

**Sérgio Duarte Lopes de Brito**

**SISTEMA DE HARDWARE PARA MONITORIZAÇÃO  
NÃO INTRUSIVA DE MOTORES ELÉTRICOS**



**UNIVERSIDADE DO ALGARVE**  
Instituto Superior de Engenharia  
2023



**Sérgio Duarte Lopes de Brito**

**SISTEMA DE HARDWARE PARA MONITORIZAÇÃO  
NÃO INTRUSIVA DE MOTORES ELÉTRICOS**

**Mestrado em Engenharia Elétrica e Eletrónica  
(Especialidade em Tecnologias de Informação e  
Telecomunicações)**

**Trabalho realizado sob a orientação de:  
Jorge Filipe Leal Costa Semião**



**UNIVERSIDADE DO ALGARVE**  
Instituto Superior de Engenharia  
2023



# **SISTEMA DE HARDWARE PARA MONITORIZAÇÃO NÃO INTRUSIVA DE MOTORES ELÉTRICOS**

## *Declaração de autoria da obra*

Declaro ser o autor desta obra, que é original e inédita. Os autores e obras consultados são devidamente citados no texto e constam da listagem de referências incluídas.

---

(Nome Completo do Autor)

©2023, Sérgio Duarte Lopes de Brito

A Universidade do Algarve reserva para si o direito, em conformidade com o disposto no Código do Direito de Autor e dos Direitos Conexos, de arquivar, reproduzir e publicar a obra, independentemente do meio utilizado, bem como de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição para fins meramente educacionais ou de investigação e não comerciais, conquanto seja dado o devido crédito ao autor e editor respetivos.



*À minha avó, cuja memória e amor me  
inspiram a nunca abandonar a curiosidade*



## AGRADECIMENTOS

Em primeiro lugar, gostaria de expressar minha mais profunda gratidão ao meu orientador, o Professor Jorge Semião. Além de ser um orientador acadêmico excepcional, o Professor Semião tem sido uma figura de apoio inestimável em diversos aspetos da minha vida universitária, indo muito além de suas obrigações e responsabilidades.

Em seguida, gostaria de agradecer aos meus pais, que me apoiaram incondicionalmente durante toda a minha jornada académica. O seu amor e encorajamento foram fundamentais para o meu desenvolvimento pessoal e profissional.

Deixo uma palavra especial de agradecimento à minha companheira, Luciana Santos, que foi a principal motivação para o meu retorno aos estudos. Juntos, compartilhámos a experiência única e desafiadora de voltar à vida académica e o seu apoio tem sido inestimável.

Estendo os meus agradecimentos aos Engenheiros Nuno Vivas e Eduardo Martins da Hubel, cujo apoio e disponibilidade foram cruciais para a integração deste projeto nos sistemas da empresa.

Um agradecimento especial também ao Aparthotel Oceanus e à Águas de Portugal, por permitirem e apoiarem os testes práticos realizados durante o desenvolvimento deste projeto.

Por último, mas definitivamente não menos importante, gostaria de dedicar este projeto à minha avó, que infelizmente faleceu durante o curso deste trabalho. Ela sempre ficou feliz em me ver voltar aos estudos e adorava ouvir-me falar sobre temas que talvez não compreendesse, mas que lhe eram caros, simplesmente porque eu os compartilhava com ela.



# RESUMO

Este projeto aborda a manutenção preditiva em contextos industriais, com foco em sistemas de refrigeração e de bombagem. Utilizando uma arquitetura de Internet das Coisas (IoT), o sistema combina hardware personalizado e algoritmos de aprendizagem de máquina para monitorizar o desempenho de equipamentos e detetar anomalias. A inovação do projeto reside na sua facilidade de instalação e natureza não intrusiva, permitindo uma integração eficaz com infraestruturas existentes. O hardware foi testado tanto em ambientes laboratoriais quanto em contextos industriais reais, como estações de tratamento de água e sistemas de ar condicionado em hotéis.

Durante os testes em campo, surgiram desafios na medição de parâmetros como as temperaturas e o consumo energético, embora estes tenham sido bem-sucedidos em ambientes laboratoriais. A falta de conectividade à internet em alguns ambientes industriais foi contornada através de soluções de armazenamento e processamento local de dados, assegurando a continuidade da monitorização, mesmo em condições adversas.

Um ponto forte do sistema é o seu custo económico, oferecendo uma alternativa acessível em comparação a outras soluções mais caras ou específicas a determinadas marcas de equipamentos no mercado. Isso não só aumenta a sua aplicabilidade em diferentes contextos industriais, como também demonstra a sua viabilidade como uma solução de monitorização eficiente e económica.

Este trabalho tem implicações significativas tanto a nível académico como industrial, servindo como um modelo multidisciplinar para a implementação de sistemas IoT inteligentes em cenários industriais. Destaca áreas para melhoria e desenvolvimentos futuros, como a otimização do hardware e a integração com outros sistemas de gestão, solidificando o seu papel como um sistema inovador na manutenção preditiva.

**Palavras-chave:** Manutenção Preditiva, Internet das Coisas, Aprendizagem de Máquina, Monitorização Industrial, Sensores, Anomalias.



## ABSTRACT

This project addresses predictive maintenance in industrial contexts, focusing on refrigeration and pumping systems. Utilizing an Internet of Things (IoT) architecture, the system combines custom hardware and machine learning algorithms to monitor equipment performance and detect anomalies. The project's innovation lies in its ease of installation and non-intrusive nature, allowing for effective integration with existing infrastructures. The hardware was tested in both laboratory environments and real industrial settings, such as water treatment stations and hotel air conditioning systems.

During field tests, challenges arose in measuring parameters such as temperature and energy consumption, although these were successfully measured in laboratory environments. The lack of internet connectivity in some industrial environments was overcome through local data storage and processing solutions, ensuring continued monitoring even in adverse conditions.

A strong point of the system is its low economic cost, offering an affordable alternative compared to more expensive solutions or those specific to certain equipment brands on the market. This not only increases its applicability in different industrial contexts but also demonstrates its viability as an efficient and economical monitoring solution.

This work has significant implications both academically and industrially, serving as a multidisciplinary model for the implementation of intelligent IoT systems in industrial scenarios. It highlights areas for improvement and future developments, such as hardware optimization and integration with other management systems, solidifying its role as an innovative system in predictive maintenance.

**Keywords:** Predictive Maintenance, Internet of Things, Machine Learning, Industrial Monitoring, Sensors, Anomalies.



# ÍNDICE

1	Introdução .....	1
1.1	Objetivos e Características do Projeto .....	2
1.2	Contexto do Trabalho .....	2
1.3	Organização da dissertação.....	3
2	Estudos Preliminares e Estado da Arte .....	5
2.1	Manutenção Industrial de Equipamentos.....	6
2.1.1	Manutenção Reativa .....	6
2.1.2	Manutenção Planeada .....	6
2.1.3	Manutenção Proativa .....	7
2.1.4	Manutenção Preditiva .....	7
2.2	Monitorização de Motores Elétricos e Análise Vibracional.....	8
2.2.1	Transformada Rápida de Fourier .....	9
2.2.2	Deteção de Anomalias pela Análise Espectral .....	10
2.3	Estratégias da Indústria 4.0.....	16
2.3.1	Algoritmos de Aprendizagem de Máquina em Manutenção Industrial.....	17
2.3.2	Internet das Coisas .....	18
2.3.3	Gestão dos Equipamentos.....	18
2.4	Estudos Semelhantes ou Relacionados .....	20
2.4.1	Machine Fault Detection Using a Hybrid CNN-LSTM Attention-Based Model.....	20
2.4.2	Establishing a Real-Time Multi-Step Ahead Forecasting Model of Unbalance Fault in a Rotor-Bearing System .....	21
2.4.3	Early Fault Classification in Rotating Machinery with Limited Data Using TabPFN.....	21
2.5	Soluções Existentes de Manutenção Preditiva com Análise Vibracional .....	22
2.5.1	Industrial IoT Wireless Predictive Maintenance Sensor V3.....	22
2.5.2	Leap Sensors Motor Monitor.....	24
2.5.3	ABB Ability Smart Sensor .....	25
3	Hardware.....	27

3.1	Componentes Ativos .....	28
3.1.1	Plataforma Principal e Conectividade .....	28
3.1.2	Sistema de Captura de Vibrações .....	30
3.1.3	Temperatura .....	35
3.1.4	Corrente .....	38
3.1.5	Armazenamento .....	40
3.1.6	Relógio .....	41
3.1.7	Ecrã OLED .....	42
3.2	Componentes Passivos, Alimentação e Interface Humana .....	43
3.2.1	Resistências .....	43
3.2.2	Condensadores .....	44
3.2.3	Díodos .....	44
3.2.4	Reguladores de Tensão .....	45
3.2.5	MOSFET .....	46
3.2.6	Interface Humana e Controle do Sistema de Sensores .....	47
3.2.7	Terminais .....	48
3.2.8	Bateria .....	49
3.3	Esquemas do Circuito .....	50
3.3.1	Circuito 5 V .....	51
3.3.2	Circuito 3.3 V .....	52
3.3.3	Circuito de Amplificação .....	52
3.3.4	PIC32 e FRAM .....	53
3.3.5	ESP32, Sensores, Armazenamento e RTC .....	55
3.4	Protótipos e Design do PCB .....	58
3.4.1	Protótipo em Breadboard .....	58
3.4.2	Protótipo em Through Hole Board 1.0 .....	59
3.4.3	Protótipo em Through Hole Board 1.1 .....	60
3.4.4	Desenvolvimento do PCB .....	61
3.5	Servidor IoT Local .....	66
4	Software .....	67
4.1	PIC32 .....	68
4.2	ESP32 .....	69
4.3	Servidor FTP .....	70

4.4	API.....	72
4.5	Machine Learning.....	74
4.5.1	Modelos Utilizados e Suas Características.....	74
4.5.2	Métrica de Certeza de Detecção de Anomalia.....	75
4.5.3	Métricas de Avaliação.....	76
5	Testes e Aplicações do Sistema.....	77
5.1	Operação do Sistema.....	78
5.2	Testes em Laboratório.....	79
5.2.1	Bomba de ÁGUA.....	80
5.2.2	Ar Condicionado.....	81
5.3	Oceanus Aparthotel.....	83
5.4	Estação de Tratamento de Águas de Tavira.....	84
5.5	Grupo Hubel.....	86
6	Resultados Experimentais.....	87
6.1	Laboratório.....	87
6.1.1	Bomba de ÁGUA.....	87
6.1.2	Ar Condicionado.....	96
6.2	Estação de Tratamento de Águas.....	104
6.3	Aparthotel Oceanus.....	106
6.4	Hubel.....	108
6.5	Comparação com Trabalhos Prévios e Produtos Existentes.....	109
7	Conclusões e Trabalhos Futuros.....	111
7.1	Resumo dos Resultados.....	112
7.1.1	Laboratório da Universidade do Algarve.....	112
7.1.2	Sistema de Ar Condicionado em Laboratório.....	112
7.1.3	Estação de Tratamento de Água (ETA) de Tavira.....	112
7.1.4	Aparthotel Oceanus em Albufeira.....	113
7.1.5	Sistema de Rega da Hubel em Olhão.....	113
7.2	Problemas Encontrados.....	113
7.3	Melhorias e Possíveis Alterações.....	116
7.4	Estudos Futuros.....	117
7.5	Comentário Final e Conclusão.....	118

Referências.....	121
Apêndices.....	129
A Esquema Completo do Circuito.....	131

## LISTA DE FIGURAS

Figura 1 Exemplo do resultado de uma FFT .....	10
Figura 2 Espectro Desequilíbrio do Rotor .....	11
Figura 3 Espectro Eixo Empenado .....	11
Figura 4 Espectro Desalinhamento Angular .....	12
Figura 5 Espectro Desalinhamento Paralelo .....	12
Figura 6 Espectro Folgas Mecânicas 1 .....	12
Figura 7 Espectro Folgas Mecânicas 2 .....	13
Figura 8 Espectro Folgas Mecânicas 3 .....	13
Figura 9 Espectro Desgaste de Engrenagens .....	14
Figura 10 Espectro Desalinhamento de Engrenagens .....	14
Figura 11 Espectro Turbulência de Fluxo .....	15
Figura 12 Espectro Impulsão .....	15
Figura 13 Predictive Maintenance Sensor V3 .....	23
Figura 14 Leap Sensor Motor Monitor .....	24
Figura 15 ABB Ability Smart Sensor .....	25
Figura 16 WEMOS D1 Mini ESP32 Pinout .....	29
Figura 17 Piezo Tipo Arame .....	32
Figura 18 Piezo Tipo Botão .....	32
Figura 19 LM358P .....	33
Figura 20 LM358P Pinout .....	33
Figura 21 PIC32MX170F256B .....	34
Figura 22 PICKIT 4 .....	34
Figura 23 PIC32 Pinout .....	34
Figura 24 FM25V20A .....	35
Figura 25 FM25V20A Pinout .....	35
Figura 26 Termopar Tipo K .....	37
Figura 27 Termopar Tipo K Esquema .....	37
Figura 28 MAX31855 .....	38
Figura 29 HSTS016L .....	39
Figura 30 MicroSD Adapter .....	40
Figura 31 MicroSD Adapter Pinout .....	40

---

Figura 32 DS3231 RTC .....	41
Figura 33 DS3231 Esquema .....	41
Figura 34 SSD1306 Front .....	42
Figura 35 SSD1306 Pinout .....	42
Figura 36 Resistências .....	43
Figura 37 Condensadores .....	44
Figura 38 Díodo .....	44
Figura 39 L7805CV .....	45
Figura 40 L7805CV Pinout.....	45
Figura 41 MIC29150-3.3WT .....	45
Figura 42 MIC29150-3.3WT Pinout.....	45
Figura 43 IRF9540NPBF .....	47
Figura 44 IRF9540NPBF Schema .....	47
Figura 45 ON-OFF-ON Interruptor Deslizante .....	47
Figura 46 Esquema Interruptor Deslizante .....	47
Figura 47 Push Button.....	48
Figura 48 Button Cap.....	48
Figura 49 Push Button Squema.....	48
Figura 50 1M $\Omega$ Potenciômetro .....	48
Figura 51 2 Pin Terminal .....	49
Figura 52 4 Pin Terminal .....	49
Figura 53 5.5 DC-IN Terminal .....	49
Figura 54 DC-IN Esquema .....	49
Figura 55 Suporte de Células .....	50
Figura 56 18650 Célula de Lítio .....	50
Figura 57 Circuito de Alimentação .....	51
Figura 58 Circuito Regulador 3.3 V.....	52
Figura 59 Circuito do Amplificador.....	53
Figura 60 Circuito PIC32 e FRAM.....	54
Figura 61 Circuito de Sensores e Controlo .....	55
Figura 62 Protótipo Breadboard.....	58
Figura 63 Protótipo 1.0 Superior.....	59
Figura 64 Protótipo 1.0 Inferior .....	59
Figura 65 Protótipo 1.1 Frente .....	60
Figura 66 Protótipo 1.1 Trás .....	60

Figura 67 Protótipo 1.1 Inferior.....	61
Figura 68 Esquema do Circuito Completo .....	62
Figura 69 PCB Design.....	63
Figura 70 Representação 3D PCB .....	63
Figura 71 PCB .....	64
Figura 72 PCB Finalizado .....	64
Figura 73 Caixa Impressa 3D .....	64
Figura 74 Componentes Adquiridos.....	65
Figura 75 Montagem Final .....	65
Figura 76 Servidor IoT .....	66
Figura 77 MPLABX IDE .....	68
Figura 78 Arduino IDE.....	69
Figura 79 PyCharm IDE FTP .....	71
Figura 80 PyCharm IDE API.....	73
Figura 81 PyCharm IDE ML Training .....	76
Figura 82 Montagem Laboratório.....	80
Figura 83 Bomba Laboratório .....	80
Figura 84 HVAC Laboratório 1.....	82
Figura 85 HVAC Laboratório 2.....	82
Figura 86 HVAC Laboratório 3.....	82
Figura 87 Instalação Oceanus 1 .....	83
Figura 88 Instalação Oceanus 2.....	84
Figura 89 Instalação ETA 1 .....	85
Figura 90 Instalação ETA 2.....	85
Figura 91 Exemplo Amostra sem Anomalia Bomba Laboratório.....	88
Figura 92 Exemplo Amostra Anómala Bomba Laboratório.....	88
Figura 93 Análise Espectral Bomba Todos Estados 1 .....	90
Figura 94 Análise Espectral Todos Estados 2 .....	90
Figura 95 Análise Espectral Bomba Laboratório 100% .....	91
Figura 96 Análise Espectral Bomba Laboratório 1 70% .....	91
Figura 97 Análise Espectral Bomba Laboratório 50% .....	92
Figura 98 Análise Espectral Bomba Laboratório 30% .....	92
Figura 99 Dataset Bomba .....	93
Figura 100 Resultados ML Bomba 1 .....	95
Figura 101 Resultados ML Bomba 2.....	95

---

Figura 102 Resultados ML Bomba 3 .....	95
Figura 103 Resultados ML Bomba 4 .....	95
Figura 104 Exemplo Amostra sem Anomalia HVAC Laboratório.....	96
Figura 105 Exemplo Amostra Anómala HVAC Laboratório .....	96
Figura 106 Análise Espectral HVAC Laboratório 95% .....	97
Figura 107 Análise Espectral HVAC Laboratório 90% .....	98
Figura 108 Análise Espectral HVAC Laboratório 80% .....	98
Figura 109 Análise Espectral HVAC Laboratório 60% .....	99
Figura 110 Análise Espectral HVAC Todos Estados1 .....	100
Figura 111 Análise Espectral HVAC Todos Estados 2 .....	100
Figura 112 dataset HVAC.....	101
Figura 113 Resultados ML HVAC 1 .....	103
Figura 114 Resultados ML HVAC 2 .....	103
Figura 115 Resultados ML HVAC 3 .....	103
Figura 116 Resultados ML HVAC 4 .....	103
Figura 117 Exemplo Amostra Bomba ETA 1.....	105
Figura 118 Exemplo Amostra Bomba ETA 2.....	105
Figura 119 Análise Espectral Bomba ETA.....	105
Figura 120 Exemplo Amostra Bomba APT 1 .....	107
Figura 121 Exemplo Amostra Bomba APT 2.....	107
Figura 122 Exemplo Amostra Bomba APT 3 .....	107

## LISTA DE ACRÓNIMOS

ACRÓNIMO	Significado
$V_{CC}$	Voltage Common Collector
AC	Alternating Current
ACK	Acknowledgement
ADC	Analog to Digital Converter
ADC	Analog-to-Digital Converter
AMP	Amplifier
API	Application Programming Interface
AVAC	Aquecimento, Ventilação e Ar Condicionado
BD	Base de Dados
CAD	Computer Assisted Design
CLK	Clock
CS	Chip Select
CSV	Comma-Separated Values
DC	Direct Current
ETA	Estação de Tratamento de Água
FRAM	Ferroelectric Random-Access Memory
FTP	File Transfer Protocol
GND	Ground
GPIO	General-Purpose Input/Output
HTTP	HyperText Transfer Protocol
I <sup>2</sup> C	Inter-Integrated Circuit
IC	Integrated Circuit
IDE	Integrated Development Environment
IoT	Internet of Things
JSON	JavaScript Object Notation
LED	Light-Emitting Diode
LOF	Local Outlier Factor
MCLR	Master Clear

<b>MCU</b>	Microcontroller Unit
<b>MicroSD</b>	Micro Secure Digital
<b>MISO</b>	Master In Slave Out
<b>ML</b>	<i>Machine learning</i>
<b>MOSI</b>	Master Out Slave In
<b>MQTT</b>	Message Queuing Telemetry Transport
<b>OLED</b>	Organic Light-Emitting Diode
<b>PCA</b>	Principal Component Analysis
<b>PCB</b>	Printed Circuit Board
<b>RAM</b>	Random Access Memory
<b>RF</b>	Radio Frequency
<b>RMS</b>	Root Mean Square
<b>RTC</b>	Real Time Clock
<b>SCL/SCK</b>	Serial Clock
<b>SD</b>	Secure Digital
<b>SDA</b>	Serial Data
<b>SO</b>	Slave Out
<b>SoC</b>	System on a Chip
<b>SPI</b>	Serial Peripheral Interface
<b>SVM</b>	Support Vector Machine
<b>UART</b>	Universal Asynchronous Receiver-Transmitter
<b>USB</b>	Universal Serial Bus
<b>WiFi</b>	Wireless Fidelity

# 1

## INTRODUÇÃO

A manutenção preditiva é uma estratégia de manutenção com vasta aplicação na indústria, especialmente em ambientes onde a eficiência e a confiabilidade são cruciais. A possibilidade de reconhecer sinais de desgaste atempadamente permite, não apenas um melhor planeamento das ações a tomar na sua resolução, mas também uma otimização dos recursos, tanto humanos como materiais. Esta abordagem minimiza o tempo de inatividade dos equipamentos, poupando recursos e permitindo uma melhor gestão da operação.

No entanto, a implementação de sistemas de manutenção preditiva não está isenta de desafios. Já existem no mercado equipamentos especializados e soluções de gestão para manutenção preditiva, mas muitas vezes têm um alto custo e pouca adaptabilidade às necessidades específicas de cada indústria. Além disso, a integração desses sistemas com as infraestruturas já existentes pode ser complexa, exigindo um investimento adicional em formação e adaptação.

A evolução tecnológica tem permitido o desenvolvimento de dispositivos mais acessíveis e flexíveis, como é o caso dos microcontroladores PIC32 e ESP32. Estes dispositivos, quando combinados com um conjunto diversificado de sensores, oferecem uma solução económica e adaptável para a monitorização em tempo real de equipamentos industriais. A aplicação de algoritmos de *Machine Learning* (ML) na análise dos dados recolhidos aumenta ainda mais o potencial deste tipo de sistemas. O ML permite que o sistema "aprenda" o que constitui um funcionamento normal do equipamento e, assim, possa detetar anomalias com maior precisão, facilitando e melhorando a tomada de decisões sobre a manutenção e reparação.

Em suma, a manutenção preditiva, apoiada por tecnologias emergentes e algoritmos de aprendizagem automática, representa um avanço significativo na forma como as indústrias podem gerir a sua operação, melhorando a eficiência e reduzindo custos.

## 1.1 OBJETIVOS E CARACTERÍSTICAS DO PROJETO

Este projeto visa a criação de um sistema de monitorização não intrusiva especializado em motores elétricos, com foco particular em equipamentos de sistemas AVAC (Aquecimento, Ventilação e Ar Condicionado) e sistemas de bombagem. Utilizando uma arquitetura para Internet das Coisas (IoT) expansível, o sistema é composto por um servidor central e múltiplos dispositivos de recolha de dados. Estes dispositivos são equipados com um conjunto de sensores de baixo custo e são capazes de monitorizar vários equipamentos em simultâneo.

Uma das inovações deste projeto reside na sua facilidade de instalação e na sua natureza não intrusiva, permitindo uma integração suave com os sistemas já existentes. Além disso, a utilização de algoritmos de ML potencia a capacidade do sistema em detetar anomalias no funcionamento dos equipamentos, fornecendo assim uma ferramenta robusta para a utilização de estratégias de manutenção preditiva.

Ao longo deste documento, serão abordadas todas as fases de desenvolvimento do projeto. Isso inclui o estudo preliminar, a análise de soluções já existentes no mercado, o desenvolvimento do *hardware* e *software* que compõem o sistema e, finalmente, a apresentação e discussão dos resultados obtidos nos testes práticos.

## 1.2 CONTEXTO DO TRABALHO

O advento da Internet das Coisas (IoT) tem revolucionado diversos setores, incluindo a indústria e a gestão de infraestruturas críticas. No entanto, a implementação eficaz de sistemas de monitorização baseados em IoT ainda enfrenta desafios significativos, especialmente no que diz respeito à deteção de anomalias em equipamentos industriais. A falha em detetar irregularidades pode resultar em custos elevados de manutenção, paralisações não planeadas e, em casos extremos, acidentes catastróficos.

Neste contexto, a presente tese foca-se no desenvolvimento e implementação de um sistema de monitorização de equipamentos industriais, utilizando sensores de diversos tipos e algoritmos de *Machine Learning* (ML) para a deteção de anomalias. O trabalho justifica-se

pela necessidade crescente de sistemas mais inteligentes e autónomos que possam, não apenas coletar dados, mas também interpretá-los de forma eficaz para a tomada de decisões.

Apesar da existência de estudos e implementações anteriores na área de monitorização industrial, poucos trabalhos abordam uma solução integrada que combine a recolha de dados multissensorial com análise de dados avançada. Além disso, a integração com plataformas IoT existentes, como a FulgurIT desenvolvida pela Hubel, representa um avanço na direção de sistemas de monitorização mais holísticos.

O projeto também se destaca pela sua aplicabilidade prática, tendo sido testado em diferentes ambientes e tipos de equipamentos, nomeadamente bombas de água e sistemas de AVAC (Aquecimento, Ventilação e Ar Condicionado). Isto, não apenas valida a eficácia do sistema proposto, mas também demonstra sua versatilidade e adaptabilidade a diferentes cenários industriais.

Portanto, este trabalho não só contribui para o campo académico, fornecendo insights valiosos sobre a implementação de sistemas de monitorização baseados em IoT e ML, mas também tem implicações práticas significativas, oferecendo uma solução viável para a deteção de anomalias em equipamentos industriais.

### **1.3 ORGANIZAÇÃO DA DISSERTAÇÃO**

Este relatório abrange todos os aspetos do desenvolvimento do sistema de monitorização não intrusiva para motores elétricos e está organizado como a seguir se descreve:

O próximo capítulo é dedicado ao estudo do estado da arte e serve como uma base teórica para o projeto. Este capítulo inclui a explicação de conceitos fundamentais, a apresentação de estudos e artigos científicos que servem de motivação para o projeto, uma análise crítica de soluções comerciais e domésticas já existentes no mercado e as novas tendências no espaço da manutenção preditiva. Finaliza com a proposta justificada para a criação deste projeto, destacando a sua relevância e inovação.

A secção seguinte aborda o desenvolvimento completo do sistema e está dividida em três grandes capítulos:

O primeiro destes, o terceiro capítulo do documento, foca-se no *hardware* físico e é subdividido em cinco componentes:

- Seleção dos componentes principais que irão constituir o sistema de sensores.
- Discussão dos componentes passivos necessários para o funcionamento dos controladores e circuito de alimentação.
- Descrição detalhada do esquemático do circuito.
- Processo de manufatura física do circuito, incluindo prototipagem, *design* do PCB e montagem final.
- Aspectos de instalação e configuração, destacando a facilidade e a natureza não intrusiva do sistema.

O quarto capítulo explora o *software* desenvolvido e também se divide em três subcapítulos:

- Programação dos controladores do sistema de sensores, incluindo uma explicação dos métodos e a interação entre os vários componentes.
- Descrição dos programas desenvolvidos para o componente IoT do sistema, abrangendo o servidor FTP, soluções de armazenamento e API baseada na arquitetura REST.
- Análise do *software* desenvolvido para gerir a operação do sistema de sensores, incluindo a análise de dados e a implementação de algoritmos de ML.

O quinto capítulo descreve o funcionamento completo do sistema e apresenta a metodologia dos testes experimentais conduzidos em laboratório com condições controladas e as várias implementações em ambientes reais. Estas incluem o sistema de ar condicionado num complexo hoteleiro, as bombas de água numa Estação de Tratamento de Água (ETA) e um sistema de rega em escala industrial.

O sexto capítulo apresenta e discute os resultados obtidos, compara os objetivos iniciais do projeto com os resultados alcançados, aborda as falhas ou dificuldades encontradas e propõe melhorias para futuras iterações do sistema.

O relatório é finalizado com o resumo das conclusões e trabalho futuro (sétimo capítulo), com as referências bibliográficas e apêndices pertinentes ao projeto.

# 2

## ESTUDOS PRELIMINARES E ESTADO DA ARTE

Não é nova a utilização do conceito de manutenção preditiva como forma de manutenção industrial, assim como não é nova a utilização de análise espectral da vibração de motores para detetar anomalias nos equipamentos [1]. Porém, com as recentes tendências relacionadas com a Internet das Coisas (IoT – *Internet of Things*) e a Indústria 4.0, tem vindo a aumentar a utilização de algoritmos de aprendizagem de máquina (*Machine Learning*)[2], conjugados com as anteriores técnicas de manutenção industrial, para a deteção de anomalias em ambiente industrial. Estas novas técnicas trazidas pela 4ª revolução industrial têm vindo a ganhar destaque, pois existem vários estudos que demonstram a sua eficácia e estão a moldar o futuro da manutenção industrial[1], [3]–[5]. O trabalho desenvolvido nesta dissertação enquadra-se nesta área, com novos desenvolvimentos relacionados com a manutenção preditiva em ambiente industrial, focado em aplicações de sistemas de bombagem e sistemas AVAC.

Neste capítulo pretende-se apresentar um resumo do estado da arte em deteção de anomalias em equipamentos industriais, mas focando sempre os aspetos relacionados com a manutenção de sistemas de bombagem e de sistemas AVAC, que são os objetivos principais deste trabalho. Também serão abordados conceitos fundamentais que servem de base para o projeto desenvolvido como a definição de manutenção preditiva, a Transformada Rápida de Fourier (FFT) e como a análise espectral pode ser utilizada para identificar diferentes tipos de anomalias. Para além disso, serão ainda apresentados neste capítulo algumas soluções comerciais já existentes no mercado, bem como outros estudos realizados na temática, para fornecer uma visão abrangente do trabalho que já existe desenvolvido nesta área de estudo.

## **2.1 MANUTENÇÃO INDUSTRIAL DE EQUIPAMENTOS**

Existem quatro tipos principais de manutenção de equipamentos que podem ser aplicados em equipamentos industriais[6], e que se resumem a seguir: [7].

### **2.1.1 MANUTENÇÃO REATIVA**

A manutenção reativa é a abordagem mais básica e direta, que foca-se em resolver problemas apenas após a sua ocorrência. Esta estratégia é comum em equipamentos menos críticos ou em sistemas com redundâncias, onde uma falha não resulta em paralisações significativas de funções críticas. Por existir sempre uma paralisação dos equipamentos, é frequentemente considerada a estratégia de manutenção menos eficaz e mais dispendiosa a longo prazo. A intervenção só acontece quando o equipamento já falhou, o que pode resultar em períodos de inatividade não planejados e custos elevados com reparações de emergência.

As principais vantagens deste tipo de manutenção incluem: um menor custo inicial de implementação e a necessidade de um menor planejamento. No entanto, estas são vantagens frequentemente ofuscadas pelas desvantagens, que incluem custos elevados de reparação de emergência e períodos de inatividade não planejados. Para além disso, esta abordagem não é adequada para equipamentos críticos ou sistemas onde a falha pode resultar em riscos de segurança.

