



**TECNOLOGIA
SETÚBAL**

ESCOLA SUPERIOR
POLITÉCNICO SETÚBAL

Francisco
Laureano Gervásio

**Sistema IoT de Monitorização
da Qualidade Ambiental e
Postural**

Relatório de Dissertação do Mestrado em
Engenharia Eletrotécnica e de
Computadores na Área de Especialização de
Computadores e Sistemas de Ciberfísicos

ORIENTADOR

Doutor, Prof. Rui Amaral

Dezembro 2024



**TECNOLOGIA
SETÚBAL**

ESCOLA SUPERIOR
POLITÉCNICO SETÚBAL

Francisco
Laureano Gervásio

**Sistema IoT de Monitorização
da Qualidade Ambiental e
Postural**

JÚRI

*Presidente: Prof. Doutor Filipe Cardoso (IPS-
ESTSetúbal, DEE)*

*Orientador: Prof. Doutor Rui Amaral (IPS-
ESTSetúbal, DEE)*

*Vogal: Prof. Doutor António Navarro
(Universidade de Aveiro, DEIT)*

Dezembro 2024

Agradecimentos

Gostaria de expressar os meus sinceros agradecimentos a todas as pessoas e entidades que, de alguma forma, contribuíram para a realização deste trabalho. Em particular, deixo um agradecimento especial ao Prof. Rui Amaral, orientador desta tese, pelo apoio constante, orientação técnica e motivação ao longo de todo o percurso.

Agradeço também à empresa Dynasys, pelo apoio, pela disponibilização de recursos e pelo contributo para o desenvolvimento das soluções implementadas neste projeto.

Aos docentes que me acompanharam durante o curso, pela partilha de conhecimentos e incentivo ao desenvolvimento académico e profissional, manifesto o meu profundo reconhecimento.

Aos meus colegas de curso, pelo companheirismo, troca de ideias e momentos de descontração, que tornaram esta jornada mais leve e enriquecedora.

Um agradecimento muito especial à minha namorada, pelo apoio incondicional, paciência e incentivo durante todas as fases deste projeto, e à minha família, pelo suporte emocional, pela confiança depositada em mim e por estarem sempre ao meu lado.

A todos, o meu sincero obrigado por contribuírem de forma tão significativa para o sucesso deste trabalho.

Resumo

A presente dissertação apresenta o desenvolvimento de um sistema baseado na Internet das Coisas para monitorizar a qualidade ambiental e postural em salas de aula, com o objetivo de promover o bem-estar e o desempenho académico dos estudantes. Foram desenvolvidos sensores especializados para medir parâmetros como temperatura, dióxido de carbono, partículas suspensas, ruído, iluminação e postura. O sistema integra cadeiras inteligentes equipadas com sensores e algoritmos de inteligência artificial para avaliar posturas e sinais vitais, bem como uma rede integrada para centralizar os dados num *dashboard* interativo. A metodologia incluiu o *design* e validação de protótipos, com testes em diferentes condições e análise dos resultados através de métricas de precisão e eficiência. Os principais resultados destacam a eficácia do sistema na monitorização contínua de parâmetros ambientais e posturais, permitindo ajustes em tempo real e contribuindo para a criação de ambientes de aprendizagem mais saudáveis e eficientes. Este trabalho apresenta um impacto positivo não só no contexto educacional, mas também em outros cenários, como hospitais e escritórios, demonstrando a versatilidade da solução proposta.

Palavras-chave: IoT, Qualidade do Ar, Postura, Cadeiras inteligentes, Inteligência Artificial, Aprendizagem

Abstract

This dissertation presents the development of a system based on the Internet of Things to monitor environmental and postural quality in classrooms, aiming to promote students' well-being and academic performance. Specialized sensors were developed to measure parameters such as temperature, carbon dioxide, particulate matter, noise, lighting, and posture. The system integrates smart chairs equipped with sensors and artificial intelligence algorithms to evaluate postures and vital signs, as well as a networked system that centralizes data in an interactive dashboard. The methodology included the design and validation of prototypes, testing under different conditions, and analysis of results using metrics for precision and efficiency. The main findings highlight the system's effectiveness in continuously monitoring environmental and postural parameters, enabling real-time adjustments and contributing to healthier and more efficient learning environments. This work demonstrates a positive impact not only in educational contexts but also in other scenarios, such as hospitals and offices, showcasing the versatility of the proposed solution.

Keywords: Internet of Things, Air Quality, Posture, Smart Chairs, Artificial Intelligence, Learning.

Índice

Agradecimentos	i
Resumo	ii
Abstract	iii
Índice.....	iv
Lista de Figuras.....	viii
Lista de Tabelas	xiii
Lista de Siglas e Acrónimos	xiv
Capítulo 1.....	1
Introdução.....	1
1.1. Enquadramento	1
1.2. Objetivos do trabalho	3
1.3. Estrutura da Dissertação.....	4
Capítulo 2.....	6
Influência dos parâmetros ambientais e fisiológicos no ensino e saúde	6
2.1. Influência dos parâmetros ambientais	6
2.1.1. <i>Temperatura.....</i>	6
2.1.2. <i>Humidade Relativa</i>	7
2.1.3. <i>Dióxido de Carbono (CO₂).....</i>	7
2.1.4. <i>Partículas Suspensas</i>	8
2.1.5. <i>Iluminação</i>	9
2.1.6. <i>Ruído Sonoro</i>	9
2.2. Influência da postura	10
2.2.1. <i>Postura.....</i>	10
2.2.1.1. <i>Em ambiente académico</i>	11
Capítulo 3.....	12
Monitorização da qualidade ambiental	12
3.1. Sistemas de monitorização da qualidade do ar no interior.....	12
3.1.1. <i>Sistemas encontrados na literatura</i>	12
3.2. Equipamento desenvolvido.....	14
3.2.1. <i>Sensores do equipamento.....</i>	16
3.2.1.1. <i>Qualidade do Ar.....</i>	16
3.2.1.2. <i>Dióxido de carbono</i>	18

3.2.1.3. Luminosidade.....	19
3.2.1.4. Presença.....	19
3.2.1.5. Partículas Suspensas	20
3.2.1.6. Ruído Sonoro	21
3.2.1.6.1. Equalização	21
3.2.1.6.2. A-weighting.....	25
3.2.1.6.3. Cálculo do ruído sonoro	28
3.2.2. Firmware	30
3.2.3. Comunicação	30
3.2.4. Teste Realizado.....	31
3.3. Controlo de Iluminação	35
Capítulo 4.....	36
Sistema de monitorização da postura e sinais vitais	36
4.1. Equipamento desenvolvido.....	36
4.2. Monitorização da Postura.....	37
4.2.1. Sitting Posture Monitoring System (SPMS).....	37
4.2.2. SPMS propostos na literatura.....	38
4.2.3. SPMS Desenvolvido.....	41
4.2.3.1. Primeiro protótipo	41
4.2.3.1.1. Recolha de dados	44
4.2.3.1.2. Procedimento de recolha	45
4.2.3.1.3. Processamento e Limpeza de dados	47
4.2.3.1.4. Treino, Classificação e Validação.....	51
4.2.3.1.5. Experiência I.....	52
4.2.3.1.6. Experiência II	56
4.2.3.1.7. Experiência III	60
4.2.3.1.8. Comparação entre as experiências.....	63
4.2.3.2. Segundo protótipo.....	64
4.2.3.2.1. Recolha de dados	64
4.2.3.2.2. Análise de dados	67
4.2.3.2.3. Processamento de dados.....	77
4.2.3.2.4. Treino, Classificação e Validação.....	80
4.3. Monitorização dos Sinais vitais	83
4.3.1. Frequência Cardíaca	85

4.3.1.1. Acondicionamento do sinal PPG.....	87
4.3.1.2. Algoritmo para detecção de picos.....	89
4.3.2. Oximetria	92
4.4. Testes realizados	96
4.5. Comunicação.....	98
Capítulo 5.....	100
Sistema Central – DISPLAY.....	100
5.1. Sistema	100
5.2. Hardware.....	102
5.3. Especificações do Sistema	102
5.4. Tecnologias Utilizadas e funcionalidades	103
5.4.1. Backend.....	104
5.4.2. Frontend.....	105
5.4.3. Interface de Utilizador.....	106
5.4.4. Broker MQTT.....	107
5.4.5. Base de dados	107
5.5. Interface de Utilizador.....	108
5.5.1. Ecrã Inicial	108
5.5.2. Gráficos de tendência	110
5.5.3. Controlo de Iluminação	110
5.5.4. Código QR para acesso à Página WEB	112
5.6. Plataforma Web	112
5.6.1. Dashboard	112
5.6.2. Histórico de dados.....	114
5.6.3. Dashboard Cadeira	117
Capítulo 6.....	118
Conclusão.....	118
Bibliografia	120
Anexo I	A.1
Equalização	A.1
Anexo II	A.5
Mapa de Pressão - Posturas	A.5
Ranking de Características	A.10
Anexo III	A.12

