [63].




Figura 4.5: Arquitetura de contentores no Docker [63].

No âmbito deste projeto, o Docker foi utilizado para implementar um ecossistema FIWARE. FIWARE é uma plataforma open-source amplamente utilizada para o desenvolvimento aplicações baseadas em IoT e gestão de dados contextuais, este fornece uma infraestrutura flexível e modular, essencial para gerir os dados recolhidos dos sensores em tempo real. O principal componente utilizado foi o *Orion Context Broker* [37], responsável pela gestão de dados contextuais em tempo real. Este componente atua como um intermediário que permite a receção, atualização e consulta de informações contextuais.

Para suportar o armazenamento de dados no *Orion Context Broker*, foi utilizada a base de dados MongoDB [64]. Esta escolha deve-se à sua flexibilidade e capacidade de armazenar documentos em formato JSON [100], o que se adequa à natureza dos dados contextuais geridos pelo FIWARE.

Além do Orion, foi implementado o componente *QuantumLeap* [38], também parte do ecossistema FIWARE, que é responsável pela persistência de dados históricos. O QuantumLeap permite armazenar dados temporais provenientes do Orion, garantindo que informações históricas possam ser utilizadas para análises preditivas e outras aplicações analíticas. Para o armazenamento desses dados foi utilizada a base de dados CrateDB [22] que é otimizada para lidar com grandes volumes de dados e consultas complexas em tempo real. Figura 4.6




Figura 4.6: Estrutura do FIWARE do sistema.

A configuração de todos esses serviços foi realizada em containers Docker individuais, interligados através de uma rede interna do Docker dentro do próprio Raspberry Pi. Esta abordagem assegurou a modularidade do sistema, permitindo a fácil substituição, atualização e escalabilidade dos componentes. A figura 4.7 apresenta a interface do Docker Desktop com os containers configurados, incluindo o Orion, QuantumLeap, MongoDB, e CrateDB.




Figura 4.7: Arquitetura do ecossistema FIWARE em Docker

A combinação do Docker com os serviços FIWARE foi importante para atingir os objetivos desta fase, proporcionando uma infraestrutura robusta e escalável para a gestão de dados contextuais

e históricos. Esta abordagem modular não só simplificou o desenvolvimento, como também facilitou a integração com outras tecnologias implementadas no sistema.

O Grafana [36] é uma plataforma de visualização de dados que permite criar dashboards interativos. Integra-se com o QuantumLeap e o Orion Context Broker e oferece uma visão abrangente do estado do sistema, como mostra a Figura 4.8, permitindo visualizar dados em tempo real e históricos recolhidos pelo FIWARE .



Figura 4.8: Dashboard usando o Grafana recebendo dados do FIWARE.

4.1.3.3 Base de Dados Híbrida

A base de dados desenvolvida para o projeto adota uma estrutura híbrida, combinando um sistema relacional SQL [94] com grafos [89] para armazenamento e análise de dados industriais. A componente relacional [20] armazena informações transacionais detalhadas sobre as máquinas, componentes, processos e materiais envolvidos nas operações industriais. Por outro lado, os grafos permitem representar intuitivamente relações complexas, como sequências de produção ou dependências em processos de manutenção. A estrutura completa desta base de dados híbrida encontra-se ilustrada na Figura 4.9.

Esta abordagem híbrida oferece diversas vantagens face às soluções exclusivamente relacionais. A representação visual proporcionada pelos grafos facilita a compreensão das conexões entre subprocessos e passos de manutenção, permitindo análises mais rápidas e intuitivas, especialmente úteis em cenários industriais complexos. Consultas relacionadas com caminhos, dependências ou sequências são executadas de forma significativamente mais eficiente com grafos, reduzindo o tempo de resposta, comparativamente às operações de junção complexas necessárias em bases puramente relacionais. Outro benefício relevante é a flexibilidade deste modelo híbrido que permite facilmente incorporar novos requisitos e alterar estruturas existentes sem grandes modificações.




Figura 4.9: Estrutura da base de dados do sistema da Fase 1.

Um exemplo prático desta abordagem híbrida é a sua aplicação numa fábrica têxtil. A base de dados é utilizada para gerir operações tanto da área produtiva como da manutenção. Na vertente produtiva as tabelas relacionais armazenam dados sobre as indústrias, processos produtivos, subprocessos específicos e respetivos materiais necessários. Os grafos, por sua vez, ligam sequencialmente subprocessos, permitindo otimizar os fluxos produtivos e minimizar tempos de paragem não planeados. Na vertente de manutenção as tabelas relacionais detalham as máquinas e respetivos componentes bem, como os passos específicos de manutenção. Em paralelo, os grafos definem a sequência lógica desses passos, assegurando uma execução ordenada e correta das atividades de manutenção preventiva e corretiva.

O modelo de dados utilizado consiste numa rede interligada de tabelas, cada uma com funções claramente definidas, a tabela *Industria* identifica setores produtivos e relaciona-se diretamente com a tabela *Processo*, que detalha os processos industriais de cada setor. Cada processo subdivide-se em etapas específicas descritas na tabela *SubProcesso*, que por sua vez conecta-se à tabela *Material*, através da tabela intermediária *SubProcesso Material*, para especificar




Figura 4.10: Modelo de comunicação de uma REST API [11].

os materiais utilizados em cada etapa produtiva. A tabela *SequenciaSubProcesso* determina explicitamente a ordem dos subprocessos, essencial para garantir eficiência operacional.

Para a gestão da manutenção, as tabelas *Maquina* e *Componente* detalham os equipamentos industriais e respectivos componentes individuais. A organização das tarefas de manutenção é feita através das tabelas *PassoManutencao* e *SequenciaPassos*, estruturando claramente as ações necessárias e a respetiva ordem de execução. A tabela *Media* complementa estas informações ao associar conteúdos multimédia às máquinas, componentes e subprocessos.

4.1.3.4 API REST em Nodejs

As APIs (*Application Programming Interfaces*) desempenham um papel essencial na comunicação entre diferentes sistemas, permitindo que aplicações interajam de maneira eficiente e organizada com base em regras bem definidas. Elas promovem a modularidade, simplificando o desenvolvimento e a integração de sistemas complexos. Neste projeto, optou-se pela utilização de APIs REST [34, 8], um modelo arquitetural baseado no conceito de *Representational State Transfer*, amplamente adotado devido à sua simplicidade e eficiência.

As APIs REST utilizam métodos padrão do protocolo HTTP, como GET, POST, PUT e DELETE, para realizar operações básicas de leitura, escrita, atualização e eliminação de dados.

Essa independência torna o design mais escalável permitindo que os servidores lidem com múltiplos clientes simultaneamente de modo eficiente. As APIs REST são extremamente versáteis podendo ser aplicadas em diferentes contextos e facilmente integradas com diversas plataformas, o que favorece a interoperabilidade e modularidade do sistema. A Figura 4.10 ilustra como uma API REST funciona destacando o fluxo de comunicação entre o cliente, a API e o servidor.

No desenvolvimento da Fase 1 foi utilizado o *Node.js* como tecnologia base para a construção da API REST. O *Node.js* é um ambiente de execução para JavaScript construído sobre o motor V8 do Google Chrome, projetado para criar aplicações rápidas e escaláveis. Com uma arquitetura

orientada a eventos e não bloqueante, o *Node.js* é capaz de processar múltiplas requisições ao mesmo tempo, sendo ideal para aplicações que requerem interações em tempo real [40].

A integração entre o *Node.js* e as APIs REST foi um ponto-chave para a criação de um sistema eficiente e modular. No contexto desta fase o *Node.js* atuou como uma ponte entre as APIs REST e os demais módulos do sistema, processando e transformando dados, antes de os disponibilizar a diferentes aplicações externas. Essa combinação garantiu que o sistema pudesse comunicar de forma ágil com outras aplicações, mantendo a flexibilidade e a escalabilidade necessárias para a implementação do Gêmeo Digital.

Com o *Node.js* e a API REST, foi possível estabelecer uma infraestrutura robusta e confiável para a comunicação entre os módulos do sistema. Essa abordagem modular permitiu que diferentes partes do projeto fossem desenvolvidas e geridas de modo independente enquanto permaneciam integradas de forma coesa. Como resultado, alcançou-se um design flexível, escalável e altamente adaptável, pronto para responder às exigências de sistemas complexos e dinâmicos.

4.1.3.5 Machine Learning para predição de temperatura e humidade

No campo da análise de dados e predição de falhas, foi implementado um modelo de regressão linear com Python e TensorFlow. A escolha deste modelo deve-se à sua simplicidade e eficiência em contextos iniciais de prototipagem [75, 129]. Embora existam modelos mais avançados, como redes neurais profundas [47], florestas aleatórias [31] e máquinas de vetores de suporte, a regressão linear foi escolhida para demonstrar a viabilidade da integração de tecnologias e destacar que abordagens simples podem gerar resultados relevantes.

Esta abordagem foi motivada por dois fatores principais. Primeiro, a regressão linear é amplamente compreendida e fácil de implementar, o que facilita a integração inicial com outras tecnologias, como o FIWARE. Segundo, o objetivo do projeto não era atingir o desempenho máximo do modelo preditivo, mas sim validar a arquitetura proposta e sua capacidade de operar eficientemente em tempo real. Em futuras iterações, planeia-se explorar modelos mais sofisticados para melhorar a precisão das predições, mantendo a base tecnológica estabelecida.

Para estimar previsões de temperatura com base em dados históricos, foi implementado um modelo de Regressão Linear utilizando a biblioteca `sklearn.linear_model` [119]. Este modelo é adequado para dados com comportamento aproximadamente linear, pois identifica a relação entre uma variável independente (tempo) e uma variável dependente (temperatura).

Processo de Treino e Teste

O processo inicia-se com a recolha de dados históricos, que são divididos em dois conjuntos: treino e teste. O conjunto de treino é utilizado para ajustar o modelo e determinar os coeficientes da regressão, enquanto o conjunto de teste avalia a capacidade preditiva do modelo em novos dados. Durante o treino, o modelo ajusta uma linha reta aos dados, minimizando o erro entre as previsões e os valores observados por meio do método dos mínimos quadrados. Este método resolve a seguinte equação para encontrar os valores ótimos de θ_1 (termo independente) e θ_0 (inclinação):

$$y = \theta_1 + \theta_0 x$$

A inclinação (θ_0) representa a taxa de variação da temperatura ao longo do tempo, enquanto o termo independente (θ_1) indica o valor inicial de temperatura quando $x = 0$.

4.1.4 Descrição do Fluxo de Trabalho

A Figura 4.11 apresenta um esquema do processo de recolha e análise de dados, destacando as principais etapas envolvidas. O esquema ilustra os passos principais:

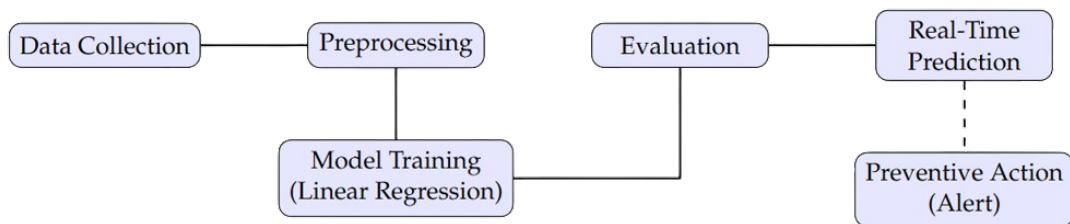


Figura 4.11: Representação das etapas do processo desde a recolha de dados até às ações preventivas.

- **Recolha de Dados:** Sensores recolhem valores de temperatura e outros parâmetros operacionais em tempo real.
- **Pré-processamento:** Os dados são tratados para remover valores atípicos e normalizar valores.
- **Treino do Modelo:** Os dados históricos são usados para ajustar o modelo de regressão.
- **Avaliação:** O modelo é testado para verificar a precisão das previsões.
- **Previsão em Tempo Real:** O modelo é integrado em um sistema que fornece previsões de temperatura.
- **Ações Preventivas:** Alertas são gerados para condições anómalas, acionando a equipa de manutenção.

4.1.5 Cálculo das Previsões

Na Figura 4.12, é ilustrado o cálculo das previsões de temperatura futura, destacando:

- y : Valor observado (pontos vermelhos), representando a temperatura real recolhida.
- y_p : Valor previsto pelo modelo de regressão linear, calculado pela fórmula.
- ε_i : Erro residual, que é a diferença entre o valor observado (y) e o previsto (y_p).
- θ_1 : Termo independente, representando o valor inicial da temperatura.

- θ_0 : Inclinação da reta, indicando a relação entre tempo e temperatura.




Figura 4.12: Cálculo das previsões de temperatura futura.

4.1.6 Integração e Aplicações Práticas

A integração do modelo com o FIWARE permite recolher, processar e visualizar dados em tempo real. Utilizando o QuantumLeap para armazenamento histórico e o Grafana para visualização dinâmica, o sistema é capaz de:

- Monitorizar Anomalias: Identificar tendências anormais, como o aumento súbito de temperatura, que podem indicar falhas iminentes.
- Prevenir Falhas: Gerar alertas automáticos para ações corretivas, reduzindo o tempo de inatividade de máquinas.
- Otimizar Manutenção: Planear intervenções preventivas com base em dados concretos, evitando a manutenção reativa e melhorando a eficiência operacional.

A integração do modelo com o FIWARE permite a recolha, o processamento e a visualização de dados em tempo real. A função de recolha obtém dados do QuantumLeap, prepara-os e usa o modelo representado na Figura 4.12 para prever temperaturas futuras. A visualização é atualizada dinamicamente, proporcionando uma interface gráfica interativa e intuitiva para o acompanhamento em tempo real [29, 30].

Por exemplo, numa fábrica de têxteis, o sistema pode prever sobreaquecimentos em motores, permitindo que a equipa técnica intervenha antes de ocorrerem danos. Da mesma forma, em ambientes de refrigeração, desvios na temperatura podem ser corrigidos rapidamente para preservar a qualidade do produto final.




Figura 4.13: Esquema geral do sistema CoffeeTwin

A visualização contínua e as previsões em tempo real tornam o sistema desenvolvido nesta fase, uma ferramenta essencial para a manutenção preditiva, alinhada com os princípios da Indústria 5.0.

4.1.7 CoffeeTwin: expansão interativa do Digital Twin

O CoffeeTwin surgiu como uma extensão da primeira fase do projeto, focado em explorar e validar a integração do paradigma do Gêmeo Digital com tecnologias imersivas, nomeadamente a Realidade Aumentada, a Realidade Virtual e a interação por voz. Utilizando uma máquina de café como estudo de caso, devido à sua simplicidade operacional e à sua escalabilidade, o projeto permitiu criar um ambiente controlado para testar diferentes formas de interação com o sistema. A Figura 4.13 apresenta uma visão geral do sistema, evidenciando a arquitetura que interliga o gêmeo físico (máquina de café, sensores e atuadores) com os diferentes modos de interação digital (Web, AR e VR). Através do Gêmeo Digital, os dados recolhidos em tempo real e os comandos de controlo são partilhados entre o mundo físico e as interfaces digitais, permitindo uma experiência completa de operação remota e monitorização.

A interação com o Gêmeo Digital ocorre através de três modalidades complementares, oferecendo ao utilizador experiências diversificadas:

1. **Interação Web:** Esta interface funciona como uma introdução ao projeto, onde o utilizador pode controlar remotamente a máquina de café através de comandos vocais ou botões. Após iniciar a aplicação, é guiado passo a passo no processo de tirar café, podendo escolher entre "café curto" e "café longo" usando a voz. No final, é possível visualizar gráficos com os dados



Figura 4.14: Ecrã da aplicação Web que permite ao utilizador escolher entre “café curto” e “café longo” através da voz.

recolhidos em tempo real (temperatura e humidade), bem como um histórico dos mesmos. A Figura 4.14 ilustra esta interface.

2. Realidade Aumentada : Através de um dispositivo móvel, o utilizador pode reconhecer fisicamente a máquina de café e sobrepor um painel virtual sobre a mesma. Esse painel permite controlar remotamente a máquina (ligar/desligar, selecionar quantidade de café), visualizar valores de temperatura e humidade em tempo real, bem como consultar um gráfico histórico com os últimos registos. A interface é interativa e suporta comandos por toque ou voz. A Figura 4.15 apresenta o painel de controlo em AR sobreposto à máquina real.
3. Realidade Virtual : A aplicação VR oferece um ambiente totalmente imersivo onde o utilizador pode simular todas as operações da máquina. O cenário recria fielmente o contexto real, permitindo realizar ações como ligar/desligar, colocar cápsulas, encher o depósito de água ou consultar dados técnicos. Esta abordagem é especialmente útil para fins de formação, sem risco de danificar o equipamento físico. A interação é feita com controladores e por comandos de voz. A Figura 4.16 mostra o ambiente VR do sistema.