### **2.1.2 MANUTENÇÃO PLANEADA**

A manutenção planeada é uma estratégia que procura antecipar e prevenir falhas, executando operações de manutenção em intervalos de tempo regulares. Esta abordagem é mais eficaz do que a manutenção reativa e é normalmente aplicada em equipamentos industriais e infraestruturas de transporte. Ao contrário da manutenção reativa, que age apenas após a ocorrência de falhas, a manutenção planeada tenta evitar, em primeiro lugar, que essas falhas aconteçam. Isso conduz a custos de manutenção mais previsíveis e também à redução de falhas inesperadas[8].

No entanto, a manutenção planeada tem também as suas próprias desvantagens. Pode ser ineficiente para equipamentos mais novos ou menos usados, onde a manutenção regular pode não ser necessária. Além disso, esta abordagem carece de flexibilidade para se adaptar às mudanças nas condições do equipamento, o que pode resultar em manutenções desnecessárias ou inadequadas. A falta de flexibilidade é uma das principais críticas a esta abordagem,

especialmente quando comparada com métodos mais modernos, como a manutenção preditiva.

### 2.1.3 MANUTENÇÃO PROATIVA

A manutenção proativa é uma abordagem que vai além da simples prevenção de falhas. Esta estratégia foca-se na identificação e eliminação de fatores de risco ou pontos fracos no sistema, antes destes causarem problemas. É especialmente útil em edifícios, estruturas e sistemas de energia, que requeiram manutenção regular para evitar a deterioração e maximizar a vida útil dos equipamentos. Ao contrário das abordagens reativas e planeadas, a manutenção proativa procura entender as causas subjacentes às falhas potenciais e procura abordá-las antes que causem dano[9], [10].

No entanto, a manutenção proativa não é isenta de desvantagens. Os custos iniciais para implementar esta estratégia podem ser elevados, dado que frequentemente requerem uma análise contínua e detalhada dos sistemas e dos equipamentos. Além disso, a eficácia desta abordagem depende da qualidade dos dados e da competência da equipa de manutenção. Se for mal-executada, a manutenção proativa pode resultar em gastos desnecessários e até mesmo à introdução de novos riscos ao sistema.

### 2.1.4 MANUTENÇÃO PREDITIVA

A manutenção preditiva é uma das abordagens mais avançadas e tem vindo a ser cada vez mais utilizada face às estratégias anteriores, especialmente com o aparecimento de tecnologias como o "*Digital Twin*" (ou Gémeos Digitais, em tradução livre para português)[11]. Esta estratégia utiliza a análise de dados provenientes de redes de sensores para prever a viabilidade do equipamento e identificar anomalias no seu funcionamento antes que ocorram falhas. É frequentemente aplicada em indústrias de alta tecnologia, como a aeroespacial, automóvel e energias renováveis, onde os custos de falha no equipamento podem ser extremamente elevados.

Apesar das suas vantagens, como a redução de tempo de inatividade e a extensão da vida útil do equipamento, a manutenção preditiva também tem desvantagens. A implementação inicial é complexa e dispendiosa, exigindo não apenas sensores avançados, mas também uma infraestrutura de dados robusta. Além disso, a eficácia desta abordagem depende fortemente da qualidade dos algoritmos de análise de dados e da formação da equipa de manutenção, em interpretar corretamente os dados[12].

No entanto, pelo grande desenvolvimento atual dos sistemas IoT, da inteligência artificial, ou de uma forma geral, da Indústria 4.0, a manutenção preditiva é claramente uma estratégia de futuro (e até do presente), tendo ainda muito potencial de crescimento.

## 2.2 MONITORIZAÇÃO DE MOTORES ELÉTRICOS E ANÁLISE VIBRACIONAL

Em motores elétricos existem vários métodos de diagnóstico e monitorização, que podem ser utilizados para identificar falhas de operação ou sinais de desgaste. Alguns dos métodos mais comuns incluem:

- **Termografia Infravermelha:** Este método permite identificar pontos quentes ou temperaturas fora dos valores esperados no equipamento. É uma técnica não intrusiva, fácil de implementar e muito adotada na indústria para a deteção precoce de problemas como o sobreaquecimento[13], [14].
- **Monitorização Acústica:** Esta técnica é capaz de identificar fugas de gases ou líquidos através da análise do som emitido pelo equipamento. Embora eficaz, os equipamentos necessários para esta monitorização tendem a ser de alto custo, e o conjunto de problemas que consegue identificar é limitado[15], [16].
- **Análise de Lubrificantes:** Este é um método mais intrusivo que envolve a análise do lubrificante usado no motor para identificar contaminantes ou partículas que possam indicar desgaste ou falha iminente.
- **Análise de Vibrações:** Este método envolve a colocação de sensores de vibração no equipamento para monitorizar as oscilações e movimentos, que podem ser um indicativo de desalinhamento, desgaste de peças ou outros problemas mecânicos[17].
- **Monitorização de Consumo de Energia:** A análise do consumo de energia do motor pode também fornecer *insights* valiosos sobre o seu estado de funcionamento, como picos de consumo, que podem indicar sobrecarga ou falha.

De todas as técnicas de monitorização, a Análise Vibracional mostra-se particularmente eficaz em equipamentos rotacionais. Motores elétricos em bom estado de funcionamento exibem uma "assinatura" vibracional específica, composta por um conjunto de frequências, que podem ser decompostas, com o recurso a algoritmos como a FFT, e analisadas[18]. Esta assinatura serve como um indicador confiável do estado do motor. Com o desgaste ou a ocorrência de falhas, esta assinatura vibracional muda. Através da comparação da nova assinatura com dados históricos e estudos prévios, é possível identificar a natureza do problema e tomar medidas corretivas de forma antecipada[18]–[21].

Porém, um dos principais desafios na implementação desta técnica é o custo associado aos equipamentos sensoriais e/ou às necessidades de comunicação periódica de leituras, como é evidenciado em várias soluções comerciais. O mercado atual oferece uma variedade de soluções especializadas para a análise de vibrações em equipamentos elétricos, como a solução *ABB Ability Smart Sensor*, ou a *Industrial IoT Wireless Predictive Maintenance Sensor V3* da NCD. Estas soluções são frequentemente habilitadas para IoT e utilizam sensores de vibração avançados para fornecer informações em tempo real sobre o estado dos equipamentos. Estes sensores são projetados para serem energeticamente eficientes e fornecer leituras precisas, embora possam ser soluções muito caras. No entanto, o investimento inicial pode ser justificado pela capacidade de prolongar a vida útil dos equipamentos e reduzir os custos de substituição[22]–[24].

### 2.2.1 TRANSFORMADA RÁPIDA DE FOURIER

A Transformada Rápida de Fourier (FFT) é um algoritmo eficiente para calcular a Transformada Discreta de Fourier (DFT) e a sua inversa. A FFT foi popularizada por James Cooley e John Tukey em 1965, embora suas raízes possam ser identificadas até Carl Friedrich Gauss em 1805. A fórmula básica para a DFT é:

$$X(k) = \sum_{n=0}^{N-1} x(n) \cdot e^{-i2\pi kn/N}$$

A FFT serve para decompor um sinal nas suas componentes de frequência (Figura 1). É amplamente utilizada em muitas áreas, sobretudo na área da engenharia eletrotécnica, para analisar frequências contidas em sinais. As vantagens da FFT sobre a DFT incluem uma complexidade computacional significativamente menor. Enquanto a DFT tem uma complexidade computacional de  $O(N^2)$ , a FFT reduz a complexidade para  $O(N \log N)$ , tornando-a mais eficiente para grandes conjuntos de dados. Ao utilizar a FFT na análise vibracional de equipamentos rotativos, é possível obter uma decomposição mais rápida e eficiente das frequências, o que permite uma monitorização mais precisa e em tempo real do estado do equipamento[25].




Figura 1 Exemplo do resultado de uma FFT

### 2.2.2 DETEÇÃO DE ANOMALIAS PELA ANÁLISE ESPECTRAL

Cada tipo de anomalia em máquinas rotativas produz um efeito específico no espectro de vibração. Desde desalinhamentos e desgaste das engrenagens, até problemas de fluxo e cavitação, cada irregularidade manifesta-se através de padrões distintos de frequência e amplitude. Compreender estas assinaturas espectrais é fundamental para a identificação precisa de falhas e para a implementação de medidas corretivas eficazes[26].

Nesta secção, apresentam-se exemplos de anomalias em máquinas rotativas e como se manifestam na análise espectral. Porém, os objetivos do trabalho da presente dissertação não se focam no diagnóstico das anomalias, mas apenas na identificação de que existe uma anomalia, sobretudo com a utilização de estratégias não intrusivas, baseadas em equipamentos e sensores de baixo custo. No entanto, é fundamental perceber como algumas possíveis anomalias se podem manifestar, facilitando o trabalho de campo e laboratorial[27].

#### 2.2.2.1 Desequilíbrio do Rotor

O desequilíbrio é o defeito mais vulgar em maquinaria rotativa, dividindo-se em três tipos: estático, de casal e dinâmico. Nos espectros obtidos pela FFT (Figura 2), todos mostram uma frequência predominante correspondente ao valor da frequência de rotação da máquina, ou frequência fundamental da rotação da máquina, denominada neste documento de  $f_0$  (neste caso,  $1 \times f_0$ ), cuja amplitude varia proporcionalmente ao quadrado da velocidade de rotação. Mudanças na fase da vibração, consoante a posição do sensor, podem ajudar a identificar o tipo de desequilíbrio.




Figura 2 Espectro Desequilíbrio do Rotor

O desequilíbrio estático é geralmente constante e em fase, enquanto o desequilíbrio de casal costuma estar  $180^\circ$  fora de fase no mesmo eixo. Rotores em balanço podem mostrar características de ambos os tipos e são mais complexos de analisar. Estes defeitos podem causar vibrações axiais e radiais elevadas, tornando crucial a sua detecção e correção[27].

#### 2.2.2.2 Eixo Empenado

Um eixo empenado causa vibrações elevadas tanto na direção radial como axial. No espectro obtido pela FFT (Figura 3), encontram-se componentes a  $1 \times f_0$  e a  $2 \times f_0$  (a frequência fundamental de rotação e um primeiro harmónico). Se a amplitude a  $1 \times f_0$  for dominante, o empeno está perto do centro do eixo; se for a  $2 \times f_0$ , está perto da extremidade. A fase será de  $180^\circ$  tanto na direção axial como na radial, o que significa que não há mudança de fase ao mover a sonda do plano vertical para o horizontal[27].




Figura 3 Espectro Eixo Empenado

### 2.2.2.3 Desalinhamento

O desalinhamento é uma causa predominante de vibração em maquinaria. Existem dois tipos fundamentais: angular (Figura 4) e paralelo (Figura 5). No desalinhamento angular, as vibrações axiais são mais proeminentes a uma frequência de  $1 \times f_0$ . No entanto, este cenário raramente ocorre de forma isolada e pode coexistir com problemas de acoplamento. Quanto ao desalinhamento paralelo, este resulta em vibrações radiais a  $2 \times f_0$ . Em casos severos de qualquer forma de desalinhamento, podem surgir picos de alta amplitude em harmônicos mais elevados[27].

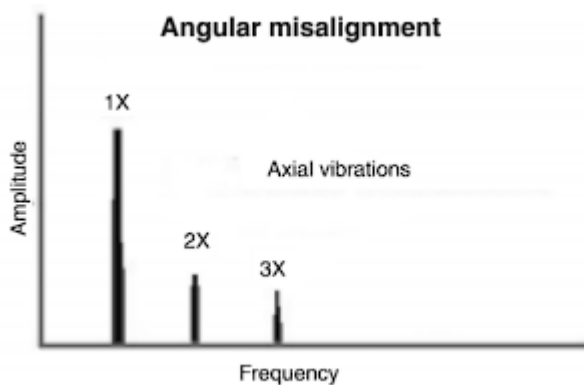


Figura 4 Espectro Desalinhamento Angular




Figura 5 Espectro Desalinhamento Paralelo

### 2.2.2.4 Folgas Mecânicas

A folga mecânica em máquinas rotativas pode ocorrer em três locais principais: na montagem interna, na interface entre a máquina e a placa base, e na estrutura. No caso da montagem interna, a folga pode ser causada por um ajuste inadequado entre as partes, resultando em múltiplos harmônicos na análise obtida pela FFT (Figura 6).

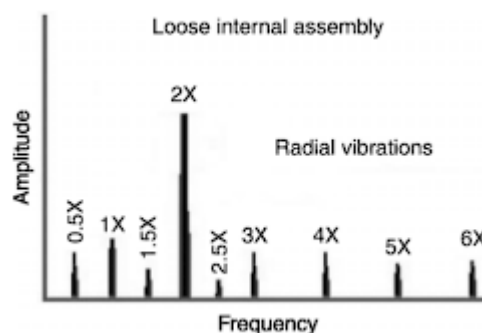


Figura 6 Espectro Folgas Mecânicas 1

A folga entre a máquina e a placa base está geralmente associada a parafusos soltos ou a fissuras na estrutura, o que pode gerar harmônicos mais elevados (Figura 7).




Figura 7 Espectro Folgas Mecânicas 2

A folga estrutural é geralmente causada por fraquezas na base ou na fundação da máquina. A análise de fase pode revelar uma mudança de fase de aproximadamente  $180^\circ$  entre as medições verticais (Figura 8).




Figura 8 Espectro Folgas Mecânicas 3

Se há uma suspeita de uma condição de "pé mole" (ou apoio fraco), um teste simples é afrouxar cada parafuso, um de cada vez, e verificar se isso provoca mudanças significativas na vibração. Nesse caso, pode ser necessário melhorar as bases de apoio, ou instalar calços[27].

### 2.2.2.5 Engrenagens

A frequência de malha da engrenagem (com a sigla GMF, do termo em inglês *Gear Mesh Frequency*) é uma métrica crítica na análise espectral de caixas de engrenagens. É calculada pelo produto do número de dentes de uma engrenagem ou pinhão e a sua velocidade de rotação correspondente. O GMF é acompanhado por bandas laterais relativas à velocidade do eixo ao qual a engrenagem está acoplada[27].

$$\text{GMF} = (\text{Número de dentes no pinhão}) \times (\text{RPM do pinhão})$$

Um indicador significativo do desgaste do dente da engrenagem é a excitação das frequências naturais da engrenagem, com bandas laterais espaçadas pela velocidade de rotação da engrenagem defeituosa. Estas bandas laterais são frequentemente mais indicativas do estado de desgaste do que o próprio GMF (Figura 9).




Figura 9 Espectro Desgaste de Engrenagens

O desalinhamento da engrenagem frequentemente excita harmônicos de segunda ordem ou superiores do GMF. Estes harmônicos são acompanhados por bandas laterais espaçadas pela velocidade de rotação. É crucial ajustar o F-max do espectro FFT para mais de  $3 \times$  GMF para capturar adequadamente essas variações (Figura 10).




Figura 10 Espectro Desalinhamento de Engrenagens

### 2.2.2.6 Vibrações Relacionadas com Fluxo

A frequência de passagem de pás (BPF, Blade Pass Frequency) é comum em bombas e ventoinhas. Calcula-se multiplicando o número de pás pelo rpm. Se a folga entre o rotor e o estator não for igual, pode resultar em grandes amplitudes da BPF e dos seus harmônicos.

$$BPF = \text{Número de pás (ou alhetas)} \times rpm$$

A turbulência ocorre frequentemente em ventoinhas devido a variações na pressão ou velocidade do ar. Isso pode causar vibrações aleatórias de baixa frequência (Figura 11).




Figura 11 Espectro Turbulência de Fluxo

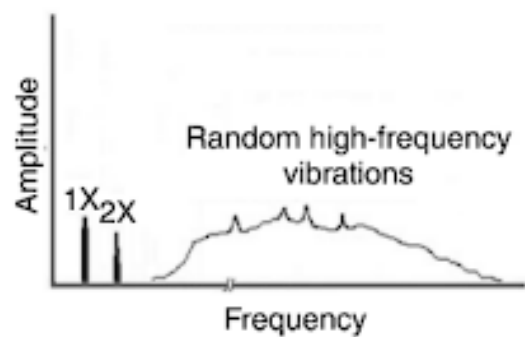


Figura 12 Espectro Impulsão

A cavitação é um fenômeno que ocorre quando a pressão do líquido numa bomba cai abaixo da sua pressão de vapor. Isso faz com que bolhas de vapor se formem no líquido. À medida que essas bolhas se movem para áreas de maior pressão dentro da bomba, elas colapsam ou implodem.

Cada implosão gera um tipo de impacto, que por sua vez cria vibrações de alta frequência. Estas vibrações podem ser muito destrutivas para os componentes internos da bomba, como as pás do impulsor. A cavitação é frequentemente responsável pela erosão dessas pás e pode afetar gravemente o desempenho da bomba (Figura 12).

A cavitação gera energia de banda larga de alta frequência, muitas vezes sobreposta com harmônicos da frequência de passagem de pás. É um fenômeno destrutivo que pode causar erosão nas pás do impulsor[27].

## 2.3 ESTRATÉGIAS DA INDÚSTRIA 4.0

A quarta revolução industrial, denominada Indústria 4.0, representa a integração de tecnologias avançadas nos processos de fabricação para criar "fábricas inteligentes". Esse termo foi introduzido pela primeira vez na Feira de Hannover, na Alemanha, em 2011, e desde então tem sido amplamente adotado para descrever a transformação digital na indústria[28].

A Indústria 4.0 envolve várias tecnologias e conceitos inter-relacionados, incluindo:

- **Internet das Coisas (IoT):** Sensores e dispositivos conectados à internet são incorporados em máquinas, equipamentos e produtos para coletar e trocar dados em tempo real. Isso permite uma monitorização mais eficiente e uma tomada de decisão mais informada.
- **Big Data e Análise de Dados:** A enorme quantidade de dados gerada pelos sensores e outros dispositivos na Indústria 4.0 é analisada para extrair *insights* valiosos. Isso ajuda as empresas a tomar decisões mais rápidas e precisas, otimizando os processos de produção.
- **Inteligência Artificial (IA):** Algoritmos de IA são usados para análise preditiva, manutenção preventiva e otimização de processos. Sistemas de aprendizado de máquina podem melhorar continuamente com base nos dados coletados.
- **Computação em Nuvem:** Armazenamento e processamento de dados na nuvem proporcionam maior flexibilidade, escalabilidade e acessibilidade aos dados em qualquer lugar e a qualquer momento.
- **Manufatura Aditiva (Impressão 3D):** A capacidade de criar produtos camada por camada oferece flexibilidade na produção, permitindo designs mais complexos e personalizados.
- **Integração Horizontal e Vertical:** A integração horizontal refere-se à colaboração entre diferentes áreas da cadeia de suprimentos, enquanto a integração vertical abrange a conexão de diferentes níveis hierárquicos dentro de uma empresa, desde o chão de fábrica até a administração.
- **Realidade Aumentada (RA) e Virtual (RV):** Essas tecnologias são usadas para melhorar a eficiência e a precisão em tarefas como manutenção, treinamento de funcionários e design de produtos.

- **Cibersegurança:** Com a interconexão de sistemas, a segurança da informação torna-se crítica para proteger dados sensíveis e garantir a operação segura das fábricas inteligentes.

A implementação bem-sucedida da Indústria 4.0 visa melhorar a eficiência, a flexibilidade e a personalização na produção, reduzindo custos e tempo de inatividade. Ela tem o potencial de transformar significativamente a maneira como as empresas operam e produzem bens. Neste sentido, é de extrema importância para a Indústria 4.0 o conceito de manutenção preditiva. Aliás, a utilização de tecnologias introduzidas pela indústria 4.0, como a IA, IoT, *Big Data*, Análise de Dados e Computação na Nuvem, contribuem decisivamente para uma melhor implementação de estratégias de manutenção preditiva. Dada a importância destas áreas para o trabalho desta dissertação, serão abordadas nas seguintes subseções como algumas destas tecnologias estão a ser utilizadas para melhorar a manutenção industrial na indústria 4.0[29].

### 2.3.1 ALGORITMOS DE APRENDIZAGEM DE MÁQUINA EM MANUTENÇÃO INDUSTRIAL

A utilização de técnicas de aprendizagem de máquina (ML) tem revolucionado o campo da manutenção preditiva, especialmente quando combinada com análises vibracionais. Redes Neurais Recorrentes (RNN) mostraram ser particularmente eficazes na detecção de falhas em motores elétricos usando apenas sinais de tempo de vibração do motor[30]. Além disso, o uso de Redes Neurais Convulsivas (CNN) em ambientes da Indústria 4.0 tem demonstrado ser altamente eficaz na detecção de anomalias em motores de esteira transportadora[2], [4], [31], [32].

Outro avanço significativo é a utilização de Análise de Componentes Principais (PCA) e Análise Discriminante Linear (LDA) para redução de dimensionalidade, o que facilita a visualização e detecção de modos de falha desconhecidos ou diferentes[33]. Além disso, a transformada de Fourier de curto prazo (STFT) tem sido usada para representar sinais de vibração como espectrogramas, que são então processados por CNN para diagnóstico de falhas em rolamentos, mesmo sob condições de ruído[3].

### 2.3.2 INTERNET DAS COISAS

Tecnologias de Internet das Coisas (IoT) de baixo consumo energético estão a revolucionar a forma como a manutenção preditiva é realizada em ambientes industriais. Estas tecnologias permitem a implementação de redes de sensores altamente escaláveis e flexíveis que podem monitorizar uma variedade de parâmetros em tempo real. Estes dados são então enviados para plataformas de armazenamento em nuvem, onde podem ser analisados usando algoritmos avançados de aprendizagem de máquina, para detetar anomalias e prever falhas de equipamento[34].

Já se encontram várias plataformas comerciais disponíveis no mercado, algumas das quais são especificamente projetadas para aplicações de manutenção preditiva em ambientes industriais, como a Predix<sup>1</sup> da GE ou a Uptake<sup>2</sup>. Outras plataformas, como o AWS IoT<sup>3</sup> ou o Microsoft Azure<sup>4</sup>, oferecem soluções mais genéricas que podem ser personalizadas para atender a necessidades específicas[35]. Além disso, o advento de tecnologias abertas e *frameworks* como o MQTT<sup>5</sup> facilita a criação de soluções de manutenção preditiva personalizadas, tornando-as acessíveis, não apenas para grandes indústrias, mas também para pequenas e médias empresas[36], [37].

### 2.3.3 GESTÃO DOS EQUIPAMENTOS

Existem soluções que permitem controlar automaticamente equipamentos com base num conjunto de sensores e parâmetros. Estas soluções são especialmente úteis para manter condições operacionais ideais, como regular uma temperatura constante em sistemas de ar condicionado ou regular a pressão em bombas de água. Isso melhora a eficiência do equipamento e reduz o consumo de energia e prolonga a vida útil do equipamento.

---

<sup>1</sup> <https://www.ge.com/digital/iiot-platform>

<sup>2</sup> <https://www.uptake.com/>

<sup>3</sup> <https://aws.amazon.com/pt/iot/>

<sup>4</sup> <https://azure.microsoft.com/pt-pt/>

<sup>5</sup> <https://mqtt.org/>

Atualmente, a maioria dos equipamentos modernos já vem com *software* de gestão integrado, permitindo o controle remoto e centralizado de múltiplas unidades. Esses sistemas de gestão são frequentemente integrados em redes de sensores sem fio para facilitar a recolha de dados e permitir diagnósticos preditivos[38].

Além disso, tecnologias de baixo consumo, como as redes de sensores sem fio, tornam-se cada vez mais prevalentes em ambientes industriais. Oferecendo a flexibilidade necessária para monitorizar condições em locais de difícil acesso ou em ambientes hostis, sem a necessidade de infraestrutura de rede extensa[39].

Incorporando um sistema de manutenção preditiva em sistemas de controle automatizado já existentes, é possível apenas monitorizar o estado do equipamento, e adaptar sua operação otimizando sua vida útil. Este sistema inteligente seria capaz de autorregular com base no estado do equipamento, ajustando parâmetros como velocidade, carga e temperatura para minimizar o seu desgaste[11].

Além disso, a integração de tal sistema permitiria uma melhor gestão das operações de manutenção. Por exemplo, em vez de programar manutenções periódicas que podem ou não ser necessárias, o sistema poderia indicar o momento mais oportuno para intervenções, seja para reparações menores ou para substituição completa do equipamento. Isto reduziria os tempos de inatividade permitindo uma alocação mais eficiente de recursos, tanto em termos de peças quanto de mão-de-obra[40].

Deste modo, um dos objetivos do trabalho realizado nesta dissertação é criar um sistema de *hardware* de monitorização não intrusiva que possa ser facilmente incorporado em sistemas de controle automatizados já existentes, fornecendo uma solução completa para manutenção preditiva e gestão otimizada de equipamentos industriais.

## **2.4 ESTUDOS SEMELHANTES OU RELACIONADOS**

No contexto da manutenção preditiva e da monitorização de condições de sistemas rotativos, como motores elétricos, a investigação recente tem demonstrado avanços significativos, empregando métodos inovadores de análise de dados e aprendizado de máquina. Esta secção do Estado da Arte explora três estudos fundamentais que ilustram o progresso na deteção e previsão de falhas em maquinaria rotativa.

Cada um destes trabalhos, embora distintos nas suas abordagens e técnicas, contribui para uma compreensão mais aprofundada da aplicação de modelos de aprendizado de máquina e análise de dados na manutenção preditiva. Estes estudos são essenciais para contextualizar o trabalho presente, demonstrando as tendências atuais e as potencialidades desta área em constante evolução.

### **2.4.1 MACHINE FAULT DETECTION USING A HYBRID CNN-LSTM ATTENTION-BASED MODEL**

Neste artigo[41], os autores desenvolvem um modelo para deteção de falhas em máquinas elétricas, combinando diferentes técnicas avançadas de aprendizado de máquina. Utilizam uma mistura de redes neurais convolucionais (CNN) e memória de longo e curto prazo (LSTM) com um mecanismo de atenção para analisar dados de vibração de motores elétricos. Esse modelo híbrido é treinado com dados coletados em três eixos diferentes e incorpora uma abordagem única, utilizando regressão quantílica, para lidar com incertezas nos dados.

Uma parte crucial do trabalho é a aplicação da transformação de ondaletas empíricas e do filtro Savitzky–Golay, que ajudam a reduzir ruídos nos dados e destacam características importantes para a análise. Essa combinação de métodos resulta num modelo altamente eficaz, capaz de prever e identificar anomalias nos dados de vibração de forma mais precisa do que os modelos tradicionais.

O sucesso do modelo proposto representa um passo significativo para melhorar a manutenção preditiva em ambientes industriais, otimizando os cronogramas de manutenção e melhorando a eficiência operacional das máquinas.

#### **2.4.2 ESTABLISHING A REAL-TIME MULTI-STEP AHEAD FORECASTING MODEL OF UNBALANCE FAULT IN A ROTOR-BEARING SYSTEM**

Neste artigo[42], os autores Banalata Bera, Chun-Ling Lin, Shyh-Chin Huang, Jin-Wei Liang e Po Ting Lin exploram um modelo de previsão para a detecção de desequilíbrio em sistemas rotor-mancais. O foco é no prognóstico e gerenciamento da saúde (PHM) de máquinas rotativas, usando monitorização baseado em condições (CBM) e métodos de aprendizado de máquina para prever falhas futuras.

A pesquisa aborda o desafio de prever falhas de desequilíbrio em tempo real num rotor industrial de turbina. Para isso, os autores, desenvolvem um modelo matemático do sistema e utilizam métodos estatísticos e de aprendizado de máquina, como Suavização Exponencial Simples (SES), Auto Regressivo Integrado de Médias Móveis (ARIMA), Regressão Vetorial de Suporte (SVR) e Memória de Longo e Curto Prazo (LSTM), para analisar dados de séries temporais e prever valores de desequilíbrio com um mês de antecedência.

Um aspeto inovador deste estudo é a avaliação dos métodos de previsão num conjunto de dados reais de uma fábrica local, proporcionando *insights* mais práticos e aplicáveis ao cenário industrial pratico. Os resultados mostram que o modelo proposto pode prever de forma eficaz o desequilíbrio futuro do sistema, auxiliando em decisões de manutenção baseadas em previsão, contribuindo para a operação eficiente e confiável de sistemas rotativos.

Esta abordagem holística, combinando modelagem matemática e técnicas de aprendizado de máquina, destaca a importância de adaptar as estratégias de manutenção preditiva às condições específicas do equipamento em ambientes industriais, garantindo uma operação mais eficiente e segura.

#### **2.4.3 EARLY FAULT CLASSIFICATION IN ROTATING MACHINERY WITH LIMITED DATA USING TABPFN**

O artigo[43] de L. Magadan, J. Roldán-Gómez, J. C. Granda, e F. J. Suárez, foca-se na classificação precoce de falhas em maquinaria rotativa usando um conjunto limitado de dados. A investigação visa superar o desafio comum de falta de dados suficientes para treinar modelos de classificação de falhas de forma eficaz.

O estudo propõe o uso do Tabular Prior-Data Fitted Network (TabPFN), um modelo pré-treinado com uma grande quantidade de dados sintéticos e relações causais. Esta abordagem permite a realização de inferência bayesiana nos dados utilizados para o treino, tornando o TabPFN adequado para ser implementado em cenários reais, onde os dados disponíveis de maquinaria rotativa são limitados.

O modelo demonstrou ser mais preciso do que os algoritmos tradicionais de classificação tabular, como XGboost e Random Forest, especialmente em situações com dados limitados. Este avanço representa um significativo passo em frente no diagnóstico inteligente de falhas e na manutenção preditiva, trazendo eficiência e confiabilidade aprimoradas para sistemas rotativos em ambientes industriais.

Em resumo, o artigo destaca a importância e eficácia do uso de modelos de aprendizado de máquina avançados, mesmo com dados limitados, para a detecção precoce e precisa de falhas em maquinaria rotativa.

## **2.5 SOLUÇÕES EXISTENTES DE MANUTENÇÃO PREDITIVA COM ANÁLISE VIBRACIONAL**

Na secção seguinte da tese, será apresentada uma análise detalhada de produtos comerciais de manutenção preditiva disponíveis no mercado. Estes produtos representam soluções avançadas que utilizam tecnologias de monitorização remota e análise de dados para prever e prevenir falhas em equipamentos industriais. A avaliação destes sistemas incluirá uma descrição das suas funcionalidades, características técnicas e aplicabilidade no contexto industrial. Esta análise é crucial para entender o estado atual do mercado de manutenção preditiva e para identificar as tendências emergentes e as melhores práticas no setor.