Acondicionamento do Sinal	A.12
--	-------------

Lista de Figuras

Figura 1.1 – Número de artigos publicados por ano relacionados ao tema "Sucesso Acadêmico", com base nos dados extraídos da base de dados Science Direct.	2
Figura 1.2 – Número de artigos publicados por ano relacionados ao tema "Monitorização da Qualidade do Ar no Interior ", com base nos dados extraídos da base de dados Science Direct.	2
Figura 1.3 – Arquitetura da rede de sensores numa Sala de Aula.....	4
Figura 2.1 – Níveis de som típicos na escala em dBA (Retirada de [10])	10
Figura 3.1 – Diagrama de blocos do equipamento desenvolvido.....	15
Figura 3.2 – Placa de circuito impresso (PCB) do equipamento desenvolvido.	16
Figura 3.3 – Princípio de funcionamento do sensor de CO ₂ NDIR (Retirada de [21])......	18
Figura 3.4 – Fluxo de Processamento de Sinal para Cálculo do Nível de Pressão Sonora.	21
Figura 3.5 – Tolerâncias especificadas pela norma IEC 61672–1:2013 para dispositivos Classe 1 e 2.....	23
Figura 3.6 – Tolerâncias especificadas pela norma IEC 61672–1:2013 mais curva da resposta em frequência do microfone utilizado.	24
Figura 3.7 – Tolerâncias especificadas pela norma IEC 61672–1:2013, curva da resposta em frequência do microfone utilizado e curva após a equalização.	25
Figura 3.8 – Ouvido humano (Retirada de [29]).	26
Figura 3.9 – Curva Ponderação A (<i>A-weighting</i>).....	27
Figura 3.10 – Outras ponderações.....	28
Figura 3.11 – Comparação das Respostas Temporais "Fast" e "Slow" na Medição de Nível Sonoro (Retirada de [32]).	30
Figura 3.12 – Teste de monitorização ambiental em sala de aula	31
Figura 3.13 – Evolução da temperatura em sala de aula.....	31
Figura 3.14 – Evolução da humidade em sala de aula.	32
Figura 3.15 – Evolução da concentração de dióxido de carbono em sala de	

aula em sala de aula.	33
Figura 3.16 – Evolução da ruído ambiente em sala de aula.	34
Figura 3.17 – Comunicação com controlador DALI.....	35
Figura 4.1 – Diagrama de blocos cadeira desenvolvido.....	37
Figura 4.2 – Tipos de sensores utilizados: (a) Formato circular, fornece uma maior precisão, 4 sensores utilizados no assento; (b) Formato retangular, capta uma área maior, sensor utilizado no encosto;(c) Composição de um sensor FSR (Adaptada a partir de [52] [53]).	41
Figura 4.3 – Ossos dos pélvis: Ísquio (Retirada de [54]).	42
Figura 4.4 – Localização dos sensores.....	43
Figura 4.5 – SPMS: (a) Cadeira com os sensores colocados; (b) Cadeira após a estofagem.....	43
Figura 4.6 – Distribuição das Variáveis Demográficas e de Saúde.....	45
Figura 4.7 – Posições utilizadas na recolha de dados e a sua respetiva classe: (P1) é a posição “ideal”, onde as costas formam um ângulo de 90° com o solo e o encosto da cadeira é utilizado, sendo a posição com maior probabilidade de as partes-chave do corpo estarem corretamente alinhadas; (P2) inclinada para a frente; (P3) sentado na extremidade da cadeira e encostada; (P4) inclinado para a direita; (P5) inclinado para a esquerda; (P6) pé direito sobre o joelho esquerdo; (P7) pé esquerdo sobre o joelho direito; (P8) perna direita cruzada sobre a esquerda; (P9) perna esquerda cruzada sobre a direita; (P10) sentado na extremidade da cadeira.	46
Figura 4.8 – Recolha de dados via Bluetooth para o PC.	46
Figura 4.9 – Plano 2D do centroide.....	48
Figura 4.10 – Agrupamentos do centroide para cada posição.....	49
Figura 4.11 – Agrupamentos do centroide para cada posição sem <i>outliers</i> ($Z\text{-Score} \leq 0.5$).....	50
Figura 4.12 – Experiência 1: Ranking de características.	52
Figura 4.13 – Experiência 1: Matrizes de confusão para 6,8,10 posições com <i>outliers</i> : ANN (tons de azul), SVM (tons de verde).....	55
Figura 4.14 – Experiência 2: Ranking de características.	57

Figura 4.15 – Experiência 2: Matrizes de confusão para 6,8,10 posições com <i>outliers</i> : ANN (tons de azul), SVM (tons de verde).	59
Figura 4.16 – Experiência 3: Fluxograma do classificador.	60
Figura 4.17 – Experiência 3: Matriz de confusão do modelo ANN para verificação da perna cruzada.	61
Figura 4.18 – Experiência 3: Matriz de confusão do modelo ANN para classificação das posições de perna cruzada (P6, P7, P8 e P9)	61
Figura 4.19 – Experiência 3: Matriz de confusão do modelo ANN para classificação das posições (P1, P2, P3, P4, P5 e P10).	62
Figura 4.20 – Experiência 3: Matriz de confusão resultante da combinação dos três modelos.	62
Figura 4.21 – Localização dos sensores no segundo protótipo	64
Figura 4.22 – Distribuição das Variáveis Demográficas e de Saúde na segunda recolha de dados.	66
Figura 4.23 – Mapa de pressão da posição 1 (P1).	67
Figura 4.24 – Mapa de pressão da posição 2 (P2).	68
Figura 4.25 – Mapa de pressão da posição 3 (P3).	69
Figura 4.26 – Mapa de pressão da posição 4 (P4).	70
Figura 4.27 – Mapa de pressão da posição 5 (P5).	71
Figura 4.28 – Mapa de pressão da posição 6 (P6).	72
Figura 4.29 – Mapa de pressão da posição 7 (P7).	73
Figura 4.30 – Mapa de pressão da posição 8 (P8).	74
Figura 4.31 – Mapa de pressão da posição 9 (P9).	75
Figura 4.32 – Mapa de pressão da posição 10 (P10).	76
Figura 4.33 – Cálculo das características de posicionamento: (a) Left; (b) Right; (c) Front (d) Back.	77
Figura 4.34 – Linhas e colunas do assento da cadeira.	79
Figura 4.35 – Estimativa do Sensor 0 (S0).	79
Figura 4.36 – Protótipo 2: Ranking de características.	80
Figura 4.37 – Sensores com maior importância para a classificação da postura.	81
Figura 4.38 – Protótipo 2: Matrizes de confusão para 10 posições: ANN (tons de azul), SVM (tons de verde).	82

Figura 4.39 – (a) Sensor ótico SFH7072 [60] ; (b) Localização do sensor na cadeira.	83
Figura 4.40 – Tipos de montagem: (a) Transmissivo; (b) Refletivo (Adaptado a partir de [61]).	84
Figura 4.41 – Sinal PPG nos três comprimentos de onda (Verde, Vermelho e Infravermelho)	85
Figura 4.42 – Transformada de Fourier do sinal: Composição do sinal PPG	87
Figura 4.43 – Transformada de Fourier: Sinal PPG com filtro passa-banda de 0.5 Hz até 10 Hz.	89
Figura 4.44 – Algoritmo de detecção do pico (Adaptada de [67]).	90
Figura 4.45 – Período refratário (Adaptado de [67]).	91
Figura 4.46 – (a) Sinal PPG original; (b) Sinal PPG com o filtro passa-banda aplicado; (c) Detecção dos picos superiores do sinal PPG ($s = 0.0025$); (d) Detecção dos picos inferiores do sinal PPG ($s = 0.0025$).	91
Figura 4.47 – Absorção da luz vermelha e infravermelha pelo sangue oxigenado e Desoxigenado (Retirada de [68]).	92
Figura 4.48 – Componentes AC e DC no sinal PPG (Retirada de [61]). ..	93
Figura 4.49 – Curva de calibração típica (Retirada de [61]).	93
Figura 4.50 – Teste de calibração:(a) Dedos FingerSim 80%, 90% e 97%; (b) Montagem de Teste.	94
Figura 4.51 – Curva de calibração obtida utilizando o simulador <i>BC Biomedical FingerSim</i>	95
Figura 4.52 – Simulador de Paciente da BC Biomedical.	96
Figura 4.53 – Gráficos das medições de frequência cardíaca e saturação de oxigênio (SpO_2) durante testes com simulador de paciente.	97
Figura 5.1 – Sistema DISPLAY.	100
Figura 5.2 – Arquitetura do sistema central - DISPLAY.	101
Figura 5.3 – Diagrama de blocos do DISPLAY: Hardware.	102
Figura 5.4 – Diagrama de blocos do <i>software</i> do sistema central - DISPLAY	103
Figura 5.5 – Tecnologias utilizadas no Sistema DISPLAY.	103

Figura 5.6 – Constituição do <i>backend</i>	104
Figura 5.7 – Arquitetura do <i>Frontend</i>	106
Figura 5.8 – DISPLAY: Layout do Ecrã inicial.	109
Figura 5.9 – DISPLAY: Ecrã inicial.....	109
Figura 5.10 – DISPLAY: Gráfico de tendência.	110
Figura 5.11 – DISPLAY: Controlo de Iluminação.	111
Figura 5.12 – DISPLAY: Layout do controlo de iluminação.	111
Figura 5.13 – DISPLAY: <i>Código QR para acesso á plataforma WEB....</i>	112
Figura 5.14 – Vista <i>Dashboard</i>	113
Figura 5.15 – Vista <i>History</i>	114
Figura 5.16 – Vista <i>History</i> : Gráfico de tendência.	115
Figura 5.17 – Exemplo do relatório.	116
Figura 5.18 – Secção <i>Dashboard</i> da Cadeira.	117
Figura 5.19 – Secção de Postura da Cadeira.	117