Cada modalidade proporciona uma interação intuitiva e imersiva, projetada para melhorar a aprendizagem prática, a monitorização remota e a operação assistida em contextos industriais. O foco principal está na criação de uma experiência de utilização natural, acessível e que replica cenários reais de operação industrial.



Figura 4.15: Interface de Realidade Aumentada com dados em tempo real e comandos remotos.



Figura 4.16: Ambiente imersivo da aplicação VR com simulação completa da operação da máquina.

Desta forma, o projeto CoffeeTwin demonstra claramente o potencial de combinar Gémeos Digitais com tecnologias imersivas para enriquecer e otimizar operações no contexto da Indústria 4.0. A implementação do CoffeeTwin representou um passo significativo na consolidação dos objetivos definidos para a primeira fase do projeto. Esta expansão permitiu validar, num ambiente seguro e controlado, a aplicabilidade de tecnologias emergentes — como Realidade Aumentada, Realidade Virtual e controlo por voz — no contexto de um Gémeo Digital funcional. A escolha da máquina de café como estudo de caso revelou-se acertada, não só pela sua complexidade reduzida, mas também por permitir simular com fidelidade os princípios operacionais de equipamentos industriais reais. Através de uma arquitetura modular baseada em comunicação bidirecional entre o mundo físico e as interfaces digitais, foi possível criar uma experiência interativa completa, com foco na usabilidade e na replicabilidade. Com esta abordagem, não só se aprofundaram os conceitos já trabalhados na Fase 1, como também se testaram novas dimensões de interação homem-máquina alinhadas com os paradigmas da Indústria 4.0.

4.2 Transição entre a Fase 1 e a Fase 2 do Projeto

A primeira fase do projeto teve um papel fundamental na exploração de novas tecnologias para a Indústria 5.0, com especial destaque na predição e visualização de dados. Serviu como um teste inicial, uma prova de conceito para avaliar a integração de sensores IoT, a recolha e o processamento de dados em tempo real bem como a utilização de plataformas para análise preditiva e a implementação de interfaces de visualização.

Embora esta fase tenha sido centrada no desenvolvimento de um Gémeo Digital, não teve continuidade direta na segunda fase do projeto. No entanto, a experiência adquirida foi de enorme valor. O contacto prático com soluções de monitorização e predição permitiu uma melhor compreensão dos desafios associados à recolha e análise de dados industriais. Esta aprendizagem foram essenciais para fundamentar decisões tecnológicas mais estratégicas na transição para a Fase 2 que passou a ter um novo foco: a Assistência Virtual Inteligente (AVI).

Nesta nova etapa, o projeto seguiu um rumo distinto, sem ligação direta ao Gémeo Digital ou às tecnologias testadas na fase anterior, mas beneficiando do conhecimento e da experiência acumulados ao longo do processo.

A transição da Fase 1 para a Fase 2 marcou uma mudança significativa no rumo do projeto. Se, na primeira fase, o foco esteve na implementação de um Gémeo Digital para visualização e predição, na segunda fase, a atenção centrou-se totalmente no desenvolvimento do Assistente Virtual Inteligente.

O objetivo principal foi o de criar um assistente virtual, integrando um DT já construído, capaz de interpretar manuais técnicos, responder a perguntas em linguagem natural e apoiar os técnicos/funcionários na operação e manutenção de máquinas industriais, neste caso em específico, máquinas de fição numa fábrica têxtil. A introdução da RIA representa um novo desafio dentro do projeto, assente na integração de inteligência artificial, processamento de linguagem natural e uma interação eficaz com os utilizadores.

Apesar das diferenças entre ambas as fases, a experiência adquirida na Fase 1 foi essencial para compreender melhor os desafios da digitalização industrial, contribuindo para um planeamento mais sólido e para a definição da arquitetura da RIA. Esta transição reflete a evolução natural do projeto, passando de uma abordagem exploratória para um desenvolvimento mais aplicado, alinhado com as necessidades da fábrica onde a Fase 2 será implementada.

Um dos principais objetivos do projeto foi assegurar uma abordagem tecnológica modular e flexível, que permitisse a reutilização eficiente dos componentes desenvolvidos em diferentes contextos industriais. Neste sentido, a base de dados híbrida, composta por um sistema relacional SQL combinado com grafos e a API REST desenvolvida em Node.js na Fase 1, foram projetadas especificamente para serem independentes do domínio e altamente modulares. Esta abordagem possibilitou a aplicação direta da mesma infraestrutura tecnológica desenvolvida inicialmente para uma máquina de café no laboratório para um contexto industrial completamente diferente, nomeadamente nas máquinas de fição da indústria têxtil da empresa RIOPELE. Esta transição foi feita sem necessidade de alterações estruturais ou de esquema da base de dados, demonstrando na prática a robustez e versatilidade do modelo implementado. Adicionalmente, a API REST criada em Node.js funcionou como elemento integrador essencial, garantindo a interoperabilidade e modularidade necessárias para conectar diferentes componentes do sistema, permitindo ainda processar múltiplas requisições em tempo real de forma eficiente e escalável. Esta clara separação entre a lógica específica de domínio, gerida por módulos externos ou serviços auxiliares, e a camada de dados e comunicação garantiu a eficácia e simplicidade da reutilização do sistema, confirmando assim os benefícios práticos e estratégicos de uma arquitetura modular bem definida.

4.3 Fase 2: Desenvolvimento de um Assistente Virtual Inteligente

4.3.1 Requisitos e Objetivos

Na Fase 2 do projeto, o objetivo principal foi o de desenvolver e implementar um Assistente Virtual Inteligente integrado com o Gémeo Digital da unidade fabril da RIOPELE. O Assistente Virtual Inteligente desenvolvido nesta fase foi batizado de RIA – acrónimo de **RI**opele **A**ssistente –, uma identidade curta, clara e representativa da ligação entre a inovação digital e a empresa parceira.

Com esta abordagem o sistema funcionará como uma camada inteligente sobre a réplica digital dos processos industriais, garantindo uma operação eficiente, escalável e totalmente integrada com os fluxos produtivos reais. Para que isso aconteça, foram definidos alguns requisitos fundamentais que precisam de ser cumpridos.

A RIA terá a capacidade de processar e interpretar dados operacionais em tempo real, obtidos a partir de sensores industriais e sistemas de monitorização já existentes. Permitirá uma interação intuitiva, tanto por comandos de voz quanto por texto, facilitando o acesso a informações e a execução de ações de forma simples e direta por operadores e técnicos. A assistência será personalizada, fornecendo respostas contextuais baseadas em dados históricos e operacionais da fábrica, ajudando na tomada de decisões e aumentando a eficiência dos processos.

Um dos pontos essenciais é a adaptação da RIA a três modos principais de funcionamento. No Modo Manutenção, dará suporte aos técnicos, permitindo a consulta de manuais digitais, o processamento de documentação técnica através de técnicas de Processamento de Linguagem Natural e fornecendo sugestões inteligentes com base em ocorrências passadas. No Modo Informação, o sistema monitorizará continuamente o estado dos equipamentos e enviará notificações e alertas em tempo real. Já no Modo Predição, a RIA utilizará algoritmos de *machine learning* para antecipar falhas e otimizar processos de manutenção, reduzindo custos e evitando paragens inesperadas.

Além de toda essa robustez técnica, pretende-se garantir que a arquitetura da RIA seja flexível e modular, permitindo futuras expansões e integração com novos sistemas sem comprometer a estabilidade do projeto a interface de utilizador será intuitiva, acessível via web e adaptável a diferentes dispositivos, garantindo facilidade de uso para operadores e técnicos.

Com esses requisitos bem definidos, estabelecem-se objetivos claros para esta fase. Deve assegurar-se que a RIA fique perfeitamente integrada no Gémeo Digital da fábrica, funcionando como uma camada inteligente que optimize a operação industrial. Pretende-se também reduzir os tempos de resposta na assistência a operadores e técnicos, aumentar a eficiência dos processos e minimizar períodos de inatividade dos equipamentos. Um ponto fundamental será demonstrar o valor da manutenção preditiva através da análise de dados históricos e da aplicação de inteligência artificial, bem como facilitar o acesso à informação técnica mediante o processamento inteligente de documentação.

Por fim, um dos principais desafios reside em garantir a robustez e a fiabilidade do sistema. Uma vez alcançados os objetivos delineados, a solução constituirá um avanço relevante na jornada de digitalização rumo à Indústria 5.0, disponibilizando uma camada inteligente que apoia as operações diárias da fábrica e potencia, em simultâneo, a otimização e a inovação contínua dos processos produtivos.

4.3.2 Arquitetura do Sistema

A arquitetura da RIA foi concebida para garantir uma comunicação eficiente e intuitiva entre os técnicos e os sistemas industriais. O seu design modular assegura escalabilidade e flexibilidade facilitando a adaptação a diferentes contextos industriais. O sistema assenta em três camadas principais: a RIA, que constitui o núcleo de inteligência artificial; o Backend, responsável pela intermediação entre a RIA e as bases de dados; e o Frontend, que disponibiliza a interface gráfica para a interação com os utilizadores. A RIA representa o coração do sistema onde se concentram os processos de interpretação da linguagem natural, análise de dados e execução dos diferentes modos de assistência. Recorrendo a algoritmos avançados de Processamento de Linguagem Natural e aprendizagem automática a RIA consegue interpretar comandos dos técnicos, consultar documentação técnica e prever falhas nos equipamentos. Esta implementação permite que os utilizadores interajam com o sistema de forma natural utilizando comandos de voz ou texto. Para assegurar uma integração fluida e eficiente o Backend desempenha um papel fundamental na gestão das interações entre a RIA e os restantes componentes do sistema. Ele é responsável pelo

processamento de requisições, armazenamento de dados históricos e fornecimento de uma interface programática que garante a persistência da informação. O backend expõe uma API RESTful que possibilita a comunicação assíncrona entre o Frontend e a RIA. Instancia a classe da RIA, processando as requisições recebidas e executando os módulos de suporte técnico e predição. Por sua vez, o Frontend é a camada encarregue de apresentar ao utilizador as informações processadas pela RIA. Concebido para ser intuitivo e acessível permite que os técnicos consultem relatórios de manutenção, recebam alertas de predição de falhas e interajam com o assistente virtual.

A Figura 4.17 mostra onde cada bloco se executa na infraestrutura: o *Frontend* reside no posto do operador, correndo num browser ou aplicação ; o *Backend* e a *RIA* estão alojados num servidor dedicado dentro da rede industrial; já as fontes de dados — vídeos, manuais e histórico de manutenção — permanecem nos servidores da fábrica e são disponibilizadas ao assistente através da API.




Figura 4.17: Esquema geral da arquitetura do sistema.

4.3.3 Tecnologias Utilizadas na Fase 2

Esta secção apresenta as principais tecnologias empregues em cada camada da RIA.

4.3.3.1 Assistente Virtual Inteligente

A RIA é o núcleo do sistema atuando como um assistente técnico digital que interpreta comandos em linguagem natural e fornece respostas precisas com base em dados históricos, documentação técnica e dados em tempo real, equipado com tecnologias de NLP e *machine learning*, a RIA analisa pedidos, prevê falhas operacionais e apoia na manutenção de máquinas. Para garantir respostas rápidas e contextuais, a RIA comunica continuamente com o sistema, que lhe dá acesso a bases de dados operacionais. Dessa forma, processa solicitações em tempo real oferecendo suporte eficiente a técnicos e operadores industriais, tornando-se uma peça-chave na manutenção preditiva e no suporte técnico de fábricas inteligentes.

SpeechRecognition

A biblioteca `SpeechRecognition` é uma ferramenta em Python que permite a conversão de áudio em texto sendo compatível com vários motores e APIs de reconhecimento de voz, tanto online quanto offline. A sua flexibilidade permite a integração com diferentes serviços, incluindo o Google Web Speech API, CMU Sphinx, Wit.ai e IBM Speech to Text.

No contexto da RIA, esta biblioteca desempenha um papel essencial ao permitir que os utilizadores interajam com o sistema por meio de comandos de voz, tendo também a opção dentro da aplicação para ativar/desativar esta função consoante o ambiente onde o operador se encontra. A sua utilização proporciona uma experiência mais fluida e intuitiva reduzindo a necessidade de interação manual com a interface gráfica. O suporte a diferentes idiomas e a capacidade de adaptação a diferentes ambientes acústicos tornam esta solução altamente versátil [136].

gTTS (Google Text-to-Speech)

Para a geração de respostas faladas, foi integrada a biblioteca `gTTS` (Google Text-to-Speech) que fornece uma interface simples para a API de síntese de voz do Google Translate. Esta ferramenta converte texto em áudio de forma eficiente e pode gerar ficheiros de áudio ou armazenar a saída diretamente em memória, em formato binário, para posterior processamento.

A principal vantagem da `gTTS` reside na sua simplicidade e eficácia, permitindo a criação de respostas faladas de forma rápida e com qualidade aceitável para interações em tempo real. A RIA utiliza esta tecnologia para fornecer feedback auditivo aos utilizadores tornando a comunicação mais acessível e dinâmica [107].

FFmpeg e Pydub

No contexto do Assistente Virtual, foi utilizada a biblioteca `pydub` [108] para manipulação de ficheiros de áudio de forma prática e eficiente. Esta biblioteca permite realizar tarefas como a conversão de formatos e a edição de áudio diretamente em Python. No entanto, para que a `pydub`

funcione corretamente com ficheiros MP3 e outros formatos populares, é necessária a instalação do FFmpeg [25], uma ferramenta poderosa e de código aberto para processamento multimédia.

Por defeito, o `pydub` apenas consegue lidar com ficheiros WAV, não requerendo dependências externas. Contudo, ao trabalhar com diferentes formatos de áudio no Assistente Virtual, a instalação do FFmpeg torna-se essencial, pois é esta ferramenta que permite ao `pydub` processar esses ficheiros sem limitações.

A integração da `pydub` e do FFmpeg no sistema permite converter diversos formatos de áudio para WAV, garantindo um processamento mais simples e eficiente. Esta conversão possibilita que o Assistente Virtual receba áudios em diferentes formatos, os converta para o formato WAV e, assim, execute transcrições precisas e gere respostas em áudio de forma fluida e natural.

Bibliotecas para Interpretação de Comandos Contextuais

Para assegurar a interpretação inteligente de comandos e o fornecimento de respostas contextualizadas, a RIA integra tecnologias avançadas de processamento de linguagem natural e extração de informação.

A empresa RIOPELE disponibilizou o acesso à API da OpenAI [93], ficando a cargo da equipa de desenvolvimento a seleção do modelo mais adequado às necessidades do projeto. Após uma análise comparativa dos modelos disponíveis, foi escolhido o modelo GPT-4o-mini, por oferecer um equilíbrio eficaz entre desempenho e custo, revelando-se particularmente indicado para aplicações industriais contínuas onde a otimização de recursos é um critério relevante.

Tabela 4.1: Comparação de Modelos da OpenAI (valores de referência em fevereiro de 2025; sujeitos a alterações futuras)

Modelo	Custo Input (\$)	Custo Output (\$)	Contexto	Notas
GPT-4.5	0.075	0.150	128k	Maior custo, desempenho superior
GPT-4o	0.0025	0.010	128k	Equilíbrio entre desempenho e custo
GPT-4o-mini	0.00015	0.0006	128k	Custo mínimo, desempenho adequado
GPT-3.5-turbo	0.0005	0.0015	16k	Modelo anterior, menor contexto

Para complementar o processo de interpretação de comandos e fornecer respostas contextualizadas, especialmente na consulta a manuais técnicos e outros documentos industriais, o sistema recorre à biblioteca `pdfplumber` [86]. Esta ferramenta foi escolhida após uma análise comparativa a alternativas como o `PyPDF2` [27] e o `pdfminer.six` [26]. A biblioteca `PyPDF2`, embora bastante fácil de utilizar, mostrou limitações significativas na extração de tabelas e elementos gráficos, essenciais em documentos técnicos complexos. Por outro lado, a biblioteca `pdfminer.six`, apesar de apresentar boa precisão na extração textual, revelou-se limitada na identificação estruturada de tabelas e na manipulação direta de imagens e gráficos presentes em documentos industriais.