### **2.5.1 INDUSTRIAL IOT WIRELESS PREDICTIVE MAINTENANCE SENSOR V3**

O Industrial IoT Wireless Predictive Maintenance Sensor V3 da NCD[44] (Figura 13) representa uma solução existente na manutenção preditiva em ambientes industriais. Este sensor de alta qualidade é projetado para monitorizar condições e prever falhas em máquinas, oferecendo uma gama abrangente de funcionalidades. Ele vem equipado com um conector e sonda termopar tipo K, capaz de medir temperaturas até 260°C com grande precisão. Além disso, o sensor pode medir corrente AC até 100A RMS, o que é vital para acompanhar o consumo de energia dos equipamentos.

Em termos de análise de vibração, o sensor é capaz de calcular o valor RMS e deslocamento RMS, bem como a frequência máxima de vibração. Fornecendo também dados de domínio de tempo para análise FFT, ajudando na identificação precisa de problemas potenciais. Para garantir a qualidade dos dados, inclui filtros passa-baixo e passa-alto para remover ruídos. A sua ampla faixa de frequência e alta taxa de amostragem, juntamente com comunicação encriptada e um alcance sem fios de até 2 milhas, tornam este sensor extremamente versátil.

O design robusto permite a sua operação em temperaturas extremas, e a sua carcaça, classificada como IP65, juntamente com múltiplas opções de montagem, garantem adaptabilidade em diferentes contextos industriais.

A longa vida útil da bateria, com até 500,000 transmissões a partir de 6 pilhas AA, assegura uma operação prolongada e confiável. O preço deste sensor varia entre \$419.95 e \$451.95, dependendo das configurações escolhidas.



Figura 13 Predictive Maintenance Sensor V3

### 2.5.2 LEAP SENSORS MOTOR MONITOR

O Leap Sensors Motor Monitor da Phase IV[45] (Figura 14), com um preço de \$780.00, é um dispositivo de monitorização de motores sem fios, concebido para aplicações industriais. Este sistema combina sensores de temperatura, vibração e corrente elétrica num único nó transceptor. A capacidade de monitorizar simultaneamente a corrente AC, a temperatura e os parâmetros de vibração fornecem uma visão abrangente da saúde e do desempenho do motor.

O sensor de vibração do motor, instalável com ímanes ou parafusos, está ligado ao nó transceptor Leap Sensor através de um cabo CAN industrial. Este sistema permite a ligação de múltiplos módulos de vibração (até 30) ao nó transceptor, utilizando um único cabo CAN industrial. O sensor de vibração fornece leituras de força G em três eixos e processa esses dados para gerar informações sobre a aceleração RMS, a velocidade RMS e a aceleração de pico em vibrações radiais e axiais. A capacidade de armazenar um grande número de conjuntos de dados de força G e a utilização de algoritmos avançados de Transformada Rápida de Fourier (FFT) no processamento de dados tornam este sistema particularmente eficaz para a deteção precoce de falhas em motores.

Além disso, a facilidade de implementação e a possibilidade de visualização e alertas em tempo real tornam o Leap Sensors Motor Monitor uma ferramenta valiosa para a manutenção preditiva em ambientes industriais.



Figura 14 Leap Sensor Motor Monitor

### 2.5.3 ABB ABILITY SMART SENSOR

O ABB Ability Smart Sensor[46] (Figura 15) é um dispositivo que transforma motores tradicionais em dispositivos inteligentes e conectados sem fios. Este sensor permite monitorizar a saúde dos motores, otimizando a eficiência e melhorando a confiabilidade e segurança. É ideal para motores industriais AC, tanto de indução como síncronos, e pode ser utilizado em motores de várias dimensões, tanto de velocidade fixa como variável, e em motores novos ou existentes, incluindo aqueles não fabricados pela ABB.

Este sensor avançado monitoriza parâmetros críticos, incluindo a condição geral do motor, vibração total (velocidade RMS), condição dos rolamentos, desalinhamento e temperatura da superfície. Também mede a vibração radial, tangencial e axial (velocidade RMS), a velocidade de operação (RPM), horas de funcionamento, número de arranques, frequência de fornecimento e potência de saída. Além disso, inclui um alarme de lubrificação, uma gama de medição de temperatura e a capacidade de comunicação sem fios Bluetooth. O sensor opera numa gama de temperaturas de  $-40^{\circ}\text{C}$  a  $+85^{\circ}\text{C}$  e tem uma expectativa de vida útil da bateria de 3 a 5 anos, dependendo do uso e das configurações.

O custo do equipamento situa-se nos 200€ pelo dispositivo de monitorização, mas tem de ser acompanhado por uma subscrição anual que acresce a esse valor.




Figura 15 ABB Ability Smart Sensor



# 3

## HARDWARE

Com base no extenso estudo do estado da arte e análise de necessidades industriais, o objetivo primordial do trabalho desta dissertação é a criação de um sistema de sensores de baixo custo, altamente eficaz e não intrusivo. Este sistema é especialmente projetado para monitorizar equipamentos elétricos, com foco em bombas de água e sistemas de Aquecimento, Ventilação e Ar Condicionado (AVAC). O sistema não se limita apenas à captação da assinatura vibracional desses equipamentos, mas também inclui sensores de temperatura e consumo energético, fornecendo uma visão completa do estado do equipamento. Para além disso, o foco é identificar preventivamente que existe uma anomalia, não havendo preocupação nesta fase em identificar a origem dessa anomalia.

Para a gestão e análise dos dados coletados, será desenvolvida uma plataforma IoT robusta, hospedada num servidor local. Esta plataforma servirá como o núcleo para o armazenamento de dados e para a execução de algoritmos de aprendizagem de máquina. Estes algoritmos serão treinados com base nos dados coletados, visando a deteção precoce de anomalias e falhas nos equipamentos monitorizados.

Neste capítulo, serão abordados em detalhe os componentes que compõem o *hardware* do sistema, o seu dimensionamento e as suas ligações. Assim, numa primeira subsecção apresenta-se a escolha e caracterização dos componentes ativos, como os microcontroladores PIC32 e ESP32, responsáveis pela leitura dos sensores e comunicação com a plataforma IoT. A segunda subsecção apresenta a caracterização dos componentes passivos utilizados, como resistências e condensadores, que são cruciais para o funcionamento estável e eficiente dos

componentes ativos. Para esclarecer, considera-se neste contexto, que os componentes ativos são aqueles que são capazes de controlar o fluxo de corrente através de algum tipo de ação externa, enquanto os componentes passivos são aqueles que não têm essa capacidade e apenas reagem às condições do circuito em que estão inseridos.

Posteriormente, na terceira subsecção são apresentadas as ligações e dimensionamento dos componentes para os principais módulos do circuito, para na secção seguinte ser, descritos os protótipos e designs das PCB (*Printed Circuit Boards*, ou placas de circuito impresso). Ainda será abordado o hardware utilizado para o servidor local de IoT.

### **3.1 COMPONENTES ATIVOS**

Nesta secção, o foco estará na seleção e funcionalidades dos componentes ativos que integram o sistema de sensores. Serão discutidos em detalhe os sensores específicos utilizados para a medição da vibração, temperatura e consumo energético. Além disso, abordaremos as soluções implementadas para o armazenamento local de dados, bem como as unidades de controlo que gerem a operação e aquisição de dados dos sensores.

Também será dada especial atenção à conectividade entre os componentes. Os protocolos de comunicação utilizados para a interação entre os vários elementos do sistema serão discutidos sempre que relevante, para fornecer uma compreensão abrangente da arquitetura do sistema.

#### **3.1.1 PLATAFORMA PRINCIPAL E CONECTIVIDADE**

O ESP32 é um *System-on-Chip* (SoC) que se destaca pela sua multifuncionalidade, oferecendo um *Microcontroller Unit* (MCU), conectividade WiFi e Bluetooth, tudo num único chip de baixo custo e baixo consumo energético. Este SoC é amplamente utilizado em aplicações de *Internet of Things* (IoT) e em redes de sensores, sendo uma escolha popular devido à sua versatilidade e eficiência.

Para este projeto, o Wemos D1 Mini ESP32 (Figura 16) foi selecionado como a plataforma central do circuito do sensor, devido a uma série de vantagens. Em primeiro lugar, o dispositivo oferece uma ampla gama de pinos GPIO, permitindo uma grande flexibilidade na integração com outros componentes. Para além disso, o ESP32 suporta múltiplos protocolos de comunicação, incluindo SPI, I2C e UART, cada um com vários canais disponíveis. Isso

torna-o um componente ideal para a comunicação com outros elementos do circuito, bem como para a integração com sensores e periféricos compatíveis com o ecossistema Arduino, para além de ser um dispositivo completo com um custo baixo.

O dispositivo é alimentado por uma tensão de 5 V e é programável em C++ através do Arduino IDE<sup>6</sup>. A programação pode ser feita facilmente através da porta USB incorporada no *Printed Circuit Board* (PCB), simplificando o processo de desenvolvimento e depuração. O ESP32 também oferece opções de personalização, com diferentes modelos disponíveis no mercado que variam em termos de memória e capacidade de processamento, permitindo aos desenvolvedores escolher a versão mais adequada às necessidades específicas do projeto.

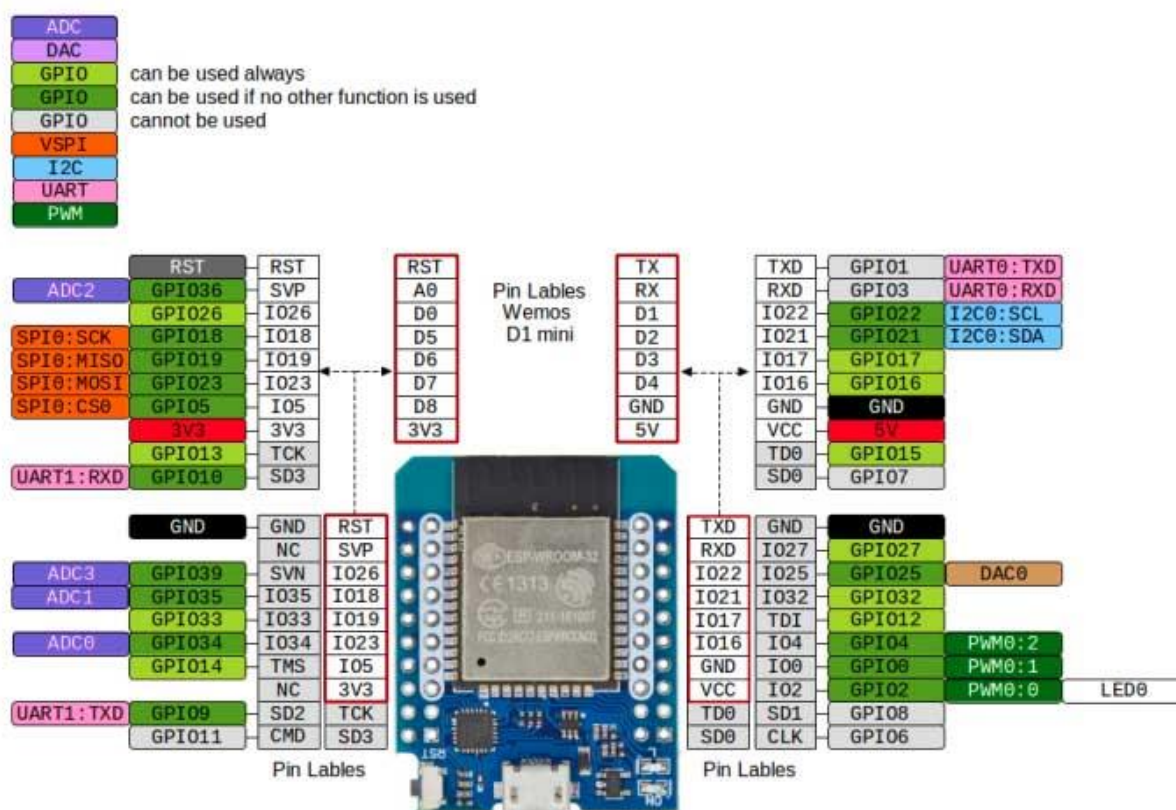


Figura 16 WEMOS D1 Mini ESP32 Pinout

<sup>6</sup> <https://www.arduino.cc/en/software>

### 3.1.2 SISTEMA DE CAPTURA DE VIBRAÇÕES

O núcleo do sistema de sensores neste projeto é, sem dúvida, o sensor de vibração. Dada a complexidade e os custos associados ao processamento de sinal digital, especialmente em aplicações de manutenção preditiva, a seleção e implementação deste componente são críticas. O objetivo é manter os custos baixos sem comprometer a eficácia do sistema, e para isso, várias soluções foram consideradas e serão detalhadas a seguir.

- **Sensor de Vibração:** O sensor de vibração é responsável pela detecção das oscilações mecânicas nos equipamentos monitorizados. A escolha do sensor deve considerar fatores como sensibilidade, faixa de frequência e robustez para operar em ambientes industriais.
- **Amplificador:** Dado que os sinais captados pelo sensor de vibração podem ser de baixa amplitude, um amplificador é utilizado para aumentar o sinal ao nível que possa ser adequadamente processado pelo sistema. O amplificador deve ser cuidadosamente calibrado para evitar a distorção do sinal.
- **Conversor Analógico-Digital (ADC):** O sinal amplificado é então convertido num formato digital através de um Conversor Analógico-Digital (ADC). Este componente é crucial para a qualidade do sinal digitalizado e, conseqüentemente, para a eficácia dos algoritmos de *Machine Learning* aplicados posteriormente.
- **Armazenamento:** Finalmente, uma solução de armazenamento de alta velocidade é implementada para capturar as amostras de dados em tempo real. Isso é especialmente importante para aplicações que requerem uma análise rápida e precisa dos dados capturados.

Cada um desses componentes desempenha um papel vital na captura e processamento das vibrações, e a sua integração eficaz é fundamental para o sucesso do sistema de manutenção preditiva desenvolvido.

### 3.1.2.1 Sensor Piezoelétrico

O sensor escolhido para este projeto foi o sensor piezoelétrico, e por boas razões. Estes sensores operam com base no princípio do acoplamento eletromecânico, que permite a conversão de força mecânica ou térmica em sinais elétricos. Basicamente, um cristal de quartzo é colocado entre duas placas metálicas isoladas, de modo que não conduzam corrente elétrica entre si[47].

Quando este cristal sofre uma deformação devido a força mecânica ou stress térmico, ocorre um desequilíbrio na carga elétrica do cristal. Este desequilíbrio cria uma diferença de potencial elétrico (tensão) entre as duas placas metálicas, que pode ser detetada e medida.

#### Vantagens

- **Resposta Instantânea:** Os sensores piezoelétricos têm uma resposta quase instantânea às mudanças, o que é crucial para a detecção em tempo real.
- **Linearidade:** A resposta do sensor é linear, facilitando a análise e interpretação dos dados.
- **Baixo Custo e Robustez:** Devido ao seu baixo custo e robustez, são amplamente utilizados em diversas aplicações, tornando-os uma escolha ideal para este projeto.

#### Tipos Testados

Foram realizados testes com dois tipos de sensores piezoelétricos:

- **Botão:** Estes são comumente usados para capturar vibrações de alta frequência e são ideais para aplicações industriais (Figura 18).
- **Sela de Arame:** Também são eficazes na captura de vibrações de alta frequência e oferecem uma alternativa ao tipo disco (Figura 17).

Ambos os tipos foram considerados devido à sua eficácia na captura de vibrações de alta frequência, que é um parâmetro crucial para a eficácia deste sistema de monitorização.



Figura 17 Piezo Tipo Arame



Figura 18 Piezo Tipo Botão

### 3.1.2.2 Amplificador

O sinal analógico gerado pelo sensor piezoelétrico é de baixa amplitude, o que torna difícil a sua deteção e análise. Para resolver este problema, um amplificador é necessário para aumentar a amplitude do sinal. O amplificador operacional linear LM358P da Texas Instruments foi escolhido para esta tarefa.

#### Características do LM358P

- **Baixo Custo:** Uma das principais razões para a escolha deste amplificador é o seu baixo custo, o que ajuda a manter o custo total do sistema baixo.
- **Ampla Faixa de Tensão de Operação:** Este amplificador pode operar numa ampla faixa de tensões, tornando-o compatível com a maioria dos microcontroladores. Quando alimentado entre 0V e 5V, permite que a saída tenha valores próximos de zero, sendo o valor máximo superior próximo dos 3.3V que é o valor por nós requerido por ser o valor máximo admissível pelos microcontroladores utilizados.
- **Baixo Consumo de Energia:** O LM358P é conhecido pelo seu baixo consumo de energia, o que é crucial para aplicações IoT, onde a eficiência energética é uma preocupação.
- **Alto Ganho:** O facto de ter um ganho grande permite que ele possa amplificar sinais de baixa amplitude de forma eficaz.
- **Estabilidade Térmica:** O LM358P tem boa estabilidade térmica, o que significa que o seu desempenho é pouco afetado por variações de temperatura.

### Aplicação no Projeto

O LM358P foi escolhido especificamente por sua capacidade de operar eficientemente dentro das tensões habituais de microcontroladores, como o ESP32 e o PIC32, tornando-o ideal para a integração com outros elementos do circuito (Figura 19) (Figura 20). Podemos ver o esquema de ligações deste componente na secção 3.3.3.




Figura 19 LM358P

### 5 Pin Configuration and Functions




Figura 20 LM358P Pinout

### 3.1.2.3 Controlador e Conversor Analógico-Digital

Para a tarefa crítica de amostragem do sinal analógico proveniente do sensor piezoelétrico, um microcontrolador com capacidades de ADC (Conversor Analógico-Digital) é indispensável. O teorema de Nyquist estabelece que a taxa de amostragem deve ser pelo menos o dobro da frequência do sinal a ser amostrado[48]. Neste projeto, os equipamentos operam em torno de 15 kHz, exigindo uma taxa de amostragem mínima de 30 kHz.

Inicialmente, o ESP32 foi considerado para esta tarefa, já que possui pinos com capacidades de ADC. No entanto, a sua taxa de amostragem provou ser inadequada para as necessidades do projeto.

Após testes preliminares com um chip mais lento de 16 bits, a decisão final recaiu sobre o PIC32MX170F256B da Microchip (Figura 21). Este MCU de 32 bits é amplamente utilizado em aplicações IoT devido às suas características de baixo custo e consumo eficiente[49]. Podemos ver o esquema de ligações deste componente na secção 3.3.2.

### Características Principais

- **Alta Taxa de Amostragem:** Este MCU oferece uma taxa de amostragem teórica máxima de 1 MHz, muito acima do requisito mínimo do projeto.
- **Várias Portas ADC:** Dispõe de 10 portas ADC de 10 bits, oferecendo flexibilidade para futuras expansões ou modificações do sistema (Figura 23).
- **Protocolos de Comunicação:** Suporta vários protocolos de comunicação como I2C e SPI, facilitando a integração com outros componentes.
- **Programação:** É programável em *MicroC*, uma linguagem semelhante a C++, através do Programador/*Debugger* Pickit 4 (Figura 22) e o MPLAB X IDE.
- **Clock e Alimentação:** Opera com um *clock* máximo de 50 MHz e uma tensão de alimentação de 3.3V, tornando-o compatível com uma ampla gama de dispositivos e aplicações.




Figura 21 PIC32MX170F256B



Figura 22 PICKIT 4

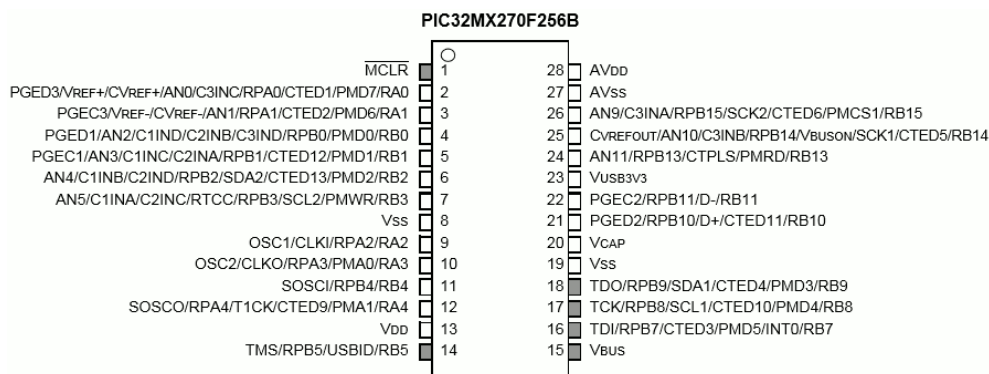


Figura 23 PIC32 Pinout

### 3.1.2.4 Armazenamento

Para armazenar as amostras coletadas pelo sistema de sensores, é crucial escolher uma memória de alta velocidade que possa acompanhar a taxa de amostragem do microcontrolador. Neste contexto, a FM25V20A (Figura 24) foi a escolha ideal para o projeto. Podemos ver o esquema de ligações deste componente na secção 3.3.4.

#### Características Principais da FM25V20A

- **Alta Velocidade:** Este chip de memória de 2 Mbit de RAM ferroelétrica é capaz de armazenar dados à velocidade do barramento de entrada, sem atrasos, tornando-o perfeitamente adequado para aplicações de alta velocidade como esta.
- **Comunicação SPI:** A comunicação com o chip é feita através do protocolo SPI (Interface Periférica Serial) (Figura 25). Embora seja mais lento do que a comunicação paralela, o SPI tem a vantagem de reduzir o número de conexões necessárias para apenas quatro.
- **Eficiência:** Apesar de sua menor velocidade em comparação com as soluções de comunicação paralela, o SPI ainda oferece velocidades que são mais do que adequadas para as necessidades deste projeto.




Figura 24 FM25V20A

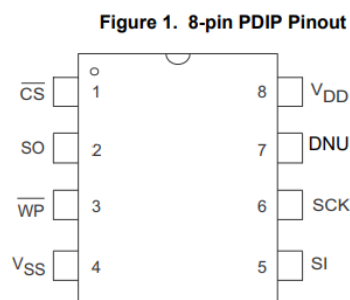


Figura 25 FM25V20A Pinout

### 3.1.3 TEMPERATURA

Para uma monitorização abrangente da temperatura nos equipamentos em estudo, decidiu-se utilizar dois sensores de temperatura. Esta abordagem permite monitorizar dois pontos críticos do equipamento simultaneamente, oferecendo uma visão mais completa do estado térmico do sistema.

## Componentes do Sensor de Temperatura

- **Termopar:** Este é o elemento sensorial que efetivamente mede a temperatura. Termopares são conhecidos pela sua robustez e ampla gama de temperaturas que podem medir, tornando-os ideais para aplicações industriais.
- **Controlador:** Este componente é responsável por ler o sinal do termopar e convertê-lo em dados que podem ser interpretados e utilizados pelo sistema. O controlador também pode incluir funcionalidades como calibração e compensação de temperatura ambiente.

Além disso, os sensores de temperatura escolhidos são compatíveis com os microcontroladores utilizados, permitindo uma integração eficiente e simplificada com o resto do sistema. Os protocolos de comunicação relevantes para a interação entre os sensores e os microcontroladores serão discutidos conforme necessário ao longo desta seção.

### 3.1.3.1 Termopar Tipo K

Termopares do tipo K (Figura 26) são um dos tipos mais comuns e versáteis de termopares, compostos por duas ligas metálicas distintas: Chromel (uma liga de níquel e cromo) e Alumel (uma liga de níquel, manganês, alumínio e silício). O Chromel é não magnético, enquanto o Alumel é magnético devido à presença de níquel (Figura 27)[50].

### Princípio de Funcionamento

O efeito Seebeck ocorre quando dois condutores ou semicondutores diferentes, conhecidos como termopares, são unidos numa de suas extremidades formando um circuito. Quando há uma diferença de temperatura entre a junção (extremidade unida) e as outras extremidades dos materiais, uma diferença de potencial elétrico é gerada. Esta tensão que aparece é diretamente proporcional à diferença de temperatura entre a junção e os pontos abertos. O efeito é linear, o que torna mais fácil a calibração e a leitura.

### Características do Tipo K

- **Gama de Temperatura:** Este tipo de termopar pode operar numa vasta gama de temperaturas, desde  $-270^{\circ}\text{C}$  até  $1260^{\circ}\text{C}$ , tornando-o extremamente versátil para várias aplicações.
- **Sensibilidade:** Aproximadamente  $54\ \mu\text{V}/^{\circ}\text{C}$ , o que é considerado bom para a maioria das aplicações.

- **Custo:** São relativamente baratos em comparação com outros tipos de termopares.
- **Robustez:** São conhecidos pela sua durabilidade e resistência a ambientes hostis, o que os torna ideais para aplicações industriais.

Por todas estas razões, os termopares do tipo K foram a escolha óbvia para este projeto, considerando a necessidade de um sensor de temperatura robusto, preciso e de baixo custo.



Figura 26 Termopar Tipo K




Figura 27 Termopar Tipo K Esquema

### 3.1.3.2 Amplificador e Controlador

O módulo MAX31855 (Figura 28) é um conversor termopar-digital altamente integrado que simplifica grandemente a tarefa de interface com termopares. Este módulo é como um canivete suíço para termopares; ele atua como amplificador (AMP), conversor analógico-digital (ADC) e microcontrolador (MCU) tudo-em-um.

#### Características Principais

- **Amplificador:** Amplifica o sinal de baixa amplitude proveniente do termopar para um nível que possa ser lido mais facilmente.
- **ADC:** Converte o sinal analógico amplificado num sinal digital que pode ser processado por outros componentes eletrónicos.
- **MCU:** Controla todo o processo de leitura e conversão, tornando a integração com outros sistemas muito mais fácil.

### Requisitos de Pinagem

- $V_{CC}$ : Alimentado por uma tensão de 5V.
- **GND**: Ligação à terra do circuito.
- **SPI**: Utiliza um protocolo de comunicação SPI e requer três pinos para isso:
  - **CS (Chip Select)**: Utilizado para iniciar e terminar a transmissão de dados.
  - **CLK (Clock)**: Fornece o ritmo para a transmissão de dados.
  - **SO (Serial Output)**: É o pino de saída de dados.

O módulo não necessita do pino MISO (*Master In Slave Out*) habitualmente usado em SPI, uma vez que ele só precisa enviar dados e não receber. O CS é usado para solicitar uma amostra quando um MCU externo o requer. Podemos ver o esquema de ligações deste componente na secção 3.3.5.2.



Figura 28 MAX31855

### 3.1.4 CORRENTE

O módulo HSTS016L (Figura 29) é uma pinça amperimétrica de núcleo dividido, que utiliza o efeito de Hall para medir a corrente elétrica que passa por um condutor[51]. Este sensor é uma escolha excelente para monitorizar o consumo de energia de forma não intrusiva.

#### Características Principais

- **Efeito de Hall**: Utiliza este princípio para medir a corrente sem necessidade de interromper o circuito elétrico.
- **Núcleo Dividido**: Permite uma instalação fácil, dado que não é necessário desconectar o condutor elétrico.

- **Polaridade:** É crucial respeitar a polaridade e colocar apenas um condutor dentro do núcleo para evitar o cancelamento do efeito de Hall.

### Especificações Técnicas

- **Amplitude de Corrente:** Funciona com valores de corrente até 50 A.
- **Output Analógico:** Produz uma saída de  $2.5\text{ V} \pm 0.625\text{ V}$ , o que permite a leitura de correntes AC e DC.

### Requisitos de Pinagem

- **$V_{CC}$ :** Alimentado por uma tensão de 5V.
- **GND:** Ligação à terra do circuito.
- **Saída Analógica:** Pino que fornece o valor da corrente medida.
- **Pino de Referência:** Utilizado para calibrar a leitura da corrente.

O valor da leitura da corrente é obtido através dos pinos ADC do ESP32, tornando a integração com outros componentes bastante simples. Podemos ver o esquema de ligações deste componente na secção 3.3.5.3.



Figura 29 HSTS016L

### 3.1.5 ARMAZENAMENTO

Para contornar as limitações de memória dos microcontroladores utilizados, foi implementada uma interface para cartão MicroSD (Figura 30) (Figura 31). Este cartão serve como um repositório para armazenar as amostras coletadas dos vários sensores. Podemos ver o esquema de ligações deste componente na secção 3.3.5.4.

#### Funções Principais

- **Backup Local:** Os dados armazenados no cartão MicroSD atuam como um backup local, garantindo que as informações não se percam.
- **Buffer de Dados:** Os dados podem ser armazenados temporariamente no cartão até serem enviados para a plataforma IoT, otimizando o uso da largura de banda e a eficiência do sistema.

#### Armazenamento de Configurações

- **Identificador e Credenciais:** O cartão MicroSD pode armazenar informações cruciais para a operação do sistema, como identificadores únicos e credenciais para a rede WiFi, servidor FTP e API.
- **Segurança e Usabilidade:** Armazenar essas informações no cartão em vez de codificá-las diretamente no ESP32 melhora a segurança e a experiência do utilizador, facilitando a configuração e a manutenção do sistema.



Figura 30 MicroSD Adapter



Figura 31 MicroSD Adapter Pinout

### 3.1.6 RELÓGIO

O DS3231 (Figura 32) é um RTC (Real-Time Clock) escolhido para este projeto devido ao seu baixo custo e consumo de energia. É amplamente utilizado em aplicações IoT para manter um registo preciso do tempo (Figura 33).

#### Conexões e Protocolo

- **Alimentação e Terra:** O IC é alimentado por  $V_{CC}$  de 5 V e tem um pino GND.
- **Comunicação:** Utiliza o protocolo I2C para comunicação, necessitando dos pinos SCL e SDA.

#### Funções Adicionais

- **32K:** Este pino fornece um relógio de referência estável e compensada, embora não tenha sido utilizado neste projeto.
- **SQW:** Este pino funciona como um interruptor para operações de alarme e foi integrado no sistema de alimentação geral do circuito.

Uma pilha tipo botão CR2032 de 3 V é usada para manter a memória do RTC em caso de falha de alimentação, garantindo que a hora e a data sejam mantidas.



Figura 32 DS3231 RTC

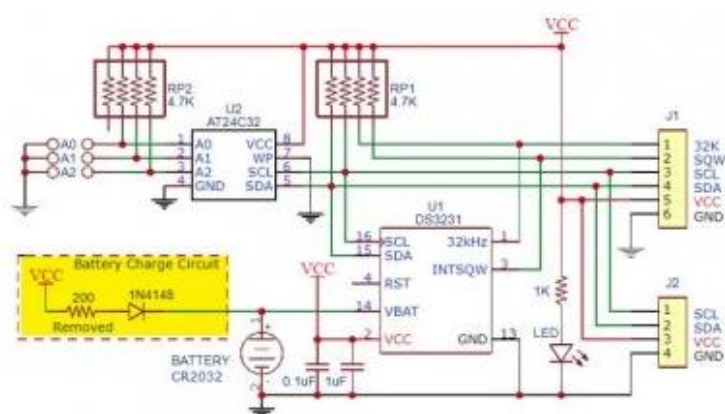


Figura 33 DS3231 Esquema

Este componente foi também utilizado neste projeto como temporizador para controlo de uma estratégia de redução de potência, com a utilização do pino SQW. Podemos ver o esquema de ligações deste componente e a explicação da sua função na secção 3.3.5.5.