Lista de Tabelas

Tabela 2.1 – Limites de concentração de dióxido de carbono no interior (Retirada de [9]).	8
Tabela 3.1 – Sistemas de monitorização da qualidade do ar interior encontrados na literatura.	14
Tabela 3.2 – Classificação do Índice de Qualidade do Ar (IAQ) (Retirada de [19]).	17
Tabela 3.3 – Características e limites de aceitação especificados em IEC 61672–1:2013 padrão para SLMs Classe 1 e 2 (Retirada de [28]).	22
Tabela 4.1 – Sistemas de monitorização da postura encontrados na literatura (Adaptada a partir de [36]).	40
Tabela 4.2 – Dados estatísticos das recolhas.	44
Tabela 4.3 – Experiência 1: Resultado dos vários modelos para 6, 8 e 10 posições com e sem <i>outliers</i> .	53
Tabela 4.4 – Experiência 2: Resultado dos vários modelos para 6, 8 e 10 posições com e sem <i>outliers</i> .	58
Tabela 4.5 – Comparação entre experiências.	63
Tabela 4.6 – Dados estatísticos das recolhas.	65
Tabela 4.7 – Resultado dos modelos ANN e SVM para a classificação das 10 posições.	81
Tabela 6.1 – Mapa de pressão com base na estimativa dos sensores.	A.5
Tabela 6.2 – <i>Ranking</i> com as 25 melhores características.	A.10

Lista de Siglas e Acrónimos

ACID	<i>Atomicity, Consistency, Isolation, Durability</i>
ANN	<i>Artificial Neural Network</i>
bpm	<i>Beats per minute</i>
BWR	<i>Body Weight Ratio</i>
CNN	<i>Convolution ANN</i>
CSV	<i>Comma-Separated Values</i>
DALI	<i>Digital Addressable Lighting Interface</i>
dBFS	<i>Decibels relative to full scale</i>
ET	<i>Empirical Threshold</i>
FSR	<i>Force-Sensing Resistor</i>
GUI	<i>Graphical User Interface</i>
HR	<i>Heart Rate</i>
HTML	<i>HyperText Markup Language</i>
HVAC	<i>Heating, Ventilation, and Air Conditioning</i>
I2C	<i>Inter-Integrated Circuit</i>
IAQ	<i>Indoor Air Quality</i>
IBI	<i>Inter-Beat Interval</i>
IEC	<i>International Electrotechnical Commission</i>
IEQ	<i>Indoor Environmental Quality</i>
IMU	<i>Inertial Measurement Unit</i>
IoT	<i>Internet of Things</i>
k-NN	<i>k-Nearest Neighbor</i>
LCD	<i>Liquid Crystal Display</i>
LED	<i>Light Emitting Diode</i>
MEMS	<i>Microelectromechanical systems</i>
MQTT	<i>Message Queuing Telemetry Transport</i>

NDIR	<i>Non-Dispersive Infrared</i>
PCB	<i>Printed Circuit Board</i>
PD	<i>Photo Diode</i>
PM	<i>Particulate Matter</i>
PPG	<i>Photoplethysmogram</i>
ppm	<i>Parts per Million</i>
PR	<i>Pulse Rate</i>
PWM	<i>Pulse Width Modulation</i>
RF	<i>Random Forest</i>
RMS	<i>Root Mean Square</i>
RMSSD	<i>Root Mean Square of Successive Differences</i>
RTOS	<i>Real-Time Operating System</i>
SBC	<i>Single Board Computer</i>
SGBD	<i>Sistema de Gestão de Base de Dados</i>
SLM	<i>Sound Level Meter</i>
SPL	<i>Sound Pressure Level</i>
SPL	<i>Sound Pressure Level</i>
SPMS	<i>Sitting Posture Monitoring System</i>
SVM	<i>Support Vector Machine</i>
TFT	<i>Thin Film Transistor</i>
TPS	<i>Typical Particle Size</i>
UART	<i>Universal Asynchronous Receiver Transmitter</i>
VOCs	<i>Volatile organic compounds</i>

Capítulo 1

Introdução

A presente dissertação descreve o trabalho realizado no âmbito do Projeto em Engenharia Eletrotécnica e de Computadores – Área de Especialização em Computadores e Sistemas Ciberfísicos, que visa a obtenção do grau de Mestre em Engenharia Eletrotécnica e de Computadores. Pretende-se neste capítulo, fazer uma breve introdução ao tema da dissertação e abordar a estruturação da mesma.

1.1. Enquadramento

O ambiente escolar desempenha um papel crucial no desenvolvimento académico, físico e psicológico dos alunos. Contudo, diversos fatores ambientais e comportamentais podem impactar negativamente o desempenho e a saúde dos estudantes, como níveis inadequados de temperatura, humidade, dióxido de carbono, iluminação e ruído, bem como posturas corporais incorretas mantidas por períodos prolongados. Estes elementos têm vindo a ser amplamente investigados pela comunidade científica, refletindo uma crescente preocupação com a criação de ambientes de aprendizagem mais saudáveis e eficientes.

A relevância deste tema é destacada pelo aumento progressivo do número de artigos publicados relacionados com "Sucesso Académico" e com "Monitorização da Qualidade do Ar no Interior". Segundo dados extraídos da base de dados Science Direct, a investigação sobre sucesso académico tem registado um crescimento notável, sobretudo a partir de 2015. Este crescimento pode ser atribuído à intensificação do interesse em compreender os fatores que influenciam diretamente o desempenho dos alunos, como condições ambientais e intervenções pedagógicas eficazes. Além disso, a aplicação de tecnologias educacionais tem contribuído significativamente para a exploração de soluções inovadoras no âmbito académico. O contexto da pandemia de COVID-19 também contribuiu para a intensificação destas investigações, evidenciando a necessidade de soluções eficazes para cenários híbridos e digitais, com foco em igualdade de oportunidades na educação. Ver Figura 1.1.




Figura 1.1 – Número de artigos publicados por ano relacionados ao tema "Sucesso Acadêmico", com base nos dados extraídos da base de dados Science Direct.

Paralelamente, a investigação sobre "Monitorização da Qualidade do Ar no Interior" também apresenta um crescimento acentuado, especialmente nos últimos anos. O aumento de publicações nesta área reflete a crescente preocupação com a qualidade do ar em espaços fechados (interior), como escolas, hospitais e escritórios, dada a sua influência na saúde e bem-estar. A ligação entre a qualidade do ar e a saúde humana é particularmente relevante no contexto escolar, onde a má ventilação e os altos níveis de poluição podem afetar diretamente a concentração e o desempenho dos estudantes. Estudos têm destacado os impactos negativos de uma má qualidade do ar, incluindo problemas respiratórios e doenças crónicas, enquanto os avanços tecnológicos, como sensores IoT e sistemas de monitorização, têm tornado a análise contínua mais acessível e prática. Além disso, regulamentações internacionais têm incentivado a conformidade com normas e a inovação tecnológica para melhorar as condições interiores, promovendo ambientes mais saudáveis e produtivos. Ver Figura 1.2.




Figura 1.2 – Número de artigos publicados por ano relacionados ao tema " Monitorização da Qualidade do Ar no Interior ", com base nos dados extraídos da base de dados Science Direct.

Além do impacto ambiental, a postura dos alunos é um fator de crescente preocupação, especialmente no contexto atual, em que os estudantes passam cada vez mais tempo sentados, frequentemente em frente a dispositivos eletrônicos. A ligação entre posturas inadequadas e problemas de saúde, como dores musculares e desconforto físico, tem levado à necessidade de integrar soluções tecnológicas que promovam boas práticas posturais e monitorem os alunos de forma contínua. Assim, abordar simultaneamente parâmetros ambientais e posturais torna-se essencial para melhorar o desempenho e o bem-estar dos estudantes.

Neste panorama, a integração de soluções baseadas na Internet das Coisas (IoT) surge como uma abordagem inovadora. A Internet das Coisas permite a interligação de dispositivos inteligentes capazes de recolher, processar e partilhar dados em tempo real, proporcionando *insights* preciosos para a criação de ambientes de aprendizagem adaptativos. Aplicada ao contexto escolar, esta tecnologia permite a criação de salas de aula inteligentes, que respondem dinamicamente a condições adversas e promovem um ambiente saudável e eficiente. A utilização de sensores IoT para monitorizar fatores como qualidade do ar, ruído, iluminação e postura dos alunos não só melhora o ambiente físico, mas também pode fornecer dados importantes para apoiar decisões pedagógicas e organizacionais.

Esta dissertação insere-se neste contexto, explorando o potencial da IoT para criar soluções integradas e acessíveis que melhorem a qualidade de vida dos alunos e otimizem o processo de aprendizagem. Embora focado em ambientes escolares, o trabalho também abre caminhos para a aplicação em outros contextos, como empresas, universidades e hospitais, demonstrando a versatilidade e o impacto positivo da tecnologia IoT em diversos setores.