O `pdfplumber` destacou-se pela sua capacidade superior de extração estruturada, mantendo o layout original, identificando eficazmente tabelas complexas e permitindo uma segmentação

correta e contextualizada da informação, além de apresentar uma interface intuitiva que facilita a sua integração no sistema. Estas características tornam-na especialmente adequada para ambientes industriais, garantindo respostas fiáveis e detalhadas aos utilizadores, onde precisão e rapidez na consulta documental são fundamentais.

Pandas

A manipulação e organização dos dados processados pela RIA são essenciais para garantir a eficiência na análise e tomada de decisões. Para essa finalidade, a biblioteca `Pandas` [79] é utilizada como ferramenta central do processamento e análise dos dados. A biblioteca `Pandas` fornece uma interface otimizada para lidar com grandes volumes de dados permitindo operações como filtragem, agregação e transformação em tempo real. No contexto da RIA, essa tecnologia desempenha um papel fundamental na gestão do histórico de interações, no armazenamento de históricos de falhas e na execução de análises preditivas baseadas em padrões operacionais. A sua compatibilidade com múltiplas fontes de dados, como bases relacionais e ficheiros estruturados, facilita a integração entre os módulos do sistema, garantindo a fluidez do fluxo de informação.

Statsmodels

A predição de falhas é assegurada através da biblioteca `Statsmodels` [120], que disponibiliza métodos estatísticos avançados, incluindo o modelo `SARIMAX` (Seasonal AutoRegressive Integrated Moving Average with eXogenous factors) [116]. Este modelo é particularmente adequado ao contexto industrial, pois permite a análise de séries temporais com variações sazonais e fatores externos, oferecendo previsões fiáveis e parâmetros interpretáveis.

Para validar empiricamente a eficácia do modelo `SARIMAX`, foi realizada uma comparação com outros métodos de previsão comuns, nomeadamente regressão Linear [75], `holt-Winters`[57] e o `SVR` (Support Vector Regression) [45]. O conjunto de dados utilizado para esta análise contém 300 observações reais de velocidade de uma máquina de fiação, recolhidas na secção de fiação da fábrica têxtil `RIOPELE`. Os dados foram divididos de forma temporal, utilizando 80% para treino e 20% para teste, assegurando o respeito pela sequência cronológica e uma avaliação mais realista da capacidade preditiva dos modelos.

A Tabela 4.2 apresenta uma comparação do desempenho de quatro modelos de previsão com base em cinco métricas bastante utilizadas na área da previsão de séries temporais. O erro médio absoluto (MAE) indica, em média, quanto é que as previsões se afastam dos valores reais. Como está expresso na mesma unidade dos dados (neste caso, velocidade da máquina), é fácil de interpretar e comparar [17, 135]. O erro quadrático médio (MSE) é semelhante, mas antes de calcular a média, os desvios são elevados ao quadrado. Isto significa que os erros maiores têm mais peso no resultado final. O RMSE (raiz do erro quadrático médio) é apenas a raiz quadrada do MSE. Tem a vantagem de manter a mesma unidade dos dados reais (tal como o MAE), mas continua a penalizar mais os erros grandes, o que pode ser útil em situações críticas. O R^2 [53], também conhecido como

coeficiente de determinação, mede o quanto do comportamento dos dados é explicado pelo modelo. Quando o valor está próximo de 1, o modelo ajusta-se bem aos dados; se for negativo, como neste caso, significa que o modelo tem pior desempenho do que simplesmente usar a média como previsão. Isto pode acontecer quando a série é curta ou tem muita variação irregular. Por fim, o erro médio percentual absoluto (MAPE) mostra o erro médio em percentagem, facilitando a comparação entre séries com escalas diferentes. No entanto, quando os valores reais estão muito próximos de zero, este indicador pode tornar-se instável e exagerar o erro [59, 69].

A escolha das métricas MAE, MSE, RMSE, R^2 e MAPE permite avaliar os modelos de forma mais completa e equilibrada. Cada uma destas medidas olha para o erro de previsão de um ângulo diferente: MAE mostra-nos, de forma simples, o erro médio entre o valor real e o previsto; o MSE e o RMSE dão mais importância aos erros maiores, o que é útil quando esses desvios podem ter impacto relevante na operação. O RMSE, em particular, devolve o erro na mesma unidade dos dados, facilitando a leitura prática. O R^2 indica até que ponto o modelo consegue reproduzir a variação dos dados, e o MAPE apresenta o erro médio em percentagem, o que é útil para comparar modelos em séries com escalas diferentes. No seu conjunto, estas métricas ajudam a perceber não só se o modelo acerta, mas também o quão graves são os erros e como se adapta ao comportamento real dos dados.

À luz destas métricas, o SARIMAX e o Holt–Winters obtiveram os melhores resultados, com valores de MAE e RMSE mais baixos. Isto mostra que são mais eficazes a prever a velocidade das máquinas de fição, em especial por conseguirem identificar padrões repetitivos ao longo do tempo (sazonalidade). A Regressão Linear, por ser mais simples e não considerar essas variações cíclicas, apresentou um desempenho um pouco inferior. Já o SVR registou os piores resultados. Este tipo de modelo tende a exigir um número elevado de observações e variáveis explicativas (p. ex. temperatura, humidade) para generalizar bem; como nesta fase inicial a empresa disponibilizou apenas 300 registos de velocidade e uma única variável independente, o SVR não conseguiu aprender os padrões de forma eficaz e acabou por produzir erros mais elevados, sobretudo no MAPE e no RMSE. O processo de treino e teste foi realizado em Python, com os dados ordenados por data. Utilizou-se uma partição temporal, reservando-se os primeiros 80% dos dados (240 observações) para treino e os últimos 20% (60 observações) para teste. Após o ajuste de cada modelo sobre os dados de treino, as previsões foram geradas para o conjunto de teste, e os erros foram calculados com base nas diferenças entre os valores reais e os previstos. As métricas apresentadas na Tabela 4.2 resultam diretamente desta avaliação.

Tabela 4.2: Comparação dos modelos preditivos aplicados à velocidade real da máquina.

Modelo	MAE	MSE	RMSE	R^2	MAPE (%)
SARIMAX	4.58	31.92	5.65	-0.06	9.32
Regressão Linear	4.76	34.40	5.87	-0.09	9.68
Holt-Winters	4.59	32.11	5.67	-0.06	9.32
SVR	5.07	39.23	6.26	-0.24	10.22

Estes resultados justificam a adoção do SARIMAX na fase atual do projeto, pois concilia

transparência estatística com poder preditivo: acomoda simultaneamente tendência, sazonalidade e fatores externos, devolve coeficientes interpretáveis aos técnicos de manutenção e mantém-se parcimonioso o suficiente para evitar sobre-ajuste em amostras de pequena dimensão. Em etapas futuras, quando estiverem disponíveis séries mais longas e variáveis adicionais (por exemplo, temperatura ambiente), tornar-se-á pertinente avaliar arquiteturas de aprendizagem profunda; por agora, porém, o SARIMAX oferece o melhor compromisso entre fiabilidade, explicabilidade e esforço computacional, assegurando uma base sólida para o funcionamento preditivo do Assistente Virtual.

4.3.3.2 Backend

O backend da RIA desempenha um papel essencial na arquitetura do sistema, assegurando a comunicação eficiente entre a RIA e o frontend bem como a gestão e persistência dos dados. Além de que fornece a estrutura necessária para que os utilizadores interajam de forma fluida com o assistente. Para alcançar este objetivo, foram integradas diversas tecnologias que garantem um funcionamento ágil e escalável.

Flask

O `Flask` é um microframework web desenvolvido em Python, amplamente utilizado para a criação de aplicações web leves e modulares. A sua simplicidade e flexibilidade fazem dele a escolha ideal para o desenvolvimento de APIs RESTful permitindo que o backend da RIA interaja facilmente com outros componentes do sistema. Uma das grandes vantagens do `Flask` é a sua capacidade de lidar com requisições HTTP de forma eficiente, permitindo que a RIA processe pedidos e devolva respostas rapidamente. Adicionalmente, conta com uma vasta documentação e uma comunidade ativa, o que facilita a implementação de novas funcionalidades e a integração com outras bibliotecas essenciais ao funcionamento do assistente virtual [101].

SQLAlchemy

Para garantir uma gestão eficiente dos dados, a RIA utiliza a biblioteca `SQLAlchemy`, um mapeador objeto-relacional (ORM) que permite interagir com bases de dados relacionais de forma intuitiva e organizada. Em vez de escrever consultas SQL complexas, os programadores podem trabalhar diretamente com objetos Python, tornando o código mais legível e de fácil manutenção.

A utilização do `SQLAlchemy` no backend da RIA é essencial para armazenar e recuperar informações como registos de interações, histórico de falhas e dados preditivos. A integração com o `Flask` facilita a configuração e otimiza a comunicação entre os diferentes módulos do sistema [125].

Execução Paralela e Threading

Para garantir um desempenho eficiente, o backend da RIA faz uso do módulo `threading` do Python, permitindo a execução simultânea de várias tarefas. Isto significa que o sistema consegue processar múltiplas interações ao mesmo tempo, reduzindo os tempos de espera e melhorando a experiência do utilizador. Para evitar problemas de concorrência, a RIA segue as boas práticas recomendadas pela documentação oficial, recorrendo a `scoped_session`, que garante que cada thread tem a sua própria sessão de base de dados, evitando conflitos e garantindo a integridade dos dados [124].

4.3.3.3 Interface gráfica

Para que os utilizadores interajam de forma simples e direta com a RIA, foi desenvolvida uma interface moderna e eficiente. A prioridade foi criar um ambiente intuitivo e acessível garantindo que qualquer operador, independentemente do nível de experiência com tecnologia, conseguisse utilizá-la sem dificuldades.

React: Estrutura Modular e Eficiente

A interface da RIA foi desenvolvida com recurso à biblioteca `React` [82], conforme solicitado pela empresa RIOPELE. Esta tecnologia permite criar componentes reutilizáveis, facilitando a manutenção, a escalabilidade e a introdução de novas funcionalidades.

O uso do Virtual DOM [126] contribui para tempos de resposta rápidos e interações fluidas, aspetos essenciais num contexto industrial onde a informação deve ser apresentada de forma clara e imediata.

A interface da RIA foi concebida para funcionar corretamente em diferentes dispositivos, seja no posto de trabalho, em mobilidade ou na linha de produção. A estrutura da interface é organizada e intuitiva, garantindo que todas as funcionalidades estejam acessíveis de forma rápida, ajudando os técnicos a obter a informação de que precisam, no momento certo.

4.3.4 RIA

A RIA é o centro do sistema, concebido para apoiar técnicos e operadores industriais no seu dia a dia. Funciona como um intermediário inteligente entre os utilizadores e o ambiente operacional, interpretando comandos, analisando dados e fornecendo respostas rápidas e relevantes. Para garantir um funcionamento eficiente e adaptado às diferentes necessidades, a RIA está dividido em três modos principais:

- **Modo Manutenção:** Desenvolvido para auxiliar na resolução de problemas e consulta de documentação técnica. Utiliza técnicas avançadas de extração de texto para processar manuais industriais em formato PDF, permitindo que os utilizadores pesquisem rapidamente informações sobre procedimentos operacionais e soluções para falhas.

- **Modo Predição:** Focado na análise de dados históricos para prever possíveis falhas nos equipamentos. Com base em modelos estatísticos e no algoritmo de *machine learning* SARIMAX, previamente analisado, este modo identifica padrões de funcionamento e deteta anomalias antes que estas causem problemas ajudando a implementar uma manutenção preditiva mais eficiente.
- **Modo Informação:** Responsável por fornecer dados operacionais em tempo real. Permite aos utilizadores monitorizar o estado atual das máquinas, consultar métricas importantes e tomar decisões informadas com base nos dados recolhidos pelo sistema.

Embora cada modo tenha uma função específica todos operam de forma integrada. Esta arquitetura garante que a RIA consiga responder de forma ágil e precisa, seja recorrendo a documentação técnica, análise estatística ou dados operacionais em tempo real. Nos tópicos seguintes cada um destes modos será explorado em maior detalhe abordando a sua implementação e impacto no sistema.


4.3.4.1 Modo Manutenção

O Modo Manutenção converte manuais industriais — habitualmente longos, em PDF estáticos e pouco práticos em ambiente de fábrica — num canal interativo suportado por pesquisa semântica e modelos de conversação. Assim, o técnico deixa de percorrer centenas de páginas e passa a interagir em linguagem natural, obtendo respostas específicas em segundos, instruções sequenciais ou vídeos tutoriais específicos associados ao equipamento em questão. Para além de acelerar a resolução de avarias, este modo consolida o conhecimento tácito da equipa e reduz dependências de especialistas externos. A Figura 4.18 sintetiza o ciclo de utilização.

Fluxo de utilização

1. Seleção da máquina — a aplicação carrega os equipamentos ativos e apresenta-os numerados.
2. Escolha da ação — o utilizador indica se pretende pdf (pesquisar no manual) ou video (ver tutoriais).
3. Execução — se o comando for pdf, “o texto é extraído com recurso à biblioteca `pdfplumber` e armazenado em cache (formato TXT) e, juntamente com a pergunta, enviado ao LLM para gerar a resposta; se o comando for video, o sistema lista os subprocessos disponíveis, o utilizador escolhe e o tutorial é apresentado num elemento `iframe` incorporado diretamente na interface do utilizador..

No Anexo B-1 podemos ter uma ideia clara sobre o funcionamento interno do Modo Manutenção através do respetivo pseudocódigo.

Figura 4.18: Fluxograma do *Modo Manutenção*

Perguntas ao manual

Para garantir rigor técnico, o comando de entrada (prompt) restringe o LLM a responder exclusivamente com informação contida no PDF e com uma temperatura de geração definida em 0.2, para garantir consistência e precisão nas respostas. A resposta é devolvida em texto estruturado, com parágrafos e referências de página ou tabela.

Vídeos de manutenção

O modo vídeo executa três passos: requisita os subprocessos da máquina selecionada, apresenta-os numa lista numerada e devolve o vídeo do tutorial escolhido.

4.3.4.2 Modo Predição

O Modo Predição antecipa falhas de equipamento através da análise, em tempo-real, das velocidades real e de referência (setup). A funcionalidade assenta num fluxo de recolha automática de dados, previsão estatística com aprendizagem automática tradicional e deteção de anomalias. O objetivo é programar intervenções antes da paragem inesperada, reduzindo custos e aumentando a disponibilidade. A Figura 4.19 ilustra o ciclo completo.




Figura 4.19: Fluxograma do *Modo Predição*

Fluxo de utilização

1. Iniciar monitorização — cria dois processos paralelos (threads): um recolhe dados da API a cada `intervalo s`, outro avalia desvios.
2. Detetar anomalias — analisa o histórico corrente; desvios acima do limiar (200 rpm por defeito) são classificados em Baixa, Média ou Alta gravidade e apresentados ao operador.
3. Prever velocidade — o operador define um horizonte temporal (minutos ou horas); o sistema treina/atualiza um modelo SARIMAX e devolve previsões em gráfico ou lista.
4. Parar monitorização — termina ambos os processos e persiste o histórico em CSV, garantindo continuidade entre sessões.

No Anexo B-2 é apresentado o pseudocódigo completo que detalha o funcionamento do Modo Predição.

Aquisição e persistência de dados

A cada ciclo, a aplicação obtém a velocidade real (`realSpeed`) e a velocidade de referência (`setupSpeed`) da máquina. Os registos são anexados a um `DataFrame` (uma estrutura de dados construída com linhas e colunas, semelhante a uma base de dados ou a uma folha de cálculo do Excel) e, no fecho da sessão, serializados para `data/velocidades/dados_velocidade.csv`. Este mecanismo evita perda de histórico se o servidor reiniciar.

Previsão de velocidade (SARIMAX)

Quando o operador solicita uma previsão, o módulo verifica se existem pelo menos 20 amostras. Os dados são passados ao modelo SARIMAX, selecionado com base em testes empíricos, por demonstrar capacidade de captar padrões sazonais e tendências. O horizonte é convertido em *passos* conforme o `intervalo` de recolha e o output devolve-se como lista arredondada a duas casas decimais ou gráfico sobreposto à velocidade de referência.

Deteção de anomalias

O desvio $\Delta = \text{RealSpeed} - \text{SetupSpeed}$ é calculado em cada iteração. Valores acima de ± 200 rpm ativam o algoritmo de gravidade: $|\Delta| > 500 \Rightarrow$ Alta; $250 < |\Delta| \leq 500 \Rightarrow$ Média; caso contrário, Baixa. Mensagens são agrupadas e apresentadas ao operador.