### 3.1.7 ECRÃ OLED

O ecrã OLED SSD1309 (Figura 34) foi incorporado ao projeto para permitir uma visualização em tempo real da operação do equipamento. Com uma resolução de 128x64 pixéis e um tamanho de 1.54 polegadas, este ecrã é mais do que adequado para as necessidades do projeto. Podemos ver o esquema de ligações deste componente na secção 3.3.5.5.

#### Eficiência Energética

- **Tecnologia OLED:** A principal vantagem deste módulo é a sua eficiência energética. Em ecrãs OLED, apenas os pixéis ativos são energizados, economizando energia.

#### Interface do Usuário

- **Informações Exibidas:** O ecrã melhora a experiência do utilizador ao exibir informações úteis como o ID dos dispositivos, as redes em uso e o estado atual da operação de amostragem.

#### Conexões e Protocolo

- **Alimentação e Terra:** O módulo é alimentado por  $V_{CC}$  de 5 V e tem um pino GND.
- **Comunicação:** Utiliza o protocolo I2C para comunicação, necessitando dos pinos SCL e SDA (Figura 35).




Figura 34 SSD1306 Front



Figura 35 SSD1306 Pinout

## 3.2 COMPONENTES PASSIVOS, ALIMENTAÇÃO E INTERFACE HUMANA

Nesta seção, abordaremos todos os outros componentes que compõem o sistema de sensores, além dos já discutidos componentes ativos. Estes elementos, embora possam parecer secundários, são cruciais para o funcionamento eficaz e eficiente do sistema. Incluídos nesta categoria estão:

- **Elementos Passivos:** Componentes como resistências e condensadores que desempenham funções de suporte no circuito.
- **MOSFET:** Transístores de efeito de campo que atuam como interruptores ou amplificadores no sistema.
- **LED de Sinalização:** Utilizados para fornecer feedback visual sobre o estado do sistema.
- **Botões e Interruptores:** Elementos de interface humana que permitem o controle manual do sistema.
- **Circuito de Alimentação:** Responsável por fornecer a energia necessária para todos os componentes do sistema.

Cada um desses componentes será discutido em detalhe, destacando a sua importância, funcionalidade e integração no sistema geral.

### 3.2.1 RESISTÊNCIAS

Em diversas seções do circuito, optou-se pelo uso de resistências cerâmicas comuns, que são conhecidas pela sua confiabilidade e baixo custo. Os valores de resistência escolhidos para este projeto incluem 330  $\Omega$ , 1 k $\Omega$ , 2 k $\Omega$  e 10 k $\Omega$  (Figura 36). Cada uma dessas resistências tem um propósito específico, seja para limitar a corrente, atuar como *pull-up* ou *pull-down*, entre outras. Detalhes sobre suas localizações específicas e aplicações serão abordados no capítulo dedicado a este tópico.




Figura 36 Resistências

### 3.2.2 CONDENSADORES

Condensadores foram empregues em várias partes do circuito com diferentes propósitos. Atuando como filtros nas fontes de alimentação e ajudando a suavizar as flutuações de tensão. Além disso, foram usados para filtrar o sinal proveniente do sensor piezoelétrico e para estabilizar o funcionamento do PIC32. Os valores de capacitância selecionados para este projeto são 22pF, 0.1 $\mu$ F e 10 $\mu$ F (Figura 37). Detalhes sobre suas localizações e aplicações específicas serão abordados no capítulo dedicado.



*Figura 37 Condensadores*

### 3.2.3 DÍODOS

O díodo 1N4007GP-E3/73 (Figura 38) foi incorporado ao circuito para fornecer uma camada adicional de segurança contra sobrecargas ou inversões na polaridade dos cabos de alimentação. Em termos simples, um díodo permite que a corrente flua apenas numa direção. Se se conectar os cabos de alimentação de forma invertida, o díodo bloqueará a corrente, protegendo os componentes sensíveis do circuito. Este tipo de díodo é comumente usado em aplicações de retificação e proteção de circuitos, e foi escolhido pela sua robustez e confiabilidade.



*Figura 38 Díodo*

### 3.2.4 REGULADORES DE TENSÃO

No circuito, foram empregues dois tipos de reguladores de tensão: o L7805CV (Figura 39) e o MIC29150-3.3WT (Figura 41). O primeiro, o L7805CV, é responsável por regular a tensão de entrada geral do circuito. Ele pode lidar com uma tensão de entrada máxima de 35 V e fornece uma saída estável de 5 V com uma corrente máxima de 1.2 A. O segundo, o MIC29150-3.3WT, pega esses 5 V e os reduz para 3.3 V. Este último é especialmente útil para alimentar o circuito responsável pelo sensor de vibração, que opera a essa tensão.

Ambos os reguladores são de baixo custo e de fácil integração, o que os torna extremamente populares numa variedade de aplicações. No entanto, eles têm um lado negativo: geram uma quantidade considerável de ruído elétrico nos condutores. Esse ruído deve ser adequadamente filtrado para garantir que não interfere na operação de nenhum dos outros componentes do circuito.

Cada regulador possui três pinos: Input, Output e GND (Figura 40)(Figura 42). Podemos ver o esquema de ligações destes componentes nas secções 3.3.1 e 3.3.2.


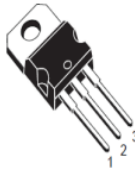
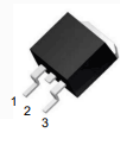


Figura 39 L7805CV

Symbol	Parameter	Value	UNIT
VI	Input Voltage	35	V
TOPR	Operating Temperature Range	0 ~ +125	°C
TSTG	Storage Temperature Range	-65 ~ +150	°C



TO-220



TO-263-3

1 Input 2 Gnd 3 Out

Figura 40 L7805CV Pinout




Figura 41 MIC29150-3.3WT




Figura 42 MIC29150-3.3WT Pinout

### 3.2.5 MOSFET

O baixo consumo de energia é crucial para dispositivos IoT, especialmente aqueles que operam em locais sem acesso à rede elétrica e são alimentados por baterias, portanto, a autonomia é uma prioridade. Para atingir esse objetivo, foi utilizado o MOSFET de canal P IRF9540NPBF (Figura 43) para implementar uma estratégia de *Power Gating*<sup>7</sup> a todo o sistema, sendo este mecanismo de poupança de energia controlado pelo RTC (*Real Time Clock*) DS3231.

Este componente tem três pinos: SOURCE, DRAIN e GATE. A corrente que flui entre o DRAIN e a SOURCE é chamada de  $I_{DS}$ , e a diferença de potencial entre o GATE e o SOURCE é  $V_{GS}$ .

O funcionamento é simples: quando  $V_{GS}$  é positivo e acima de um certo valor,  $I_{DS}$  é zero, cortando a corrente. Quando  $V_{GS}$  é próximo de zero, o MOSFET começa a conduzir corrente ( $I_{DS} > 0$ ) (Figura 44).

O pino SQW do RTC DS3231 é usado para controlar o MOSFET. Quando um alarme é agendado, o pino SQW fica em HIGH e o MOSFET corta a alimentação. Quando o alarme é desativado, o pino SQW vai para LOW, e o MOSFET começa a conduzir corrente novamente. Isto reduz o consumo de energia do sistema inteiro, mantendo apenas o DS3231 alimentado na maior parte do tempo.

A escolha de um MOSFET de canal P é justificada pela operação do pino SQW. Usar um canal P elimina a necessidade de usar dois MOSFETs de canal N, reduzindo assim o consumo desnecessário de energia devido às correntes de fuga associadas a estes dispositivos.

---

<sup>7</sup> *Power Gating* [57] é uma estratégia de redução da dissipação de potência utilizada em circuitos eletrônicos digitais, em que se utiliza um ou mais transistores (muitas vezes denominados por *Sleep Transistors*) como interruptores para a alimentação de um circuito, criando nós de alimentação virtuais e permitindo ligar/desligar a alimentação de todo o circuito, para reduzir a dissipação de potência e permitir a operação do circuito apenas quando for estritamente necessário.



Figura 43 IRF9540NPNBF




Figura 44 IRF9540NPNBF Schema

### 3.2.6 INTERFACE HUMANA E CONTROLE DO SISTEMA DE SENSORES

Para permitir uma interação mais direta e eficaz com o sistema de sensores, várias funcionalidades de controle foram incorporadas.

#### Interruptor Deslizante (500SSP3S1M2QEA)

Este interruptor permite ao utilizador desligar completamente o sistema ou escolher a fonte de alimentação desejada, seja ela externa ou a bateria interna. Isso oferece flexibilidade na operação e manutenção do sistema (Figura 45)(Figura 46).



Figura 45 ON-OFF-ON Interruptor Deslizante



Figura 46 Esquema Interruptor Deslizante

#### Botão de Leitura Forçada (PVA1 OA H1 1.2N V2)

Este botão permite ao utilizador forçar uma leitura dos sensores do sistema quando pressionado por alguns segundos. Sendo útil para testes e diagnósticos rápidos, mesmo quando o sistema está em modo de economia de energia (dormindo) (Figura 47)(Figura 48)(Figura 49).



Figura 47 Push Button



Figura 48 Button Cap




Figura 49 Push Button Squema

### Potenciômetro de Controle de Ganho (PDB12-H4301-105BF)

Este potenciômetro de 1 M $\Omega$  permite ao utilizador ajustar o ganho do amplificador operacional. Isso é crucial para adaptar o sistema às diferentes intensidades de vibração dos equipamentos monitorizados (Figura 50).



Figura 50 1M $\Omega$  Potenciômetro

### Indicadores LED

- **LED de Energia:** Indica quando o sistema está ligado e operacional.
- **LED de Status de Amostragem:** Acende quando o sistema está no processo de amostragem e envio de dados para o servidor. Isso fornece uma indicação visual rápida do estado operacional do sistema.

### 3.2.7 TERMINAIS

#### Terminais para Sensores e Baterias (691137710002 e 691137710004)

Estes terminais são usados para afixar os sensores de vibração, temperatura e corrente ao sistema. Além disso, um terminal separado é usado para os cabos que vêm das baterias. Isso facilita a instalação e a manutenção, permitindo uma conexão segura e confiável entre os componentes (Figura 51)(Figura 52).



Figura 51 2 Pin Terminal



Figura 52 4 Pin Terminal

### Terminal DC-IN (G-1005B)

Este é um terminal DC-IN de 5,5 mm projetado para montagem direta em PCB (Figura 53)(Figura 54). Ele serve como a entrada para a alimentação externa do sistema. A tensão de entrada pode variar entre 7 e 12 V e pode ser fornecida por uma fonte de alimentação externa ou transformador. Isso oferece flexibilidade na escolha da fonte de alimentação e facilita a integração do sistema em diferentes ambientes.



Figura 53 5.5 DC-IN Terminal




Figura 54 DC-IN Esquema

### 3.2.8 BATERIA

As células escolhidas são do tipo 18650 (Figura 56), que são conhecidas pela sua alta densidade energética e confiabilidade. Cada célula tem uma tensão nominal de 3,7 V e uma capacidade de 2900 mAh. Estas células são amplamente usadas em várias aplicações, desde laptops até veículos elétricos, devido à sua longa vida útil e eficiência energética.

#### Configuração

As células foram montadas numa configuração específica para atender às necessidades do sistema. Dois grupos de duas células são conectados em paralelo, resultando numa tensão combinada de 7,4 V e numa capacidade total de 5800 mAh. Isto garante que o sistema tenha energia suficiente para operar de forma eficiente por um período prolongado.

### **Suporte para Células**

Um suporte foi adquirido para acomodar e fixar as células ao sistema. Isto facilita a instalação e remoção das baterias e garante uma conexão segura, minimizando o risco de falhas ou desconexões acidentais (Figura 55).



*Figura 55 Suporte de Células*



*Figura 56 18650 Célula de Lítio*

## **3.3 ESQUEMAS DO CIRCUITO**

Este subcapítulo aborda os esquemas de ligação do circuito. Aqui, explicamos como os componentes estão conectados, os protocolos de comunicação usados e o processo de amostragem e envio de dados para o servidor IoT.

### **Protocolos de Comunicação**

Diversos protocolos como SPI e I2C são usados, dependendo das necessidades dos componentes.

### **Amostragem e Transmissão**

O sistema recolhe dados dos sensores e envia-os para o servidor IoT. Será incluída uma descrição detalhada do processo, explicando como os dados são coletados e enviados.

### **Sistema de Alimentação**

O circuito é alimentado com dois níveis de tensão: 5 V e 3,3 V para atender às diferentes necessidades dos componentes.

### 3.3.1 CIRCUITO 5 V

O sistema pode ser alimentado por duas fontes: uma bateria ou uma fonte de alimentação externa. Um interruptor ON-OFF-ON permite alternar entre as duas fontes (Figura 57).

#### Proteção do Sistema

Um diodo 1N4007GP-E3/73 é colocado logo após as entradas de alimentação para proteger o sistema contra inversão de polaridade e picos de corrente.

#### Regulador de Tensão

O regulador de tensão L7805CV é usado para fornecer uma saída estável de 5V e 1.2A. Que recebe a tensão das fontes de alimentação após passar pelo diodo de proteção.

#### Controle de Corrente com MOSFET

O MOSFET IRF9540NPBF de canal P é usado para controlar o fluxo de corrente para o resto do sistema. A GATE do MOSFET é ligada ao pino SQW do RTC DS3231, permitindo que o sistema entre em modo de baixo consumo, quando não está em uso.

#### Filtro de Ruído

Um condensador é colocado após o regulador de tensão para filtrar qualquer ruído elétrico que possa interferir com o funcionamento dos componentes.

#### Indicadores e Controles

Um LED é usado como um indicador visual para mostrar quando o sistema está ligado. Um botão está conectado entre a GATE do MOSFET e o GND. Que quando pressionado, força o sistema a "acordar" e a realizar uma leitura dos sensores.

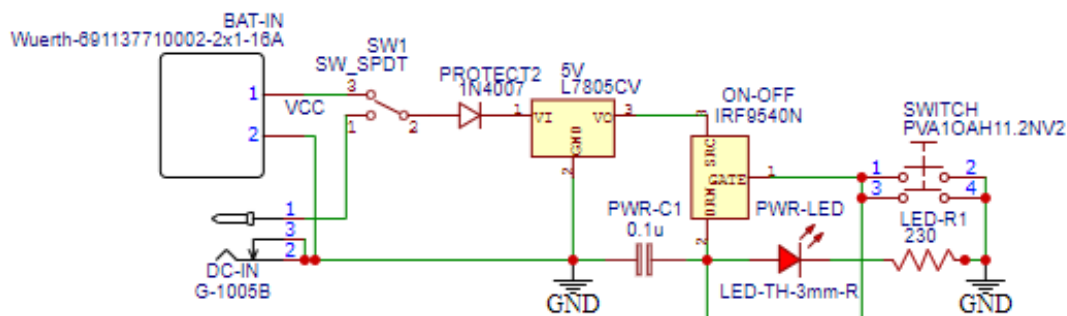


Figura 57 Circuito de Alimentação

### 3.3.2 CIRCUITO 3.3 V

Para fornecer energia aos componentes que operam a 3.3 V, um regulador de tensão MIC29150-3.3WT foi incorporado ao circuito. Este IC recebe 5 V do circuito principal e converte essa tensão para um output estável de 3.3 V (Figura 58).

#### Filtro de Ruído

Tal como no circuito de 5 V, é utilizado um condensador depois do regulador de tensão para filtrar qualquer ruído elétrico que possa ser gerado pelo próprio regulador. Isto garante que os componentes alimentados por 3.3 V operem de forma estável e confiável.




Figura 58 Circuito Regulador 3.3 V

### 3.3.3 CIRCUITO DE AMPLIFICAÇÃO

Este circuito é alimentado a 3.3 V e utiliza uma configuração conhecida como Amplificador Operacional em Configuração de Alimentação Única. Nesta configuração, o amplificador é alimentado apenas com uma fonte de tensão positiva, tornando-o ideal para sistemas que não têm uma fonte de tensão negativa disponível (ou fonte de alimentação simétrica).

Esta estratégia de utilizar uma alimentação simples em vez de alimentação simétrica, impõe no circuito algumas características adicionais, uma vez que é necessário amplificar um sinal alternado de valor médio zero, sabendo que a tensão do amplificador não poderá ser inferior a zero (pois usa uma alimentação simples com valor mínimo zero). Assim, são utilizados condensadores de polarização que permitem criar 2 circuitos de amplificação simultâneos no amplificador, ou seja: (1) em DC, o circuito amplificador funcionará como *buffer* e posicionará os valores médios das tensões em 1.65 V; (2) em AC, o circuito funcionará como um amplificador, amplificando um sinal alternado cujo valor máximo de amplitude não excede os 3 V, tendo o valor médio definido pelo circuito DC.

O circuito da entrada negativa do AmpOp (Amplificador Operacional) começa com um condensador de  $10\mu\text{F}$  que filtra a entrada positiva do elemento piezoelétrico. Seguem-se duas resistências em série, com o ponto entre elas servindo como input negativo do AMP e a segunda resistência atuando como feedback negativo. Este último é um potenciômetro, permitindo o ajuste do ganho do AMP. Isso aumenta a adaptabilidade do sistema a várias intensidades de vibração, evitando que os sinais saiam da escala e reduzam a viabilidade da informação coletada.

O circuito da entrada positiva do AmpOp apresenta um divisor de tensão que estabelece o input positivo do AMP a  $1.65\text{ V}$ . Este nível de tensão serve como uma referência virtual para a amplificação. Além disso, um condensador de  $22\text{pF}$  é utilizado para filtrar qualquer ruído residual que possa interferir no desempenho do sistema.

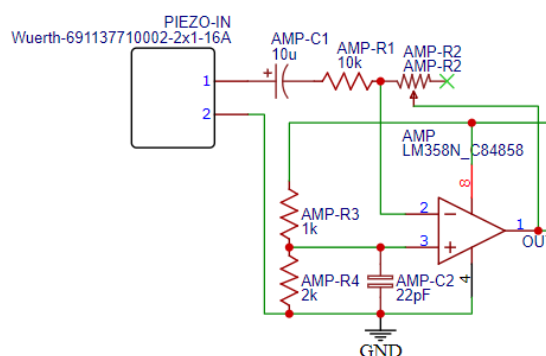


Figura 59 Circuito do Amplificador

### 3.3.4 PIC32 E FRAM

Ambos os chips, o PIC32 e a FRAM, são alimentados com  $3.3\text{ V}$  e comunicam-se através do protocolo SPI. Os pinos CS, SCK, MOSI e MISO da FRAM estão conectados aos pinos B7, B14, B8 e B11 do PIC32, respectivamente. O MCU (PIC32) amostra o sinal proveniente do amplificador (AMP) no pino A0 a uma taxa de  $60\text{ kHz}$  e com uma resolução de 10 bits. Cada leitura é então armazenada na FRAM para posterior análise. Além disso, o PIC32 também se comunica com o ESP32 através de SPI, usando os pinos B10, B15, B6 e B10 no PIC32 para os pinos CS, SCK, MOSI e MISO, respectivamente com o PIC32 com o papel de MASTER e o ESP32 de SLAVE. Os pinos DNU e WP da FRAM são fixados junto à alimentação, garantindo uma operação estável.

Para facilitar a programação e depuração, foram incluídas no PCB as ligações necessárias para injeção de código no PIC32 através do Pickit4. Isso permite uma maior flexibilidade durante o desenvolvimento e testes, permitindo atualizações de *firmware* de forma eficiente.

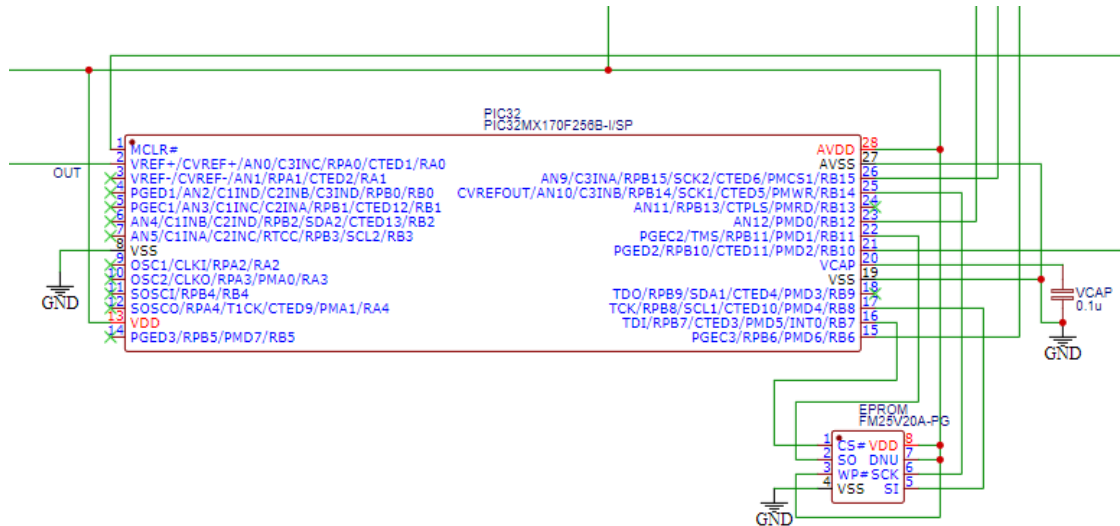


Figura 60 Circuito PIC32 e FRAM

### A sequência de operações é a seguinte

- O ESP32 ativa o PIC32, colocando o pino MCLR em estado HIGH.
- Após a inicialização, o PIC32 levanta uma FLAG no pino B12, sinalizando ao ESP32 que está ocupado com o processo de amostragem.
- Cada amostra é enviada para a FRAM via SPI e armazenada.
- Uma vez concluído o processo de amostragem, o PIC32 solicita os dados da FRAM e envia-os para o ESP32 a uma taxa de transmissão mais lenta.
- Quando o processo é concluído, o pino B12 volta ao estado LOW, indicando ao ESP32 que pode prosseguir com as suas tarefas subsequentes.
- Finalmente, o ESP32 coloca o pino MCLR em estado LOW, desativando o PIC32 e minimizando o consumo de energia até o próximo ciclo de operação.

### 3.3.5 ESP32, SENSORES, ARMAZENAMENTO E RTC

Nesta seção, serão abordados os componentes críticos que constituem a arquitetura do sistema de sensores. A discussão será segmentada em cinco subcapítulos, focando especificamente no ESP32, nos Sensores, no Armazenamento e no Relógio de Tempo Real (RTC). Cada subcapítulo elucidará o papel e a importância desses componentes no funcionamento global do sistema.

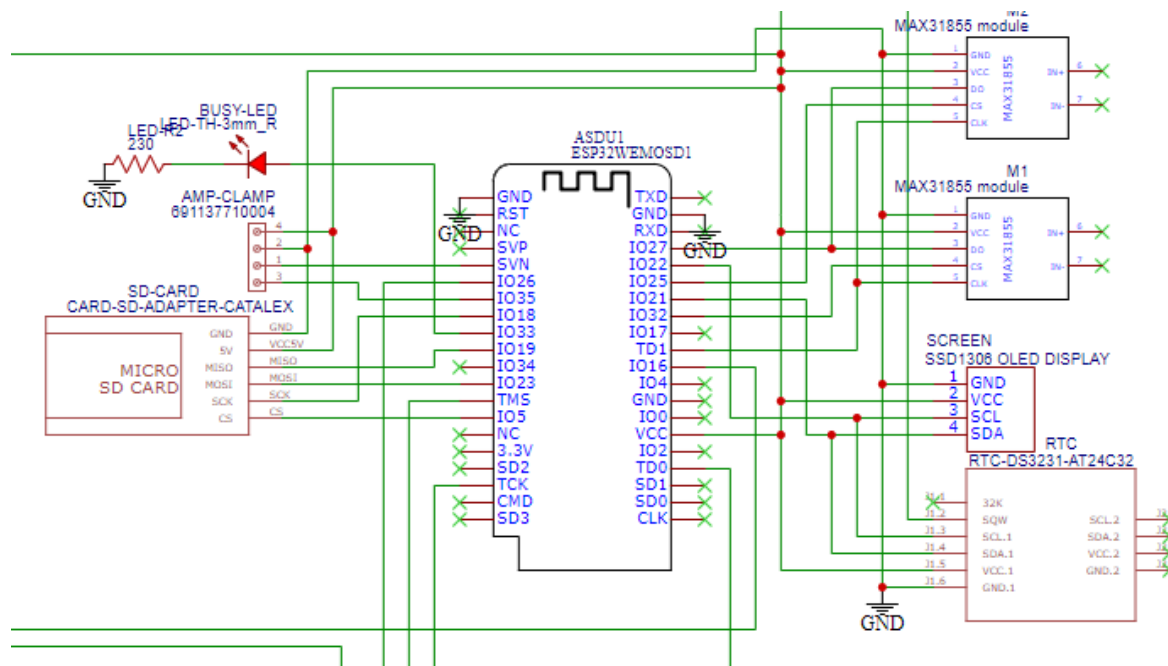


Figura 61 Circuito de Sensores e Controle

#### 3.3.5.1 ESP32

O núcleo operacional do circuito é o ESP32, um microcontrolador de alto desempenho que serve como a unidade central de processamento e gestão do sistema. Além das capacidades de processamento, o ESP32 é dotado de funcionalidades de conectividade robustas, que permitem uma comunicação eficaz com servidores IoT através da Internet. Esta ligação é fundamental para a transmissão de dados sensoriais e para o controle remoto do sistema.

Um indicador LED, ligado ao pino 33 do ESP32, foi incorporado para fornecer feedback visual durante o processo de amostragem. Adicionalmente, o *on-board* LED também serve como um indicador de sucesso no estabelecimento da conexão à Internet, fornecendo uma interface intuitiva para o utilizador e contribuindo para uma melhor experiência.

### 3.3.5.2 Sensores de Temperatura

Os sensores de temperatura aplicados no sistema utilizam um protocolo de comunicação SPI (*Serial Peripheral Interface*) de três fios. Este protocolo foi escolhido devido à sua eficiência e capacidade de permitir múltiplos dispositivos no mesmo barramento. Os pinos DO (*Data Output*) e CLK (*Clock*) dos sensores são compartilhados e conectados aos pinos 27 e TD1 do ESP32, respetivamente.

Para distinguir entre os dois sensores durante a operação, cada sensor é equipado com um pino CS (*Chip Select*) dedicado. Estes pinos CS estão conectados aos pinos 25 e 32 do ESP32. A ativação deste pino permite ao sistema capturar uma amostra de cada sensor de forma individualizada.

Esta configuração permite uma comunicação eficaz e precisa entre o ESP32 e os sensores de temperatura, contribuindo para a redução do número de ligações no circuito sem comprometer a integridade dos dados coletados.

### 3.3.5.3 Sensor de Corrente

O módulo sensor de corrente utilizado no sistema fornece uma saída analógica que é amostrada pelo ESP32 no pino 39. Paralelamente, uma amostra do output de referência é capturada no pino 35 do mesmo microcontrolador. Esta configuração dual permite uma comparação direta entre o sinal medido e um valor de referência, aumentando assim a precisão da medição.

Após a recolha de um conjunto de 4000 leituras, o ESP32 procede ao cálculo dos valores RMS (*Root Mean Square*) da corrente. Este método estatístico fornece uma medida mais precisa da magnitude da corrente, permitindo uma melhor análise e monitorização do consumo de energia do sistema.

Este procedimento assegura uma medição de corrente altamente precisa e confiável, que é crucial para a monitorização eficaz do equipamento.

### 3.3.5.4 Adaptador de Cartão SD

O adaptador de cartão SD é alimentado com uma tensão de 5 V e estabelece comunicação com o ESP32 através do protocolo SPI (*Serial Peripheral Interface*) com o ESP32 no papel de MASTER. Os pinos específicos para essa comunicação são configurados da seguinte forma:

- O pino CS (*Chip Select*) está conectado ao pino 5 do ESP32.
- O pino SCK (*Serial Clock*) está conectado ao pino 18 do ESP32.
- O pino MOSI (*Master Out Slave In*) está conectado ao pino 23 do ESP32.
- O pino MISO (*Master In Slave Out*) está conectado ao pino 19 do ESP32.

### 3.3.5.5 Ecrã OLED e Relógio

Ambos os dispositivos, o ecrã OLED e o RTC DS3231, estabelecem comunicação com o ESP32 através do protocolo I2C (*Inter-Integrated Circuit*). Os pinos SCL (*Serial Clock*) e SDA (*Serial Data*) são compartilhados entre os dois componentes e estão conectados aos pinos 22 e 21 do ESP32, respetivamente.

O pino SQW do DS3231 está diretamente conectado à GATE do MOSFET IRF9540NPBF. Isso permite que o RTC controle o fluxo de energia para o sistema, ativando ou desativando conforme necessário.

É importante notar que o RTC é o único componente do circuito que é alimentado diretamente pelo output do regulador de tensão de 5 V. Isto garante que ele tenha energia suficiente para "acordar" o resto do sistema quando necessário.

### 3.4 PROTÓTIPOS E DESIGN DO PCB

Após a seleção de componentes e elaboração do esquema de circuito, a fase de prototipagem é crucial para validar o design. Vários protótipos são desenvolvidos para identificar falhas e avaliar o desempenho do circuito final.

#### 3.4.1 PROTÓTIPO EM BREADBOARD

Na fase inicial de prototipagem, a utilização de uma *breadboard* foi empregue para testar a funcionalidade e compatibilidade de cada componente individualmente. As *breadboards* oferecem a vantagem de permitir a rápida configuração de circuitos sem a necessidade de soldagem, embora sejam ineficientes em termos de otimização espacial.

Após a verificação bem-sucedida de cada componente, a complexidade do sistema foi incrementada de forma gradual. Isso envolveu a integração de múltiplos elementos no circuito e a resolução de problemas emergentes relacionados à compatibilidade e eficiência operacional.

Com a validação bem-sucedida do sistema na sua totalidade na configuração de *breadboard*, a transição para a próxima fase de prototipagem foi iniciada.




Figura 62 Protótipo Breadboard

### 3.4.2 PROTÓTIPO EM THROUGH HOLE BOARD 1.0

Na segunda fase de prototipagem, optou-se pela utilização de uma *Through Hole Board* com o objetivo de criar um protótipo mais robusto e apto para testes práticos. Este tipo de placa oferece maior resistência a impactos e outros tipos de stress mecânico, além de otimizar significativamente o espaço ocupado pelo circuito. No entanto, a elaboração de um circuito em *Through Hole Board* é mais complexa e trabalhosa em comparação com a *breadboard*.