1.2. Objetivos do trabalho

O principal objetivo da tese de Mestrado é criar uma ferramenta que permita recolher dados de modo a futuramente se possa desenvolver um estudo detalhado de como os parâmetros ambientais e fisiológicos influenciam a aprendizagem nas escolas, e com essa informação pode se tornar numa ferramenta de auxílio aos docentes na condução das aulas. Pretende-se assim criar um sistema que permita monitorizar a sala de aula e os alunos, de forma a conseguir a medição de parâmetros tais como: temperatura, ruído ambiente, humidade relativa, níveis de dióxido de carbono (CO₂), postura do aluno, entre outros e corrigir eventuais desvios nos vários parâmetros monitorizados, nomeadamente no que diz respeito à climatização e iluminação. Nesse âmbito, o objetivo passa por desenvolver alguns dos dispositivos, e contruir a rede IoT a implementar na sala da aula (Figura 1.3). A rede de sensores consistirá essencialmente em 4 módulos:

- Sensor Ambiental – Responsável pela aquisição dos parâmetros ambientais (Temperatura [°C], Humidade Relativa [%], CO₂ [ppm], PM [µg/m³], Ruido Sonoro [dB], iluminação [lux] e detetor de presença humana)

- Controlador de iluminação – Responsável por regular a iluminação das luminárias da sala de aula
- Cadeiras Inteligentes – Responsáveis pela monitorização dos sinais vitais e postura dos alunos
- Ecrã tátil / Servidor – Responsável por receber e tratar os dados recebidos dos restantes módulos assim como apresentar os dados num formato de *dashboard* que permita a interação com o utilizador.

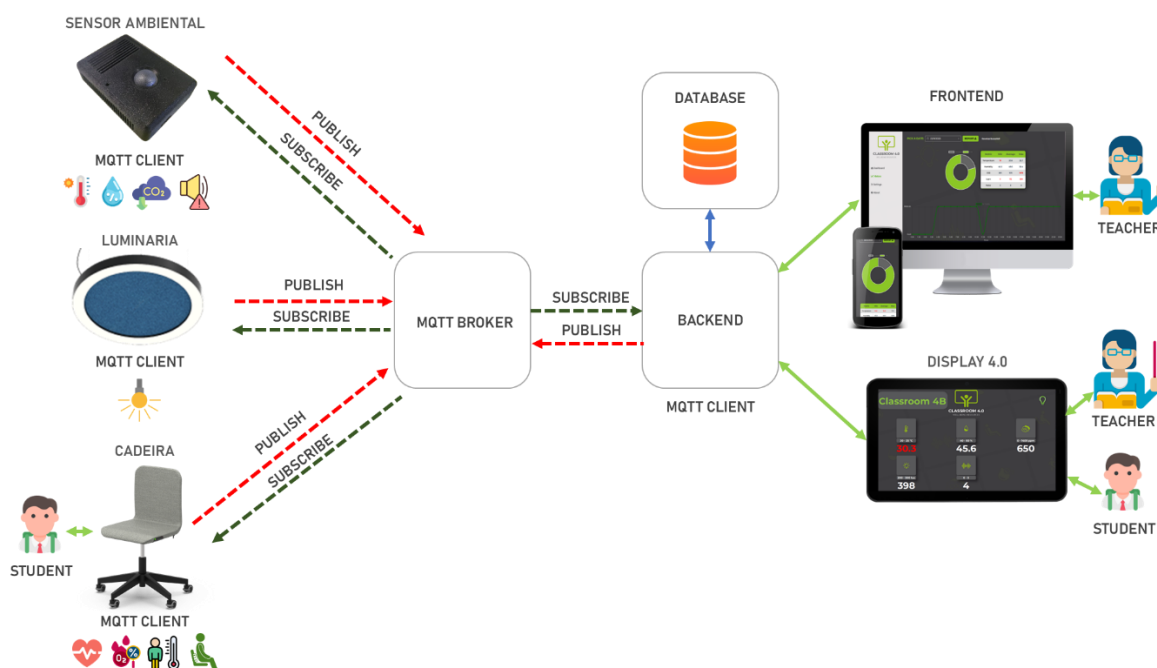


Figura 1.3 – Arquitetura da rede de sensores numa Sala de Aula.

1.3. Estrutura da Dissertação

Esta dissertação está organizada em seis capítulos, cada um estruturado para abordar os diversos aspetos do trabalho desenvolvido, desde o enquadramento teórico e contextual até à implementação prática e avaliação dos resultados obtidos.

- Capítulo 1 - Introdução: Este capítulo apresenta o enquadramento do tema, os objetivos do trabalho e a sua relevância no contexto atual, destacando a necessidade de monitorizar parâmetros ambientais e fisiológicos em ambientes escolares. Inclui ainda a descrição da estrutura da dissertação, facilitando a compreensão da organização geral do trabalho.
- Capítulo 2 - Influência dos Parâmetros Ambientais e Fisiológicos no Ensino e na Saúde: Neste capítulo, são analisados os impactos dos fatores ambientais e posturais na aprendizagem e no bem-estar dos alunos. São discutidos aspetos como temperatura,

humidade, dióxido de carbono, iluminação, ruído e postura, com base na literatura científica, demonstrando a importância de monitorizar e melhorar estes parâmetros.

- Capítulo 3 - Sistema de Monitorização da Qualidade do Ar: Este capítulo detalha o desenvolvimento de um sistema IoT para monitorizar a qualidade ambiental nas salas de aula. Inclui a descrição dos sensores utilizados, as tecnologias aplicadas e os resultados obtidos na monitorização de parâmetros como temperatura, humidade, dióxido de carbono, ruído e luminosidade.
- Capítulo 4 - Sistema de Monitorização da Postura e Sinais Vitais: Este capítulo foca-se na monitorização postural dos alunos através de cadeiras inteligentes equipadas com sensores e algoritmos de classificação. São apresentados o design, a metodologia de recolha e processamento de dados, e os resultados dos testes realizados.
- Capítulo 5 - Sistema Central - Visualização e Integração de Dados: Este capítulo apresenta a conceção de um sistema centralizado que integra os dados recolhidos pelos sensores e os exibe num *dashboard* interativo. Descreve o *hardware*, o *software* e as tecnologias utilizadas para criar uma interface amigável e funcional para os utilizadores.
- Capítulo 6 - Conclusões e Trabalho Futuro: O último capítulo sintetiza os resultados alcançados, destacando as contribuições do trabalho para o campo da IoT e sua aplicabilidade em diferentes contextos. São também sugeridas melhorias e potenciais direções para futuras investigações e aplicações.

Capítulo 2

Influência dos parâmetros ambientais e fisiológicos no ensino e saúde

Antes de abordar os aspetos relacionados com a implementação do sistema, é necessário perceber a importância dos parâmetros ambientais e fisiológicos e como estes atuam no ensino e na saúde.

Neste capítulo, é feita uma reflexão acerca da influência dos parâmetros ambientais e fisiológicos no ensino e na saúde. Serão abordados fatores como a temperatura, a humidade relativa, o dióxido de carbono (CO₂) e a iluminação, e como estes afetam o desempenho cognitivo dos alunos. A temperatura ideal para salas de aula será detalhada, assim como a importância de uma humidade relativa adequada. A concentração de CO₂ será analisada como indicador de ventilação e o seu impacto na aprendizagem. A importância de uma iluminação adequada, tanto natural quanto artificial, também será destacada para promover um ambiente de aprendizagem eficaz e saudável.

2.1. Influência dos parâmetros ambientais

Existe uma relação entre as condições ambientais em salas de aula e o desempenho cognitivo dos alunos. Diversos fatores ambientais, como a temperatura, humidade, concentrações de dióxido de carbono (CO₂) e iluminação desempenham papéis cruciais para a atividade de aprendizagem. Estudos indicam que uma ventilação inadequada e altos níveis de CO₂ podem levar a sintomas de cansaço, dificuldades de concentração e um aumento no absentismo escolar. Além disso, temperaturas extremas e má qualidade do ar interior estão associadas a problemas de saúde, como sintomas respiratórios e alergias, que afetam negativamente a performance académica dos alunos. A manutenção de uma boa qualidade ambiental interna (*Indoor Environmental Quality*, IEQ), com níveis adequados de ventilação e conforto térmico, é essencial para promover um ambiente de aprendizagem saudável e produtivo, propício ao sucesso escolar [1].

2.1.1. Temperatura

O ambiente térmico no interior de um edifício, em particular na sala de aula, é determinado pelas variáveis de temperatura do ar, humidade relativa e velocidade do ar, sendo que o intervalo de temperatura recomendado situa-se entre os 20°C e os 24°C, e mais

especificamente, entre os 20°C e os 22°C durante o inverno e os 22°C e os 24°C durante o verão. Yang [2] e colaboradores destacam especificamente que temperaturas superiores a 24 °C afetam negativamente o desempenho acadêmico na matemática e na compreensão de textos escritos [3]. Este, entre outros trabalhos, mostram que a temperatura é um dos fatores mais importantes pois afeta diretamente a capacidade cognitiva dos alunos. As temperaturas extremas, tanto as altas como as baixas, prejudicam o desempenho. Em ambientes muito quentes, existe uma tendência de diminuição no foco e na concentração, enquanto ambientes frios levam a uma redução na velocidade de processamento cognitivo.

2.1.2. Humidade Relativa

A humidade relativa pode afetar a percepção de conforto térmico dos estudantes, i.e., em condições de alta humidade o ambiente pode se tornar desconfortavelmente quente, enquanto em condições de baixa humidade, o ambiente pode parecer mais frio do que realmente é. Estudos sugerem que uma humidade relativa entre 30% e 60% é o ideal para salas de aula, proporcionando um equilíbrio entre conforto e controlo da qualidade do ar [2]. Ambientes excessivamente secos podem levar à irritação nos olhos, garganta seca e desconforto geral, afetando indiretamente na concentração. Por outro lado, ambientes excessivamente húmidos podem levar a problemas respiratórios.