Robustez e desempenho

Para garantir resiliência durante a monitorização, a aplicação recorre a dois processos paralelos (*threads*) — um dedicado à recolha de dados e outro à previsão — evitando que latências de rede interfiram no funcionamento geral do sistema. Um tempo-limite (*timeout*) de 40 segundos é aplicado às chamadas à API, assegurando que o ciclo de recolha não fica bloqueado em caso de indisponibilidade. Adicionalmente, todas as exceções relacionadas com a gravação do ficheiro CSV ou com o treino do modelo preditivo são capturadas e comunicadas ao operador, mantendo a continuidade do serviço sem falhas críticas.

4.3.4.3 Modo Informação

O Modo Informação devolve dados objetivos — identificador da máquina, velocidade nominal, estado atual, código de segurança por cor, entre outros — acerca de qualquer máquina registada na fábrica. Em vez de aceder ao ERP (Enterprise Resource Planning – sistema integrado de gestão que centraliza os dados da empresa), ou consultar folhas Excel, o operador pergunta em linguagem natural: «Qual é o estado da PCON-0201?» ou «Que cor tem a 201?», e obtém imediatamente a resposta validada pela base de dados. A Figura 4.20 mostra o ciclo lógico.




Figura 4.20: Fluxograma do *Modo Informação*

Para uma descrição detalhada da lógica implementada no Modo Informação, consultar o Anexo B-3, que apresenta o respetivo pseudocódigo.

1. Interpretar o pedido

O primeiro passo consiste em extrair dois elementos da frase: (i) o *identificador interno da máquina* — conhecido na empresa como *código SAP* — e (ii) o *atributo* pretendido (p. ex. “velocidade máxima”). Um modelo de linguagem faz essa extração; se hesitar, recorre-se a uma expressão

regular que deteta padrões do tipo PCON-dddd e a uma pequena lista de sinónimos para atributos (“vel max”, “rpm_max”, “velocidade_máxima”...).

2. Confirmar dados em falta

Se o utilizador omitir o código da máquina ou o atributo, o assistente pede o elemento em falta com uma pergunta curta, mantendo o diálogo natural. Exemplos: «*Qual é o código SAP da máquina?*» ou «*Que informação pretende ver (estado, velocidade, cor...)?*»

3. Consultar a base de dados

Quando já tem ambos os elementos, o sistema envia um pedido à API interna que expõe as máquinas em formato JSON. O detalhe técnico da chamada fica oculto do operador; a única coisa visível é o indicador de leitura (“... a obter dados”). Em caso de atraso anormal, o laço termina ao fim de 25 s e devolve um aviso em vez de “congelar”.

4. Gerar a resposta

Os valores recebidos são passados ao LLM, que os reformula numa frase curta, usando sempre português de Portugal. A temperatura do modelo é fixa em 0,0 para garantir respostas determinísticas e reproduzíveis.

5. Comandos auxiliares

Duas ordens adicionais tornam a exploração mais fácil, sem necessidade de consulta externa:

- «listar máquinas» — devolve todos os códigos SAP conhecidos, em tabela comprimida;
- «ver atributos» — mostra a lista de campos que podem ser perguntados.

Estes comandos são tratados localmente e não requerem acesso ao LLM.

Robustez

- *Validação*: se o código inserido não existir, o assistente informa e sugere o mais parecido, métrica de distância de Levenshtein (medida de similaridade entre cadeias de texto).
- *Gestão de erros*: falhas HTTP devolvem mensagens explícitas («Erro 404 – máquina não encontrada»); o operador não vê rastros de exceção.
- *Desempenho*: a consulta e a formatação correm em processos distintos, impedindo que atrasos de rede bloqueiem a interface.

4.3.5 Classe Principal: Assistente Virtual

A classe `AssistenteVirtual` constitui o núcleo lógico do sistema, centralizando:

- a lista de comandos disponíveis em cada modo (Manutenção, Informação e Predição);
- a gestão da conversação (por texto, voz ou ambos);
- a comunicação com serviços externos, nomeadamente a API da fábrica, o modelo de linguagem e os módulos de monitorização executados em paralelo.

O comportamento global é estruturado segundo uma *máquina de estados finita*, cujos estados principais são: *padrão*, *manutenção*, *informação* e *predição*. A transição entre modos é gerida pela biblioteca `transitions` [102], que automatiza as alterações de estado e garante que o contexto ativo permanece isolado e consistente.

Navegação entre modos

A mudança de contexto é realizada por comandos diretos do utilizador — como «modo manutenção», «modo informação» ou «modo predição» — ou, em alternativa, através de atalhos numéricos (“1”, “2” ou “3”). O sistema interpreta a instrução e ativa a transição correspondente na máquina de estados, como `to_manutencao()`, `to_informacao()` ou `to_predicao()`. Cada transição aciona a função `after=_update_modos`, que atualiza a variável `modo_atual`, assegurando que os pedidos subsequentes são corretamente encaminhados para o modo ativo, sem necessidade de intervenção manual.

Sugestão de comandos


Para melhorar a usabilidade, eventuais erros de escrita são tratados pela função `sugerir_comando()`, que compara a entrada do utilizador com os comandos válidos. Esta comparação recorre à biblioteca `difflib` [41] e, se o grau de correspondência ultrapassar 60 %, o sistema sugere a correção com uma pergunta como: «*Quis dizer manutenção? (sim / não)*». A confirmação evita interpretações erradas e contribui para uma experiência de diálogo mais natural.

Interação por voz

Se o modo por voz estiver ativado, o sistema aceita ficheiros áudio em formatos comuns (WebM, MP3, WAV ou OGG), converte-os internamente para WAV, e realiza a transcrição em português europeu através do serviço de reconhecimento de voz da Google. A resposta gerada é posteriormente convertida em áudio com recurso à biblioteca `gTTS`. Se o modo de voz estiver inativo, o sistema limita-se a apresentar a resposta em texto.

Integração com os modos funcionais

Cada modo funcional possui um pequeno controlo interno de estado:

Figura 4.21: Fluxograma da classe *AssistenteVirtual*.

- **Modo Manutenção** — a variável `manutencao_stage` controla as etapas: seleção da máquina, escolha da ação (manual ou vídeo) e envio da pergunta ou visualização do tutorial. Funções auxiliares gerem o carregamento de manuais e vídeos.
- **Modo Informação** — interpreta o identificador da máquina (código SAP) e o atributo solicitado; se algum deles estiver ausente, o sistema solicita ao utilizador a informação em falta antes de aceder à base de dados.
- **Modo Predição** — permite iniciar/parar a monitorização, detetar anomalias ou gerar previsões baseadas em SARIMAX. A variável `predicao_stage` indica se o sistema aguarda a definição do horizonte temporal.

A gestão de estados e a transição entre os modos no Assistente Virtual pode ser observada detalhadamente através do pseudocódigo no Anexo B-4

Robustez e experiência de utilização

O sistema foi concebido com diversas salvaguardas para garantir estabilidade e fluidez:

- **Limites de tempo (Timeouts):** todas as chamadas a serviços externos estão limitadas a 25 segundos; em caso de falha, o utilizador recebe uma mensagem clara e a interface mantém-se funcional.
- **Histórico de interações:** um comando específico permite apagar o histórico do utilizador, garantindo privacidade e reinício limpo da sessão.
- **Execução paralela:** tarefas como a recolha de dados e a preparação de gráficos são executadas em processos independentes, garantindo que atrasos não bloqueiam a interação com o utilizador.

4.3.6 Implementação do Backend

O backend da RIA é um serviço leve baseado em `Flask`, que expõe uma API REST sobre HTTPS e estabelece a ligação entre a interface do utilizador (desenvolvida em React) e a classe `AssistenteVirtual`.

Persistência

O registo de utilizadores e das respetivas mensagens reside numa base de dados MySQL, acedida através de um mapeador objeto-relacional (*Object-Relational Mapping* – ORM). Na primeira execução, a aplicação verifica se as tabelas estão criadas; caso não estejam, procede automaticamente à sua criação, dispensando migrações manuais durante a fase de prototipagem.

A estrutura segue o diagrama apresentado na Figura 4.22:

- **Users** – guarda o nome de utilizador (*username*) e a data de criação da conta;

- Messages – armazena cada troca de mensagens, indicando o remetente (utilizador ou assistente), o conteúdo textual e o momento da ocorrência.

A relação de um-para-muitos (*um utilizador : várias mensagens*) garante que, ao eliminar um utilizador, todas as suas mensagens são igualmente removidas, assegurando a integridade referencial da base de dados.




Figura 4.22: Estrutura da base de dados do backend (diagrama de classes UML).

Gestão de sessões

A aplicação mantém, em memória, um dicionário global que associa cada utilizador a uma instância da classe `AssistenteVirtual`. Desta forma, cada operador conserva o seu contexto individual (modo ativo, histórico recente, monitorização em curso), mesmo que utilize múltiplas abas do navegador em simultâneo.

Principais pontos de acesso (endpoints)

1. GET `/validate_user` — verifica se o nome de utilizador existe; devolve `{"isValid": true/false}` em formato JSON.
2. POST `/chat` — corpo do pedido: `{"username": "...", "message": "..."}.`
 - (a) Garante a existência do utilizador (ou cria-o);
 - (b) Encaminha a mensagem para a instância do assistente via `processar_comando()`;
 - (c) Regista a interação (mensagem do utilizador e resposta do assistente) na tabela `Messages`;
 - (d) Devolve a resposta estruturada produzida pelo assistente (texto simples, gráfico ou lista) em JSON.
3. GET `/history` — devolve o histórico completo, ordenado cronologicamente, permitindo reconstituir sessões após recarregamento da página.
4. POST `/clear_history` — elimina todas as mensagens associadas a um utilizador, evitando crescimento indefinido da base de dados.

5. `POST /recognize` — recebe um ficheiro de áudio e o nome do utilizador; invoca a função `reconhecer_audio()` e devolve `{"text": "..."}.`
6. `POST /sintetizar` — entrada: `{"username": "...", "mensagem": "..."};` gera áudio correspondente em formato `audio/mpeg` através de `sintetizar_voz()`.

Todos os pedidos do tipo `POST` respondem com códigos de estado HTTP adequados, permitindo uma deteção clara de erros no frontend: 400 (parâmetros em falta), 404 (utilizador inexistente) ou 500 (erro interno).

Para clarificar o fluxo de comunicação e processamento das requisições pela API REST implementada, consultar o Anexo B-5, que contém o pseudocódigo representativo

De pedido a resposta – passo a passo

1. O utilizador introduz (ou dita) uma pergunta na interface.
2. O frontend envia um pedido HTTP para o ponto de acesso `/chat`, contendo o nome de utilizador e a mensagem.
3. O backend assegura a existência de uma sessão para o utilizador e encaminha o texto para a instância da classe `AssistenteVirtual`.
4. A classe interpreta o comando consoante o modo ativo, gera a resposta, e o backend grava o par pergunta/resposta na base de dados.
5. O frontend apresenta a resposta. Caso o utilizador ative a opção de áudio, o mesmo conteúdo textual é enviado para o ponto de acesso `/sintetizar` e devolvido em formato MP3 para reprodução imediata.

O backend, construído com recurso a `Flask` e `SQLAlchemy`, fornece um ponto de integração coeso entre o utilizador, a lógica de negócio do assistente e os dados da fábrica. A separação clara de responsabilidades — persistência de dados, gestão de sessões, serviços de voz e encaminhamento de mensagens — facilita a manutenção e escalabilidade, ao mesmo tempo que assegura o desempenho necessário para um ambiente industrial em tempo real.

4.3.7 Interface Gráfica

Ao iniciar o sistema, o utilizador é recebido por uma tela simples de autenticação, onde pode inserir o seu nome de utilizador. Esta autenticação permite personalizar e carregar o histórico das interações, adaptando as respostas da RIA às necessidades individuais. A área principal da interface é composta por um chat, no qual as mensagens do utilizador e da RIA são visualmente diferenciadas para facilitar a leitura. O sistema suporta comandos por texto e por voz, oferecendo flexibilidade na interação.

A interface disponibiliza um modal de ajuda dinâmico que atualiza automaticamente os comandos disponíveis conforme o modo ativo (Manutenção, Informação ou Predição). Este recurso fornece suporte contextual direto, reduzindo a necessidade de consulta externa de documentação. Também foram implementadas funcionalidades de personalização, como o modo escuro, que melhora o conforto visual durante o uso prolongado. Pode-se ver na Figura 4.23 a interface do Assistente Virtual.

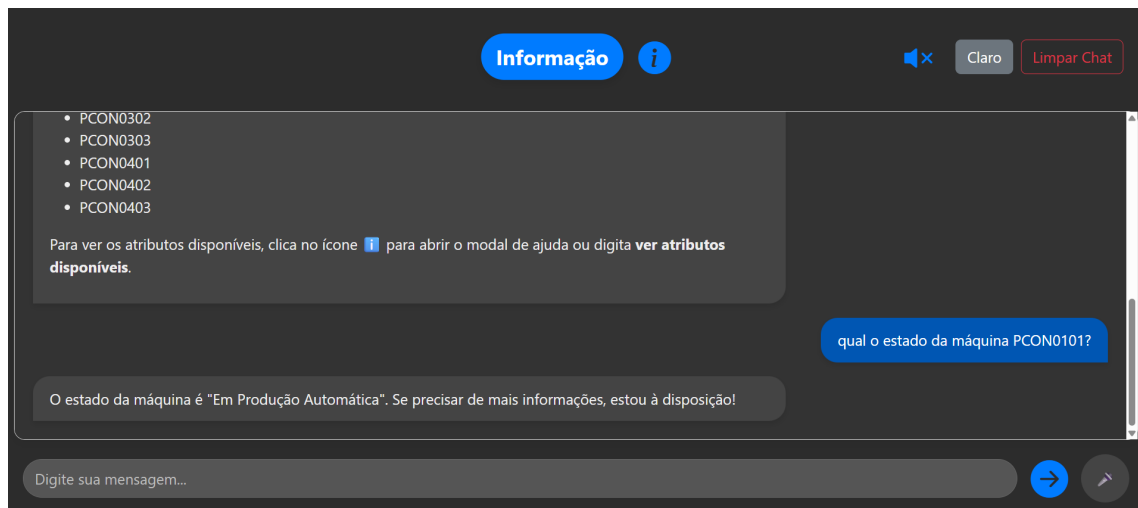


Figura 4.23: Interface da RIA.

Para facilitar a análise de dados, especialmente no modo de predição, são apresentados gráficos interativos atualizados em tempo real, com base nos dados do backend. Estes gráficos auxiliam os técnicos na visualização de tendências e na detecção de anomalias, contribuindo para decisões mais informadas. A Figura 4.24 ilustra um exemplo desse tipo de visualização.




Figura 4.24: Gráfico interativo de previsão baseado em dados operacionais

A interface foi desenvolvida com um design responsivo, adaptando-se automaticamente a

diferentes dispositivos como desktops, tablets e telemóveis. Este cuidado garante uma experiência consistente e acessível a todos os utilizadores, independentemente do ambiente em que estejam a trabalhar.

Em síntese, a interface gráfica da RIA alia usabilidade a um design intuitivo, proporcionando uma plataforma eficaz para interações técnicas complexas num ambiente industrial. A combinação de componentes modulares, visualizações dinâmicas e uma experiência personalizada assegura um sistema robusto, fácil de usar e adequado às necessidades práticas dos utilizadores.

4.3.8 Integração da RIA com Aplicações de Realidade Aumentada e Realidade Virtual

A integração da RIA com tecnologias imersivas como a Realidade Aumentada e a Realidade Virtual abre novas oportunidades para melhorar significativamente a interação e eficiência no ambiente industrial, dando continuidade ao percurso do projeto desenvolvido. Uma das aplicações práticas da RA está relacionada com a manutenção assistida diretamente no local onde ocorre o problema. Por exemplo, no modo Manutenção, a RIA, que já disponibiliza instruções passo-a-passo na interface gráfica, pode enviar estas informações diretamente para um dispositivo móvel com RA, sobrepondo digitalmente as instruções no equipamento real. Desta forma, o operador visualiza no ecrã do dispositivo as instruções detalhadas, associadas à parte específica da máquina que necessita de intervenção, através de marcadores visuais que garantem o alinhamento correto entre o real e o virtual, como podemos ver na Figura 4.25.




Figura 4.25: Interface de Realidade Aumentada integrada com a RIA.