Esta primeira iteração do protótipo em *Through Hole Board* incorporou apenas o sistema de controle e o sistema de amostragem de vibração. Notavelmente, o circuito de 3.3 V não foi projetado para ser independente do circuito de 5 V; em vez disso, utilizou-se o regulador interno do ESP32 para reduzir a tensão de entrada. Esta abordagem revelou-se problemática devido à capacidade limitada do regulador interno.




Figura 63 Protótipo 1.0 Superior




Figura 64 Protótipo 1.0 Inferior

### 3.4.3 PROTÓTIPO EM THROUGH HOLE BOARD 1.1

Na subsequente iteração do protótipo, foram incorporadas diversas melhorias e adições ao sistema. Elementos de interface, como botões, foram adicionados, bem como a inclusão dos restantes sensores. É importante destacar que foi implementado um circuito de 3.3 V totalmente independente, alimentado por um regulador de tensão dedicado. Esta modificação visou mitigar as limitações observadas na versão anterior relacionadas ao uso do regulador interno do ESP32.




Figura 65 Protótipo 1.1 Frente




Figura 66 Protótipo 1.1 Trás




Figura 67 Protótipo 1.1 Inferior

### 3.4.4 DESENVOLVIMENTO DO PCB

Após a obtenção de resultados satisfatórios com os protótipos iniciais, a fase seguinte consistiu na elaboração de um PCB (*Printed Circuit Board*) mais refinado e finalizado. Para este propósito, foi utilizado o *software* CAD EasyEDA<sup>8</sup>, uma ferramenta gratuita que oferece uma vasta biblioteca de componentes. Esta biblioteca inclui tanto esquemáticos como pegadas físicas no PCB, provenientes de bases de dados oficiais e contribuições de outros utilizadores.

O processo de design no EasyEDA inicia-se com a criação do esquema elétrico completo do circuito. É crucial prestar atenção à seleção dos componentes, especialmente quando estes são oriundos de entradas submetidas por utilizadores e não diretamente de bases de dados de peças online confiáveis.

---

<sup>8</sup> <https://easyeda.com/pt>

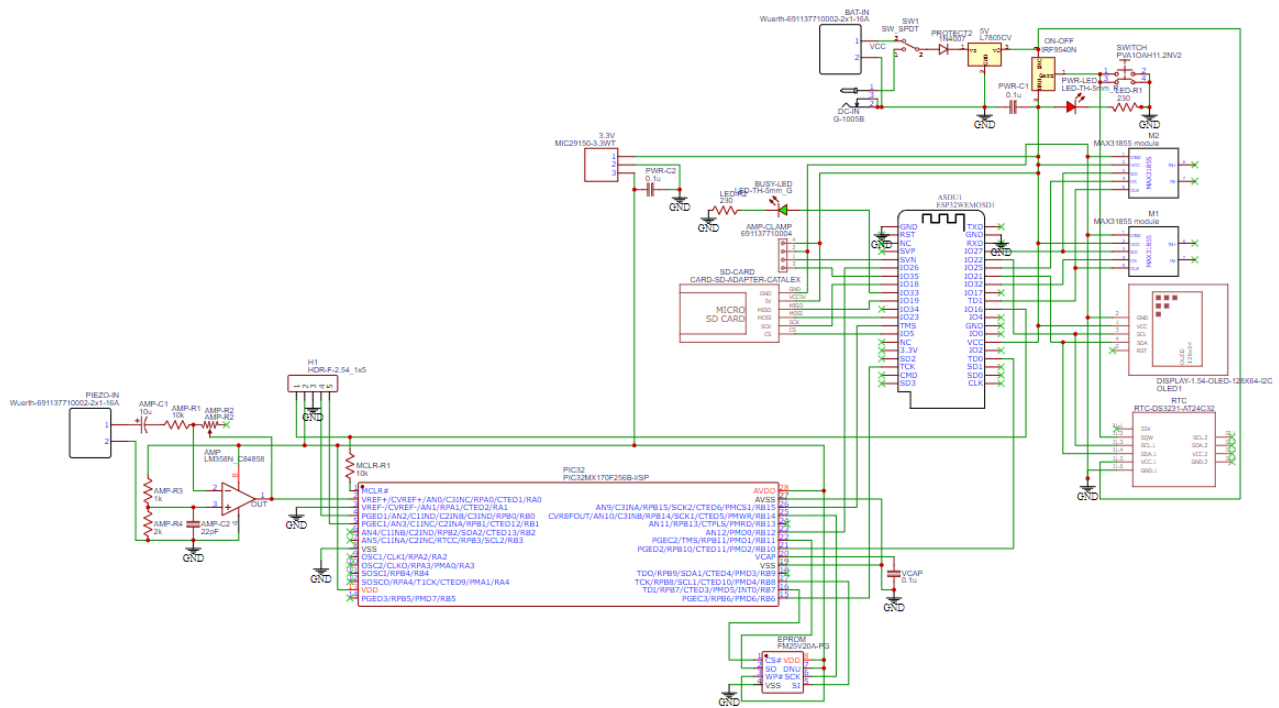


Figura 68 Esquema do Circuito Completo

Após a inserção de todos os componentes e a finalização das ligações elétricas, o passo subsequente é o design do layout do PCB. Este envolve o planeamento do posicionamento dos componentes, com o objetivo de evitar cruzamentos de trilhos desnecessários. Posteriormente, são criadas os trilhos de cobre que interligam os componentes. Uma camada de cobre comum é utilizada para conectar todos os pinos de terra (GND). O PCB final apresenta dimensões de 82.68 x 126.19 mm e é composto por duas camadas, superior e inferior.

Finalmente, o arquivo do PCB é exportado para manufatura. A empresa selecionada para a produção das placas foi a JLCPCB<sup>9</sup>.

<sup>9</sup> <https://jlcpcb.com/>




Figura 69 PCB Design

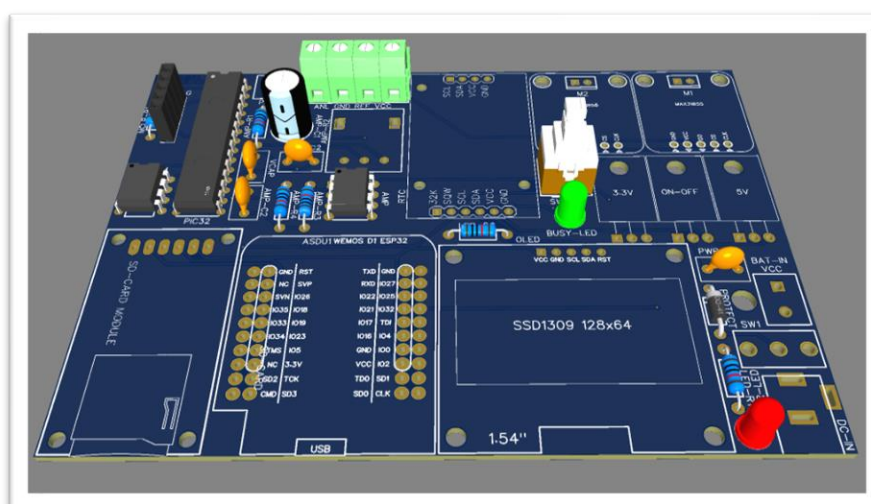


Figura 70 Representação 3D PCB

Após a fase de design e encomenda do PCB, o próximo passo crítico foi a aquisição dos componentes eletrônicos necessários para a montagem do circuito. Todos os componentes previamente descritos foram encomendados a fornecedores confiáveis para assegurar a qualidade e a compatibilidade com o design do PCB.

Uma vez recebidas as peças e o PCB, procedeu-se a uma inspeção visual do circuito impresso para identificar eventuais defeitos de fabricação ou inconsistências no layout.




Figura 71 PCB

Confirmada a integridade do PCB, iniciou-se o processo de montagem dos componentes. As baterias foram estrategicamente posicionadas na face inferior do PCB, e as suas conexões foram encaminhadas através de um orifício especialmente projetado no circuito impresso para esse fim.

Para garantir a proteção do sistema contra elementos externos durante a operação nos locais de estudo, foi desenvolvida uma caixa impressa em 3D. Este invólucro foi projetado para oferecer uma barreira física contra humidade, poeira e outros fatores ambientais que poderiam comprometer a integridade e o funcionamento do sistema eletrónico. A caixa foi também projetada para facilitar o acesso aos componentes para manutenção sem comprometer o acesso a todos os elementos de controlo do equipamento.



Figura 72 PCB Finalizado






Figura 73 Caixa Impressa 3D



*Figura 74 Componentes Adquiridos*

Durante a fase de montagem, alguns desafios foram enfrentados. Alguns componentes chegaram com defeitos de fabrico, exigindo substituições imediatas para evitar comprometimento da funcionalidade do sistema. Além disso, houve casos em que a pegada dos componentes no PCB não se alinhava perfeitamente com os componentes físicos, necessitando de ajustes manuais para garantir uma montagem precisa.

Após a resolução desses problemas e a verificação final da montagem, o protótipo foi considerado finalizado, marcando assim a conclusão desta etapa do projeto.



*Figura 75 Montagem Final*

### 3.5 SERVIDOR IOT LOCAL

No âmbito deste projeto, optou-se pela utilização de um Raspberry Pi 4B como servidor IoT local, dada a sua versatilidade e eficácia comprovadas em aplicações semelhantes[52]. Este microcomputador oferece uma combinação de recursos computacionais, como um CPU de múltiplos núcleos e diversas opções de conectividade, tornando-o adequado para a agregação e processamento de dados provenientes de múltiplos sensores.

A arquitetura implementada permite que os sensores enviem dados para o Raspberry Pi através de uma ligação Wi-Fi local, estabelecida pelo próprio dispositivo a funcionar como hotspot. Esta configuração tornou-se particularmente útil em locais remotos ou isolados onde o acesso à Internet é limitado ou inexistente. Foi também ponderada a incorporação de um HAT com capacidades de comunicação móvel, para permitir o reencaminhamento de dados para servidores externos, embora esta funcionalidade não tenha sido concretizada no contexto deste trabalho. Porém, o microcomputador tem disponível a ligação Ethernet por cabo, que permite a sua ligação à internet para envio dos dados para a *cloud*.

Para assegurar a proteção do sistema em ambientes operacionais variados, foi concebida e fabricada uma caixa impressa em 3D. Esta caixa inclui LEDs indicadores que permitem uma rápida avaliação visual do estado do servidor e da API.




Figura 76 Servidor IoT

# 4

## SOFTWARE

Este capítulo é consagrado à análise pormenorizada do *software* desenvolvido para complementar a arquitetura de *hardware* do sistema. O ecossistema de *software* é multifacetado, abrangendo desde o *firmware* dos microcontroladores até as aplicações de servidor e algoritmos de aprendizagem de máquina (ML). O *software* é dividido em três componentes principais: o servidor FTP, a API de gestão de dados e os scripts de treino e teste dos algoritmos ML, que juntos formam o núcleo do sistema IoT.

O código para os microcontroladores PIC32 e ESP32 foi desenvolvido utilizando, respetivamente, o MPLABX IDE<sup>10</sup> com a linguagem MicroC e o Arduino IDE<sup>11</sup> com a linguagem ArduinoC. Estes controladores são responsáveis pela aquisição de dados dos sensores e pela comunicação com os outros componentes do sistema.

Por outro lado, o código para o servidor FTP e a API, bem como os algoritmos de ML, foram desenvolvidos em Python<sup>12</sup> 3.11.3 utilizando o IDE PyCharm da JetBrains<sup>13</sup>.

---

<sup>10</sup> <https://www.microchip.com/en-us/tools-resources/develop/mplab-x-ide>

<sup>11</sup> <https://www.arduino.cc/en/software>

<sup>12</sup> <https://www.python.org/>

<sup>13</sup> <https://www.jetbrains.com/pycharm/>

## 4.1 PIC32

O microcontrolador PIC32 desempenha um papel importante na aquisição de dados e na comunicação entre os diferentes componentes do sistema. Para facilitar a configuração e a operação do PIC32, foram criados diversos arquivos de cabeçalho (*header files*). Estes arquivos contêm as definições e configurações necessárias para os diversos módulos e funções, incluindo o módulo ADC (Conversor Analógico-Digital), os dois canais de comunicação SPI (Interface Periférica Serial) e outras funções auxiliares.

O PIC32 opera com um *clock* interno reduzido para 20 MHz para otimizar o consumo de energia. O módulo ADC é configurado para operar num modo de 10 bits, permitindo uma resolução mais alta na aquisição de dados. Ambos os canais SPI são configurados para operar em modo de 8 bits.

Para acomodar as palavras de 10 bits provenientes do ADC, um esquema de "*zero padding*" é utilizado. Cada leitura do ADC é dividida em duas palavras de 8 bits e armazenada consecutivamente na memória FRAM. Este método permite que o sistema realize a amostragem a uma taxa de 60 kHz.

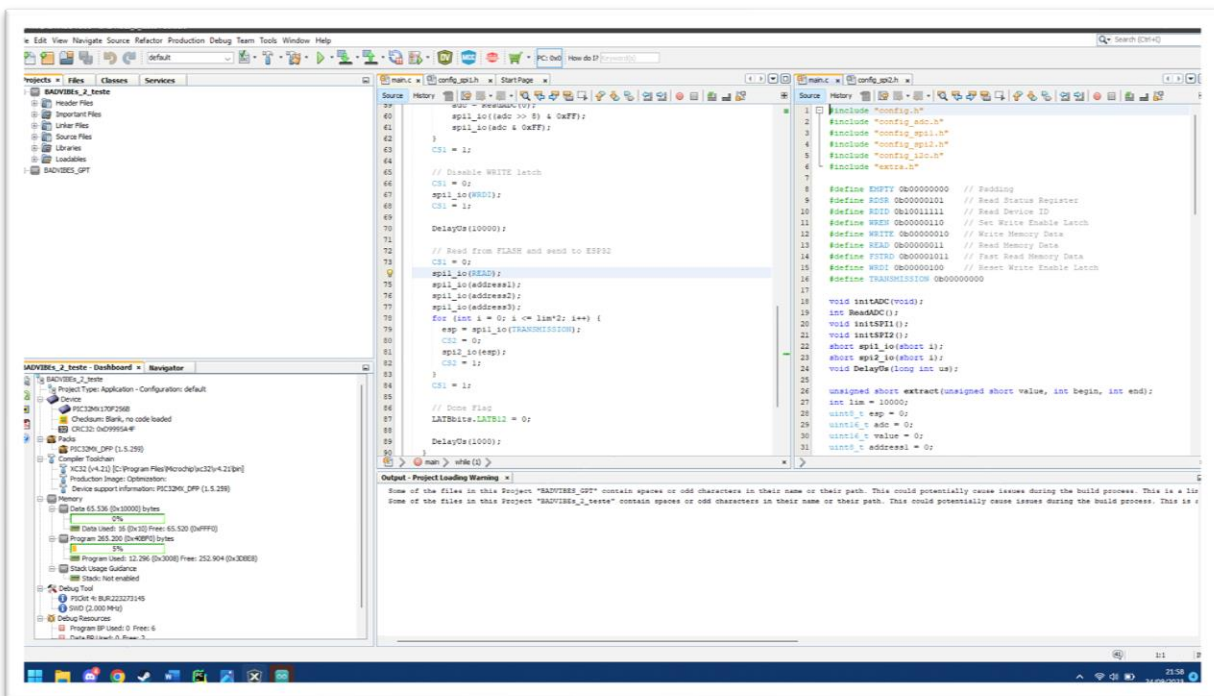


Figura 77 MPLABX IDE

Após a conclusão do processo de amostragem, o PIC32 recupera os dados da memória FRAM e transmite-os para o ESP32 através do segundo canal SPI, mas a uma taxa de transmissão mais lenta para garantir a integridade dos dados. Uma *flag* é levantada no pino B12 para sinalizar ao ESP32 que o PIC32 está ocupado com o processo de amostragem, evitando assim conflitos de comunicação.

## 4.2 ESP32

O ESP32 atua como o controlador principal do sistema, gerindo a operação do PIC32 e de todos os outros sensores. Ele é responsável por coletar amostras de dados, agregá-los e transmiti-los para o servidor FTP. Ao acordar, o ESP32 verifica inicialmente se há algum alarme agendado no relógio RTC. Se houver, o alarme é cancelado, permitindo a ativação manual de uma leitura através de um botão. Em seguida, o ESP32 acede ao cartão SD para ler o arquivo de configuração, que contém as credenciais para a rede Wi-Fi e o servidor FTP. As informações menos sensíveis são exibidas no display OLED.

Após a conexão bem-sucedida com a rede Wi-Fi, o ESP32 comunica-se com a API para determinar se deve proceder com uma leitura de dados. Se a resposta for negativa, um alarme é agendado para uma hora mais tarde, e o sistema devolve ao modo de suspensão. Caso contrário, o processo de amostragem é ativado.

```

143: myFile.println(e.v);
144: myFile.println(0.0);
145: myFile.close();
146:
147: Serial.println("Sending to FTP");
148:
149: ftp.OpenConnection();
150: ftp.sendFile("Type 1");
151: String trial = "sample" + String(ftp_user) + ".txt";
152: char trial2[50];
153: char buf2[50];
154: trial.toCharArray(buf2, trial.length());
155: memcpy(trial2, buf2, 50);
156: ftp.sendFile(trial2);
157: myFile = SD.open(dir);
158: if(myFile){
159:   while(myFile.available()){
160:     unsigned char buf[1024];
161:     memset(buf, 0, 1024);
162:     int readVal = myFile.read(buf, sizeof(buf));
163:     ftp.writeData(buf, sizeof(buf));
164:   }
165:   myFile.close();
166: }
167: ftp.closeFile();
168: myFile.close();
169:
170: http.begin(url + "/vibepred/ingest" + String(ftp_user));
171: http.GET();
172: //int reply = http.getString().toInt();
173: http.end();
174:
175: Serial.println("Done");
176: counter--;
177:
178: }
179:
180:
181: void wifi_connect(){
182:   if(WiFi.status() != WL_CONNECTED){
183:     WiFi.begin(WIFI_SSID, WIFI_PASS);
184:     while(WiFi.status() != WL_CONNECTED){
185:     }
186:   }
187: }
188:
189: void sendFileFTP(const char* path){
190:
191:
192:
193:
194:
195:
196:
197:
198:
199:
200:
201:
202:
203:
204:
205:
206:
207:
208:
209:
210:
211:
212:
213:
214:
215:
216:
217:
218:
219:
220:
221:
222:
223:
224:
225:
226:
227:
228:
229:
230:
231: void loop() {
232:   uLog.begin(uLog2, ULOG_WIDTH, ULOG_HEIGHT, uLog_buffer);
233:   uLog.setRedrawMode(1);
234:
235:   while(enable){
236:     http.begin(url + "/vibepred/enable/" + String(ftp_user));
237:     http.GET();
238:     enable = http.getString().toInt();
239:     if(count == 4){
240:       break;
241:     }
242:     count = count + 1;
243:   }
244:
245:   if(enable == 1){
246:     char buf2[50];
247:     DateTime now = rtc.now();
248:     sprintf(buf2, "%02d:%02d:%02d/%02d/%02d", now.hour(), now.minute(), now.second(), now.day(), now.month());
249:     uLog.println(buf2);
250:
251:     sprintf(buf2, "%02d_%02d_%02d_%02d_%02d", now.hour(), now.minute(), now.second(), now.day(), now.month());
252:     String dir = "sample_" + String(buf2) + ".txt";
253:
254:     SD.begin(SS);
255:
256:
257:
258:
259:
260:
261:
262:
263:
264:
265:
266:
267:
268:
269:
270:
271:
272:
273:
274:
275:
276:
277:
278:
279:
280:
281:
282:
283:
284:
285:
286:
287:
288:
289:
290:
291:
292:
293:
294:
295:
296:
297:
298:
299:
300:
301:
302:
303:
304:
305:
306:
307:
308:
309:
310:
311:
312:
313:
314:
315:
316:
317:
318:
319:
320:
321:
322:
323:
324:
325:
326:
327:
328:
329:
330:
331:
332:
333:
334:
335:
336:
337:
338:
339:
340:
341:
342:
343:
344:
345:
346:
347:
348:
349:
350:
351:
352:
353:
354:
355:
356:
357:
358:
359:
360:
361:
362:
363:
364:
365:
366:
367:
368:
369:
370:
371:
372:
373:
374:
375:
376:
377:
378:
379:
380:
381:
382:
383:
384:
385:
386:
387:
388:
389:
390:
391:
392:
393:
394:
395:
396:
397:
398:
399:
400:
401:
402:
403:
404:
405:
406:
407:
408:
409:
410:
411:
412:
413:
414:
415:
416:
417:
418:
419:
420:
421:
422:
423:
424:
425:
426:
427:
428:
429:
430:
431:
432:
433:
434:
435:
436:
437:
438:
439:
440:
441:
442:
443:
444:
445:
446:
447:
448:
449:
450:
451:
452:
453:
454:
455:
456:
457:
458:
459:
460:
461:
462:
463:
464:
465:
466:
467:
468:
469:
470:
471:
472:
473:
474:
475:
476:
477:
478:
479:
480:
481:
482:
483:
484:
485:
486:
487:
488:
489:
490:
491:
492:
493:
494:
495:
496:
497:
498:
499:
500:
501:
502:
503:
504:
505:
506:
507:
508:
509:
510:
511:
512:
513:
514:
515:
516:
517:
518:
519:
520:
521:
522:
523:
524:
525:
526:
527:
528:
529:
530:
531:
532:
533:
534:
535:
536:
537:
538:
539:
540:
541:
542:
543:
544:
545:
546:
547:
548:
549:
550:
551:
552:
553:
554:
555:
556:
557:
558:
559:
560:
561:
562:
563:
564:
565:
566:
567:
568:
569:
570:
571:
572:
573:
574:
575:
576:
577:
578:
579:
580:
581:
582:
583:
584:
585:
586:
587:
588:
589:
590:
591:
592:
593:
594:
595:
596:
597:
598:
599:
600:
601:
602:
603:
604:
605:
606:
607:
608:
609:
610:
611:
612:
613:
614:
615:
616:
617:
618:
619:
620:
621:
622:
623:
624:
625:
626:
627:
628:
629:
630:
631:
632:
633:
634:
635:
636:
637:
638:
639:
640:
641:
642:
643:
644:
645:
646:
647:
648:
649:
650:
651:
652:
653:
654:
655:
656:
657:
658:
659:
660:
661:
662:
663:
664:
665:
666:
667:
668:
669:
670:
671:
672:
673:
674:
675:
676:
677:
678:
679:
680:
681:
682:
683:
684:
685:
686:
687:
688:
689:
690:
691:
692:
693:
694:
695:
696:
697:
698:
699:
700:
701:
702:
703:
704:
705:
706:
707:
708:
709:
710:
711:
712:
713:
714:
715:
716:
717:
718:
719:
720:
721:
722:
723:
724:
725:
726:
727:
728:
729:
730:
731:
732:
733:
734:
735:
736:
737:
738:
739:
740:
741:
742:
743:
744:
745:
746:
747:
748:
749:
750:
751:
752:
753:
754:
755:
756:
757:
758:
759:
760:
761:
762:
763:
764:
765:
766:
767:
768:
769:
770:
771:
772:
773:
774:
775:
776:
777:
778:
779:
780:
781:
782:
783:
784:
785:
786:
787:
788:
789:
790:
791:
792:
793:
794:
795:
796:
797:
798:
799:
800:
801:
802:
803:
804:
805:
806:
807:
808:
809:
810:
811:
812:
813:
814:
815:
816:
817:
818:
819:
820:
821:
822:
823:
824:
825:
826:
827:
828:
829:
830:
831:
832:
833:
834:
835:
836:
837:
838:
839:
840:
841:
842:
843:
844:
845:
846:
847:
848:
849:
850:
851:
852:
853:
854:
855:
856:
857:
858:
859:
860:
861:
862:
863:
864:
865:
866:
867:
868:
869:
870:
871:
872:
873:
874:
875:
876:
877:
878:
879:
880:
881:
882:
883:
884:
885:
886:
887:
888:
889:
890:
891:
892:
893:
894:
895:
896:
897:
898:
899:
900:
901:
902:
903:
904:
905:
906:
907:
908:
909:
910:
911:
912:
913:
914:
915:
916:
917:
918:
919:
920:
921:
922:
923:
924:
925:
926:
927:
928:
929:
930:
931:
932:
933:
934:
935:
936:
937:
938:
939:
940:
941:
942:
943:
944:
945:
946:
947:
948:
949:
950:
951:
952:
953:
954:
955:
956:
957:
958:
959:
960:
961:
962:
963:
964:
965:
966:
967:
968:
969:
970:
971:
972:
973:
974:
975:
976:
977:
978:
979:
980:
981:
982:
983:
984:
985:
986:
987:
988:
989:
990:
991:
992:
993:
994:
995:
996:
997:
998:
999:
1000:

```

Figura 78 Arduino IDE

Com a autorização para prosseguir, o ESP32 ativa o PIC32 para iniciar o processo de amostragem e começa a escutar o canal SPI correspondente. Os dados coletados são armazenados num arquivo de texto no cartão SD. Posteriormente, as leituras dos sensores de temperatura e corrente são adicionadas ao mesmo arquivo. Este é então enviado para o servidor FTP.

Finalmente, uma solicitação é enviada à API para informar que o processo de amostragem foi concluído. A API responde com o tempo até à próxima leitura, que é usado para agendar o próximo alarme. É importante notar que os dados da amostra de vibração são manipulados em formato binário para preservar a integridade da informação. Além disso, informações sobre o estado do processo de amostragem e o tempo até a próxima leitura são exibidos no display OLED.

### **4.3 SERVIDOR FTP**

O servidor FTP é uma componente crucial do ecossistema IoT, responsável pelo armazenamento e gestão de dados coletados pelos sensores. Este servidor foi implementado utilizando a biblioteca PYFTPLIB, uma biblioteca *Python* robusta e altamente configurável para a criação de servidores FTP.

#### **Criação do Servidor com PYFTPLIB**

Para criar um servidor FTP com a biblioteca PYFTPLIB, é necessário inicializar uma instância do servidor e configurar os parâmetros, como o endereço IP, porta e diretório raiz. A biblioteca oferece uma ampla gama de funcionalidades, incluindo suporte para múltiplos protocolos e métodos de autenticação.

#### **Processos de Upload e Download**

O processo de upload envolve a transferência de arquivos do cliente para o servidor. O cliente inicia uma sessão FTP, autentica-se e envia um comando *STOR* para iniciar o upload. O servidor, por sua vez, aloca espaço e armazena o arquivo no diretório designado.

O download segue um procedimento semelhante, mas inverso. O cliente envia um comando *RETR* para solicitar um arquivo específico. O servidor localiza o arquivo e inicia a transferência de dados para o cliente.



## 4.4 API

A API atua como o núcleo de comunicação entre o servidor IoT e os dispositivos de sensor. Desenvolvida utilizando a micro *framework Flask*<sup>14</sup>, a API é responsável por uma série de tarefas críticas, desde a gestão da base de dados até o processamento de dados de sensores.

### Funcionalidades da API

A API oferece várias rotas e métodos HTTP para interagir com o sistema:

- **Listar Intervalos de Amostragem:** Devolve os intervalos de amostragem para todos os sensores registados.
- **Listar Estado de Ativação:** Fornece o estado de ativação de todos os sensores ou de um sensor específico.
- **Alterar Intervalo de Amostragem:** Permite modificar o intervalo de amostragem de um sensor.
- **Comutar Estado de Ativação:** Habilita ou desabilita a ativação de um sensor.
- **Receber Aviso de Nova Amostra:** Quando uma nova amostra é recebida, a API coloca o ficheiro na localização apropriada e devolve o intervalo de amostragem para o sensor correspondente.

### Processamento de Dados

Ao receber um ficheiro de amostra, a API realiza várias etapas de processamento:

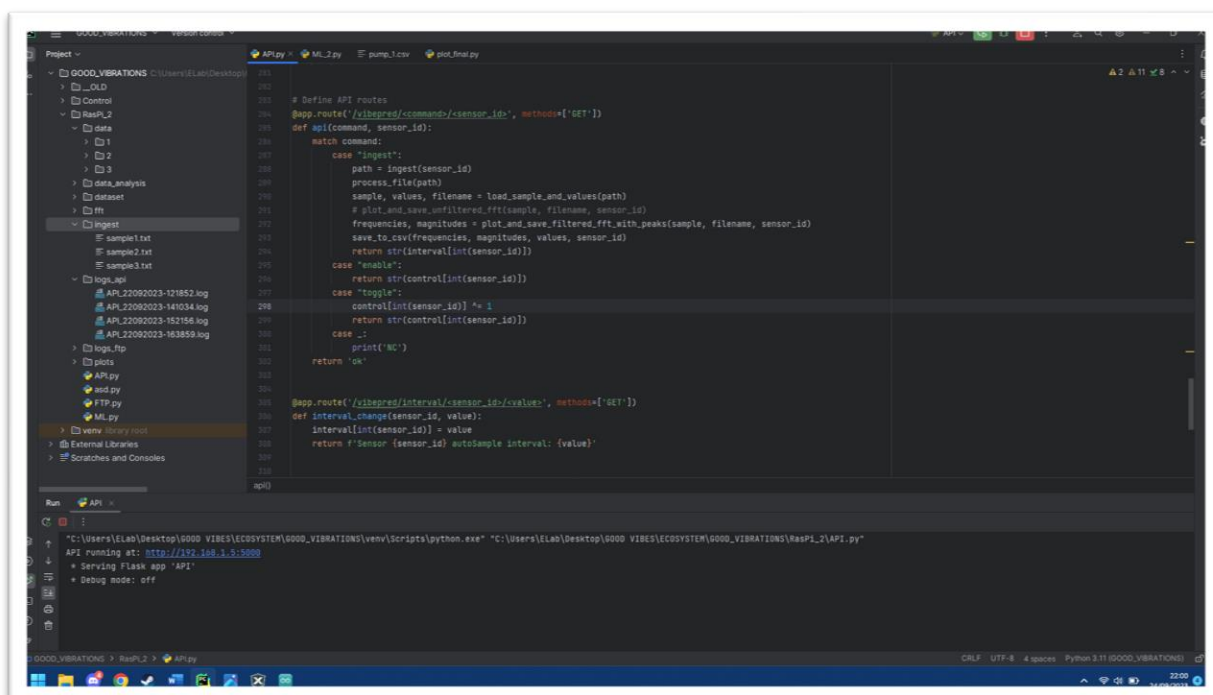
- **Conversão para Decimal:** O ficheiro binário é convertido para formato decimal.
- **Filtragem:** Um filtro passa-baixo digital é aplicado para eliminar ruídos acima de 30 kHz.
- **Transformada Rápida de Fourier:** A FFT é aplicada para transformar o sinal do domínio do tempo para o domínio da frequência.
- **Extração de Picos:** Os picos no espectro de frequência são identificados e suas magnitudes e frequências são extraídas.