2.1.3. Dióxido de Carbono (CO₂)

Em muitos estudos, o CO₂ é utilizado como um indicador para avaliar a eficácia da ventilação. Um estudo encontrou que 63% das salas de aula apresentavam concentrações médias de CO₂ superiores a 1000 ppm (partes por milhão), com níveis mantidos acima desse limite durante cerca de 58% do período de ocupação. Aproximadamente 20% das salas de aula apresentaram concentrações muito elevada, com concentrações médias de CO₂ excedendo 2000 ppm. Esses resultados indicam uma falha significativa em fornecer a ventilação mínima especificada nas recomendações existentes para um número considerável de escolas/salas de aula. A exposição a altos níveis de CO₂ tem sido associada a uma redução no desempenho cognitivo dos estudantes. Estudos mostraram que ambientes internos com maiores concentrações de CO₂ ou taxas de ventilação inadequadas resultam numa diminuição significativa no desempenho de aprendizagem das crianças. Além disso, melhorias nas taxas de ventilação foram reconhecidas como benéficas para a saúde, especialmente para a saúde respiratória, devido à redução das concentrações de poluentes gerados internamente [2].

A Tabela 2.1 representa a tabela de referência para a qualidade do ar interior, baseada na concentração de dióxido de carbono (CO₂), medida em partes por milhão (ppm).

Tabela 2.1 – Limites de concentração de dióxido de carbono no interior (Retirada de [4]).

CO ₂ [ppm]	Air Quality
2100	BAD Heavily contaminated indoor air Ventilation required
2000	
1900	
1800	
1700	
1600	MEDIOCRE Contaminated indoor air Ventilation recommended
1500	
1400	
1300	
1200	
1100	FAIR
1000	
900	
800	GOOD
700	
600	EXCELLENT
500	
400	

2.1.4. Partículas Suspensas

As partículas suspensas (*Particulate Matter*, PM) no ar são categorizadas principalmente em PM2.5 (partículas com diâmetro de 2,5 micrómetros ou menos) e PM10 (partículas com diâmetro de 10 micrómetros ou menos). Estas partículas podem ter origens tanto internas quanto externas [2]:

- Fontes Internas: Incluem atividades dentro da sala de aula, como o uso de materiais escolares, móveis de madeira e compostos usados para limpar e polir superfícies.
- Fontes Externas: Emissões de veículos e outras fontes de poluição externa podem penetrar nas salas de aula através de janelas e portas abertas

Um estudo realizado em 73 salas de aula revelou que mais de 80% das salas apresentavam concentrações de PM2.5 e PM10 superiores aos limites recomendados pela Organização Mundial da Saúde (OMS) [5], [7] para uma exposição de 8 horas. Estes níveis elevados de PM foram associados a fontes de poluição externa, como o tráfego de veículos, e a características específicas das salas de aula, como a presença de móveis laminados ou compostos de plástico e o uso de produtos de limpeza. A ventilação inadequada foi identificada como um fator contribuinte para o acúmulo de PM nas salas de aula. Em salas com ventilação natural, a prática de abrir todas as janelas durante os intervalos foi crucial para atingir taxas adequadas de ventilação e reduzir a concentração de poluentes do ar interno. No entanto, durante os períodos de ocupação, a ventilação natural também precisa ser mantida para evitar a alta concentração de partículas e outros poluentes [2].

De acordo com as diretrizes da OMS em 2021 [7], os limites recomendados para PM2.5 são

de $5 \mu\text{g}/\text{m}^3$ para a média anual e $15 \mu\text{g}/\text{m}^3$ para a média de 24 horas, enquanto para PM_{10} , os limites são de $15 \mu\text{g}/\text{m}^3$ e $45 \mu\text{g}/\text{m}^3$.

2.1.5. Iluminação

A iluminação em ambientes de sala de aula desempenha um papel crucial no desempenho e conforto dos estudantes. A exposição à luz natural tem sido associada a melhorias significativas no desempenho escolar. Estudos demonstraram que estudantes em salas com maior quantidade de luz natural apresentam melhores resultados em testes de matemática e leitura em comparação com aqueles expostos a menos luz natural. Por outro lado, a luz natural também pode trazer desafios, como o aumento do desconforto visual e do aquecimento solar. Portanto, é importante que a incorporação de luz natural nas salas de aula seja feita de forma cuidadosa para evitar esses problemas. Em muitos casos, a luz artificial ainda é necessária para manter níveis apropriados de iluminação durante todo o dia.

A luz artificial é uma componente essencial para garantir uma iluminação constante e adequada. A iluminação artificial inadequada pode causar dores de cabeça, fadiga ocular e cansaço, afetando negativamente o desempenho dos estudantes. Estudos sugerem que diferentes cores e níveis de iluminação podem ter impacto nas percepções térmicas e promover sentimentos positivos que incentivam a aprendizagem [2], [8].

A exposição a níveis muito altos de luminosidade pode causar ofuscamento, tornando difícil os alunos verem claramente objetos e textos principalmente em ambientes onde existe superfícies refletivas como telas e quadros brancos. Por outro lado, a fraca iluminação tem também impactos negativos no ambiente de aprendizagem e no desempenho dos alunos. Ambientes com pouca iluminação podem levar à fadiga visual e até mesmo à sonolência, dificultando os alunos em manterem-se focados nas atividades escolares, dificultam a leitura, forçando assim a visão, o que pode contribuir para o desenvolvimento de problemas de visão a longo prazo.

2.1.6. Ruído Sonoro

O ruído em ambientes de sala de aula é um problema significativo que pode afetar tanto o desempenho dos alunos quanto o bem-estar dos professores.

Níveis elevados de ruído em salas de aula podem interferir na capacidade dos alunos de ouvir e entender o professor, resultando em dificuldades de concentração, aumento do stress e redução do desempenho acadêmico. Segundo estudos, o nível de ruído recomendado para salas de aula é de até 35 dBA, conforme os padrões da OMS [9]. No entanto, medições em escolas frequentemente mostram níveis bem superiores, entre 70 dBA e 78 dBA, o que é considerado prejudicial.




Figura 2.1 – Níveis de som típicos na escala em dBA (Retirada de [10])

2.2. Influência da postura

A postura enquanto sentado, como em sala de aula, pode ter impactos na saúde física do aluno, bem como na capacidade de aprendizagem e concentração. Uma má postura por longos períodos pode contribuir para dores nas costas e desconforto físico. Tratando-se de crianças e adolescentes, ainda em fase de desenvolvimento, a adoção de uma postura correta evita futuros problemas musculares e esqueléticos no futuro.

2.2.1. Postura

A postura ideal ou correta, enquanto sentado, é algo que continua a ser clinicamente debatido. Uma boa postura desempenha um papel crucial na manutenção da saúde geral e bem-estar. De acordo com a literatura, não existe uma postura específica considerada cientificamente a “correta”. Dado que cada pessoa é diferente de outra, i.e., assume diferentes formas e tamanhos com uma variação natural na curvatura espinhal, a postura “correta” varia de pessoa para pessoa. Assim sendo, considera-se uma postura correta aquela em que partes-chave do corpo da pessoa estão corretamente alinhados, com a quantidade certa de apoio da tensão muscular [11]. Uma pessoa pode melhorar a postura e conseguir uma posição sentada adequada mantendo os pés apoiados no chão ou num apoio para os pés, evitando cruzar os joelhos ou tornozelos, mantendo um pequeno espaço entre a parte de trás dos joelhos e a cadeira, posicionando o joelhos na mesma altura ou ligeiramente abaixo dos quadris, colocando os tornozelos na frente dos joelhos, relaxando os ombros, mantendo os antebraços e joelhos paralelos ao chão sempre que possível, sentado ereto e olhando para a frente sem forçar o

pescoço.

2.2.1.1. Em ambiente acadêmico

O artigo [12] apresenta um estudo transversal que investigou a associação entre a postura sentada e a dor nas costas entre estudantes universitários. Os autores examinaram várias variáveis, incluindo características sociodemográficas, iluminação adequada na sala de aula, postura e tipo de cadeira, em relação à dor no pescoço ou nas costas no dia da pesquisa, tanto aguda quanto crônica. Os resultados mostraram que certas posturas sentadas, como curvar as costas, apoiar os pés em outra cadeira e cruzar as pernas, estavam significativamente associadas à dor no pescoço, bem como à dor aguda e crônica. Além disso, a quantidade de tempo passado em frente ao computador também mostrou associação com os sintomas de dor. Os resultados evidenciaram a necessidade de implementação de políticas e projetos institucionais para prevenir e controlar a dor nas costas entre os estudantes.

A implementação de um sistema para monitorizar e promover uma postura adequada no ambiente escolar ou acadêmico é uma iniciativa crucial, dado o tempo significativo que os estudantes passam sentados durante as aulas. A má postura durante esses períodos prolongados pode levar a uma série de problemas de saúde a longo prazo como dores nas costas, pescoço e ombros, além de contribuir para o desenvolvimento de problemas musculoesqueléticos crônicos. Para abordar esta questão, seria benéfico desenvolver e implementar tecnologias ou dispositivos que possam monitorizar continuamente a postura dos alunos enquanto estão sentados durante as aulas. Além disso, é importante integrar a educação sobre postura corporal nos currículos escolares, para que os alunos desenvolvam uma compreensão sólida dos princípios de uma postura saudável desde cedo. Isso pode incluir aulas dedicadas à ergonomia e postura, bem como a incorporação de práticas de postura correta em atividades regulares de sala de aula.