Neste cenário, a RIA funciona como coordenadora, comunicando continuamente com o Gêmeo Digital para garantir que as instruções estejam sempre ajustadas ao estado atual da máquina,

simplificando e acelerando significativamente as operações de manutenção.

A RV também oferece oportunidades importantes para a formação e simulação de procedimentos operacionais. Num ambiente totalmente virtual e seguro, o operador pode realizar ensaios e treinos de operações complexas antes de as executar na fábrica real. A Figura 4.26 apresenta-se um exemplo deste cenário imersivo, onde o operador pode interagir com a RIA como agente conversacional para esclarecer dúvidas específicas durante o treino. Assim, questões práticas podem ser rapidamente esclarecidas através de comandos vocais, garantindo que o conhecimento adquirido na simulação seja diretamente aplicável na realidade operacional.

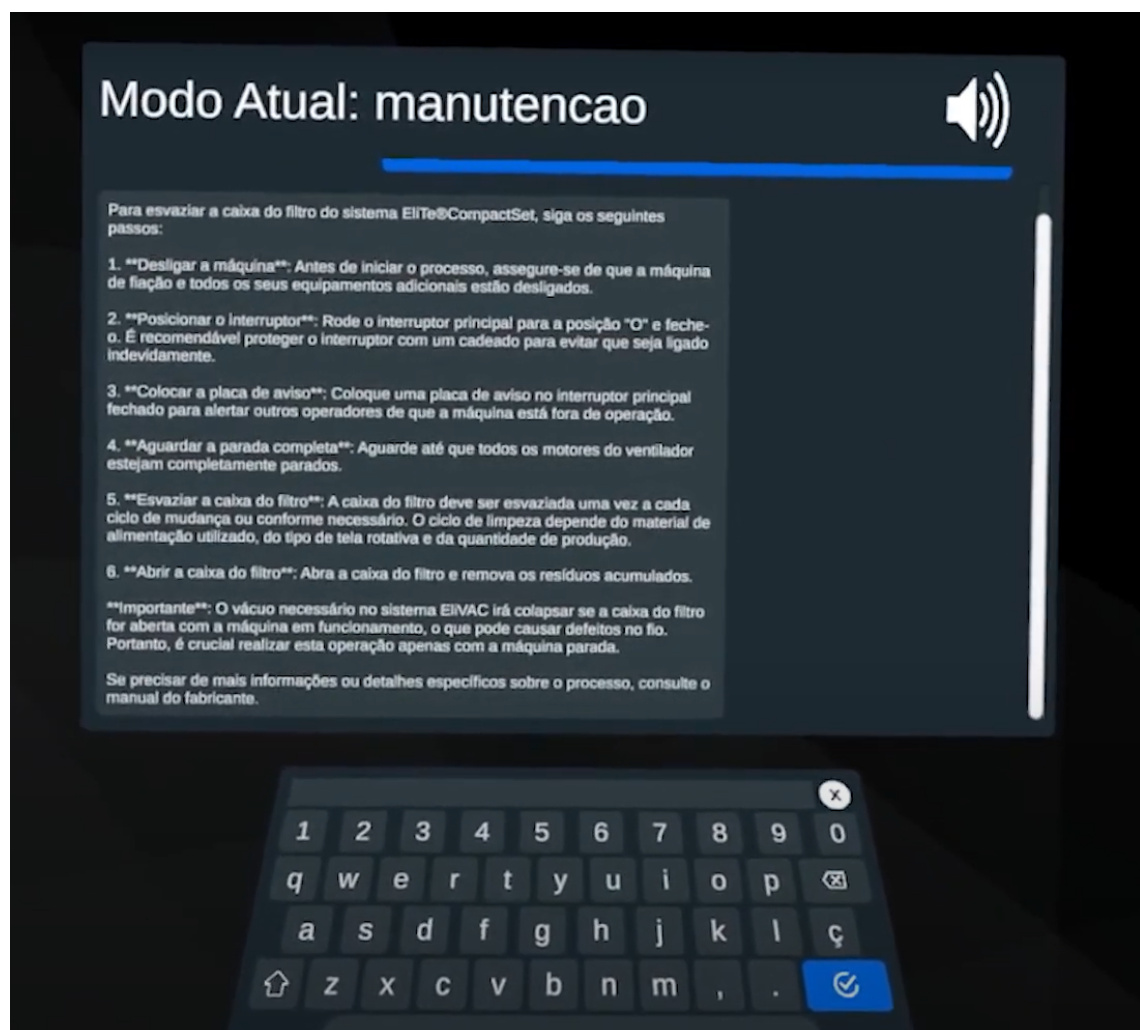


Figura 4.26: Ambiente virtual com integração da RIA.

Desta forma, a integração da RIA com aplicações de Realidade Aumentada e Virtual reforça não apenas a eficácia operacional, mas também a segurança e o conforto dos operadores, apontando para o futuro das fábricas inteligentes e centradas nas pessoas.

Capítulo 5

Resultados e Discussão

A validação da solução decorreu em duas etapas complementares. Na Fase 1, realizou-se uma prova-de-conceito em ambiente laboratorial controlado: testaram-se o Gémeo Digital, a comunicação bidirecional e os modelos de predição, confirmando a robustez técnica da arquitetura. Na Fase 2, já num contexto industrial real, avaliou-se especificamente a RIA através de questionários qualitativos aplicados a profissionais com funções críticas na manutenção e operação de equipamentos. Esta combinação de testes experimentais e feedback dos utilizadores permitiu obter uma visão completa do desempenho do sistema, identificando pontos fortes e oportunidades de melhoria.

5.1 Resultados

5.1.1 Resultados da Fase 1 – Validação Laboratorial

Nesta fase inicial, validou-se a criação de um Gémeo Digital em ambiente controlado, usando uma máquina de café como caso de estudo. O sistema mostrou capacidade para recolher, transmitir e processar dados em tempo real, mantendo comunicação bidirecional robusta entre o equipamento físico e a sua réplica digital.

Observou-se elevada eficiência do FIWARE na gestão de dados contextuais, pela facilidade de integração com sensores IoT e serviços externos. Os dashboards em Grafana forneceram visualização clara das métricas operacionais, permitindo acompanhamento contínuo dos parâmetros da máquina.

Os algoritmos de *machine learning* implementados (regressão linear e deteção de anomalias) alcançaram desempenho promissor na predição de falhas, gerando alertas antecipados que podem reduzir paragens inesperadas.

Parte destes resultados foi divulgada no artigo *Smart Maintenance Solutions: AR- and VR-Enhanced Digital Twin Powered by FIWARE* publicado na revista *Sensors* [21].

5.1.2 Resultados da Fase 2 – RIA

Os resultados apresentados derivam de um questionário qualitativo aplicado a profissionais relevantes da empresa têxtil estudada, incluindo cargos como Chefe Geral de Manutenção da fábrica, Chefe de Manutenção da secção de fição, Engenheiro Industrial e Engenheiro Informático. No total, participaram quatro profissionais, todos do género masculino e com formação superior. Em termos de faixa etária, metade dos participantes situava-se entre os 37-50 anos e a outra metade entre os 50-65 anos, indicando profissionais experientes e qualificados.

Todos os participantes concordaram que as respostas fornecidas pela RIA foram claras, eficientes e que o sistema foi fácil de utilizar, destacando que as respostas foram recebidas em tempo adequado, contribuindo assim para uma interação fluida com o assistente virtual. Os participantes também expressaram satisfação geral com a RIA, com destaque particular para o modo de manutenção, elogiado pela sua facilidade e praticidade. Os resultados numéricos podem ser consultados na Figura 5.1, onde são apresentados os valores obtidos através do questionário SUS. Durante os testes, os quatro especialistas envolvidos — entre chefes de manutenção e engenheiros — descreveram a RIA como uma ferramenta com respostas “claras”, “rápidas” e “práticas”, destacando em particular o modo de manutenção, que centraliza informação útil de forma simples e acessível.




Figura 5.1: Resultados do questionário SUS.

Nas respostas mais detalhadas sobre a experiência geral, verificou-se uma clara percepção positiva sobre a facilidade de aprender e a integração das funções. Nenhum dos participantes achou a aplicação excessivamente complexa ou sentiu necessidade significativa de suporte técnico especializado para utilizar o sistema. Contudo, registaram-se algumas observações sobre potenciais melhorias na aplicação, nomeadamente:

- Usabilidade dos diferentes modos disponíveis.
- Necessidade de mais previsibilidade, incluindo a disponibilização de dados comparativos detalhados.
- Sugestões para otimizar a estrutura da base de dados para facilitar ainda mais o acesso e a interpretação das informações operacionais.

A avaliação SUS (System Usability Scale) [80], realizada no final do questionário, revelou um resultado geral de 85 pontos, o que corresponde a uma excelente usabilidade e alta aceitação por parte dos utilizadores.

5.2 Discussão

A análise dos resultados obtidos nesta fase experimental permite destacar diversos contributos relevantes tanto para a prática industrial como para a investigação no domínio dos sistemas ciber-físicos. O desenvolvimento e validação do Assistente Virtual Inteligente, em articulação com um *Digital Twin* funcional, revela-se uma proposta exequível e com valor acrescentado no contexto de uma fábrica inteligente.

Desde logo, o trabalho beneficiou de uma base sólida construída na Fase 1, onde foi concebida e testada uma arquitetura de *Digital Twin* modular, baseada em componentes FIWARE e orientada à interoperabilidade. Esta arquitetura não só permitiu validar os fluxos bidirecionais entre o mundo físico e o digital, como serviu de alicerce para a integração natural do RIA na segunda fase. A ligação entre os módulos de aquisição de dados, tratamento em tempo-real e visualização no interface humano reforça o carácter prático e reutilizável da solução proposta. A fase de experimentação na fábrica da RIOPELE revelou uma aceitação muito positiva por parte dos técnicos envolvidos. A RIA demonstrou ser simples de utilizar, eficaz na comunicação e suficientemente adaptável às rotinas já estabelecidas. A combinação de uma interface intuitiva com acesso imediato a informações contextuais e operacionais foi amplamente elogiada, em especial no modo dedicado à manutenção. Do ponto de vista técnico, a integração entre a RIA e o *Digital Twin* foi alcançada com sucesso. Os dados são recolhidos e atualizados, permitindo a consulta dinâmica de estados da máquina e a personalização da informação apresentada ao operador. Ainda que os algoritmos de predição tenham sido já implementados, não foi possível, nesta fase, realizar uma avaliação robusta da sua precisão, devido à dimensão ainda reduzida da base de dados histórica. Este aspeto representa uma limitação atual, mas também uma oportunidade futura: com mais tempo de funcionamento, o sistema poderá acumular dados suficientes para alimentar modelos mais avançados e oferecer funcionalidades preditivas de maior confiança.

Um outro aspeto a destacar é o foco colocado na experiência do utilizador. A usabilidade foi avaliada com recurso à escala SUS, tendo sido atribuída uma pontuação média de 85, classificada como excelente. Esta avaliação foi corroborada por comentários positivos dos operadores, que referiram, de forma consistente, a facilidade de aprendizagem e a clareza das respostas geradas pelo sistema. Esta valorização da interação homem-máquina é particularmente importante em contextos

industriais, onde o tempo disponível para formação é reduzido e a adoção de novas ferramentas depende fortemente da sua intuitividade.

A Fase 2 permitiu validar a RIA num contexto real de fábrica, na secção de fiação da empresa RIOPELE. Este sistema conseguiu reunir, numa única solução, duas componentes pouco comuns quando aplicadas em conjunto: por um lado, uma interação multimodal, que permite ao utilizador comunicar por voz ou texto, com apoio contextual durante a navegação; por outro, uma capacidade preditiva em tempo-real, que recorre a modelos estatísticos para antecipar comportamentos da máquina.

A Tabela 5.1 apresenta uma comparação direta entre a RIA desenvolvido e cinco soluções estudadas na revisão de literatura, considerando apenas os aspetos relacionados com a aplicação prática.

Tabela 5.1: Análise comparativa de assistentes.

Característica	Li 2022	Trappey 2022	Pavlov 2020	Casillo 2020	Mantravadi 2020	Guachun 2022	RIA
Interação por voz	✓	✓	–	–	–	✓	✓
Assistência física/robótica	✓	–	–	–	–	✓	–
Base de conhecimento	✓	✓	–	–	✓	–	✓
Dados em tempo real	✓	–	✓	–	✓	✓	✓
Informação estática	–	✓	–	✓	–	–	✓
Predição/diagnóstico	–	–	✓	–	–	–	✓
Formação de operadores	–	–	–	✓	–	–	✓
Integração MES/ERP	–	–	–	–	✓	–	✓

Legenda: ✓ → característica presente; – → ausente/não referenciada.

Interação por voz: controlo ou consulta por comandos falados. *Assistência física/robótica:* ações mecânicas (robots, atuadores). *Base de conhecimento estruturada:* ontologias, grafos, regras formais. *Dados em tempo real:* trabalha com variáveis ao vivo. *Informação estática:* documentos, manuais, FAQ. *Predição/diagnóstico:* modelos de previsão de falhas ou apoio a decisão. *Formação:* suporte a aprendizagem de novos operadores. *Integração MES/ERP:* ligação a sistemas de gestão de produção ou planeamento empresarial.

De forma geral, a RIA apresentado vai além do que foi encontrado nos outros trabalhos analisados, ao transformar o assistente numa ferramenta verdadeiramente útil no chão-de-fábrica. Destaca-se especialmente por:

1. Permitir prever comportamentos da máquina com base em dados reais, algo ausente nas soluções comparadas;
2. Oferecer um modo de manutenção prático e guiado, com acesso a documentação, vídeos de manutenções num único local;
3. Apresentar uma interface versátil, que permite alternar facilmente entre comandos de voz e texto — contornando assim limitações típicas em ambientes ruidosos.

Assim, na Fase 2, a RIA não só acompanha as vantagens oferecidas pelas soluções anteriores, como introduz funcionalidades adicionais de apoio à decisão, reforçando a sua aplicabilidade no contexto real numa fábrica.

Em resumo, o sistema desenvolvido cumpre os principais objetivos delineados para esta investigação, tanto na sua componente técnica como na sua vertente funcional. A validação inicial

permite concluir que é possível criar, com tecnologias acessíveis e abertas, um sistema integrado de assistência virtual sobre um *Digital Twin* real, com impacto direto na eficiência e qualidade da operação industrial.

Capítulo 6

Conclusões e Trabalho Futuro

6.1 Conclusões

A presente dissertação teve como principal objetivo explorar o potencial do paradigma do *Digital Twin* em articulação com tecnologias emergentes como IoT , a Inteligência Artificial e a Assistência Virtual Inteligente , no contexto das fábricas inteligentes. Ao longo do trabalho, procurou-se desenvolver uma solução tecnológica integrada que contribuísse para uma maior eficiência, fiabilidade e inteligência na operação e manutenção de equipamentos industriais, alinhando-se com os princípios da Indústria 5.0. A abordagem foi dividida em duas fases complementares. Na Fase 1, foi concebido e testado um protótipo de *Digital Twin* em ambiente laboratorial, recorrendo a sensores, dispositivos IoT, FIWARE, algoritmos de *machine learning* e dashboards de visualização em tempo real. Esta etapa permitiu validar os conceitos fundamentais, nomeadamente a comunicação bidirecional entre o sistema físico e o digital, a recolha e tratamento eficiente de dados contextuais e a aplicação de modelos preditivos simples, demonstrando a viabilidade técnica do sistema proposto.

Já na Fase 2, foi desenvolvido um Assistente Virtual Inteligente destinado a operar sobre um *Digital Twin* existente numa unidade fabril real, no caso, da empresa RIOPELE. Este sistema foi desenhado com uma arquitetura modular, capaz de interpretar comandos em linguagem natural, consultar documentação técnica, apresentar informação em tempo real e realizar análises preditivas com base em dados históricos operacionais. A implementação técnica envolveu o uso de tecnologias modernas tendo resultado numa solução funcional, escalável e ajustada ao contexto fabril.

A validação do sistema foi realizada com o apoio de técnicos e engenheiros da RIOPELE, através de um questionário de avaliação qualitativa. Os resultados foram bastante encorajadores: todos os participantes consideraram o sistema claro, eficiente e fácil de utilizar, com especial destaque para o modo de manutenção. A pontuação SUS atribuída foi de 85 pontos, evidenciando uma excelente usabilidade e aceitação geral.