---

<sup>14</sup> <https://flask.palletsprojects.com/en/2.3.x/>

## Armazenamento e Análise

Os dados processados, incluindo os valores dos picos, temperatura e consumo, são armazenados num ficheiro CSV. Este ficheiro serve como um conjunto de dados para treinar e testar algoritmos de aprendizagem de máquina. Para fins de demonstração, vários gráficos foram gerados para representar tanto o sinal amostrado quanto a FFT com picos sinalizados.



```
381
382 # Define API routes
383 @app.route('/vibresd/commands/<sensor_id>', methods=['GET'])
384 def api(command, sensor_id):
385     match command:
386         case "ingest":
387             path = ingest(sensor_id)
388             process_file(path)
389             sample, values, filename = load_sample_and_values(path)
390             # plot and save unfiltered fft(samples, filename, sensor_id)
391             frequencias, magnitudes = plot_and_save_filtered_fft_with_peaks(sample, filename, sensor_id)
392             save_to_csv(frequencias, magnitudes, values, sensor_id)
393             return str(interval[int(sensor_id)])
394         case "enable":
395             return str(control[int(sensor_id)])
396         case "toggle":
397             control[int(sensor_id)] ^= 1
398             return str(control[int(sensor_id)])
399         case _:
400             print('NO')
401             return 'ok'
402
403 @app.route('/vibresd/interval/<sensor_id>/<value>', methods=['GET'])
404 def interval_change(sensor_id, value):
405     interval[int(sensor_id)] = value
406     return f'Sensor {sensor_id} autoSample interval: {value}'
407
408
409
410
411
412
413
414
415
416
417
418
419
420
421
422
423
424
425
426
427
428
429
430
431
432
433
434
435
436
437
438
439
440
441
442
443
444
445
446
447
448
449
450
451
452
453
454
455
456
457
458
459
460
461
462
463
464
465
466
467
468
469
470
471
472
473
474
475
476
477
478
479
480
481
482
483
484
485
486
487
488
489
490
491
492
493
494
495
496
497
498
499
500
501
502
503
504
505
506
507
508
509
510
511
512
513
514
515
516
517
518
519
520
521
522
523
524
525
526
527
528
529
530
531
532
533
534
535
536
537
538
539
540
541
542
543
544
545
546
547
548
549
550
551
552
553
554
555
556
557
558
559
560
561
562
563
564
565
566
567
568
569
570
571
572
573
574
575
576
577
578
579
580
581
582
583
584
585
586
587
588
589
590
591
592
593
594
595
596
597
598
599
600
601
602
603
604
605
606
607
608
609
610
611
612
613
614
615
616
617
618
619
620
621
622
623
624
625
626
627
628
629
630
631
632
633
634
635
636
637
638
639
640
641
642
643
644
645
646
647
648
649
650
651
652
653
654
655
656
657
658
659
660
661
662
663
664
665
666
667
668
669
670
671
672
673
674
675
676
677
678
679
680
681
682
683
684
685
686
687
688
689
690
691
692
693
694
695
696
697
698
699
700
701
702
703
704
705
706
707
708
709
710
711
712
713
714
715
716
717
718
719
720
721
722
723
724
725
726
727
728
729
730
731
732
733
734
735
736
737
738
739
740
741
742
743
744
745
746
747
748
749
750
751
752
753
754
755
756
757
758
759
760
761
762
763
764
765
766
767
768
769
770
771
772
773
774
775
776
777
778
779
780
781
782
783
784
785
786
787
788
789
790
791
792
793
794
795
796
797
798
799
800
801
802
803
804
805
806
807
808
809
810
811
812
813
814
815
816
817
818
819
820
821
822
823
824
825
826
827
828
829
830
831
832
833
834
835
836
837
838
839
840
841
842
843
844
845
846
847
848
849
850
851
852
853
854
855
856
857
858
859
860
861
862
863
864
865
866
867
868
869
870
871
872
873
874
875
876
877
878
879
880
881
882
883
884
885
886
887
888
889
890
891
892
893
894
895
896
897
898
899
900
901
902
903
904
905
906
907
908
909
910
911
912
913
914
915
916
917
918
919
920
921
922
923
924
925
926
927
928
929
930
931
932
933
934
935
936
937
938
939
940
941
942
943
944
945
946
947
948
949
950
951
952
953
954
955
956
957
958
959
960
961
962
963
964
965
966
967
968
969
970
971
972
973
974
975
976
977
978
979
980
981
982
983
984
985
986
987
988
989
990
991
992
993
994
995
996
997
998
999
1000
```

```
Run: API
C:\Users\ELab\Desktop\GOOD_VIBES\ECOSYSTEM\GOOD_VIBRATIONS\venv\scripts\python.exe "C:\Users\ELab\Desktop\GOOD_VIBES\ECOSYSTEM\GOOD_VIBRATIONS\BspI_2\API.py"
API running at: http://192.168.1.3:5000
* Serving Flask app 'API'
* Debug mode: off
```

Figura 80 PyCharm IDE API

## 4.5 MACHINE LEARNING

O código em *Python* é responsável por treinar e testar algoritmos de aprendizagem de máquina para detecção de anomalias. Utiliza a biblioteca *scikit-learn*.

### Preparação dos Dados

O conjunto de dados é carregado do ficheiro CSV de cada sensor. Os dados são então preparados, limpos e divididos em conjuntos de treino e teste para alimentar os modelos de aprendizagem de máquina.

#### 4.5.1 MODELOS UTILIZADOS E SUAS CARACTERÍSTICAS

##### Isolation Forest

- **Operação:** Este algoritmo isola as observações ao particionar aleatoriamente o conjunto de dados em subconjuntos. Anomalias são mais fáceis de isolar, tornando o processo mais rápido.
- **Vantagens:** Eficiente em conjuntos de dados de alta dimensão e requer menos memória.
- **Desvantagens:** Pode não ser eficaz em identificar anomalias subtis ou localizadas.
- **Aplicações Sugeridas:** Detecção de fraudes, diagnóstico de sistemas mecânicos.

##### One-Class SVM

- **Operação:** Este algoritmo cria uma fronteira que separa todos os pontos de dados do espaço de origem. Pontos fora dessa fronteira são considerados anomalias.
- **Vantagens:** Bom para detecção de novidades e *outliers* em dados não rotulados.
- **Desvantagens:** Não é eficiente em conjuntos de dados grandes e requer ajuste cuidadoso de hiperparâmetros.
- **Aplicações Sugeridas:** Detecção de anomalias em texto ou imagens.

##### Local Outlier Factor (LOF)

- **Operação:** Este algoritmo mede a densidade local de cada ponto e identifica aqueles que têm uma densidade significativamente menor do que seus vizinhos.
- **Vantagens:** Eficiente em identificar anomalias em clusters de dados.
- **Desvantagens:** Sensível a ruídos e a hiperparâmetros, como o número de vizinhos.

- **Aplicações Sugeridas:** Detecção de anomalias em redes sociais ou em conjuntos de dados de topologia complexa.

### **Elliptic Envelope**

- **Operação:** Este algoritmo assume que os dados são gaussianos e baseia-se na covariância dos dados para definir um “envelope” elíptico.
- **Vantagens:** Bom para dados gaussianos e pode identificar *outliers* globais.
- **Desvantagens:** Não é adequado para dados multimodais e pode ser sensível a ruídos.
- **Aplicações Sugeridas:** Detecção de anomalias em conjuntos de dados pequenos.

## **4.5.2 MÉTRICA DE CERTEZA DE DETECÇÃO DE ANOMALIA**

Cada algoritmo fornece uma métrica de "certeza" que indica a probabilidade de uma amostra ser uma anomalia. Esta métrica varia entre os algoritmos, mas serve como uma ferramenta útil para avaliar a confiança do modelo na classificação de uma amostra como anómala ou não.

### **Isolation Forest:**

- Este algoritmo usa uma pontuação de anomalia que varia de -1 a 1. Uma pontuação próxima de -1 indica uma alta probabilidade de a amostra ser anómala, enquanto uma pontuação próxima de 1 sugere que a amostra é normal.

### **One-Class SVM:**

- A métrica usada aqui é a distância do hiperplano separador no espaço transformado. Um valor negativo indica uma amostra anómala, e quanto mais negativo o valor, maior a certeza de que a amostra é anómala.

### **Elliptic Envelope:**

- Este algoritmo usa a "distância de *Mahalanobis*" para quantificar a semelhança de uma amostra com relação à distribuição geral dos dados. Valores elevados dessa distância sugerem uma alta probabilidade de a amostra ser anómala.

### **Local Outlier Factor:**

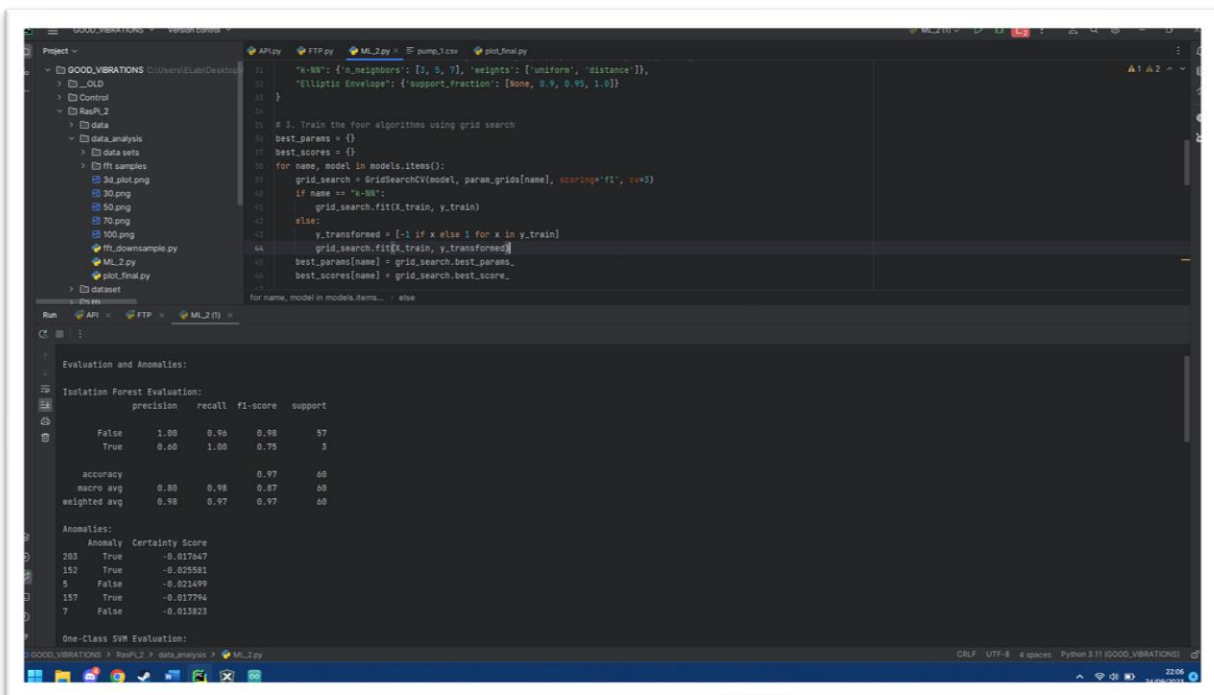
- O fator de *outlier* local (LOF) é calculado, e mede a densidade local da amostra em comparação com os seus vizinhos. Um LOF elevado indica que a amostra é significativamente diferente dos seus vizinhos, sugerindo que é uma anomalia.

### 4.5.3 MÉTRICAS DE AVALIAÇÃO

Para avaliar a eficácia dos algoritmos, foram utilizadas várias métricas:

- **Precisão:** A proporção de verdadeiros positivos sobre o total de verdadeiros e falsos positivos.
- **Recall:** A proporção de verdadeiros positivos sobre o total de verdadeiros positivos e falsos negativos.
- **F1-Score:** A média harmônica da precisão e do *recall*, útil quando as classes estão desequilibradas.
- **Acurácia:** A proporção de previsões corretas sobre o total de previsões.

As anomalias detetadas por cada modelo são registadas para análise posterior, permitindo uma avaliação mais aprofundada das suas capacidades e limitações.



The screenshot shows the PyCharm IDE interface. The top pane displays Python code for training models using Grid Search. The bottom pane shows the output of the training process, including evaluation metrics for Isolation Forest and One-Class SVM, and a list of detected anomalies.

```
20 "k-NN": {"n_neighbors": [3, 5, 7], "weights": ["uniform", "distance"]},
21 "Elliptic Envelope": {"support_fraction": [None, 0.9, 0.99, 1.0]}
22 }
23 # 3. Train the four algorithms using grid search
24 best_params = {}
25 best_scores = {}
26 for name, model in models.items():
27     grid_search = GridSearchCV(model, param_grids[name], scoring='f1', cv=3)
28     if name == "k-NN":
29         grid_search.fit(X_train, y_train)
30     else:
31         y_transformed = [-1 if x else 1 for x in y_train]
32         grid_search.fit(X_train, y_transformed)
33     best_params[name] = grid_search.best_params_
34     best_scores[name] = grid_search.best_score_
35
36 for name, model in models.items():
```

Run Evaluation and Anomalies:

Isolation Forest Evaluation:

	precision	recall	f1-score	support
False	1.00	0.96	0.98	57
True	0.68	1.00	0.75	3
accuracy			0.97	60
macro avg	0.80	0.98	0.87	60
weighted avg	0.98	0.97	0.97	60

Anomalies:

Anomaly	Certainty Score
203	True -0.017647
152	True -0.025581
9	False -0.021499
157	True -0.017794
7	False -0.015823

One-Class SVM Evaluation:

Figura 81 PyCharm IDE ML Training

# 5

## TESTES E APLICAÇÕES DO SISTEMA

Esta secção é dedicada à avaliação empírica do sistema de sensores IoT desenvolvido. Inicialmente, será descrita a operação completa do sistema de sensores, abordando a sua funcionalidade e desempenho. Posteriormente, serão apresentados os testes realizados em diferentes cenários, tanto em ambiente de laboratório quanto em aplicações práticas:

- **Laboratório:** Testando ambos os sistemas de foco com a possibilidade de induzir anomalias de forma controlada.
- **Oceanus Aparthotel<sup>15</sup>, Olhos de Água:** Testes num sistema de Aquecimento, Ventilação e Ar Condicionado (AVAC).
- **Estação de Tratamento de Água (ETA) de Tavira:** Avaliação num equipamento de bombagem de água.
- **Hubel, Olhão:** Testes num sistema de bombagem, com ênfase na integração com a plataforma IoT da FulgurIT<sup>16</sup>, desenvolvida pela Hubel<sup>17</sup>. Esta integração permite não apenas o armazenamento de dados, mas também a possibilidade de incorporar os resultados da deteção de anomalias em sistemas de controle de bombagem já existentes na empresa.

---

<sup>15</sup> <https://www.oceanusaparthotel.com/>

<sup>16</sup> <https://www.hubelengenharia.pt/pt/home/servicos/saas-fulgur-it/>

<sup>17</sup> <https://www.hubel.pt/pt/>

## 5.1 OPERAÇÃO DO SISTEMA

Nesta secção, vamos explorar em detalhe o funcionamento do sistema de monitorização IoT desenvolvido, desde a fase de instalação e configuração até a fase de operação e análise. O objetivo é fornecer uma visão abrangente de como o sistema funciona na sua totalidade, abordando todos os componentes críticos, como sensores, controladores, servidor FTP e API.

### Instalação e Configuração Inicial

- **Seleção do Equipamento:** O primeiro passo é identificar o equipamento que será monitorizado, seja ele um sistema de bombagem, AVAC ou outro.
- **Pontos de Temperatura:** É imperativo identificar os pontos onde os sensores de temperatura serão mais eficazes. Por exemplo, num sistema de AVAC, os sensores podem ser colocados na entrada e saída do ar.
- **Alimentação:** A fonte de alimentação deve ser escolhida com base na disponibilidade de energia no local. Se não houver uma fonte de energia próxima, deve-se considerar o uso de baterias ou outras fontes autónomas.

### Funcionamento

- **Ativação do Sistema:** Ao ser ligado, o sistema inicia uma série de verificações, incluindo a leitura de um ficheiro de configuração no cartão SD para obter credenciais de rede Wi-Fi e servidor FTP.
- **Conexão Wi-Fi:** O sistema tenta conectar-se à rede Wi-Fi. Se for bem-sucedido, prossegue para a próxima etapa.
- **Comunicação com a API:** O ESP32 envia um pedido à API para verificar se deve prosseguir com a leitura dos sensores. Se a resposta for negativa, o sistema agenda um alarme pré-definido e volta a dormir.
- **Amostragem de Sensores:** Se a API autorizar, o ESP32 ativa o PIC32, que começa a amostrar dados dos sensores de vibração. Os dados são então enviados ao ESP32.
- **Leitura de Sensores Adicionais:** O ESP32 também lê os sensores de temperatura e corrente.
- **Armazenamento e Transmissão:** Todos os dados são armazenados num ficheiro no cartão SD e, de seguida, enviados para o servidor FTP.

- **Finalização:** Após o envio bem-sucedido dos dados, o ESP32 envia um pedido final à API, que responde com o tempo até a próxima leitura. O sistema agenda um novo alarme e volta a dormir.
- **Servidor FTP e API:** Enquanto isso, o servidor FTP armazena os dados recebidos e a API processa-os, aplicando algoritmos de aprendizagem de máquina para detecção de anomalias.

Após um número pré-determinado de leituras num sensor específico, o sistema entra numa fase onde é possível treinar o algoritmo de *Machine Learning*. Isso ocorre quando o *dataset* acumulado atinge um volume suficiente para fornecer uma base sólida para o treino. Cada sensor terá um modelo de ML dedicado, otimizado para o equipamento que está sendo monitorizado. Durante esta fase de recolha de dados, a taxa de amostragem é significativamente mais alta do que na fase subsequente de monitorização.

Uma vez que o modelo de ML está treinado e operacional, cada nova amostra recebida pelo servidor FTP é avaliada. O modelo gera um valor que varia de -1 a 1, indicando se a leitura está dentro ou fora do padrão estabelecido. Este "*threshold*" pode ser calibrado para atender às necessidades específicas do equipamento ou da empresa. No caso da Hubel, esse valor pode ser integrado à plataforma IoT FulgurIT, permitindo uma melhor coordenação com os sistemas de controle já existentes na empresa.

## 5.2 TESTES EM LABORATÓRIO

No âmbito deste estudo, foram realizados dois conjuntos distintos de testes em laboratório para avaliar a eficácia e versatilidade do sistema de sensores desenvolvido. O primeiro conjunto de experimentos foi conduzido numa bomba de água, enquanto o segundo focou-se num sistema de ar condicionado. Ambos os testes foram realizados em condições controladas, permitindo a indução de certos tipos de falhas e anomalias para avaliar rigorosamente o desempenho do sistema. Estas experiências em ambientes controlados forneceram uma oportunidade única para entender como o sistema responde a diferentes tipos de erros e condições operacionais, estabelecendo assim um ponto de partida sólido para futuras implementações em cenários mais complexos e menos previsíveis.

### 5.2.1 BOMBA DE ÁGUA

Testes foram realizados numa bomba de água da Grundfos[53] instalada no Instituto Superior de Engenharia da Universidade do Algarve. A configuração incluiu um depósito de água e torneiras que permitiam o controle preciso do fluxo de água. Essas torneiras foram especialmente úteis para induzir erros controlados no sistema, como a aeração. A aeração ocorre quando o ar entra no sistema de bombeamento, causando uma série de problemas como perda de eficiência e potenciais danos ao equipamento. Ao ajustar as torneiras para permitir a entrada de ar, foi possível simular esse fenómeno num ambiente controlado.

O treino e teste dos algoritmos de *Machine Learning* foram realizados sob supervisão, o que significa que cada conjunto de dados foi rotulado com o estado correspondente do sistema (normal ou com aeração). O treino supervisionado é diferente do não supervisionado porque os dados têm rótulos, o que permite uma avaliação mais precisa da performance do algoritmo. Isto é especialmente útil para ajustar o modelo às especificidades do equipamento em teste, permitindo uma deteção de anomalias mais precisa.



Figura 82 Montagem Laboratório



Figura 83 Bomba Laboratório

### 5.2.2 AR CONDICIONADO


O segundo conjunto de testes foi realizado num sistema de ar condicionado da marca Panasonic. O equipamento foi instalado num ambiente controlado e isolado, o que permitiu simular diferentes cenários de funcionamento com precisão. Um dos parâmetros críticos que pôde ser manipulado foi a quantidade de gás no compressor, graças a um depósito externo especialmente instalado para esse propósito.

Três diferentes conjuntos de leituras foram obtidos, variando a quantidade de gás no depósito para 60%, 80%, 90% e 95%. É importante salientar que em condições normais de funcionamento, os níveis de gás no compressor devem estar entre 100% e 90%. Qualquer valor abaixo de 90% é geralmente um indicativo de que o depósito de gás necessita de ser reabastecido para evitar falhas e problemas de eficiência no sistema.


Operar um sistema de ar condicionado com níveis de gás abaixo do recomendado pode resultar numa série de problemas, incluindo:

- **Baixa Eficiência de Resfriamento:** A falta de gás reduz a capacidade do sistema de remover calor, tornando-o ineficiente.
- **Sobrecarga do Compressor:** O compressor precisa trabalhar mais para tentar alcançar a temperatura desejada, o que pode levar ao seu desgaste prematuro.
- **Aumento do Consumo de Energia:** A operação ineficiente resulta num maior consumo de energia, elevando os custos operacionais.
- **Risco de Danos Permanentes:** A operação prolongada nestas condições pode resultar em danos irreversíveis ao sistema.

Portanto, entender como diferentes níveis de gás afetam o desempenho do ar condicionado é crucial para a manutenção preventiva e para otimizar a operação do sistema.



*Figura 84 HVAC Laboratório 1*



*Figura 85 HVAC Laboratório 2*



*Figura 86 HVAC Laboratório 3*

### 5.3 OCEANUS APARTHOTEL


No Oceanus Aparthotel em Olhos de Água, um sensor foi instalado num sistema de AVAC industrial responsável pela climatização da maioria dos quartos na área do hotel. O sensor de vibração foi estrategicamente posicionado na lateral do compressor, onde foi observada a maior intensidade de vibração. Isto é crucial para captar dados mais precisos e relevantes.

Para os sensores de temperatura, áreas de maior e menor temperatura foram identificadas no sistema de AVAC. Isto permite uma visão mais completa do desempenho do equipamento em diferentes condições. Infelizmente, o sensor de consumo elétrico não pôde ser instalado devido a limitações não previstas. O único local viável para sua instalação estava muito distante do resto do sistema, tornando a integração impraticável.

Os dados coletados foram armazenados localmente num servidor IoT executado num Raspberry Pi 4B. Vale ressaltar que este teste foi mais focado na recolha de dados e não na gestão ativa do equipamento com base nas anomalias detetadas. Isso porque os testes foram realizados numa fase mais inicial do projeto, onde o foco era principalmente a recolha e armazenamento de dados.



Figura 87 Instalação Oceanus 1



*Figura 88 Instalação Oceanus 2*

## **5.4 ESTAÇÃO DE TRATAMENTO DE ÁGUAS DE TAVIRA**

Na Estação de Tratamento de Água (ETA) de Tavira, uma instalação operada pela Águas de Portugal, foi realizado um teste de monitorização de uma bomba de água industrial da Grundfos. Esta bomba é de maior dimensão em comparação com a utilizada nos testes na Universidade do Algarve. A Águas de Portugal é uma empresa que desempenha um papel fundamental na gestão de recursos hídricos em Portugal, e a ETA de Tavira é uma instalação crítica para o tratamento e fornecimento de água na região.

Para a instalação dos sensores, foram identificados os pontos de maior vibração e variação de temperatura na bomba. O sensor de corrente foi excluído da instalação devido a dificuldades de acesso ao sistema de alimentação elétrica da bomba.

Dado que o local não tinha acesso à Internet no momento da instalação, foi configurado um servidor local utilizando um Raspberry Pi 4B. O foco deste teste foi posto estritamente na recolha de dados, semelhante ao teste realizado no Oceanus Aparthotel.



*Figura 89 Instalação ETA 1*



*Figura 90 Instalação ETA 2*

## 5.5 GRUPO HUBEL

O Grupo Hubel é uma corporação portuguesa multifacetada, com interesses que abrangem desde a agricultura até a energia renovável e tecnologias da informação. Um dos principais objetivos estratégicos da empresa é a inovação contínua e a eficiência operacional nos setores em que atua. A Hubel desenvolveu uma plataforma de Internet das Coisas (IoT) própria, denominada FulgurIT, que serve como um ecossistema para a gestão e monitorização de diversos sistemas e dispositivos interconectados.

No contexto do projeto em questão, um sensor foi instalado numa bomba de água localizada nas proximidades da sede da Hubel. Este equipamento é responsável pelo sistema de irrigação em campos agrícolas adjacentes. O processo de instalação do sensor seguiu metodologias semelhantes às utilizadas em estudos anteriores, com a exclusão do sensor de corrente elétrica devido a restrições logísticas e de acessibilidade. Um servidor local foi estabelecido utilizando um Raspberry Pi 4B<sup>18</sup>, para facilitar a recolha e transmissão de dados.

A singularidade deste estudo reside na integração dos dados coletados com a plataforma FulgurIT da Hubel. A comunicação entre o sistema de sensores e a plataforma FulgurIT é mediada pelo protocolo MQTT (*Message Queuing Telemetry Transport*). Este protocolo é amplamente utilizado em aplicações de IoT devido à sua eficiência em termos de largura de banda e a sua capacidade de facilitar comunicações bidirecionais. Os dados são encapsulados em objetos JSON (*JavaScript Object Notation*), permitindo uma integração mais fluida e uma interpretação mais fácil dos dados coletados.

---

<sup>18</sup> <https://www.raspberrypi.com/products/raspberry-pi-4-model-b/>

# 6

## RESULTADOS EXPERIMENTAIS

Nesta seção, serão discutidos os resultados experimentais obtidos durante o curso deste estudo. As experiências foram conduzidas em quatro locais distintos, nomeadamente o Aparthotel Oceanus em Albufeira, a Estação de Tratamento de Águas (ETA) de Tavira, o Grupo Hubel em Olhão e o laboratório do Instituto Superior de Engenharia da Universidade do Algarve. Cada local proporcionou um conjunto único de condições e desafios, permitindo uma avaliação abrangente da eficácia das técnicas e algoritmos desenvolvidos.

Também aborda o processo de treino dos algoritmos de aprendizagem de máquina utilizados no estudo. Serão analisadas métricas chave para avaliar o desempenho dos modelos, e os resultados serão discutidos em detalhe.

### 6.1 LABORATÓRIO

Aqui serão discutidos os resultados obtidos a partir das experiências realizadas em ambiente de laboratório. A análise está dividida em duas partes: a primeira é dedicada à bomba de água e a segunda ao sistema de ar condicionado. Ambas as partes visam avaliar o desempenho e eficácia do sistema de sensores em detetar condições anómalas.

#### 6.1.1 BOMBA DE ÁGUA

No ambiente de laboratório do Instituto Superior de Engenharia da Universidade do Algarve, uma bomba da marca Grundfos foi aparafusada firmemente ao chão. Um tanque de água foi utilizado como reservatório para permitir a circulação de água através do sistema de bombeamento. Para simular condições de funcionamento anómalo, uma válvula foi instalada na entrada da bomba.

### Simulação de Funcionamento Anômalo e Recolha de Dados

A simulação de funcionamento anômalo foi realizada através do ajuste parcial da válvula. Esta ação induziu a aeração no sistema, um fenómeno que pode comprometer significativamente a eficiência e longevidade de uma bomba de água. A aeração ocorre quando o ar entra no sistema, podendo causar cavitação e, conseqüentemente, erosão do material da bomba, ruído excessivo e diminuição da eficiência de bombeamento.

Testes foram conduzidos em quatro configurações diferentes da válvula: completamente aberta, 70%, 50% e 30% aberta. Em cada configuração, várias leituras foram obtidas para assegurar a robustez dos dados coletados.




Figura 91 Exemplo Amostra sem Anomalia Bomba Laboratório




Figura 92 Exemplo Amostra Anômala Bomba Laboratório

### **6.1.1.1 Análise dos Dados**

Para obter uma representação mais precisa do funcionamento da bomba em diferentes condições, foram coletadas dez amostras de leituras de vibração em cada configuração da válvula. A transformada rápida de Fourier (FFT) foi aplicada a cada uma dessas amostras para converter o sinal de domínio do tempo para o domínio da frequência.

#### **Redução de Dados a Intervalos de 1 kHz**

As frequências resultantes variaram de 0 a 20 kHz. Para tornar os dados mais manejáveis e focar nas frequências mais significativas, as leituras foram segmentadas em intervalos de 1 kHz. Dentro de cada intervalo, foi selecionado o valor de pico para representar a magnitude da frequência para aquele segmento específico.

#### **Cálculo da Média entre as Leituras**

Uma vez reduzidos os dados, foi calculada a média dos valores de pico em cada intervalo de 1 kHz entre as dez leituras coletadas para cada configuração da válvula. Este passo assegurou uma análise mais robusta, minimizando o impacto de anomalias pontuais ou ruído no sinal.

#### **Análise Espectral e Representação Gráfica**

Finalmente, os dados médios foram utilizados para construir um gráfico 3D, demonstrando como a análise espectral varia conforme o funcionamento da bomba. O gráfico foi elaborado utilizando uma superfície com gradiente de cor, para facilitar a visualização da intensidade das frequências em diferentes condições de operação da bomba.

#### **Dados de Temperatura e Consumo Energético**

Durante o período de testes, os valores de temperatura mantiveram-se constantes. No entanto, é importante notar que as anomalias induzidas no sistema, através do fecho da válvula, não foram mantidas por tempo suficiente para permitir a verificação de eventuais alterações na temperatura. Esta abordagem foi adotada para evitar qualquer dano permanente ao equipamento. Similarmente, o consumo energético não apresentou variações notáveis, mesmo durante os períodos em que a válvula estava fechada. Esta estabilidade nos indicadores de temperatura e consumo energético reforça a importância da análise de vibrações como uma métrica fiável para deteção de anomalias em sistemas como o estudado.