Em última análise, a implementação de um sistema abrangente para monitorizar e promover uma postura adequada nas escolas não apenas pode ajudar a prevenir problemas de saúde a longo prazo entre os estudantes, mas também pode promover hábitos saudáveis que beneficiarão a sua saúde e bem-estar ao longo da vida.

Capítulo 3

Monitorização da qualidade ambiental

Este capítulo centra-se essencialmente no desenvolvimento de um equipamento IoT para monitorização ambiental, com foco específico no ambiente das salas de aula. O objetivo principal é garantir que parâmetros como a qualidade do ar, níveis de ruído, luminosidade e presença de partículas suspensas sejam continuamente monitorizados para proporcionar um ambiente mais saudável e adequado ao processo de aprendizagem.

O equipamento desenvolvido é parte essencial deste projeto, consistindo num conjunto de sensores capazes de medir dióxido de carbono (CO_2), partículas suspensas, temperatura, humidade, níveis de ruído e iluminação. Este sistema foi projetado para ser utilizado em salas de aula, com o intuito de monitorizar e ajustar as condições ambientais em tempo real, criando um ambiente mais propício para o bem-estar dos alunos e professores.

3.1. Sistemas de monitorização da qualidade do ar no interior

A qualidade do ar em ambientes interiores desempenha um papel crucial na saúde e no bem-estar das pessoas. Em espaços fechados, como salas de aula, escritórios e residências, a acumulação de poluentes como dióxido de carbono (CO_2), partículas suspensas e compostos orgânicos voláteis (*Volatile Organic Compounds*, VOCs) pode afetar negativamente a concentração, o desempenho e até causar problemas respiratórios. Sistemas de monitorização da qualidade do ar no interior permitem a medição contínua desses parâmetros, proporcionando informações em tempo real que podem ser usadas para ajustar a ventilação e melhorar as condições ambientais. Estes sistemas tornam-se essenciais para criar ambientes mais saudáveis e seguros, sobretudo em espaços com ocupação prolongada.

3.1.1. Sistemas encontrados na literatura

Foram analisados diversos estudos que propõem sistemas de monitorização da qualidade do ar interior, cada um com diferentes focos, parâmetros medidos e finalidades.

Jongkwon Son et al. [13], teve como objetivo analisar a correlação entre a qualidade ambiental interna (IEQ) e a qualidade do ar interno (*Indoor Air Quality*, IAQ) utilizando dispositivos IoT. Os parâmetros medidos incluíram temperatura, humidade, concentração de CO_2 , poeira fina e ultrafina (partículas suspensas). A motivação para este estudo reside na necessidade de

proteger a saúde das pessoas contra poluentes internos, que podem causar problemas como sonolência, dores de cabeça e diminuição da concentração. A finalidade do estudo foi estabelecer padrões para manter a qualidade ambiental interna, criando um ambiente seguro para indivíduos com saúde frágil, como crianças e idosos. As principais conclusões indicaram que a qualidade do ar interno variava significativamente com a estação do ano e a localização dentro do ambiente. A análise de correlação revelou uma relação entre temperatura e poeira fina e ultrafina, além de uma correlação negativa entre temperatura e CO₂ na primavera.

Felix-Constantin Adochiei et al.[14], desenvolveu um sistema de monitorização em tempo real da qualidade do ar interior utilizando um equipamento capaz de medir uma ampla gama de parâmetros do ar, incluindo CO, CO₂-equivalente (CO₂eq), EtOH, H₂, H₂S, NO₂, O₃, PM1.0, PM2.5, PM4.0, PM10, RH/T, Rn, SO₂, tamanho típico de PM (TPS) e compostos orgânicos voláteis totais (tVOCs). A motivação para este estudo foi o impacto direto da má qualidade do ar interno na saúde, conforto e desempenho humano. A finalidade foi permitir que os *stakeholders* tomassem decisões informadas sobre as ações necessárias para melhorar a qualidade do ar interno com base nos dados recolhidos. As principais conclusões destacaram que o sistema foi eficaz em fornecer dados em tempo real, permitindo a visualização de níveis de poluentes em diferentes formatos, como gráficos de linha, medidores e valores numéricos. Isso ajudou a identificar rapidamente áreas problemáticas e a tomar medidas corretivas.

Sayantani Bhattacharya et al. [15] propôs uma solução sem fios para a monitorização da qualidade do ar interno. Os parâmetros medidos incluíram temperatura, humidade, gases poluentes (CO, CO₂) e partículas em suspensão (PM2.5, PM10). A motivação foi evitar os efeitos adversos à saúde dos ocupantes do edifício devido a contaminantes microbianos e poluentes gasosos. A finalidade foi representar a qualidade do ar em termos de Índice de Qualidade do Ar (IAQ) e fornecer informações ambientais para controlar sistemas HVAC em edifícios inteligentes. As principais conclusões indicaram que a rede de sensores sem fios foi eficaz em monitorizar a qualidade do ar em tempo real e que os dados recolhidos poderiam ser usados para ajustar automaticamente os sistemas de ventilação para manter a qualidade do ar em níveis seguros.

Farida A. Ali et al. [16], teve como objetivo desenvolver um sistema baseado em IoT para monitorização da qualidade do ar interno, com foco na saúde humana. Os parâmetros medidos incluíram partículas em suspensão, compostos orgânicos voláteis, monóxido de carbono e dióxido de nitrogénio (NO₂). A motivação para este estudo foi a periculosidade da má qualidade do ar interno para pessoas com alergias respiratórias, crianças pequenas e idosos. A finalidade foi melhorar a qualidade do ar interno e a qualidade de vida nas residências, reduzindo a incidência de problemas respiratórios relacionados a asma e alergias em crianças e pessoas alérgicas. As principais conclusões apontaram que o sistema conseguiu monitorizar efetivamente os níveis de poluentes e fornecer alertas em tempo real quando os níveis de poluentes ultrapassaram os limites seguros, permitindo uma resposta rápida para mitigar os riscos à saúde.

A Tabela 3.1 sintetiza alguns dos sistemas de monitorização da qualidade do ar interior encontrados na literatura.

Tabela 3.1 – Sistemas de monitorização da qualidade do ar interior encontrados na literatura.

Artigos	Tecnologias Utilizadas	Parâmetros Medidos	Objetivos
Jongkwon Son et al. [13]	WiFi	Temperatura, humidade, CO ₂ , PM 2.5 e PM10	Analisar a correlação entre IEQ e IAQ, propor critérios para gestão da IAQ
Felix-Constantin Adochiei et al. [14]	WiFi	CO, CO ₂ eq, EtOH, H ₂ , H ₂ S, NO ₂ , O ₃ , PM1.0, PM2.5, PM4.0, PM10, RH/T, Rn, SO ₂ , TPS, tVOCs	Desenvolver um sistema de monitorização em tempo real da IAQ
Bhattacharya et al. [15]	Zigbee	Temperatura, humidade, CO, CO ₂ , PM2.5, PM10	Monitorizar a qualidade do ar interno usando rede de sensores sem fios
Farida A. Ali et al. [16]	WiFi	PM, VOCs, CO, NO ₂	Desenvolver um sistema de monitorização da IAQ com foco na saúde humana
Liang Zhao et al. [17]	Modbus, LoRa, Wi-Fi, GPRS, NB-IoT	Benzene, CO, formaldeído, NO ₂ , PM, CO ₂ , ozono	Monitorização em tempo real da qualidade do ar interno para diferentes cenários de aplicação usando comunicação de múltiplas interfaces.

Seguidamente é feita a descrição do equipamento desenvolvido no âmbito do projeto para monitorizar a qualidade do ar no interior.

3.2. Equipamento desenvolvido

O equipamento desenvolvido, conforme ilustrado no diagrama de blocos (Figura 3.1), foi concebido para monitorizar a qualidade do ar em espaços interiores, mas vai além das funções típicas de um dispositivo de monitorização ambiental. Para além de medir parâmetros essenciais, como dióxido de carbono (CO₂), partículas suspensas (PM2.5), temperatura e humidade relativa, o sistema também monitoriza a poluição sonora, através da medição dos níveis de ruído em decibéis (dBA), e a intensidade da luz ambiente.




Figura 3.1 – Diagrama de blocos do equipamento desenvolvido.

Este equipamento IoT, com múltiplos sensores integrados para monitorização ambiental (qualidade do ar, ruído, luz e presença), pode ser aplicado em diversas áreas, trazendo vantagens significativas em termos de conforto, segurança e eficiência energética. Exemplos de possíveis aplicações:

- **Edifícios inteligentes**

- Gestão eficiente de energia: Em edifícios comerciais ou residenciais, o equipamento pode monitorizar a ocupação das salas e ajustar automaticamente a iluminação e climatização, reduzindo o consumo de energia quando os espaços estão desocupados.
- Monitorização ambiental contínua: O sensor pode ser usado para monitorizar a qualidade do ar em tempo real, contribuindo para a criação de ambientes de trabalho mais saudáveis e confortáveis.
- Segurança acústica e luminosa: Sensores de ruído e luz podem ser usados para assegurar que os níveis de poluição sonora e luminosa estão dentro dos limites recomendados, proporcionando ambientes mais agradáveis e produtivos.