No que diz respeito à satisfação dos objetivos definidos no início do trabalho, conclui-se que todos foram integralmente cumpridos. Foi realizada uma revisão exaustiva do estado da arte, desenvolvida uma arquitetura coerente e funcional, implementadas soluções técnicas para recolha

e análise de dados, criada uma interface gráfica amigável e validada a utilidade do sistema em ambiente real. A solução proposta revela-se, assim, uma ferramenta relevante para o apoio à manutenção e operação em contexto industrial, contribuindo para a redução de tempos de paragem, a antecipação de falhas e a melhoria da comunicação entre operadores e sistemas digitais. Esta dissertação representa um contributo prático e científico para a transformação digital das fábricas, demonstrando como a convergência entre os mundos físico e digital pode ser potenciada através de uma abordagem centrada no utilizador, orientada por dados e sustentada por tecnologias inteligentes. O trabalho desenvolvido abre caminho a novas possibilidades de investigação e aplicação, num cenário cada vez mais exigente e interligado como é o da Indústria 5.0.

6.2 Trabalho Futuro

Os resultados obtidos nesta dissertação representam um ponto de partida promissor, mas abrem também espaço para várias melhorias e aprofundamentos. Abaixo identificam-se algumas direções concretas para o desenvolvimento futuro do sistema. Um dos aspetos centrais a evoluir prende-se com a melhoria da interação entre o utilizador e a inteligência artificial. Embora a interface atual já permita um diálogo funcional, há margem para tornar a comunicação mais fluida e natural, nomeadamente através do reconhecimento de intenções implícitas, sugestões proativas por parte do assistente e maior contextualização das respostas. Esta evolução contribuirá para uma experiência mais próxima da linguagem humana, reduzindo a necessidade de comandos explícitos e tornando o sistema mais intuitivo.

Outro eixo de evolução fundamental passa pelo enriquecimento da base de conhecimento do assistente. A introdução de dados técnicos adicionais, como especificações detalhadas de equipamentos, registos de funcionamento, manuais avançados ou relatórios de manutenção, permitirá à IA fornecer respostas mais completas e ajustadas ao contexto. Com esta informação, o assistente poderá, por exemplo, comparar desempenhos entre máquinas, sugerir melhorias operacionais ou apresentar diagnósticos mais precisos com base em ocorrências anteriores. A componente preditiva do sistema será também um dos focos principais numa futura iteração. Está prevista a integração de mecanismos para antecipação de avarias, com base na análise cruzada entre relatórios técnicos, registos de falhas anteriores e parâmetros operacionais em tempo real. Ao consolidar estas fontes de informação, a IA poderá emitir alertas que permitam agir preventivamente, reduzindo tempos de paragem e aumentando a disponibilidade das máquinas.

Do ponto de vista da recolha de dados, propõe-se a introdução de uma funcionalidade que permita o registo por voz das intervenções de manutenção. Esta funcionalidade permitirá ao operador ditar, através de um microfone, os procedimentos realizados (como peças substituídas, duração da intervenção ou observações técnicas). O sistema fará a transcrição automática da informação e garantirá a validação dos campos mais críticos, assegurando a integridade dos registos.

Por fim, pretende-se explorar o aproveitamento inteligente desses registos históricos, tanto em formato de texto como de voz, para apoio a futuras manutenções. Com base em casos semelhantes

anteriormente registados, o assistente poderá sugerir procedimentos já testados, planos de ação adequados e decisões informadas que resultaram bem em intervenções passadas. Este tipo de apoio contextual pode contribuir significativamente para a consistência e eficiência das operações técnicas.

Para além das melhorias técnicas previstas, importa referir que o sistema desenvolvido já se encontra disponível na rede interna da RIOPELE, em fase piloto, desde abril de 2025. Esta versão inicial tem servido para testar a integração da RIA com os processos reais da fábrica, recolher feedback dos utilizadores e validar o seu funcionamento em contexto industrial. Está previsto que, até janeiro de 2026, seja implementada uma versão mais robusta e estável do sistema, com melhorias resultantes dos testes realizados e do trabalho futuro identificado nesta dissertação.

No que respeita à transferência da tecnologia, prevê-se que a solução evolua progressivamente para ser totalmente integrada nos processos internos da empresa. A médio prazo, a RIA passará a ser inteiramente gerida e mantida pela equipa técnica da RIOPELE, assegurando a sua continuidade e adaptação às necessidades da fábrica.

Referências

- [1] Festo Corporation. Cp systems – industry 4.0 learning factories. https://www.festo.com/us/en/e/technical-education/educational-concepts/highlights/learning-factories/cp-systems-large-scale-industry-4-0-learning-factories-id_32122/, 2025. Acedido em abril de 2025.
- [2] The MathWorks, Inc. Simulink is for model-based design. <https://www.mathworks.com/products/simulink.html>, 2025. Acedido em abril de 2025.
- [3] Saifeddin Alimamy e Mohammad Amin Kuhail. I will be with you alexa! the impact of intelligent virtual assistant’s authenticity and personalization on user reusage intentions. *Computers in Human Behavior*, 143:107711, 2023.
- [4] Amazon. What is alexa? <https://developer.amazon.com/en-US/alexa>, 2025. Accessed: 11 de março de 2025.
- [5] Apache Kafka. Apache kafka - distributed event streaming platform. <https://kafka.apache.org/>, 2025. Acedido em abril de 2025.
- [6] Mohsen Attaran e Bilge Gokhan Celik. Digital twin: Benefits, use cases, challenges, and opportunities. *Decision Analytics Journal*, 6:100165, 2023.
- [7] Sharmin Attaran, Mohsen Attaran, e Bilge Gokhan Celik. Digital twins and industrial internet of things: Uncovering operational intelligence in industry 4.0. *Decision Analytics Journal*, 10:100398, 2024.
- [8] Microsoft Azure. Api design guidance. <https://learn.microsoft.com/en-us/azure/architecture/best-practices/api-design>, 2025. Accessed: 24 January 2025.
- [9] LLC BayesFusion. What are bayesian networks? https://www.bayesfusion.com/bayesian-networks/?gad_source=1&gclid=CjwKCAjwvr--BhB5EiwAd5YbXhi3oFL9U0mfIavONUQNlUj_tHoPMIVTTniTAuGprHkJjzpMov22ghoCKHYQAvD_BwE, 2023. Accessed: 28 January 2025.
- [10] Stephen A Billings. *Nonlinear system identification: NARMAX methods in the time, frequency, and spatio-temporal domains*. John Wiley & Sons, 2013.
- [11] Akouendy Blog. Rest api principle: How rest apis work. <https://www.akouendy.com/blog/rest-api-principle/>, 2025. Accessed: 24 January 2025.

- [12] Pat Brans. Markov model. <https://www.techtarget.com/whatis/definition/Markov-model>, 2022. Accessed: 28 January 2025.
- [13] Jan vom Brocke, Alan Hevner, e Alexander Maedche. *Introduction to Design Science Research*, páginas 1–13. 09 2020.
- [14] Tom Brown, Benjamin Mann, Nick Ryder, Melanie Subbiah, Jared D Kaplan, Prafulla Dhariwal, Arvind Neelakantan, Pranav Shyam, Girish Sastry, Amanda Askell, et al. Language models are few-shot learners. *Advances in neural information processing systems*, 33:1877–1901, 2020.
- [15] Diogo Cardoso e Luís Ferreira. Application of predictive maintenance concepts using artificial intelligence tools. *Applied Sciences*, 11:1–18, 2021.
- [16] Mario Casillo, Francesco Colace, Loretta Fabbri, Marco Lombardi, Alessandra Romano, e Domenico Santaniello. Chatbot in industry 4.0: An approach for training new employees. Em *2020 IEEE International Conference on Teaching, Assessment, and Learning for Engineering (TALE)*, páginas 371–376, 2020.
- [17] Tianfeng Chai e Roland R Draxler. Root mean square error (rmse) or mean absolute error (mae)?—arguments against avoiding rmse in the literature. *Geoscientific model development*, 7(3):1247–1250, 2014.
- [18] Chong Chen, Huibin Fu, Yu Zheng, Fei Tao, e Ying Liu. The advance of digital twin for predictive maintenance: The role and function of machine learning. *Journal of Manufacturing Systems*, 71:581–594, 2023.
- [19] components101. Dht11—temperature and humidity sensor. <https://components101.com/sensors/dht11-temperature-sensor/>. Accessed: 10 December 2024.
- [20] Oracle Corporation. What is a relational database? <https://www.oracle.com/pt/database/what-is-a-relational-database/>, 2025. Acessado em: 7 de março de 2025.
- [21] André Costa, João Miranda, Duarte Dias, Nuno Dinis, Luís Romero, e Pedro Miguel Faria. Smart maintenance solutions: Ar- and vr-enhanced digital twin powered by fiware. *Sensors*, 25(3), 2025.
- [22] Crate.io. Cratedb: The sql database for machine data. <https://crate.io/>, 2025. Accessed: 24 January 2025.
- [23] José Osvaldo De Sordi. *Design Science Research Methodology: Theory Development from Artifacts*. Palgrave Macmillan, Cham, 2021.
- [24] Deloitte University Press. Industry 4.0 and digital twin technology. https://www2.deloitte.com/content/dam/insights/us/articles/3833_Industry4-0_digital-twin-technology/DUP_Industry-4.0_digital-twin-technology.pdf, 2017. Acedido em Maio 2025.
- [25] FFmpeg Developers. A complete, cross-platform solution to record, convert and stream audio and video., 2025. FFmpeg Documentation. Disponível em: <https://ffmpeg.org/>. Acessado em 24 de fevereiro de 2025.

- [26] PDFMiner.six Developers. pdfminer.six: Uma ferramenta para extração de texto de pdfs, 2025. Disponível em: <https://pdfminersix.readthedocs.io/>. Acessado em 27 de abril de 2025.
- [27] PyPDF2 Developers. Pypdf2: Uma biblioteca python para manipulação de pdfs, 2025. Disponível em: <https://pypi.org/project/PyPDF2/>. Acessado em 27 de abril de 2025.
- [28] Circuit Digest. How to interface dht11 sensor with raspberry pi. <https://circuitdigest.com/microcontroller-projects/raspberry-pi-dht11-interfacing-with-python-code>. Accessed: 10 December 2024.
- [29] Matplotlib Documentation. Matplotlib: Visualization with python. <https://matplotlib.org/stable/contents.html>, 2025. Accessed: 7 de março de 2025.
- [30] Tkinter Documentation. Tkinter: Python interface to tcl/tk. <https://docs.python.org/3/library/tkinter.html>, 2025. Accessed: 7 de março de 2025.
- [31] Niklas Donges. Random forest: A complete guide for machine learning. <https://builtin.com/data-science/random-forest-algorithm/>, 2024. Accessed: 7 de março de 2025.
- [32] Charles M Eastman. *BIM handbook: A guide to building information modeling for owners, managers, designers, engineers and contractors*. John Wiley & Sons, 2011.
- [33] Jeffrey L. Elman. Finding structure in time. *Cognitive Science*, 14:179–211, 1990.
- [34] Roy T. Fielding. Architectural styles and the design of network-based software architectures. https://www.ics.uci.edu/~fielding/pubs/dissertation/rest_arch_style.htm, 2000. Accessed: 24 January 2025.
- [35] International Organization for Standardization (ISO). What is artificial intelligence? <https://www.iso.org/artificial-intelligence/what-is-ai>, 2025. Accessed: 22 January 2025.
- [36] FIWARE Foundation. Fiware integration with grafana. <https://fiware-tutorials.readthedocs.io/en/latest/time-series-data.html#grafana>, 2025. Accessed: 24 January 2025.
- [37] FIWARE Foundation. Orion context broker. <https://fiware-orion.readthedocs.io/en/latest/>, 2025. Accessed: 24 January 2025.
- [38] FIWARE Foundation. Quantumleap documentation. <https://quantumleap.readthedocs.io/>, 2025. Accessed: 24 January 2025.
- [39] FIWARE Foundation. What is fiware? <https://www.fiware.org/about-us/>, 2025. Accessed: 24 January 2025.
- [40] Node.js Foundation. What is node.js? <https://nodejs.org/en/about/>, 2025. Accessed: 24 January 2025.
- [41] Python Software Foundation. difflib — helpers for computing deltas, 2025. Disponível em: <https://docs.python.org/3/library/difflib.html>. Acessado em 26 de fevereiro de 2025.

- [42] Raspberry Pi Foundation. Raspberry pi 3 model b+ specifications. <https://www.raspberrypi.com/products/raspberry-pi-3-model-b-plus/>. Accessed: 10 December 2024.
- [43] Aidan Fuller, Zhong Fan, Charles Day, e Chris Barlow. Digital twin: Enabling technologies, challenges and open research. *IEEE Access*, 8:108952–108971, 2020.
- [44] Chandrika G. Natural language processing (nlp). *International Journal for Research in Applied Science & Engineering Technology (IJRASET)*, 12(VI):1092–1095, 2024. Accessed: 22 January 2025.
- [45] GeeksforGeeks . Support vector regression (svr) using linear and non-linear kernels in scikit learn. <https://www.geeksforgeeks.org/support-vector-regression-svr-using-linear-and-non-linear-kernels-in-scikit-learn/>. Accessed: 10 April 2025.
- [46] Ian Goodfellow. Deep learning, 2016.
- [47] Ian Goodfellow, Yoshua Bengio, e Aaron Courville. *Deep Learning*. MIT Press, 2016. <http://www.deeplearningbook.org>.
- [48] Google LLC. Google Scholar. <https://scholar.google.com>. Acesso em 21 Jun. 2025.
- [49] Michael Grieves e John Vickers. Digital twin: Mitigating unpredictable, undesirable emergent behavior in complex systems. *Transdisciplinary perspectives on complex systems: New findings and approaches*, páginas 85–113, 2017.
- [50] Rong Gu, Teodor Barbuceanu, Ning Xiong, e Tiberiu Seceleanu. Experiences in building a digital twin framework: Challenges and possible solutions. *2024 IEEE 48th Annual Computers, Software, and Applications Conference (COMPSAC)*, páginas 531–534, 2024.
- [51] John Guachun-Arias e Luis Serpa-Andrade. Implementation of an iot-based environment to control an industrial process by voice commands using a virtual assistant. *AHFE international*, 2022.
- [52] Furkan Guc e YangQuan Chen. Smart predictive maintenance enabled by digital twins and smart big data: A new framework. *2022 IEEE 2nd International Conference on Digital Twins and Parallel Intelligence (DTPI)*, páginas 1–10, 2022.
- [53] Avi Gupta, Thor S Stead, e Latha Ganti. Determining a meaningful r-squared value in clinical medicine. *Academic Medicine & Surgery*, 2024.
- [54] Parian Haghighat, Toan Nguyen, Mina Valizadeh, Mohammad Arvan, Natalie Parde, Myunghee Kim, e Heejin Jeong. Effects of an intelligent virtual assistant on office task performance and workload in a noisy environment. *Applied Ergonomics*, 109:103969, 2023.
- [55] Zellig S. Harris. Distributional structure. *Word*, 10(2–3):146–162, 1954.
- [56] Sepp Hochreiter e Jürgen Schmidhuber. Long short-term memory. *Neural computation*, 9(8):1735–1780, 1997.
- [57] Holt and Winters . Holt-winters’ seasonal method. <https://otexts.com/fpp2/holt-winters.html>. Accessed: 10 April 2025.