Figura 93 Análise Espectral Bomba Todos Estados 1

3D Surface Plot of FFT Data at Different Pump Performances (Inverted Order)




Figura 94 Análise Espectral Todos Estados 2

### Análise dos Gráficos

A análise espectral dos dados revela padrões distintos dependendo do estado operacional da bomba, descritos a seguir:

- Válvula 100% Aberta:** No funcionamento normal, observa-se um pico de maior magnitude perto dos 5 kHz, com valor aproximado de 22.000. Um pico secundário é notável em torno dos 10 kHz com magnitude de cerca de 14.000. Estes picos podem ser interpretados como as frequências naturais de operação da bomba.




Figura 95 Análise Espectral Bomba Laboratório 100%

- Válvula 70% Aberta:** Com a válvula 70% aberta, o pico de 10 kHz praticamente desaparece e surge um novo pico predominante em torno dos 4 kHz com uma magnitude significativamente elevada de mais de 35.000. Além disso, harmônicos de alta frequência tornam-se quase inexistentes, indicando uma alteração drástica na dinâmica do sistema.




Figura 96 Análise Espectral Bomba Laboratório 70%

- Válvula 50% Aberta:** Ao reduzir ainda mais a abertura da válvula para 50%, o pico em 4 kHz diminui drasticamente para cerca de 15.000, enquanto a frequência principal se desloca para a faixa de 2 kHz com uma magnitude de aproximadamente 18.000.




Figura 97 Análise Espectral Bomba Laboratório 50%

- Válvula 30% Aberta:** Neste cenário, ocorre apenas uma redução geral na intensidade do espectro, em comparação com a configuração de 50%.




Figura 98 Análise Espectral Bomba Laboratório 30%

Com base na análise espectral detalhada, fica claro que há variações significativas no comportamento da bomba, dependendo da posição da válvula.

Neste contexto, optou-se pela criação de um conjunto de dados mais amplo, coletado sob diversas condições de operação da bomba. Este *dataset* servirá como base para o treino e teste de diversos algoritmos de aprendizagem de máquina, com o objetivo de desenvolver um modelo robusto capaz de identificar e, possivelmente, prever estados anômalos da bomba.

### 6.1.1.2 Detecção de Anomalias

Um conjunto de dados composto por 300 amostras foi elaborado para a fase de aprendizagem de máquina. Destas, 19 foram categorizadas como anómalas, representando diversas condições de fecho parcial da válvula.

	voltageL1 :	currentL1 :	voltageL2 :	currentL2 :	voltageL3 :	currentL3 :	anomaly :
183	4344.26	22437.34	4350.57	20676.04	4533.42	17446.57	False
184	5432.2	21078.17	4449.11	20801.59	4373.49	16910.33	False
185	4491.81	20764.31	5172.2	17547.73	4403.61	17319.74	False
186	4406.85	20290.52	4469.9	19106.61	4375.33	18052.31	False
187	4473.38	22963.42	5701.98	20127.63	5664.18	17178.15	False
188	4428.81	19080.94	4466.61	17477.65	4403.61	16997.38	False
189	4469.9	19912.0	4406.85	17002.73	5466.01	15879.56	False
190	4417.6	20371.34	5659.07	17769.46	3623.57	15615.54	False
191	5472.89	19946.59	4533.42	19117.48	4489.28	18537.51	False
192	4560.56	16122.16	4453.32	15313.1	4409.17	14529.92	False
193	5730.8	19270.45	4507.72	18274.43	5535.36	17446.46	False
194	4374.41	16887.58	5716.99	16168.0	5427.04	15292.57	False
195	4570.29	19089.46	5654.55	16955.77	4343.35	16814.09	False
196	4495.11	18550.71	4501.42	17669.58	4469.9	16171.61	False
197	4349.2	19064.84	5698.08	18770.42	5244.25	16301.11	False
198	5787.54	19679.73	5762.32	17851.84	5642.53	17129.99	False
199	5700.47	19980.14	4508.67	19012.58	4344.72	17255.17	False
200	4480.62	17350.78	4360.89	17237.57	5589.75	16334.72	False
201	1850.03	18487.63	1743.05	15690.89	2196.12	13849.01	True
202	1855.93	14220.77	1704.94	14048.36	1912.55	12958.97	True
203	1930.82	11595.51	1754.72	11294.6	1861.64	11024.28	True
204	1792.64	10603.99	2270.68	9691.5	1780.06	9066.32	True
205	2183.53	13260.12	2013.63	11850.64	1831.15	11814.81	True
206	1944.01	14873.51	2019.5	14678.67	2170.49	13798.21	True
207	1856.32	17843.28	1673.83	15636.77	1843.73	12553.98	True
208	1931.63	17515.9	1881.29	14145.99	1837.25	12355.83	True
209	1926.35	14221.91	1781.55	14144.43	1951.53	11091.44	True
210	1667.02	11034.02	2818.2	9806.33	1553.78	9686.25	True
211	5737.7	22950.46	5435.06	19559.13	9438.84	17864.84	False
212	9965.33	15869.09	5193.82	15854.65	5452.25	15096.98	False
213	5486.04	17911.98	4320.81	17177.12	4522.36	17056.75	False

Figura 99 Dataset Bomba

Posteriormente, o conjunto de dados foi dividido em grupos de treino e teste, seguindo boas práticas de aprendizagem de máquina. Foi realizada uma pesquisa em grelha para a otimização dos hiperparâmetros em diversos tipos de algoritmos de detecção de anomalias.

### **Análise dos Resultados do Treino**

Os modelos de aprendizagem de máquina foram treinados e testados em ambiente supervisionado, graças à identificação prévia das amostras anómalas no conjunto de dados. Os melhores parâmetros para cada algoritmo foram identificados como se segue:

- **Isolation Forest:** Contaminação de 0.1, 100 estimadores
- **One-Class SVM:** Kernel linear,  $\nu=0.05$
- **k-NN:** 3 vizinhos mais próximos, pesos uniformes
- **Elliptic Envelope:** Fração de suporte indefinida

### **Análise de Resultados**

#### **Isolation Forest:**

- **Avaliação:** O modelo teve uma acurácia de 92%, mas com uma precisão mais baixa para identificar anomalias (38%).
- **Anomalias:** Detetou mais falsos positivos e teve pontuações de certeza negativas, conforme esperado.

#### **One-Class SVM:**

- **Avaliação:** Este modelo teve um desempenho perfeito, com 100% em todas as métricas.
- **Anomalias:** Identificou corretamente todas as anomalias com certeza muito alta (valores negativos elevados).

#### **k-NN:**

- **Avaliação:** Também teve um desempenho perfeito em todas as métricas.
- **Anomalias:** Detetou todas as amostras anómalas com uma certeza de 1.0.

#### **Elliptic Envelope:**

- **Avaliação:** Acurácia de 95% com uma precisão mais baixa para detecção de anomalias (50%).
- **Anomalias:** Teve algumas falsas detecções, e a pontuação de certeza foi dada pela distância de Mahalanobis.

O One-Class SVM e o k-NN sobressaíram com uma eficácia de 100%, enquanto o *Isolation Forest* e o *Elliptic Envelope* foram menos precisos na detecção de anomalias, ainda que tenham tido acurácias elevadas.

```

Isolation Forest Evaluation:
      precision    recall  f1-score   support

   False         1.00     0.95     0.97         57
    True         0.50     1.00     0.67          3

 accuracy                   0.95         60
 macro avg                 0.75     0.97     0.82         60
 weighted avg              0.97     0.95     0.96         60

```

Figura 100 Resultados ML Bomba 1

```

k-NN Evaluation:
      precision    recall  f1-score   support

   False         1.00     1.00     1.00         57
    True         1.00     1.00     1.00          3

 accuracy                   1.00         60
 macro avg                 1.00     1.00     1.00         60
 weighted avg              1.00     1.00     1.00         60

```

Figura 101 Resultados ML Bomba 2

```

One-Class SVM Evaluation:
      precision    recall  f1-score   support

   False         1.00     1.00     1.00         57
    True         1.00     1.00     1.00          3

 accuracy                   1.00         60
 macro avg                 1.00     1.00     1.00         60
 weighted avg              1.00     1.00     1.00         60

```

Figura 102 Resultados ML Bomba 3

```

Elliptic Envelope Evaluation:
      precision    recall  f1-score   support

   False         1.00     0.95     0.97         57
    True         0.50     1.00     0.67          3

 accuracy                   0.95         60
 macro avg                 0.75     0.97     0.82         60
 weighted avg              0.97     0.95     0.96         60

```

Figura 103 Resultados ML Bomba 4

### 6.1.2 AR CONDICIONADO

Em ambiente de laboratório semelhante ao utilizado para os testes da bomba de água, foi instalado um sistema de ar condicionado completo, com as unidades interna e externa alojadas em câmaras isoladas. Para induzir anomalias e avaliar o desempenho do sistema de sensores, um reservatório de gás externo foi integrado ao sistema de ar condicionado. Este reservatório estava equipado com um conjunto de válvulas que permitiam o controle preciso da quantidade de gás no compressor.




Figura 104 Exemplo Amostra sem Anomalia HVAC Laboratório




Figura 105 Exemplo Amostra Anômala HVAC Laboratório

### 6.1.2.1 Análise dos Dados

Para cada um dos quatro cenários de operação (60%, 80%, 90% e 95% de gás no depósito), foram coletadas 10 amostras de dados. A análise espectral foi então aplicada a cada amostra utilizando a Transformada Rápida de Fourier (FFT) e os resultados foram armazenados.

De modo a facilitar a identificação de padrões e anomalias, os gráficos de frequência foram processados de maneira semelhante ao caso da bomba de água onde os espectros foram divididos em intervalos de 1 kHz. Dentro de cada intervalo, o valor de pico foi identificado e usado como representante daquele intervalo. Este processo foi realizado para cada uma das 10 amostras em cada cenário e, finalmente, os valores de pico foram médios para obter um único conjunto de dados representativo para cada estado do sistema de ar condicionado.

Os dados de temperatura foram recolhidos nos tubos de entrada e saída do compressor. Estes valores permaneceram estáveis em todas as condições da operação, mesmo quando anomalias foram induzidas. O mesmo ocorreu com o consumo energético, que não demonstrou variações significativas entre os diferentes estados de funcionamento. Importante referir que os períodos de operação anómala foram mantidos curtos para evitar potenciais danos ao sistema. Estes resultados reforçam a utilidade da análise espectral como uma métrica útil para a deteção de anomalias, particularmente, quando outros indicadores, como temperatura e consumo energético, podem não ser tão elucidativos quanto ao estado do sistema.

### Análise dos Gráficos

- **Depósito a 95%:** A análise espectral mostrou um pico predominante na faixa de 1k a 2kHz, com poucos harmónicos presentes. Isso sugere que o sistema está operando num estado estável, exibindo uma vibração bem definida e uniforme.




Figura 106 Análise Espectral HVAC Laboratório 95%

- Depósito a 90%:** Foi observada uma diminuição significativa na frequência fundamental na faixa de 1k a 2kHz. Além disso, surgiu um harmônico notável na faixa de 9k a 10kHz, indicando uma possível instabilidade no sistema.




Figura 107 Análise Espectral HVAC Laboratório 90%

- Depósito a 80%:** O pico na faixa de 2kHz continuou a diminuir, enquanto os harmônicos nas faixas de 7k, 8k, 9k e 10kHz mostraram um aumento. Isso sugere que a operação do sistema está a tornar-se cada vez mais instável.




Figura 108 Análise Espectral HVAC Laboratório 80%

- **Depósito a 60%:** O pico nas faixas de 1k e 2k praticamente desapareceu, sendo substituído por picos menores em 4kHz e 7kHz. Além disso, a intensidade do espectro mostrou-se inferior em comparação com as amostras anteriores, apontando para uma condição operacional altamente irregular.




Figura 109 Análise Espectral HVAC Laboratório 60%

Os resultados acima indicam que a quantidade de gás no depósito tem um impacto direto na estabilidade operacional do sistema de ar condicionado, conforme evidenciado pelas mudanças nos padrões de vibração e harmônicos observados.

Os gráficos em 3D a seguir oferecem uma visualização mais intuitiva do impacto da quantidade de gás no depósito sobre o desempenho do sistema de ar condicionado. Neles, é possível observar a progressão da estabilidade operacional do equipamento. As diferenças na magnitude e na distribuição das frequências tornam-se mais evidentes à medida que a quantidade de gás no depósito varia, reforçando a importância de monitorizar esse parâmetro na detecção de anomalias no sistema.

Procedeu-se à criação de um *dataset* abrangente com o objetivo de treinar e testar um conjunto de algoritmos de aprendizagem de máquina para a detecção eficaz de estados anómalos no equipamento.




Figura 110 Análise Espectral HVAC Todos Estados 1

3D Surface Plot of FFT Data at Different Gas Percentages




Figura 111 Análise Espectral HVAC Todos Estados 2

### 6.1.2.2 Detecção de Anomalias

Foi construído um *dataset* com um total de 73 amostras, das quais 10 foram identificadas como anômalas, refletindo diferentes níveis de gás no depósito do sistema de ar condicionado. A mesma *suíte* de algoritmos de aprendizagem de máquina utilizada para a bomba de água foi empregue aqui. Os algoritmos incluídos na análise foram:

- Isolation Forest
- One-Class SVM
- k-NN (k-Nearest Neighbors)
- Elliptic Envelope

	voltageL1	currentL1	voltageL2	currentL2	voltageL3	currentL3	anomaly
1	3312.42	19198.64	4774.15	11709.42	6775.41	10204.74	True
2	3419.43	26240.71	5370.7	12373.27	7629.4	12130.0	True
3	3267.82	26100.64	3769.6	15354.98	6780.26	12790.47	True
4	3522.76	32631.27	5594.98	20679.47	6643.64	17729.08	True
5	3182.72	18618.13	6812.03	18267.55	3799.14	15244.34	True
6	3476.53	21963.55	6739.31	20973.76	7449.71	17015.07	True
7	3473.25	19392.87	5338.64	14303.66	6795.77	11182.39	True
8	2409.03	19802.64	7766.62	19156.72	3569.64	17871.37	True
9	6114.37	25060.72	6799.33	15693.37	5284.88	13211.05	True
10	6129.37	23538.09	7190.71	21936.04	5513.92	16235.9	True
11	1101.32	42978.42	100.69	14893.64	9081.18	11796.38	False
12	1050.64	39894.69	100.66	15249.24	8486.95	10833.17	False
13	1001.36	43832.23	100.77	17380.65	8728.88	9452.16	False
14	1007.56	47147.69	100.76	18975.77	8960.96	8303.94	False
15	1006.61	48308.21	100.66	19643.74	8864.42	9763.43	False
16	1058.71	37762.91	2646.78	9484.54	100.83	9123.4	False
17	1059.16	41499.92	100.87	12499.51	9103.71	10327.08	False
18	1059.49	47077.07	8488.54	10353.47	151.36	9313.89	False
19	1059.6	65075.91	100.91	14924.15	8520.97	10568.56	False
20	1058.27	55805.7	100.79	22325.09	1644.09	9247.37	False
21	958.79	73094.92	100.93	18268.28	1482.34	14713.58	False
22	1058.82	65575.52	100.84	19354.0	8527.31	11532.79	False
23	1059.05	71255.4	100.86	14880.69	1588.57	9239.41	False
24	1059.49	83874.77	100.9	14710.52	1633.38	11567.62	False
25	1061.61	59369.36	101.11	18098.61	1636.65	13330.61	False
26	1009.78	71863.89	100.98	15762.03	1640.9	11559.15	False
27	1009.46	106255.09	100.95	16124.4	1539.43	15198.39	False
28	1010.85	153300.15	423.29	22645.82	1667.9	14425.11	False
29	1008.72	109337.73	1639.17	16328.27	100.87	15240.27	False
30	1009.78	151465.23	151.47	16339.4	1514.67	16262.34	False
31	1009.36	135410.69	151.4	14275.25	1816.84	13870.28	False
32	1008.4	114313.37	1714.29	16347.06	8495.8	12562.22	False
33	1008.3	100789.98	1638.48	13893.82	8526.42	12124.96	False

Figura 112 dataset HVAC

## **Análise dos Resultados do Treinamento**

Os modelos foram treinados e validados num ambiente de aprendizagem supervisionado, graças à classificação antecipada das amostras anómalas. Os melhores parâmetros identificados para cada algoritmo foram:

- **Isolation Forest:** Contaminação de 0.1, 150 estimadores
- **One-Class SVM:** Kernel linear,  $\nu=0.1$
- **k-NN:** 3 vizinhos mais próximos, pesos uniformes
- **Elliptic Envelope:** Fração de suporte indefinida

## **Análise de Resultados**

### **Isolation Forest:**

- **Avaliação:** O modelo alcançou uma acurácia de 94%, com uma precisão de 67% para detecção de anomalias.
- **Anomalias:** Detetou duas verdadeiras anomalias, com certeza scores negativos, como esperado.

### **One-Class SVM:**

- **Avaliação:** Este algoritmo exibiu um desempenho impecável, atingindo 100% em todas as métricas.
- **Anomalias:** Identificou todas as anomalias com elevados valores negativos de certeza.

### **k-NN:**

- **Avaliação:** Também apresentou um desempenho perfeito, com 100% em todas as métricas.
- **Anomalias:** Detetou todas as anomalias com uma certeza de 1.0.

### **Elliptic Envelope:**

- **Avaliação:** Obteve uma acurácia de 100% e uma precisão de 100% na detecção de anomalias.
- **Anomalias:** Detetou as anomalias corretamente, com altos valores negativos de certeza.

O One-Class SVM e o k-NN destacaram-se com uma eficácia de 100%, enquanto o *Isolation Forest*, embora com alta acurácia, foi menos preciso na detecção de anomalias. O *Elliptic Envelope* também mostrou um desempenho adequado, com 100% de acurácia e precisão.

```

Isolation Forest Evaluation:
      precision    recall  f1-score   support

   False         1.00      0.93      0.97         15
    True         0.67      1.00      0.80          2

 accuracy                   0.94         17
 macro avg                   0.83         17
 weighted avg                 0.96         17

```

Figura 113 Resultados ML HVAC 1

```

One-Class SVM Evaluation:
      precision    recall  f1-score   support

   False         1.00      1.00      1.00         15
    True         1.00      1.00      1.00          2

 accuracy                   1.00         17
 macro avg                   1.00         17
 weighted avg                 1.00         17

```

Figura 114 Resultados ML HVAC 2

```

k-NN Evaluation:
      precision    recall  f1-score   support

   False         1.00      1.00      1.00         15
    True         1.00      1.00      1.00          2

 accuracy                   1.00         17
 macro avg                   1.00         17
 weighted avg                 1.00         17

```

Figura 115 Resultados ML HVAC 3

```

Elliptic Envelope Evaluation:
      precision    recall  f1-score   support

   False         1.00      1.00      1.00         15
    True         1.00      1.00      1.00          2

 accuracy                   1.00         17
 macro avg                   1.00         17
 weighted avg                 1.00         17

```

Figura 116 Resultados ML HVAC 4

## 6.2 ESTAÇÃO DE TRATAMENTO DE ÁGUAS

Durante a fase de recolha de dados na Estação de Tratamento de Águas (ETA) de Tavira, o sistema de sensores foi instalado por um período de dois meses, com uma cadência de recolha de amostras de 4 em 4 horas. Dado que o local não dispõe de uma conexão ativa à internet, optou-se pela instalação de um servidor de recolha local, executado num Raspberry Pi 4B.

As amostras coletadas durante este período apresentaram uma consistência razoável. As variações observadas nos dados são mais provavelmente atribuíveis a diferentes velocidades de operação do sistema, em vez de indicarem anomalias no funcionamento da bomba. É importante salientar que, durante o período de instalação do sistema de sensores, não foram realizadas nem agendadas quaisquer intervenções de manutenção preventiva ou corretiva no equipamento.

Dado que não foi possível induzir anomalias de forma forçada, e também devido à baixa probabilidade de ocorrência de anomalias naturais no curto período de observação, o objetivo principal desta experiência centrou-se na validação das operações de recolha e armazenamento de dados pelo sistema de sensores. Esta fase foi crucial para confirmar a robustez e a fiabilidade do sistema num ambiente real e operacional.

Nos gráficos a seguir, apresentamos algumas das amostras coletadas na ETA de Tavira, juntamente com uma análise que segue uma abordagem semelhante à adotada nos casos de laboratório. Para esta análise, foram selecionadas 10 amostras aleatórias, que foram então processadas da mesma forma que as amostras dos estudos laboratoriais.

Esta abordagem permite uma comparação direta e válida entre os dados coletados em ambientes controlados e os obtidos num ambiente real de operação, fornecendo assim uma visão abrangente da eficácia e aplicabilidade do sistema de sensores em diferentes cenários.




Figura 117 Exemplo Amostra Bomba ETA 1




Figura 118 Exemplo Amostra Bomba ETA 2




Figura 119 Análise Espectral Bomba ETA

Ao comparar os gráficos obtidos da bomba em ambiente de laboratório com os da ETA de Tavira, notamos que os espectros de vibração em operação normal são consideravelmente distintos entre os dois. Este facto sublinha a importância de utilizar algoritmos de aprendizagem de máquina na deteção de anomalias. A flexibilidade oferecida por tais algoritmos permite que o sistema de sensores seja implementado em diferentes tipos de equipamentos sem a necessidade de um estudo prévio para ajustar os parâmetros de deteção. Isso torna o sistema mais versátil e adaptável a uma variedade de cenários operacionais.

### **6.3 APARTHOTEL OCEANUS**

Durante um período de dois meses, o sistema de sensores foi instalado num compressor de dimensões industriais no Aparthotel Oceanus em Albufeira. Este compressor é responsável por alimentar a maioria dos sistemas de ar condicionado embutidos nos quartos da zona hoteleira do complexo. Assim, como no caso da ETA de Tavira, o sensor conseguiu capturar várias amostras representativas do funcionamento normal do equipamento, já que durante o período de teste não foram reportados problemas nem realizadas operações de manutenção preventiva ou corretiva.

Devido à ausência de uma conexão à Internet no local, um servidor de recolha de dados foi estabelecido localmente, executado num Raspberry Pi 4B. A cadência da recolha de amostras foi mantida idêntica à da ETA de Tavira, com leituras realizadas a cada quatro horas.

Ao longo do período em que o sistema de sensores esteve instalado no Aparthotel Oceanus, várias amostras de dados foram coletadas do compressor. A análise dessas amostras foi conduzida de maneira similar aos estudos anteriores. Primeiramente, os dados de frequência foram segmentados em intervalos de 1 kHz. Em seguida, o pico de magnitude mais alto de cada intervalo foi selecionado. Esse processo foi repetido para um conjunto de 10 amostras aleatórias. Por fim, as médias dos picos selecionados foram calculadas para cada intervalo, resultando numa representação mais genérica e interpretável do funcionamento normal do equipamento.




Figura 120 Exemplo Amostra Bomba APT 1




Figura 121 Exemplo Amostra Bomba APT 2




Figura 122 Exemplo Amostra Bomba APT 3

Ao analisar os gráficos resultantes, é possível observar que o padrão do espectro de frequências é muito similar ao do ar condicionado examinado em ambiente laboratorial. O funcionamento normal do sistema é caracterizado por um pico de magnitude elevada em baixa frequência, neste caso, aproximadamente aos 700 Hz.

Além disso, são observados harmônicos próximos, especificamente nos 150 Hz e 1200 Hz, enquanto o restante do espectro permanece praticamente sem harmônicos. Esses resultados são bastante consistentes com o que foi observado no equipamento de laboratório, indicando que este tipo de ar condicionado pode ser um bom candidato para a detecção de anomalias utilizando os algoritmos previamente escolhidos, desde que a progressão do espectro em casos de avaria ou mau funcionamento se revele semelhante.

## 6.4 HUBEL

O sensor foi implementado numa bomba de água pertencente a um sistema de rega da Hubel em Olhão. O equipamento recolheu amostras de vibração da bomba e processou-as localmente num servidor instalado num Raspberry Pi 4B. As características relevantes, nomeadamente os picos de frequência, foram extraídas e enviadas para a plataforma FulgurIT da Hubel através do protocolo MQTT. Após a recolha de 50 leituras, o algoritmo *K-Nearest Neighbors* (KNN) foi treinado para detecção de anomalias. As leituras subsequentes foram analisadas, e os resultados, junto com um grau de certeza, foram também enviados para a FulgurIT.

Semelhante aos casos anteriores, nenhum tipo de anomalia foi identificado na operação da bomba de água. É importante notar que a bomba analisada é muito semelhante, tanto em marca quanto em dimensões, à bomba estudada em laboratório. Portanto, a assinatura vibracional é semelhante, com poucas variações nas amostras obtidas.

O objetivo principal deste estudo foi a integração do sistema desenvolvido com outros sistemas de gestão de dados provenientes de sensores, como a plataforma FulgurIT. Esta integração poderá servir como um elo de ligação a sistemas de gestão de equipamentos industriais mais amplos. Por exemplo, a detecção de anomalias pode permitir o controle dinâmico de um sistema de rega com múltiplas bombas. A operação de cada bomba poderia ser ajustada com base nos dados de detecção de anomalias, otimizando assim o uso de recursos e prolongando a vida útil do equipamento.

## 6.5 COMPARAÇÃO COM TRABALHOS PRÉVIOS E PRODUTOS EXISTENTES

Ao comparar o projeto desenvolvido com os produtos comerciais existentes, observa-se que o custo total de cada dispositivo criado, cerca de 50€, é significativamente mais baixo. Esta economia pode ser atribuída a fatores como a utilização de plataformas de conectividade e módulos ADC mais recentes e acessíveis, bem como a adoção de sensores piezoelétricos em detrimento de acelerómetros, mais dispendiosos. Apesar de perdermos a capacidade de registar a direção da vibração com os sensores piezoelétricos, ganhamos em taxas de amostragem mais elevadas, o que é crucial para detetar ruídos de alta frequência, importantes na identificação de determinadas anomalias como a cavitação [54]–[56].

O sistema de IoT incorporado no nosso equipamento, baseado em tecnologias abertas, oferece flexibilidade de adaptação às necessidades específicas das empresas. Pode funcionar tanto localmente num dispositivo dedicado (no nosso exemplo, um raspberry pi), como remotamente num servidor da empresa ou na *cloud*, caso exista ligação Wi-Fi ou à internet. Isto contrasta com as soluções comerciais que tendem a ter *software* proprietário com limitações inerentes, ou no caso do *ABB Smart Sensor*, dependem da recuperação periódica de dados via *Bluetooth*.

A utilização de algoritmos de *machine learning* para deteção de anomalias elimina a necessidade de configurações específicas para cada equipamento monitorizado, permitindo uma adaptação automática após um período de treino. Além disso, o maior controlo sobre o servidor IoT facilita a integração com *software* de controle já existentes nas indústrias, possibilitando uma gestão abrangente dos equipamentos e uma previsão de falhas mais eficaz.

É importante notar que a aquisição dos componentes para o nosso dispositivo foi realizada em pequenas quantidades. Com o refinamento do *design* e a compra de componentes em maior volume, ou até escalando a produção com fabrico na China, o custo de produção poderia ser reduzido ainda mais. Esta economia em escala reforça o potencial competitivo do nosso dispositivo no mercado, tornando-o uma solução ainda mais acessível e atraente para aplicações industriais de monitorização e manutenção preditiva.



# 7

## CONCLUSÕES E TRABALHOS FUTUROS

Esta secção destina-se a consolidar as conclusões obtidas a partir dos resultados experimentais em todas as zonas estudadas. Será feita uma avaliação abrangente, englobando não só os sucessos, mas também os problemas e desafios identificados durante a operação do sistema de monitorização. Serão discutidos potenciais alterações e novos projetos que poderão surgir como extensões ou melhorias do projeto atual.

Neste projeto, desenvolveu-se um dispositivo baseado em arquitetura IoT, projetado para capturar dados de vibração, temperatura e consumo energético em motores elétricos. O equipamento, de baixo consumo, foi construído utilizando o ESP32 e o PIC32, integrando um sensor piezoelétrico para medição de vibração, dois termopares tipo K para temperatura e uma pinça amperimétrica para o consumo energético.

Este dispositivo é capaz de armazenar e enviar dados para um servidor IoT hospedado localmente num *Raspberry Pi*, com comunicação via rede Wi-Fi. Vários exemplares foram testados em ambientes reais, incluindo um ar condicionado industrial num hotel, bombas de água numa Estação de Tratamento de Água (ETA) e num sistema de rega. Além disso, testes controlados em laboratório em sistemas de AVAC e bombas de água foram realizados para induzir falhas e criar um conjunto de dados com anomalias identificadas, visando avaliar a performance dos algoritmos de *machine learning* implementados.

## **7.1 RESUMO DOS RESULTADOS**

### **7.1.1 LABORATÓRIO DA UNIVERSIDADE DO ALGARVE**

O estudo inicial no laboratório focou-se na avaliação do desempenho de uma bomba de água sob diferentes condições anómalas. A análise espectral das vibrações da bomba revelou que as variações nas configurações da válvula tinham um impacto significativo na eficiência da bomba. O espectro de frequência mudou de acordo com o estado da válvula, proporcionando um meio robusto para deteção de anomalias.

Os algoritmos de aprendizagem de máquina empregados, especialmente o One-Class SVM e o k-NN, demonstraram uma eficácia impressionante na classificação dos estados anómalos. Com eficácia de 100%, estes métodos validaram o uso da análise espectral como uma ferramenta confiável para monitorizar a condição da bomba.

### **7.1.2 SISTEMA DE AR CONDICIONADO EM LABORATÓRIO**

O caso de estudo do sistema de ar condicionado visava entender como diferentes níveis de gás no reservatório afetam o desempenho do sistema. Ficou evidente que a redução nos níveis de gás estava diretamente correlacionada com a instabilidade no sistema, como demonstrado pela análise espectral.

Os algoritmos de aprendizagem de máquina, particularmente o One-Class SVM e o k-NN, mostraram novamente uma eficácia de 100% na identificação de estados anómalos. Isto reforça a ideia de que a análise espectral é uma métrica valiosa para monitorizar sistemas complexos como unidades de ar condicionado.

### **7.1.3 ESTAÇÃO DE TRATAMENTO DE ÁGUA (ETA) DE TAVIRA**

Neste ambiente real, o foco estava menos na deteção de anomalias e mais na validação da operação de recolha e armazenamento de dados. O sistema provou ser fiável, capturando dados consistentes ao longo do período de instalação. Além da robustez do sistema, a consistência nos dados coletados sugere que as variações nas amostras são mais provavelmente devidas a diferentes velocidades de operação do sistema, ao invés de anomalias. Isso valida o sistema como uma ferramenta confiável para monitorização em tempo real em ambientes industriais.