- **Escolas e instituições de Ensino**

- Ambientes saudáveis: O equipamento pode monitorizar e garantir que os níveis de CO₂ e partículas suspensas estão em níveis adequados, promovendo um ambiente de aprendizagem saudável, o que pode influenciar positivamente o desempenho académico e a concentração dos alunos.
- Iluminação e ruído: A adaptação da iluminação às condições de luz natural e a monitorização do ruído nas salas de aula também podem melhorar as condições de ensino.

- **Hospitais e clínicas**

- Monitorização da qualidade do ar: Em ambientes de saúde, a qualidade do ar é crucial para a segurança dos pacientes. O equipamento pode monitorizar constantemente os níveis de partículas e CO₂, ajudando a reduzir a propagação de doenças e melhorando a recuperação dos pacientes.
- Ambientes controlados: O sensor de presença e os controlos de luz podem ser utilizados em áreas como quartos de recuperação, ajustando automaticamente os níveis de luminosidade conforme necessário, proporcionando conforto adicional aos pacientes.

3.2.1. Sensores do equipamento

Na Figura 3.2 está apresentada a placa de circuito impressa (PCB), o *hardware* desenvolvido pela Dynasys, que integra vários componentes essenciais para a monitorização de parâmetros ambientais. A placa foi concebida para suportar sensores especializados em diferentes áreas de monitorização ambiental, como qualidade do ar, dióxido de carbono (CO₂), partículas suspensas (PM2.5), poluição sonora e luminosa.




Figura 3.2 – Placa de circuito impresso (PCB) do equipamento desenvolvido.

3.2.1.1. Qualidade do Ar

O equipamento desenvolvido utiliza um sensor digital integrado da Bosch [18], capaz de monitorizar simultaneamente vários parâmetros ambientais. Este dispositivo, comunica por I2C e é particularmente adequado para sistemas portáteis e dispositivos *wearables* devido ao seu baixo consumo de energia. O sensor esse que permite medir a temperatura, a humidade relativa, a pressão atmosférica e compostos orgânicos voláteis (VOCs), sendo amplamente utilizado em

aplicações de monitorização da qualidade do ar.

A medição de temperatura é realizada com uma precisão de $\pm 1^\circ\text{C}$ na faixa operacional de 0 a 65°C , enquanto a humidade relativa é medida com uma precisão de $\pm 3\%$, cobrindo de 0 a 100% de humidade. Adicionalmente, a pressão atmosférica é monitorizada com alta resolução, o que permite a utilização do sensor em sistemas de previsão meteorológica e estimativa de altitude, tornando-o adequado para aplicações de navegação.

O sensor inclui ainda um mecanismo interno para deteção de gases e VOCs, fornecendo informações cruciais sobre a qualidade do ar, especialmente útil em ambientes interiores. Um algoritmo integrado analisa as variações na resistência da camada sensível aos gases, convertendo esses dados numa estimativa em tempo real da poluição do ar. Esta característica é particularmente vantajosa para aplicações como automação residencial, dispositivos vestíveis e ambientes ligados à Internet das Coisas (IoT).

O sensor capaz de fornecer um Índice de Qualidade do Ar (*Indoor Air Quality*, IAQ), que reflete o nível de poluição ou pureza do ar em ambientes fechados. Este índice é calculado com base nas medições dos compostos orgânicos voláteis (VOCs) presentes no ar, que são gases emitidos por diversos materiais e atividades humanas, como tintas, produtos de limpeza, cozinhar ou até respirar. O IAQ é uma métrica essencial para monitorizar a qualidade do ar, especialmente em espaços interiores onde a ventilação pode ser limitada.

O IAQ é representado numa escala que varia entre 0 e 500, onde um valor mais baixo indica ar limpo e um valor mais alto sugere ar poluído. A classificação geral pode ser dividida como apresenta a Tabela 3.2.

Tabela 3.2 – Classificação do Índice de Qualidade do Ar (IAQ) (Retirada de [19]).

IAQ Index	Air Quality	Impact (long-term exposure)	Suggested action
0 – 50	Excellent	Pure air; best for well-being	No measures needed
51 – 100	Good	No irritation or impact on well-being	No measures needed
101 – 150	Lightly polluted	Reduction of well-being possible	Ventilation suggested
151 – 200	Moderately polluted	More significant irritation possible	Increase ventilation with clean air
201 – 250 ¹	Heavily polluted	Exposition might lead to effects like headache depending on type of VOCs	optimize ventilation
251 – 350	Severely polluted	More severe health issue possible if harmful VOC present	Contamination should be identified if level is reached even w/o presence of people; maximize ventilation & reduce attendance
> 351	Extremely polluted	Headaches, additional neurotoxic effects possible	Contamination needs to be identified; avoid presence in room and maximize ventilation

3.2.1.2. Dióxido de carbono

O equipamento desenvolvido também inclui um sensor de dióxido de carbono (CO_2) [20], que utiliza tecnologia de infravermelho não dispersivo (NDIR) para medir a concentração de CO_2 no ar. Este tipo de sensor é amplamente utilizado em sistemas de monitorização da qualidade do ar interior, dispositivos de ventilação, climatização e automação residencial, devido à sua precisão e estabilidade a longo prazo.

A tecnologia NDIR funciona com base na absorção de luz infravermelha por moléculas de CO_2 (Figura 3.3). O sensor emite luz infravermelha através de um tubo de medição, e um detetor no outro extremo mede a quantidade de luz absorvida pelas moléculas de CO_2 presentes no ar. A concentração de dióxido de carbono é então calculada com base na quantidade de luz absorvida. Este método oferece alta precisão e é menos suscetível a interferências de outros gases, tornando-o confiável para monitorizar a concentração de CO_2 em ambientes interiores.




Figura 3.3 – Princípio de funcionamento do sensor de CO_2 NDIR (Retirada de [21]).

Este sensor opera numa faixa de medição que varia, geralmente, entre 0 e 5000 ppm (partes por milhão) de CO_2 , com uma precisão tipicamente em torno de ± 50 ppm, o que o torna ideal para aplicações onde é necessário controlar os níveis de ventilação com base na concentração de CO_2 , como em edifícios comerciais, escolas e sistemas de ar condicionado. Além disso, o sensor inclui uma compensação automática de temperatura e humidade, assegurando que as medições de CO_2 sejam precisas, independentemente das variações ambientais.

Com uma interface de comunicação digital, como UART ou PWM, o sensor pode ser facilmente integrado em sistemas eletrónicos, permitindo que os dados sejam monitorizados em tempo real ou transmitidos para outros dispositivos. O baixo consumo de energia do sensor também facilita a sua utilização em dispositivos alimentados por bateria, o que o torna apropriado para sistemas de monitorização contínua.

As suas aplicações incluem a monitorização da qualidade do ar interior em edifícios residenciais e comerciais, sistemas de ventilação e climatização, dispositivos de automação residencial e ambientes de cultivo de plantas, onde o controlo da concentração de CO_2 é essencial para manter um ambiente saudável e eficiente.

3.2.1.3. Luminosidade

O equipamento desenvolvido também integra um sensor de luz ambiente [22], que é capaz de medir a intensidade de luz visível em ambientes internos e externos. Este sensor utiliza um foto-díodo para captar a luz visível e converter essa informação em sinais digitais, permitindo o ajuste automático de sistemas de iluminação, displays ou outros dispositivos eletrônicos com base nas condições de iluminação do ambiente.

Uma das principais características deste sensor é a sua alta sensibilidade à luz ambiente, com capacidade para medir um amplo intervalo de intensidades luminosas, desde condições de pouca luz até a ambientes com alta luminosidade. Isso o torna ideal para aplicações como ajuste automático do brilho de ecrãs em dispositivos móveis, tablets, monitores ou sistemas de iluminação inteligente, garantindo que o nível de luminosidade seja sempre o mais adequado para o conforto visual e economia de energia.

O sensor também possui a capacidade de compensar variações na luz infravermelha e filtrar o espectro de luz visível, o que garante medições mais precisas, independentemente da interferência de outras fontes de luz, como a luz solar direta ou luzes artificiais. O seu design compacto e baixo consumo de energia tornam-no adequado para uma vasta gama de dispositivos portáteis e sistemas embutidos.

Com uma interface de comunicação digital, tipicamente I2C, o sensor pode ser facilmente integrado em sistemas eletrônicos, permitindo uma leitura rápida e eficiente dos dados de luz ambiente. Isso facilita a sua aplicação em dispositivos que necessitam ajustar automaticamente a sua operação com base nas condições de iluminação, como smartphones, sistemas de iluminação automatizada e até sistemas de segurança que dependem de deteção de mudanças nas condições de luz.

Além disso, o sensor é altamente fiável e oferece uma resposta rápida, sendo adequado para ambientes onde as condições de luz variam rapidamente, garantindo uma adaptação contínua e precisa do sistema a essas mudanças.

3.2.1.4. Presença

O equipamento desenvolvido também utiliza um sensor de radar para detetar presença humana [23], utilizando a tecnologia de radar Doppler de 24 GHz. Este tipo de sensor é amplamente utilizado em aplicações de automação residencial, segurança, iluminação inteligente e monitorização de presença em edifícios. Através da análise de sinais de micro-ondas refletidos pelos objetos em movimento, o sensor é capaz de identificar a presença e o movimento de pessoas ou objetos, mesmo através de obstáculos, como paredes finas ou portas.