- [58] Kurt Hornik, Maxwell Stinchcombe, e Halbert White. Multilayer feedforward networks are universal approximators. *Neural networks*, 2(5):359–366, 1989.
- [59] Rob J Hyndman e Anne B Koehler. Another look at measures of forecast accuracy. *International journal of forecasting*, 22(4):679–688, 2006.
- [60] IBM. Artificial intelligence. <https://www.ibm.com/think/topics/artificial-intelligence>, 2025. Accessed: 22 January 2025.
- [61] IEEE. IEEE Xplore Digital Library. <https://ieeexplore.ieee.org>. Acesso em 21 Jun. 2025.
- [62] Apple Inc. Siri. <https://developer.apple.com/design/human-interface-guidelines/siri/>, 2025. Accessed: 11 de março de 2025.
- [63] Docker Inc. What is a container? <https://www.docker.com/resources/what-container/>, 2025. Accessed: 24 January 2025.
- [64] MongoDB Inc. What is mongodb? <https://www.mongodb.com/>, 2025. Accessed: 24 January 2025.
- [65] InfluxData. Influxdb - time series database. <https://www.influxdata.com/products/influxdb/>, 2025. Acedido em abril de 2025.
- [66] David Jones, Chris Snider, Aydin Nassehi, Jason Yon, e Ben Hicks. Characterising the digital twin: A systematic literature review. *CIRP Journal of Manufacturing Science and Technology*, 29:36–52, 2020.
- [67] Yue Kang, Zhao Cai, Chee-Wee Tan, Qian Huang, e Hefu Liu. Natural language processing (nlp) in management research: A literature review. *Journal of Management Analytics*, 7(2):139–172, 2020.
- [68] Chadi Khneyzer, Zaher Boustany, e Jean Dagher. Ai-driven chatbots in crm: Economic and managerial implications across industries. *Administrative Sciences*, 14:182, 2024.
- [69] Sungil Kim e Heeyoung Kim. A new metric of absolute percentage error for intermittent demand forecasts. *International Journal of Forecasting*, 32(3):669–679, 2016.
- [70] Yoon Kim. Convolutional neural networks for sentence classification. Em *Proc. EMNLP*, páginas 1746–1751, 2014.
- [71] Werner Kritzinger, Matthias Karner, Georg Traar, Jan Henjes, e Wilfried Sihn. Digital twin in manufacturing: A categorical literature review and classification. *IFAC-PapersOnLine*, 51(11):1016–1022, 2018. 16th IFAC Symposium on Information Control Problems in Manufacturing INCOM 2018.
- [72] Yann LeCun, Yoshua Bengio, e Geoffrey Hinton. Deep learning. *nature*, 521(7553):436–444, 2015.
- [73] J. Leng, W. Sha, B. Wang, e et al. Industry 5.0: Prospect and retrospect. *Journal of Manufacturing Systems*, 65:279–295, 2022.

- [74] Chen Li, Andreas Kornmaaler Hansen, Dimitrios Chrysostomou, Simon Bøgh, e Ole Madsen. Bringing a natural language-enabled virtual assistant to industrial mobile robots for learning, training and assistance of manufacturing tasks. Em *2022 IEEE/SICE International Symposium on System Integration (SII)*, páginas 238–243, 2022.
- [75] Linear Regression. What is linear regression? <https://www.ibm.com/think/topics/linear-regression/>. Accessed: 29 December 2024.
- [76] Sizhe Ma, Katherine A. Flanigan, e Mario Bergés. State-of-the-art review: The use of digital twins to support artificial intelligence-guided predictive maintenance. *arXiv preprint arXiv:2406.13117*, 2024.
- [77] Hitesh Manglani, George L. Hodge, e William Oxenham. Application of the internet of things in the textile industry. *Textile Progress*, 51:225–297, 2020.
- [78] Soujanya Mantravadi, Andreas Dyrøy Jansson, e Charles Møller. User-friendly mes interfaces: Recommendations for an ai-based chatbot assistance in industry 4.0 shop floors. Em *Asian Conference on Intelligent Information and Database Systems*, páginas 189–201. Springer, 2020.
- [79] W. McKinney. Pandas: Biblioteca para análise e manipulação de dados em python, 2010. PyData. Disponível em: <https://pandas.pydata.org/>. Acessado em 6 de fevereiro de 2025.
- [80] MeasuringU. Recent advances with the system usability scale. <https://measuringu.com/sus-advances/>, 2017. Accessed: 18 Dezembro 2024.
- [81] Dirk Merkel et al. Docker: lightweight linux containers for consistent development and deployment. *Linux j*, 239(2):2, 2014.
- [82] Inc Meta Platforms. React – a javascript library for building user interfaces, 2025. Acessado em 7 de fevereiro de 2025.
- [83] B. Metcalfe, H. C. Boshuizen, J. Bulens, e J. J. Koehorst. Digital twin maturity levels: a theoretical framework for defining capabilities and goals in the life and environmental sciences. *F1000Research*, 12:961, 2023.
- [84] S. Mihai, W. Davis, D. V. Hung, R. Trestian, M. Karamanoglu, e B. Barn. A digital twin framework for predictive maintenance in industry 4.0. Em *2024 International Conference on Smart Manufacturing Technologies*, páginas 1–8, 2024.
- [85] Tomas Mikolov, Kai Chen, Greg Corrado, e Jeffrey Dean. Efficient estimation of word representations in vector space. Em *Proc. ICLR*, 2013.
- [86] J. Miller. pdfplumber: Biblioteca para extração de texto estruturado de documentos pdf, 2020. MIT License. Disponível em: <https://github.com/jsvine/pdfplumber>. Acessado em 6 de fevereiro de 2025.
- [87] nbspSenthil Kumaran, Kumaran N, Rangaraj, Rangaraj, Siva Sharan S, Siva Sharan S, R. Dhanalakshmi, e Dhanalakshmi R. Intelligent personal assistant - implementing voice commands enabling speech recognition. *2020 International Conference on System, Computation, Automation and Networking (ICSCAN)*, 2020.
- [88] Neo4j. Neo4j - the world's leading graph database. <https://neo4j.com/>, 2025. Acedido em abril de 2025.

- [89] Neo4j. What is a graph database. <https://neo4j.com/docs/getting-started/graph-database/>, 2025. Acessado em: 7 de março de 2025.
- [90] Ngrok, Inc. Ngrok — secure introspectable tunnels to localhost. <https://ngrok.com>, 2025. Acesso em 21 Jun. 2025.
- [91] P. Nunes, J. Santos, e E. Rocha. Challenges in predictive maintenance – a review. *CIRP Journal of Manufacturing Science and Technology*, 40:53–67, 2023.
- [92] University of Illinois Chicago. Ai (artificial intelligence): What is the definition of ai and how does ai work? <https://meng.uic.edu/news-stories/ai-artificial-intelligence-what-is-the-definition-of-ai-and-how-does-ai-work> 2025. Accessed: 22 January 2025.
- [93] OpenAI. Openai api: Modelos de linguagem avançados para análise de texto, 2024. OpenAI Documentation. Disponível em: <https://platform.openai.com/docs/api-reference>. Acessado em 6 de fevereiro de 2025.
- [94] Oracle. <https://www.mysql.com/>, 2025. Acessado em: 7 de março de 2025.
- [95] Modbus Organization. Modbus application protocol specification V1.1b3. https://modbus.org/docs/Modbus_Application_Protocol_V1_1b3.pdf, 2012. Acesso em 21 Jun. 2025.
- [96] Matthew J Page, Joanne E McKenzie, Patrick M Bossuyt, Isabelle Boutron, Tammy C Hoffmann, Cynthia D Mulrow, Larissa Shamseer, Jennifer M Tetzlaff, Elie A Akl, Sue E Brennan, Roger Chou, Julie Glanville, Jeremy M Grimshaw, Asbjørn Hróbjartsson, Manoj M Lalu, Tianjing Li, Elizabeth W Loder, Evan Mayo-Wilson, Steve McDonald, Luke A McGuinness, Lesley A Stewart, James Thomas, Andrea C Tricco, Vivian A Welch, Penny Whiting, e David Moher. The prisma 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*, 372, 2021.
- [97] Pallets Projects. Flask - python web framework. <https://flask.palletsprojects.com/>, 2025. Acedido em abril de 2025.
- [98] Dmitry Pavlov, Igor Sosnovsky, Vyacheslav Dimitrov, Vasilii Melentyev, e Dmitry Korzun. Case study of using virtual and augmented reality in industrial system monitoring. Em *2020 26th Conference of Open Innovations Association (FRUCT)*, páginas 367–375. IEEE, 2020.
- [99] Rodrigo Pereira, Claudio Cleverson de Lima, Tiago Pinto, e Arsénio Reis. Virtual assistants in industry 4.0: A systematic literature review. *Electronics*, 2023.
- [100] Felipe Pezoa, Juan L Reutter, Fernando Suarez, Martín Ugarte, e Domagoj Vrgoč. Foundations of json schema. Em *Proceedings of the 25th International Conference on World Wide Web*, páginas 263–273. International World Wide Web Conferences Steering Committee, 2016.
- [101] Pallets Projects. Flask documentation, 2025. Disponível em: <https://flask.palletsprojects.com/en/stable/patterns/sqlalchemy/>. Acessado em 7 de fevereiro de 2025.
- [102] Python Software Foundation . Project description. <https://pypi.org/project/transitions/>. Accessed: 18 June 2025.

- [103] Silvio Quincozes, Tubino Emilio, e Juliano Kazienko. Mqtt protocol: Fundamentals, tools and future directions. *IEEE Latin America Transactions*, 17(09):1439–1448, 2019.
- [104] Afiqah R. Radzi, Nur F. Azmi, Syahrul N. Kamaruzzaman, e Rahimi A. Rahman. Relationship between digital twin and building information modeling: A systematic review and future directions. *Construction Innovation: Information, Process, Management*, 24(2):—, 2023.
- [105] Michael Rath, Aymen Gannouni, Daniel Luetticke, e Thomas Gries. Digitizing a distributed textile production process using industrial internet of things: A use-case. Em *2021 IEEE International Conference on Industrial Cyber-Physical Systems (ICPS)*, páginas 315–321, 2021.
- [106] Mohsin Raza, Priyan Malarvizhi Kumar, Dang Viet Hung, William Davis, Huan Nguyen, e Ramona Trestian. A digital twin framework for industry 4.0 enabling next-gen manufacturing. Em *2020 9th International Conference on Industrial Technology and Management (ICITM)*, páginas 73–77, 2020.
- [107] T. Rijdsdijk. gtts: Conversão de texto para fala utilizando a api do google, 2019. gTTS Documentation. Disponível em: <https://gtts.readthedocs.io/en/latest/>. Acessado em 6 de fevereiro de 2025.
- [108] J. Robert. Pydub: Manipulação simples de áudio com python, 2019. Pydub Documentation. Disponível em: <https://github.com/jiaaro/pydub>. Acessado em 24 de fevereiro de 2025.
- [109] Roland Rosen, Georg von Wichert, George Lo, e Kurt D. Bettenhausen. About the importance of autonomy and digital twins for the future of manufacturing. *IFAC-PapersOnLine*, 48:567–572, 2015.
- [110] Rosaria Rossini, Davide Conzon, Gianluca Prato, Claudio Pastrone, João Reis, e Gil Gonçalves. Replica: A solution for next generation iot and digital twin based fault diagnosis and predictive maintenance. *IoT and Pervasive Technology Area*, páginas 55–58, 2020.
- [111] Stuart Russell e Peter Norvig. *Artificial Intelligence: A Modern Approach*. Pearson, 4th edição, 2020. Accessed: 22 January 2025.
- [112] Gerard Salton e Christopher Buckley. Term-weighting approaches in automatic text retrieval. *Information Processing & Management*, 24(5):513–523, 1988.
- [113] Gerasimos G. Samatas, Seraphim S. Moumgiakmas, e George A. Papakostas. Predictive maintenance - bridging artificial intelligence and iot. Em *2021 IEEE World AI IoT Congress (AIIoT)*, páginas 0413–0419, 2021.
- [114] Teodora Sanislav, George Dan Mois, e Silviu Folea. Digital twins in the internet of things context. *29th Telecommunications Forum TELFOR 2021*, páginas 1–8, 2021.
- [115] A. Raja Santhi e P. Muthuswamy. Industry 5.0 or industry 4.0s? introduction to industry 4.0 and a peek into the prospective industry 5.0 technologies. *International Journal on Interactive Design and Manufacturing*, 17:947–979, 2023.
- [116] SARIMAX. Sarimax and arima forecasters. https://skforecast.org/0.9.1/user_guides/forecasting-sarimax-arima/. Accessed: 26 de fevereiro de 2025.

- [117] Iqbal H. Sarker. Machine learning: Algorithms, real-world applications and research directions. *Preprints*, 2021. Accessed: 22 January 2025.
- [118] Jürgen Schmidhuber. Deep learning in neural networks: An overview. *Neural networks*, 61:85–117, 2015.
- [119] scikit learn. scikit-learn developers. https://scikit-learn.org/stable/modules/linear_model.html, 2025. Accessed: 7 de março de 2025.
- [120] Skipper Seabold e Josef Perktold. statsmodels: Econometric and statistical modeling with python. Em *9th Python in Science Conference*, 2010.
- [121] Mustafa Siddiqui, Gayan Kahandawa, e H.S Hewawasam. Artificial intelligence enabled digital twin for predictive maintenance in industrial automation system: A novel framework and case study. *2023 IEEE International Conference on Mechatronics (ICM)*, páginas 1–10, 2023.
- [122] Siemens AG. *SIMATIC S7-1200: System Manual*, 2023. Acesso em 21 Jun. 2025.
- [123] Ajit Singh. Foundations of machine learning. *SSRN Electronic Journal*, 2020. Accessed: 22 January 2025.
- [124] SQLAlchemy. Contextual/thread-local sessions, 2025. Disponível em: <https://docs.sqlalchemy.org/en/20/orm/contextual.html>. Acessado em 7 de fevereiro de 2025.
- [125] SQLAlchemy. Ssqlalchemy documentation, 2025. Disponível em: <https://docs.sqlalchemy.org/en/13/index.html>. Acessado em 7 de fevereiro de 2025.
- [126] Narayanan Sundaram. React.js virtual dom: An in-depth exploration, 2025. Disponível em: <https://medium.com/@narayanansundar02/react-js-virtual-dom-an-in-depth-exploration-9f0e9caec7cf>. Acessado em 27 de abril de 2025.
- [127] Fei Tao, He Zhang, Ang Liu, e A. Y. C. Nee. Digital twin in industry: State-of-the-art. *IEEE Transactions on Industrial Informatics*, 15(4):2405–2415, 2019.
- [128] Nehal Tarek, Nancy A. El-Hefnawy, Amira Abdelatey, e Hatem Abdel-Kader. A flexible digital twin framework for poultry feed industrial factory. *Proceedings of the 2022 International Conference on Computer Theory and Applications (ICCTA)*, páginas 253–256, 2022.
- [129] TensorFlow. Introduction to tensorflow for deep learning. <https://www.tensorflow.org/>, 2025. Accessed: 7 de março de 2025.
- [130] Erik F. Tjong Kim Sang e Fien De Meulder. Introduction to the conll-2003 shared task: Language-independent named entity recognition. Em *Proc. CoNLL-2003*, páginas 142–147, 2003.
- [131] Amy J.C. Trappey, Charles V. Trappey, Min-Hua Chao, e Chun-Ting Wu. Vr-enabled engineering consultation chatbot for integrated and intelligent manufacturing services. *Journal of Industrial Information Integration*, 26:100331, 2022.
- [132] R. van Dinter, B. Tekinerdogan, e C. Catal. Reference architecture for digital twin–based predictive maintenance systems. *Computers & Industrial Engineering*, 177:109099, 2023.

- [133] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez, Łukasz Kaiser, e Illia Polosukhin. Attention is all you need. *Advances in neural information processing systems*, 30, 2017.
- [134] Jason Wei, Yi Tay, Rishi Bommasani, Colin Raffel, Barret Zoph, Sebastian Borgeaud, Dani Yogatama, Maarten Bosma, Denny Zhou, Donald Metzler, et al. Emergent abilities of large language models. *arXiv preprint arXiv:2206.07682*, 2022.
- [135] Cort J Willmott e Kenji Matsuura. Advantages of the mean absolute error (mae) over the root mean square error (rmse) in assessing average model performance. *Climate research*, 30(1):79–82, 2005.
- [136] A. Zhang. Speechrecognition: Biblioteca para reconhecimento de fala em python, 2017. Speech Recognition (Version 3.11) [Software]. Disponível em: <https://pypi.org/project/SpeechRecognition/>. Acessado em 6 de fevereiro de 2025.
- [137] Wayne Xin Zhao, Kun Zhou, Junyi Li, Tianyi Tang, Xiaolei Wang, Yupeng Hou, Yingqian Min, Beichen Zhang, Junjie Zhang, Zican Dong, et al. A survey of large language models. *arXiv e-prints*, páginas arXiv–2303, 2023.
- [138] Zeki Murat Çınar, Abubakar Abdussalam Nuhu, Qasim Zeeshan, Orhan Korhan, Mohammed Asmael, e Babak Safaei. Machine learning in predictive maintenance towards sustainable smart manufacturing in industry 4.0. *Sustainability*, 12:8211, 2020.