#### **7.1.4 APARTHOTEL OCEANUS EM ALBUFEIRA**

Neste estudo com um compressor industrial, a principal observação foi a semelhança no espectro de frequência entre os resultados de laboratório e os resultados em campo. Isso sugere que os algoritmos treinados em dados de laboratório podem ser aplicados eficazmente em ambientes reais.

A capacidade de aplicar os mesmos algoritmos de ML em diferentes cenários destaca a versatilidade do sistema de sensores. Isso é crucial para a implementação em larga escala em diversos tipos de equipamentos industriais.

#### **7.1.5 SISTEMA DE REGA DA HUBEL EM OLHÃO**

O objetivo, aqui, foi principalmente avaliar a integração do sistema de sensores com plataformas de gestão de dados existentes, como o FulgurIT. Com a integração bem-sucedida, o sistema não só pode monitorizar a condição do equipamento, mas também comunicar com outros sistemas para otimizar o desempenho.

O sucesso desta integração sugere que o sistema desenvolvido pode servir como um elo eficaz em sistemas de gestão de equipamentos industriais mais amplos. Isso abre caminho para implementações mais complexas, como o controle dinâmico de sistemas de rega com múltiplas bombas, permitindo uma operação mais eficiente e prolongando a vida útil do equipamento.

## **7.2 PROBLEMAS ENCONTRADOS**

Embora o projeto tenha demonstrado potencial em várias áreas, também enfrentou uma série de desafios e limitações que precisam ser estudados para aprimorar a viabilidade e eficácia do sistema. Os problemas encontrados variam desde questões técnicas até limitações operacionais.

A seguir, detalhamos essas preocupações para fornecer um panorama completo dos obstáculos enfrentados:

### **Funcionamento Contínuo dos Equipamentos**

O maior obstáculo foi a falta de funcionamento contínuo dos equipamentos nos casos de estudo reais. O sistema de sensores atualmente não tem a capacidade de determinar se o equipamento está em operação ou não, resultando em muitas leituras inúteis. Isso representa um desafio significativo na implementação prática do sistema, pois requer um método de validação adicional para assegurar a utilidade das leituras.

### **Medição de Consumo de Energia**

Embora a pinça amperimétrica tenha sido uma solução eficaz em ambientes de laboratório, a sua implementação em cenários reais provou ser complicada. Isso deveu-se principalmente à necessidade de isolar condutores, o que muitas vezes é impraticável em instalações industriais. Além disso, os quadros elétricos geralmente estão localizados longe dos equipamentos de estudo, tornando a recolha de dados desafiadora.

### **Viabilidade dos Sensores de Temperatura e Consumo**

Os dados de temperatura e consumo de energia revelaram-se ineficazes para deteção de anomalias nos casos estudados. Isso pode ser parcialmente atribuído ao curto período para o qual as anomalias foram induzidas, evitando danos permanentes aos equipamentos. No entanto, estas métricas não parecem ser indicadoras confiáveis para identificar problemas em tempo real.

### **Acesso à Internet**

O acesso à Internet foi um desafio em todos os cenários reais devido à localização dos equipamentos. Embora servidores locais tenham sido estabelecidos para armazenamento de dados, uma conexão com uma rede maior ou mesmo com a Internet seria ideal para facilitar a integração com outros sistemas de gestão e permitir um sistema de armazenamento mais centralizado.

### **Longevidade do Sistema**

A duração da bateria dos dispositivos de sensor foi outra preocupação. Em alguns casos, a presença de tomadas elétricas próximas facilitou o problema, mas para uma implementação mais ampla, seria necessário explorar métodos alternativos de alimentação ou redução do consumo energético do sistema.

**Período de Estudo Curto**

O curto período de estudo não permitiu uma avaliação completa das capacidades do sistema em cenários reais, especialmente porque nenhum equipamento apresentou problemas durante o período de teste. Isso limita a confiabilidade dos resultados obtidos e sugere a necessidade de um estudo de longo prazo.

**Espectro Limitado de Anomalias**

O conjunto de anomalias que poderia ser induzida em laboratório era limitado e não abrangente. Problemas, como falhas de rolamento ou desgaste de escovas em motores elétricos são difíceis de induzir de forma controlada e podem causar danos irreparáveis aos mesmos.

**Interação com Sistemas de Gestão Existentes**

Muitos dos equipamentos estudados já possuem sistemas de gestão centralizados, e a maioria deles são proprietários ou feitos sob medida. A integração com esses sistemas exigiria mais tempo e pesquisa para determinar a melhor abordagem.

**Necessidade de Melhorias na Automação e UX**

Para tornar o sistema comercialmente viável, melhorias significativas na automação e na experiência do utilizador são necessárias. Isso inclui uma interface de utilizador mais intuitiva e recursos adicionais para facilitar a implementação e monitorização.

**Requisitos de *Hardware* para Análise de Dados**

A análise dos dados requer um servidor dedicado para armazenamento e manipulação das amostras. Isso implica a necessidade de *hardware* adicional no local ou uma ligação à Internet para aceder um a servidor remoto.

### **7.3 MELHORIAS E POSSÍVEIS ALTERAÇÕES**

A evolução deste projeto não se limita apenas à análise dos resultados e problemas encontrados. É crucial considerar ajustes e melhorias para tornar o sistema mais eficaz e adaptável a diferentes cenários. As áreas de foco para desenvolvimentos futuros abrangem desde otimizações de *hardware* e soluções para acesso à Internet até expansão dos estudos para validação e integração com sistemas de gestão de equipamentos existentes. Neste contexto, diversas estratégias e modificações são propostas para aprimorar o projeto em múltiplos aspetos.

#### **Deteção de Operação do Equipamento**

A primeira e mais urgente melhoria é implementar um sistema que detete se o equipamento monitorizado está em operação. Uma sugestão é utilizar o sensor piezoelétrico existente para acordar todo o sistema apenas quando for gerada uma tensão suficiente, indicando que o equipamento está a funcionar. Isso economiza energia e reduz a recolha de dados inúteis.

#### **Otimização do PCB**

A pegada do PCB atual pode ser reduzida ao optar por componentes SMD, permitindo uma montagem mais eficiente e economizando espaço. Também torna o dispositivo mais adaptável a diferentes ambientes operacionais.

#### **Flexibilidade na Instalação de Sensores**

Dada a complexidade de instalar sensores em locais ideais, uma possível solução é separar os componentes de amostragem de temperatura e consumo. Isso traria desafios adicionais, como a necessidade de mais controladores e soluções de alimentação, mas ofereceria maior flexibilidade na instalação.

#### **Monitorização e Carregamento de Baterias**

Incorporar um sistema de monitorização de baterias pode ajudar na manutenção preventiva. Um carregador de bateria integrado também eliminaria a necessidade de remover fisicamente as baterias para carregá-las.

### **Eficiência Energética**

A busca por componentes mais eficientes em termos energéticos ou a exclusão de partes desnecessárias pode prolongar a vida útil da bateria, tornando o sistema mais prático para uso prolongado.

### **Interface Humana**

Finalmente, o sistema deve permitir configurações mais fáceis, talvez através de uma interface de utilizador simplificada que elimine a necessidade de um PC externo para ajustar as configurações.

### **Soluções para Acesso à Internet**

A falta de acesso à Internet nos locais de instalação é um problema significativo. Utilizar um HAT de conectividade celular no Raspberry Pi pode ser uma solução viável. Isso permitiria a criação de uma rede Wi-Fi local para a recolha de dados, que poderia então ser encaminhada para um servidor centralizado através de uma rede celular.

### **Recolha de Dados de Consumo**

O acesso a dados de consumo já coletados por sistemas industriais existentes poderia ser uma solução alternativa para a medição direta. No entanto, isso exigiria uma integração complexa e personalizada, dependendo do sistema industrial em questão.

## **7.4 ESTUDOS FUTUROS**

### **Testes em Locais Reais**

Com as melhorias de *hardware* implementadas, o próximo passo seria testar o sistema em condições reais por períodos prolongados. Isso não só validaria as atualizações, mas também permitiria a recolha de um conjunto de dados mais robusto e informativo.

### **Variedade de Anomalias**

Futuros estudos de laboratório devem focar-se em simular uma gama mais ampla de condições anómalas, além das que são fáceis de induzir. Isso ajudará a melhorar a precisão e a confiabilidade dos algoritmos de deteção de anomalias.

### **Integração com Sistemas de Gestão de Equipamentos**

Identificar e colaborar com sistemas de gestão de equipamentos comuns no mercado permitiria uma integração mais suave do sistema de sensores. Isso não só forneceria dados adicionais para análise, mas também permitiria que os resultados da detecção de anomalias fossem usados para ajustar os parâmetros operacionais dos equipamentos monitorizados.

## **7.5 COMENTÁRIO FINAL E CONCLUSÃO**

O projeto realizou um avanço significativo na área de manutenção preditiva, abordando a necessidade de sistemas de monitorização eficientes, económicos e não intrusivos. Utilizando tecnologias emergentes como microcontroladores e algoritmos de ML, o sistema foi capaz de fornecer dados valiosos sobre o estado de equipamentos industriais, particularmente motores eléctricos em sistemas de refrigeração e bombagem. Este feito alinha-se com o objetivo inicial de criar uma solução de monitorização expansível e fácil de integrar, destacando a inovação, a aplicabilidade prática do projeto e o seu baixo custo, o que o pode tornar numa solução competitiva de mercado.

No entanto, como qualquer projeto de pesquisa e desenvolvimento, este trabalho não está isento de limitações e desafios. Foram identificadas várias áreas para melhoria, incluindo a capacidade do sistema em determinar se um equipamento está em operação, a dificuldade na recolha de dados de consumo de forma não invasiva, e o desafio de integrar o sistema com infraestruturas industriais já existentes. Estas questões, longe de serem falhas, fornecem uma base sólida para futuras pesquisas e desenvolvimentos.

Estes desenvolvimentos futuros já têm um roteiro claro, delineado pelas melhorias sugeridas e pelos desafios identificados. Desde ajustes no *hardware* até estratégias para uma integração mais eficaz com sistemas de gestão existentes, há um conjunto de etapas lógicas que podem ser seguidas para aumentar a eficácia e a aplicabilidade do sistema, demonstrando assim o potencial para se tornar uma ferramenta indispensável em estratégias de manutenção preditiva mais holísticas.

Em termos de contribuição para o campo acadêmico e a indústria, este projeto oferece uma visão única sobre como as tecnologias emergentes podem ser aplicadas em desafios práticos. A integração bem-sucedida com plataformas como FulgurIT indica um passo positivo na direção de sistemas de monitorização mais abrangentes, fornecendo um modelo que pode ser adaptado e implementado em diversos cenários industriais.

Este projeto também oferece contribuições pedagógicas substanciais, funcionando como um caso de estudo multidisciplinar que abrange áreas como arquiteturas de *hardware*, programação em várias linguagens e análise de dados em cenários industriais reais. O caráter abrangente do projeto oferece uma plataforma educacional rica para entender como diferentes disciplinas podem convergir para resolver problemas práticos complexos. Além disso, o objetivo de elevar o sistema a um nível comercial adiciona uma camada de complexidade que prepara qualquer envolvido para os desafios encontrados na transição de soluções acadêmicas para aplicações industriais reais.

Em conclusão, o projeto atingiu os seus objetivos principais, fornecendo uma solução viável para a manutenção preditiva em ambientes industriais. Embora tenham sido identificados desafios e limitações, estes servem como pontos de partida para futuros avanços no campo. Assim, o trabalho realizado não apenas atende aos critérios acadêmicos de pesquisa e desenvolvimento, mas também oferece um caminho tangível para melhorias práticas na gestão de manutenção preditiva industrial.



## REFERÊNCIAS

- [1]R. Muñiz, F. Nuño, J. Díaz, M. González, M. J. Prieto, e Ó. Menéndez, «Real-time monitoring solution with vibration analysis for industry 4.0 ventilation systems», *J Supercomput*, vol. 79, n. 6, pp. 6203–6227, Abr. 2023, doi: 10.1007/s11227-022-04897-3.
- [2]K. S. Kiangala e Z. Wang, «An Effective Predictive Maintenance Framework for Conveyor Motors Using Dual Time-Series Imaging and Convolutional Neural Network in an Industry 4.0 Environment», *IEEE Access*, vol. 8, pp. 121033–121049, 2020, doi: 10.1109/ACCESS.2020.3006788.
- [3]M. T. Pham, J.-M. Kim, e C. H. Kim, «Accurate Bearing Fault Diagnosis under Variable Shaft Speed using Convolutional Neural Networks and Vibration Spectrogram», *Applied Sciences*, vol. 10, n. 18, p. 6385, Set. 2020, doi: 10.3390/app10186385.
- [4]M. A. A. Khan, M. A. Jamil, e S. Khanam, «Intelligent Prediction of Multiple Defects in Rolling Element Bearing using ANN Algorithm», em *2022 5th International Conference on Multimedia, Signal Processing and Communication Technologies (IMPACT)*, IEEE, Nov. 2022, pp. 1–5. doi: 10.1109/IMPACT55510.2022.10029154.
- [5]Z. M. Çınar, A. Abdussalam Nuhu, Q. Zeeshan, O. Korhan, M. Asmael, e B. Safaei, «Machine Learning in Predictive Maintenance towards Sustainable Smart Manufacturing in Industry 4.0», *Sustainability*, vol. 12, n. 19, p. 8211, Out. 2020, doi: 10.3390/su12198211.
- [6]P. Kumar e S. R.K, «Development of a Condition Based Maintenance Architecture for Optimal Maintainability of Mine Excavators», *IOSR Journal of Mechanical and Civil Engineering*, vol. 11, n. 3, pp. 18–22, 2014, doi: 10.9790/1684-11351822.
- [7]Silicon Laboratories., «SILICON LABS Predictive Maintenance». Acedido: 15 de Março de 2023. [Em linha]. Disponível em: [https://www.silabs.com/applications/industrial-iot/predictive-maintenance?s\\_kwid=AL%2116736%213%21581604618843%21%21%21g%21%2](https://www.silabs.com/applications/industrial-iot/predictive-maintenance?s_kwid=AL%2116736%213%21581604618843%21%21%21g%21%2)

- 1&gclid=Cj0KCQjwtsCgBhDEARIsAE7RYh03WjpLcoFRJTIWzJ9gYmS5Si3EwLLKDT3FayUjymIuLI8tO24YAh4aAgKYEALw\_wcB&tab=overview
- [8] S. Kamlu e V. Laxmi, «Condition-based maintenance strategy for vehicles using hidden Markov models», *Advances in Mechanical Engineering*, vol. 11, n. 1, p. 168781401880638, Jan. 2019, doi: 10.1177/1687814018806380.
- [9] A. Shahin, N. Aminsabouri, e K. Kianfar, «Developing a Decision Making Grid for determining proactive maintenance tactics», *Journal of Manufacturing Technology Management*, vol. 29, n. 8, pp. 1296–1315, Out. 2018, doi: 10.1108/JMTM-12-2017-0273.
- [10] I. Flores-Colen e J. de Brito, «Discussion of proactive maintenance strategies in façades’ coatings of social housing», *Journal of Building Appraisal*, vol. 5, n. 3, pp. 223–240, Jan. 2010, doi: 10.1057/jba.2009.21.
- [11] R. C. Parpala e R. Jacob, «Application of IoT concept on predictive maintenance of industrial equipment», *MATEC Web of Conferences*, vol. 121, p. 02008, Ago. 2017, doi: 10.1051/mateconf/201712102008.
- [12] Inc. Cloud Software Group, «TIBCO What is Predictive Maintenance?» Acedido: 15 de Março de 2023. [Em linha]. Disponível em: <https://www.tibco.com/reference-center/what-is-predictive-maintenance>
- [13] N. Chandarana, H. Lansiaux, e M. Gresil, «Characterisation of Damaged Tubular Composites by Acoustic Emission, Thermal Diffusivity Mapping and TSR-RGB Projection Technique», *Applied Composite Materials*, vol. 24, n. 2, pp. 525–551, Abr. 2017, doi: 10.1007/s10443-016-9538-8.
- [14] Y. Ham e M. Golparvar-Fard, «Automated Cost Analysis of Energy Loss in Existing Buildings through Thermographic Inspections and CFD Analysis», Ago. 2013. doi: 10.22260/ISARC2013/0117.
- [15] M. R. Barusu, U. Sethurajan, e M. Deivasigamani, «Non-invasive method for rotor bar fault diagnosis in three-phase squirrel cage induction motor with advanced signal processing technique», *The Journal of Engineering*, vol. 2019, n. 17, pp. 4415–4419, Jun. 2019, doi: 10.1049/joe.2018.8242.
- [16] K. Lu, J. X. Gu, H. Fan, X. Sun, B. Li, e F. Gu, «Acoustics Based Monitoring and Diagnostics for the Progressive Deterioration of Helical Gearboxes», *Chinese Journal of Mechanical Engineering*, vol. 34, n. 1, p. 82, Dez. 2021, doi: 10.1186/s10033-021-00603-1.

- [17] S. Bin Lee *et al.*, «Condition Monitoring of Industrial Electric Machines: State of the Art and Future Challenges», *IEEE Industrial Electronics Magazine*, vol. 14, n. 4, pp. 158–167, Dez. 2020, doi: 10.1109/MIE.2020.3016138.
- [18] C. G. Novoa, G. A. G. Berrios, e R. A. Soderberg, «Predictive maintenance for motors based on vibration analysis with compact rio», em *2017 IEEE Central America and Panama Student Conference (CONESCAPAN)*, IEEE, Set. 2017, pp. 1–6. doi: 10.1109/CONESCAPAN.2017.8277603.
- [19] M. Walsh, B. O’Flynn, e J. Torres, «Vibration Characterisation for Fault Detection and Isolation in Linear Synchronous Motor based Conveyor Systems», em *2019 International Conference on Automation, Computational and Technology Management (ICACTM)*, IEEE, Abr. 2019, pp. 500–504. doi: 10.1109/ICACTM.2019.8776825.
- [20] T. Vaimann, J. Sobra, A. Belahcen, A. Rassölkin, M. Rolak, e A. Kallaste, «Induction machine fault detection using smartphone recorded audible noise», *IET Science, Measurement & Technology*, vol. 12, n. 4, pp. 554–560, Jul. 2018, doi: 10.1049/iet-smt.2017.0104.
- [21] M. S. Moiz *et al.*, «Health Monitoring of Three-Phase Induction Motor Using Current and Vibration Signature Analysis», em *2019 International Conference on Robotics and Automation in Industry (ICRAI)*, IEEE, Out. 2019, pp. 1–4. doi: 10.1109/ICRAI47710.2019.8967356.
- [22] Alibaba.com, «digital vibration meter,vibrometer». Acedido: 15 de Março de 2023. [Em linha]. Disponível em: [https://www.alibaba.com/pla/digital-vibration-metervibrometer\\_62124142281.html?mark=google\\_shopping&biz=pla&searchText=testing+equipment&product\\_id=62124142281&language=en&src=sem\\_ggl&field=UG&from=sem\\_ggl&cmpgn=18600245734&adgrp=&fditm=&tgt=&locintrst=&locphyscl=1011742&mtchtyp=&ntwrk=x&device=c&dvcmdl=&creative=&plcmnt=&plcmntcat=&aceid=&position=&gclid=Cj0KCQjwtsCgBhDEARIsAE7RYh13BuWNeEaKug2QFVMfTlc9i-U6hzCpjHRNcZisBB1K64x2iiJn81AaAulHEALw\\_wcB](https://www.alibaba.com/pla/digital-vibration-metervibrometer_62124142281.html?mark=google_shopping&biz=pla&searchText=testing+equipment&product_id=62124142281&language=en&src=sem_ggl&field=UG&from=sem_ggl&cmpgn=18600245734&adgrp=&fditm=&tgt=&locintrst=&locphyscl=1011742&mtchtyp=&ntwrk=x&device=c&dvcmdl=&creative=&plcmnt=&plcmntcat=&aceid=&position=&gclid=Cj0KCQjwtsCgBhDEARIsAE7RYh13BuWNeEaKug2QFVMfTlc9i-U6hzCpjHRNcZisBB1K64x2iiJn81AaAulHEALw_wcB)
- [23] Toolnation.nl, «FLUKE 3542635 810 Vibration meter». Acedido: 15 de Março de 2023. [Em linha]. Disponível em: [https://www.toolnation.com/fluke-3542635-810-vibration-meter.html?gclid=Cj0KCQjwtsCgBhDEARIsAE7RYh3Gg4zljDETws2fuT-ogj3zBCRoVSBaZK3PAUDZaNnuQlmtx\\_aCbE0aAsHyEALw\\_wcB](https://www.toolnation.com/fluke-3542635-810-vibration-meter.html?gclid=Cj0KCQjwtsCgBhDEARIsAE7RYh3Gg4zljDETws2fuT-ogj3zBCRoVSBaZK3PAUDZaNnuQlmtx_aCbE0aAsHyEALw_wcB)

- [24] Adash spol. s r.o., «ADASH VIBRATION ANALYZERS AND CONDITION MONITORING». Acedido: 15 de Março de 2023. [Em linha]. Disponível em: <https://adash.com/>
- [25] Rich, «Separate FFT components into separate plots using MATLAB code». Acedido: 26 de Novembro de 2023. [Em linha]. Disponível em: <https://dsp.stackexchange.com/questions/81785/separate-fft-components-into-separate-plots-using-matlab-code>
- [26] G. Senapaty e U. Sathish Rao, «Vibration based condition monitoring of rotating machinery», *MATEC Web of Conferences*, vol. 144, p. 01021, Jan. 2018, doi: 10.1051/mateconf/201814401021.
- [27] Cornelius Scheffer e Paresh Girdhar, *Practical Machinery Vibration Analysis and Predictive Maintenance*, 1st Edition. 2004.
- [28] M. Singh, E. Fuenmayor, E. Hinchy, Y. Qiao, N. Murray, e D. Devine, «Digital Twin: Origin to Future», *Applied System Innovation*, vol. 4, n. 2, p. 36, Mai. 2021, doi: 10.3390/asi4020036.
- [29] Z. Liu, N. Meyendorf, e N. Mrad, «The role of data fusion in predictive maintenance using digital twin», 2018, p. 020023. doi: 10.1063/1.5031520.
- [30] Y. Huang, C.-H. Chen, e C.-J. Huang, «Motor Fault Detection and Feature Extraction Using RNN-Based Variational Autoencoder», *IEEE Access*, vol. 7, pp. 139086–139096, 2019, doi: 10.1109/ACCESS.2019.2940769.
- [31] N. Apinantanapong e P. Nivesrangsan, «Application of Artificial Neural Networks to Fault Detection of Rolling Ball Bearing», em *2021 6th International Conference on Business and Industrial Research (ICBIR)*, IEEE, Mai. 2021, pp. 147–152. doi: 10.1109/ICBIR52339.2021.9465860.
- [32] K. Baiche e L. Abderrazak, «A statistical parameters and artificial neural networks application for rolling element bearing fault diagnosis using wavelet transform preprocessing», em *2017 5th International Conference on Electrical Engineering - Boumerdes (ICEE-B)*, IEEE, Out. 2017, pp. 1–6. doi: 10.1109/ICEE-B.2017.8192000.
- [33] G. Scalabrini Sampaio, A. R. de A. Vallim Filho, L. Santos da Silva, e L. Augusto da Silva, «Prediction of Motor Failure Time Using An Artificial Neural Network», *Sensors*, vol. 19, n. 19, p. 4342, Out. 2019, doi: 10.3390/s19194342.
- [34] A. Javed, H. Larijani, A. Ahmadiania, e D. Gibson, «Smart Random Neural Network Controller for HVAC Using Cloud Computing Technology», *IEEE Trans Industr Inform*, vol. 13, n. 1, pp. 351–360, Fev. 2017, doi: 10.1109/TII.2016.2597746.

- [35] Amazon Web Services, «AWS Marketplace Predictive Maintenance». Acedido: 14 de Março de 2023. [Em linha]. Disponível em: <https://aws.amazon.com/marketplace/solutions/IoT/predictive-maintenance>
- [36] A. K. Al Mhdawi e H. S. Al-Raweshidy, «A Smart Optimization of Fault Diagnosis in Electrical Grid Using Distributed Software-Defined IoT System», *IEEE Syst J*, vol. 14, n. 2, pp. 2780–2790, Jun. 2020, doi: 10.1109/JSYST.2019.2921867.
- [37] L. O. Aghenta e M. T. Iqbal, «Low-Cost, Open Source IoT-Based SCADA System Design Using Thinger.IO and ESP32 Thing», *Electronics (Basel)*, vol. 8, n. 8, p. 822, Jul. 2019, doi: 10.3390/electronics8080822.
- [38] J. T. Price, «Vibration analysis methods for preventative maintenance [of cement plants]», em *IEEE-IAS/PCA 2001 Cement Industry Technical Conference. Conference Record (Cat. No.01CH37150)*, 2001, pp. 333–341. doi: 10.1109/CITCON.2001.934122.
- [39] Peter J. Theisen, Ph. D. Bin Lu, e Charles J. Luebke, «Wireless Sensor Network for Advanced Energy Management Solutions», Golden, CO (United States), Set. 2009. doi: 10.2172/964682.
- [40] A. I. Vlasov, P. V. Grigoriev, A. I. Krivoshein, V. A. Shakhnov, S. S. Filin, e V. S. Migalin, «Smart management of technologies: predictive maintenance of industrial equipment using wireless sensor networks», *Entrepreneurship and Sustainability Issues*, vol. 6, n. 2, pp. 489–502, Dez. 2018, doi: 10.9770/jesi.2018.6.2(2).
- [41] A. Borré, L. O. Seman, E. Camponogara, S. F. Stefenon, V. C. Mariani, e L. dos S. Coelho, «Machine Fault Detection Using a Hybrid CNN-LSTM Attention-Based Model», *Sensors*, vol. 23, n. 9, p. 4512, Mai. 2023, doi: 10.3390/s23094512.
- [42] B. Bera, C.-L. Lin, S.-C. Huang, J.-W. Liang, e P. T. Lin, «Establishing a Real-Time Multi-Step Ahead Forecasting Model of Unbalance Fault in a Rotor-Bearing System», *Electronics (Basel)*, vol. 12, n. 2, p. 312, Jan. 2023, doi: 10.3390/electronics12020312.
- [43] L. Magadán, J. Roldán-Gómez, J. C. Granda, e F. J. Suárez, «Early fault classification in rotating machinery with limited data using TabPFN», *IEEE Sens J*, pp. 1–1, 2023, doi: 10.1109/JSEN.2023.3331100.
- [44] L. National Control Devices, «Industrial IoT Wireless Predictive Maintenance Sensor V3». Acedido: 27 de Novembro de 2023. [Em linha]. Disponível em: <https://store.ncd.io/product/iot-wireless-predictive-maintenance-sensor/>
- [45] Inc. Phase IV Engineering, «Industrial Grade Wireless Motor Sensor for Predictive Maintenance». Acedido: 27 de Novembro de 2023. [Em linha]. Disponível em:

- <https://www.phaseivengr.com/product/sensors/temperature/wireless-motor-sensor-predictive-maintenance/>
- [46] SMS Machine Automation, «ABB Ability Smart Sensor for Motors». Acedido: 27 de Novembro de 2023. [Em linha]. Disponível em: <https://www.automation.co.uk/abb-smart-sensor.php>
- [47] Sensor-Works, «Sensor Works How Do Piezoelectric Sensors Work». Acedido: 15 de Março de 2023. [Em linha]. Disponível em: <https://www.sensor-works.com/how-do-piezoelectric-sensors-work/>
- [48] Tassia Nunes, «Amostragem, teorema de Nyquist e aliasing - Ferramentas importantes durante processamento de sinal neural por EEG», Brain Support. Acedido: 17 de Setembro de 2023. [Em linha]. Disponível em: <https://www.brainlatam.com/blog/amostragem-teorema-de-nyquist-e-aliasing-ferramentas-importantes-durante-processamento-de-sinal-neural-por-eeeg-4233>
- [49] Microchip Technology Inc., «Microchip - PIC32MX170F256B». Acedido: 15 de Março de 2023. [Em linha]. Disponível em: <https://www.microchip.com/en-us/product/PIC32MX170F256B#document-table>
- [50] Tempsens Instrument Pvt. Ltd., «Tempsens - K Type Thermocouple». Acedido: 16 de Março de 2023. [Em linha]. Disponível em: <https://tempsens.com/blog/k-type-thermocouple>
- [51] L. EETech Media, «All About Circuits - Hall Effect Current Sensing: Open-Loop and Closed-Loop Configurations». Acedido: 15 de Março de 2023. [Em linha]. Disponível em: <https://www.allaboutcircuits.com/technical-articles/hall-effect-current-sensing-open-loop-and-closed-loop-configurations/>
- [52] Raspberry Pi, «Raspberry Pi 4B». Acedido: 31 de Agosto de 2022. [Em linha]. Disponível em: <https://www.raspberrypi.com/products/raspberry-pi-4-model-b/>
- [53] Grundfos Holding A/S, «Grundfos». Acedido: 15 de Março de 2023. [Em linha]. Disponível em: <https://www.grundfos.com/>
- [54] P. S. Al-Hashmi, A. Abdurrrhman, I. Nasir, e M. Elhaj, « Spectrum Analysis of Vibration Signals for Cavitation Monitoring *Journal of Pure & Applied Sciences -*», *.Sebha University*, vol. 16, pp. 14–20, Dez. 2017
- [55] D. Siano e M. A. Panza, «Diagnostic method by using vibration analysis for pump fault detection», *Energy Procedia*, vol. 148, pp. 10–17, Ago. 2018, doi: 10.1016/j.egypro.2018.08.013.

- 
- [56] Y. Li, G. Feng, X. Li, Q. Si, e Z. Zhu, «An experimental study on the cavitation vibration characteristics of a centrifugal pump at normal flow rate», *Journal of Mechanical Science and Technology*, vol. 32, n. 10, pp. 4711–4720, Out. 2018, doi: 10.1007/s12206-018-0918-x.
- [57] Hailin Jiang, M. Marek-Sadowska, e S. R. Nassif, «Benefits and costs of power-gating technique», em *2005 International Conference on Computer Design*, IEEE Comput. Soc, pp. 559–566. doi: 10.1109/ICCD.2005.34.



# APÊNDICES

- ESQUEMA COMPLETO DO CIRCUITO





## **ESQUEMA COMPLETO DO CIRCUITO**

No Apêndice, apresentamos o esquema completo do circuito do nosso dispositivo de captura de dados. Este esquema detalha a arquitetura eletrônica, mostrando a disposição dos componentes, as conexões e as especificações técnicas necessárias para a montagem e funcionamento do dispositivo. Este anexo é essencial para a compreensão da implementação prática do projeto e serve como um guia valioso para replicar ou modificar o sistema para futuras aplicações e melhorias.

ESQUEMA COMPLETO DO CIRCUITO