Anexo A

Trabalho Publicado

Revolutionizing Industrial Maintenance: Virtual and Augmented Reality Meets Digital Twin

João Miranda

Instituto Politécnico de Viana do Castelo
Viana do Castelo, Portugal
joao.miranda@ipvc.pt

Luís Romero

Instituto Politécnico de Viana do Castelo
Viana do Castelo, Portugal
romero@estg.ipvc.pt

André Costa

Instituto Politécnico de Viana do Castelo
Viana do Castelo, Portugal
afilipecosta@ipvc.pt

Pedro Miguel Faria

Instituto Politécnico de Viana do Castelo
Viana do Castelo, Portugal
pfaria@estg.ipvc.pt

Abstract — The optimization of processes, cost reduction, and increased efficiency stand as primary objectives within the textile industry. With the advancement of technologies, the digital twin concept – a digital representation model of the processes and physical objects within the manufacturing environment – has been extensively employed. This article aims to examine and investigate how it is possible to integrate the use of augmented and virtual reality technologies with a digital twin model, in order to enhance equipment maintenance within this industry. In addition to a review of the current state of the art in this field, several articles related to the topic were studied, complemented by the results of a small-scale experiment. These findings indicate that the utilization of these technologies is indeed advantageous in supporting equipment maintenance and managing the flow of data generated by real physical objects and processes.

Keywords - Digital Twin, Augmented Reality, Virtual Reality, Textile Industry.

I. INTRODUCTION

Nowadays, due to the significant development and advancement of technologies, there is a strong initiative for industry updates, particularly in the realm of information technologies. These innovations play a crucial role in transforming the industry, driving efficiency, and fostering innovation. The new technologies optimize processes, reduce costs, and facilitate logistics. The intelligent adoption of these innovations is essential to boost competitiveness. With the goal of monitoring, analyzing, understanding, and predicting the performance/results achieved by a manufacturing system, the digital twin concept emerges. This concept represents a dynamic model allowing the digital representation of an entire manufacturing system. However, at times, managing the vast amount of data generated by the model can be challenging for a significant number of users. Thus, virtual and augmented reality come into play, aiming to be the link between both technologies, providing a more intuitive experience for the user, according to [1]. Indeed, the use of these technologies has increasingly become a significant ally in this sector. According to opinions in [2], augmented and virtual reality together play crucial roles in enhancing user experiences and efficiency in the ever-evolving landscape of digitized industries. The purpose of this article is to

examine the useful uses of augmented and virtual reality technologies, particularly as they relate to equipment maintenance in an actual manufacturing environment. These devices are a component of a larger system that a digital twin model represents digitally. In order to accomplish this, a selection of IEEE approved publications will be made first, and then a cutting-edge analysis of the key themes and ideas covered will be conducted. Finally, this article will conclude with a small-scale experiment aimed at evaluating the effectiveness of an augmented reality application for digital twin model equipment maintenance. The goal of this, is to not only highlight the potential of these technologies but also to offer insightful information about how they actually affect industrial operations and maintenance procedures in the real world.

II. SYSTEMATIC REVIEW

To obtain a list of related works, a systematic review was conducted. Initially, the review included all papers published on IEEE within the last 5 years, emphasizing the keywords "Digital Twin," "Augmented Reality," and "Virtual Reality" as the central theme. However, this resulted in an enormous quantity of papers. To narrow down the results it was decided to include only the ones published in the last five years and with the keyword "Manufacturing", resulting in 31 different papers. In the end, this systematic review was used to select 14 papers as an initial research base (Figure 1). Additionally, brief summaries were provided for some of these papers.

In [3] is emphasized that, digital twin technology not only lowers sustainment costs and enhances product improvement but also provides vendors with early insights into system design. By facilitating real-time collaboration between vendors and end users, it reduces the need for costly in-person events, fostering continuous feedback loops in system design. Integrating high-fidelity digital twins into immersive training applications allows realistic training before system deployment, potentially saving costs on New Equipment Training (NET) and live fire events. While virtual reality can't fully replace real-time interaction, immersive experiences with digital systems models offer substantial benefits in terms of cost

Figura A.1: Artigo publicado na conferência CISTI 2024.



sensors



Article

Smart Maintenance Solutions: AR- and VR-Enhanced Digital Twin Powered by FIWARE

André Costa ¹, João Miranda ¹, Duarte Dias ¹, Nuno Dinis ², Luís Romero ¹  and Pedro Miguel Faria ^{1,*}

¹ IPVC—Instituto Politécnico de Viana do Castelo, 4900-347 Viana do Castelo, Portugal; afilipecosta@ipvc.pt (A.C.); joao.miranda@ipvc.pt (J.M.); duartedias@ipvc.pt (D.D.); romero@estg.ipvc.pt (L.R.)

² RIOPELE, 4770-405 Vila Nova de Famalicão, Portugal; nuno.dinis@riopele.pt

* Correspondence: pfaria@estg.ipvc.pt

Abstract: In the modern era of industrial digitalization, the convergence of the Internet of Things (IoT), advanced data analysis, augmented reality (AR) and virtual reality (VR) is significantly transforming various industrial sectors. This research aimed to study and develop a proposal for an integrated system that combines IoT, data analysis, AR and VR for the monitoring and maintenance of industrial equipment. The importance of this research lies in its potential to contribute to the implementation of predictive maintenance solutions, which can significantly reduce machine downtime in an industrial environment and thus reduce or prevent operational failures. The central research question of this work was the following: how can the integration of IoT, data analysis and augmented and virtual reality contribute to optimizing industrial maintenance? We tested the combination of technologies to enable the creation of an effective predictive maintenance system, capable of alerting operators to anomalous conditions and providing detailed visual instructions for maintenance tasks. As a result, a prototype system was developed and tested, and it has shown the potential to evolve into a real system in an industrial environment.

Keywords: internet of things; data analysis; augmented reality; virtual reality; predictive maintenance; industrial digitization; system integration; operational efficiency



Received: 15 December 2024
Revised: 9 January 2025
Accepted: 27 January 2025
Published: 30 January 2025

Citation: Costa, A.; Miranda, J.; Dias, D.; Dinis, N.; Romero, L.; Faria, P.M. Smart Maintenance Solutions: AR- and VR-Enhanced Digital Twin Powered by FIWARE. *Sensors* **2025**, *25*, 845. <https://doi.org/10.3390/s25030845>

Copyright: © 2025 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

In the modern era of industrial digitalization, technologies such as the Internet of Things (IoT), FIWARE, visualization platforms like Grafana, advanced databases, APIs, artificial intelligence (AI), augmented reality (AR) and virtual reality (VR) are profoundly transforming various industrial sectors. These technologies have been extensively studied for their ability to optimize industrial processes and reduce operational costs, driving the progress of Industry 4.0. Recent studies emphasize the relevance of these approaches. For instance, Ref. [1] explored a framework based on a digital twin for predictive maintenance in industrial environments, highlighting the integration between physical systems and their digital twins to enhance the maintenance efficiency and improve the failure prediction accuracy.

Digital twins (DTs) have emerged as a key solution in Industry 4.0, offering real-time simulations and performance predictions for physical systems. Ref. [2] discusses how DTs can integrate operational, environmental and sensor data to build robust predictive models, minimizing unplanned equipment and machinery downtime, thereby boosting business competitiveness. Technologies associated with the Internet of Things (IoT) and machine learning provide unique opportunities for the real-time monitoring and efficient

Assistente Intelligent Virtual Assistant for Industry 5.0

André Costa¹, Luis Romero¹, Pedro Miguel Faria^{1*}

^{1*}Instituto Politécnico de Viana do Castelo, Viana do Castelo, Portugal.

*Corresponding author(s). E-mail(s): pfaria@estg.ipv.pt;
Contributing authors: afilipecosta@ipvc.pt; romero@estg.ipv.pt;

Abstract

This article describes the development of an Intelligent Virtual Assistant (IVA) designed specifically to support maintenance and operation in factories aligned with the Industry 5.0 paradigm. The IVA integrates advanced Natural Language Processing and Machine Learning technologies to provide effective technical assistance and proactive prediction of operational failures. The paper presents the modular architecture of the system in detail, addressing the development of the backend, the intuitive graphical interface, and the voice recognition and synthesis features adapted to industrial environments. The experimental results demonstrate that AVI is capable of significantly improving operational efficiency by reducing diagnostic time and anticipating critical problems. Finally, the challenges identified during implementation are discussed, and solutions are proposed for robust integration in real industrial contexts, promoting more efficient and collaborative interaction between human operators and technological systems.

Keywords: Virtual Assistant, Industry 5.0, Predictive Maintenance, Artificial Intelligence, NLP, Machine Learning

1 Introduction

The recent transition to Industry 5.0 has brought about a new vision of industrial operations, emphasizing collaboration between humans and machines and promoting the sustainability and resilience of production processes. Nahavandi [1] highlights that Industry 5.0 is a human-centered paradigm, where close cooperation between operators and intelligent machines results in greater operational efficiency, leveraging human creativity and cognitive potential in conjunction with automated systems. In

Article

Coffee_Twin: An Interactive Digital Twin featuring Augmented Reality (AR), Virtual Reality (VR) and Voice Interaction

André Costa, João Miranda, João Mirra and Pedro Miguel Faria

* Correspondence: pfaria@estg.ipv.pt

Abstract: The increasing digitalization of industrial environments has led to the emergence of new paradigms such as Digital Twins (DT), which enable the real-time connection between physical assets and their virtual counterparts. In this context, the Coffee_Twin project was developed to explore and validate the integration of DT technology with Augmented Reality (AR) and Virtual Reality (VR) in a controlled environment. A coffee machine was selected as the case study due to its manageable complexity and scalability potential. The system architecture was based on a Raspberry Pi as the central controller, combined with local data acquisition from temperature and humidity sensors, mechanical actuation via a servo motor, and remote control through a smart switch. Three applications were developed to interact with the Digital Twin: a Web application offering a voice-guided operation process and real-time data visualization, an AR application providing remote control and contextual information, and a VR application simulating the full operation of the machine in an immersive 3D environment. The Coffee_Twin project demonstrates the potential of combining Digital Twins with immersive technologies to enhance training, monitoring, and operation in smart manufacturing environments.

Keywords: Digital Twin; Industry 4.0; Augmented Reality; Virtual Reality; Internet of Things; Usability Evaluation; Human-Machine Interaction;

Figura A.4: Artigo submetido para avaliação ao *Journal of Applied Sciences - MDPI*
URL:<https://www.mdpi.com/journal/applsci>

Anexo B

Pseudocódigo do AVI

B-1 Modo Manutenção

```
1: Receber o comando «modo manutenção» e definir stage ← escolher_máquina
2: Obter lista de máquinas via API e apresentar numerada no chat
3: while stage = escolher_máquina do
4:   if utilizador insere número válido then
5:     Guardar maquina_id
6:     Mostrar opções {pdf, vídeo, voltar, sair}
7:     stage ← escolher_ação
8:   else if comando global {ajuda, sair, listar máquinas} then
9:     Tratar comando global (ver pontos C1–C3)
10:  else
11:    Pedir nova escolha (input inválido)
12:  end if
13: end while
14: if comando = pdf then
15:   Carregar ou ler do cache o manual técnico em PDF
16:   Pedir pergunta ao operador (ex. “Como limpar o EliTube?”)
17:   Enviar texto extraído + pergunta ao modelo LLM e devolver resposta estruturada
18:   Permanecer no sub-modo PDF até receber voltar
19: end if
20: if comando = vídeo then
21:   Pedir lista de subprocessos com tutoriais e numerar
22:   Se número válido: abrir URL em iframe
23:   Se voltar: regressar a stage ← escolher_ação
24: end if
```

C1. Ajuda — comando ajuda lista todos os comandos locais

C2. Sugestão — se erro ortográfico, propor comando semelhante

C3. Sair — comando sair limpa variáveis internas e volta ao menu principal

B-2 Modo Predição

```
1: Receber comando do utilizador e normalizar texto:
2: if comando = "sair" then
3:     Parar monitorização se ativa; regressar ao menu principal
4:     return
5: end if
6: if comando = "ajuda" then
7:     Mostrar lista de comandos disponíveis; aguardar novo comando
8: else if comando = "iniciar monitorizacao" then
9:     Criar duas threads: (i) recolha de dados; (ii) deteção de anomalias:
10:    Alterar estado interno para monitorando = True
11: else if comando = "parar monitorizacao" then
12:    Encerrar as threads e guardar CSV com históricos:
13: else if comando = "detetar anomalias" then
14:    Executar varredura única; devolver lista de desvios > 200 rpm, classificando gravidade
    (Baixa / Média / Alta):
15: else if comando = "prever velocidade" then
16:    Definir predicao_stage ← "aguardando_tempo"
17:    Solicitar intervalo (ex.: "10 minutos" ou "1 hora")
18: else if estado = "aguardando_tempo" then
19:    Extrair número e unidade; converter para minutos
20:    Calcular passos =  $\frac{\text{segundos}}{\text{intervalo}}$  da monitorização
21:    Treinar modelo SARIMAX e prever velocidade real para os próximos passos (lista
    arredondada a 2 decimais):
22:    Mostrar gráfico/tabela ao utilizador
23:    Restaurar estado predicao_stage ← None
24: else
25:    Responder "Não entendi, diz 'ajuda'..."
26: end if
```

B-3 Modo Informação

```
1: Receber comando em linguagem natural:
2: if comando = "sair" then
3:     Regressar ao menu principal; return
4: else if comando = "ajuda" then
5:     Exibir opções: ver máquinas, ver atributos, ...
6: else if comando = "ver máquinas" then
7:     Pedir lista via API e apresentar códigos SAP disponíveis:
8: else if comando = "ver atributos disponíveis" then
9:     Mostrar atributos consultáveis (velocidades, estado, cor, ...):
10: else
11:     (1) Interpretar pedido – extrair cod_sap e campo_desejado usando LLM; se falhar, aplicar
        regex de fallback
12:     if faltam dados then
13:         Solicitar elemento em falta ao utilizador
14:     else
15:         (2) Consultar base de dados: enviar GET à API /machine/<cod_sap>:
16:         if resposta da API contém campo_desejado then
17:             Gerar resposta natural com LLM, sem inventar valores:
18:         else
19:             Retornar: "Informação não encontrada."
20:         end if
21:     end if
22: end if
```

B-4 Classe Assistente Virtual

1: **Construtor** (`__init__`):

1. Guardar URLs, tokens e pastas de trabalho
2. Carregar manuais extraídos → dicionário contextos
3. Instanciar monitor de predição `MonitoramentoVelocidade`
4. Criar máquina de estados `transitions.Machine` (4 estados, 4 triggers)
5. Inicializar variáveis de apoio: `stage`, caches de vídeo, flags de confirmação, etc.

2: **Método** `processar_comando(cmd)`:

1. Normalizar texto e verificar se há confirmação pendente
2. Se `modo = padrao`: ir para `processar_modo_padrao`
3. Se `modo = manutencao`: ir para `modo_manutencao`
4. Se `modo = informacao`: ir para `modo_informacao`
5. Caso contrário: `modo_predicao`
6. Devolver `{response, current_mode}`

3: **Áudio**: `sintetizar_voz()` gera MP3 com gTTS; `reconhecer_audio()` converte WAV, usa Google STT.

4: **Sugestões / Confirmação**: `_trata_sugestao()` + `_trata_confirmacao()` guardam `lambda` e pedem “sim / não”.

5: **Modo Manutenção** — seleccionar máquina, PDF - vídeo, cache, sugestões, sair.

6: **Modo Informação** — interpretar `cod_SAP` + campo, pedir atributos, fallback Regex.

7: **Modo Predição** — iniciar/parar *threads* de recolha, detetar anomalias, prever velocidade (SARIMAX), gráfico/tabela.

8: Qualquer `sair` global - voltar a `padrao` e limpar estado

B-5 Backend Flask API

- 1: Configurar SQLAlchemy com a DB_URI
 - 2: Declarar modelos User e Message; executar `db.create_all()`
 - 3: Criar dicionário global instancias para guardar assistentes
 - 4: **Função obter_assistente(username):**
 - Se username não está em instancias → criar nova AssistenteVirtual e guardar
 - Devolver a instância correspondente
 - 5: **GET /validate_user** → verifica se existe utilizador e devolve isValid
 - 6: **POST /chat:**
 1. Cria utilizador se necessário
 2. Envia message para `assistente.processar_comando()`
 3. Persiste {utilizador, mensagem} e {bot, resposta} na BD
 4. Devolve JSON com texto ou payload específico (gráfico, áudio, ...)
 - 7: **GET /history** → devolve histórico ordenado por timestamp
 - 8: **POST /clear_history** → apaga todas as mensagens do utilizador
 - 9: **POST /recognize** → bytes áudio -> texto (Speech-to-Text)
 - 10: **POST /sintetizar** → texto -> MP3 (Text-to-Speech)
 - 11: Todos os end-points respeitam origens definidas no CORS; o token de autenticação é reenviado para o AssistenteVirtual.
-