Com uma elevada sensibilidade, este sensor é capaz de detetar movimentos em distâncias que variam, normalmente, entre 5 e 10 metros, dependendo da configuração e das condições ambientais. Ele oferece múltiplos modos de operação que permitem ajustar a sensibilidade e o alcance de deteção, tornando-o adaptável a diferentes cenários de uso, como deteção de presença em iluminação automática ou ativação de alarmes em sistemas de segurança.

Além disso, o sensor é projetado para operar com baixo consumo de energia, tornando-o ideal para dispositivos alimentados por bateria. A sua interface de comunicação digital, geralmente UART, permite fácil integração em sistemas eletrônicos, facilitando a troca de dados entre o sensor e outros dispositivos, como microcontroladores ou sistemas de automação.

Uma das vantagens desta tecnologia de radar é a sua capacidade de operar em diferentes condições de iluminação e temperatura, sem ser afetada por fatores como poeira ou fumo, ao contrário de sensores baseados em infravermelho. Isso torna o sensor altamente confiável para uma ampla gama de aplicações, incluindo automação residencial, iluminação inteligente, monitorização de ocupação em escritórios ou segurança perimetral.

Com uma alta taxa de resposta, este sensor é ideal para aplicações que exigem deteção rápida e precisa de movimento ou presença, sendo utilizado tanto em dispositivos de consumo como em ambientes industriais, onde a precisão e a fiabilidade são cruciais para o bom funcionamento do sistema.

3.2.1.5. Partículas Suspensas

O equipamento desenvolvido integra um sensor de partículas a laser [24], que mede a concentração de material particulado no ar, incluindo partículas finas como PM2.5 e PM10. Este tipo de sensor é amplamente utilizado em sistemas de monitorização da qualidade do ar

A tecnologia de deteção utilizada permite identificar e quantificar as partículas no ar através da dispersão de luz. Quando as partículas atravessam o feixe de laser, elas dispersam a luz, e essa dispersão é captada por um detetor, que analisa o tamanho e a quantidade de partículas presentes.

O sensor é capaz de medir partículas em duas categorias principais: partículas com diâmetro inferior a 2,5 micrómetros (PM2.5) e partículas com diâmetro inferior a 10 micrómetros (PM10). Esta medição é crucial, pois as partículas de menor tamanho, como as PM2.5, podem penetrar profundamente nos pulmões, causando problemas de saúde, especialmente em ambientes urbanos com altos níveis de poluição.

Além de ser eficiente em termos de deteção, o sensor possui uma interface digital, normalmente utilizando comunicação UART, facilitando a sua integração em sistemas eletrônicos, como microcontroladores. O baixo consumo de energia deste sensor torna-o particularmente adequado para dispositivos portáteis e para sistemas de monitorização contínua, permitindo o seu uso em equipamentos alimentados por bateria, como purificadores de ar portáteis.

As suas aplicações incluem o uso em purificadores de ar, sistemas de ar condicionado e monitorização de qualidade do ar em interiores, sendo também uma solução eficaz para integrar em sistemas HVAC (*Heating, Ventilation and Air Conditioning*) e em dispositivos ligados à Internet das Coisas (IoT), onde é necessário um controlo preciso da qualidade do ar.

Este sensor é capaz de fornecer leituras rápidas e precisas sobre os níveis de poluição, com um tempo de resposta típico de menos de 10 segundos, tornando-o ideal para ambientes

onde é necessário monitorizar a qualidade do ar em tempo real.

3.2.1.6. Ruído Sonoro

O ruído sonoro é medido através do nível de pressão sonora, expresso em decibéis (dB). Este nível de pressão sonora é uma medida logarítmica da intensidade do som, refletindo a forma como o ouvido humano percebe diferentes pressões do ar causadas pelas ondas sonoras. Para medir o ruído sonoro, utiliza-se normalmente um sonómetro.

Para tal foi desenvolvido um sonómetro utilizando um microfone MEMS digital. O microfone selecionado [25], possui uma interface de saída I²S (*Inter-IC Sound*), o que permite transmitir o sinal de áudio diretamente em formato digital, eliminando a necessidade de conversão analógico-digital. Uma das vantagens deste microfone é que a sua sensibilidade é especificada como ≈ 1 dB. Isto significa que, ao medir um tom puro de 1 kHz a 94 dB SPL (*Sound Pressure Level*), o nível de saída do microfone será de -26 dBFS, com uma variação possível de apenas ≈ 1 dB, sem necessidade de calibração adicional. Esta precisão é excelente, especialmente considerando que não se teve acesso a equipamento de calibração especializado [26].

A frequência de amostragem utilizada neste trabalho foi de 48 kHz. Este valor é amplamente utilizado em sistemas de gravação de áudio de alta qualidade e em aplicações de processamento de som, como a medição de ruído. Com esta frequência de amostragem, é possível captar com precisão frequências audíveis até cerca de 24 kHz, respeitando o teorema de Nyquist. Isto assegura a cobertura de toda a gama de frequências que o ouvido humano pode perceber.

A Figura 3.4 apresenta um diagrama de blocos que descreve o fluxo de processamento do sinal de áudio captado por um microfone, como o ICS-43434, para a obtenção do nível de pressão sonora em decibéis (dBA).




Figura 3.4 – Fluxo de Processamento de Sinal para Cálculo do Nível de Pressão Sonora.

3.2.1.6.1. Equalização

A norma IEC 61672-1:2013 [27] estabelece requisitos para instrumentos de medição de nível sonoro, com foco em sonómetros (ou decibelímetros). Essa norma define as especificações e os critérios de desempenho para esses dispositivos, garantindo que as medições de som sejam consistentes e precisas em diferentes ambientes e condições.

A IEC 61672-1:2013 categoriza os sonómetros em duas classes principais:

- Classe 1: Sonómetros de alta precisão, usados em medições críticas onde a exatidão é essencial, como em avaliações ambientais ou de saúde ocupacional.
- Classe 2: Sonómetros de menor precisão, geralmente utilizados em aplicações gerais onde uma precisão extrema não é necessária.

Os sonómetros de Classe 1 têm tolerâncias mais estritas do que os de Classe 2, principalmente em termos de resposta em frequência, resposta temporal e outras características técnicas, como apresentado na Tabela 3.3.

Tabela 3.3 – Características e limites de aceitação especificados em IEC 61672-1:2013 padrão para SLMs Classe 1 e 2 (Retirada de [28]).

Performance criteria defined by IEC 61672-1:2013		Class 1 SLMs	Class 2 SLMs
Operational Frequency Range		20 – 16 000 Hz	20 – 8 000 Hz
Operational Temperature Range		-10 – 50° C	0 to 40° C
Operational Humidity		25 – 90%	30 – 90%
Multichannel Crosstalk		-70 dB	-70 dB
Frequency Range in 1/3 Octave Bands (Hz)	Uncertainty for Class 1 & 2 SLMs (dB)	Acceptance Limits (dB)	Acceptance Limits (dB)
10	0.6	+3.0; -∞	+5.0; -∞
12.5	0.6	+2.5; -∞	+5.0; -∞
16	0.6	+2.0; -∞	+5.0; -∞
20	0.6	±2.0	±3.0
25	0.6	+2.0; -1.5	±3.0
31.5	0.6	±1.5	±3.0
40-80	0.6	±1.0	±2.0
100-800	0.6	±1.0	±1.5
1000	0.6	±0.7	±1.0
1250	0.6	±1.0	±1.5
1600-2000	0.6	±1.0	±2.0
2500-3100	0.6	±1.0	±2.5
4000	0.6	±1.0	±3.0
5000	0.7	±1.5	±3.5
6300	0.7	+1.5; -2.0	±4.5
8000	0.7	+1.5; -2.5	±5.0
10000	0.7	+2.0; -3.0	+5.0; -∞
12500	1	+2.0; -5.0	+5.0; -∞
16000	1	+2.5; -16.0	+5.0; -∞
20000	1	+3.0; -∞	+5.0; -∞

Em relação à frequência, o ideal num sonómetro é uma resposta de frequência perfeitamente plana, i.e., que o dispositivo capte e meça todos os sons com a mesma precisão, independentemente da frequência, mas obter esse resultado é algo altamente improvável na realidade [28].

A Figura 3.5 apresenta um gráfico de tolerância em dB em função da frequência (Hz) para dois tipos de classificações de precisão: Classe 1 e Classe 2.




Figura 3.5 – Tolerâncias especificadas pela norma IEC 61672–1:2013 para dispositivos Classe 1 e 2.

Na Figura 3.6 foi adicionada a curva aproximada da resposta do microfone (curva verde) obtida do *datasheet*, sobreposta às faixas de tolerância para sonômetros de Classe 1 e Classe 2. Observando a Figura 3.6, verifica-se que o principal problema identificado na resposta do microfone está tanto nas baixas frequências quanto nas altas frequências, onde a sua resposta está fora das tolerâncias impostas pela norma. Por estarem fora das tolerâncias impostas pela norma, especialmente para dispositivos de Classe 1, essas variações nas extremidades do espectro de frequências podem comprometer a precisão das medições. Nas frequências médias (onde o ouvido humano é mais sensível), o microfone funciona bem, mas fora dessa faixa, ajustes ou correções adicionais podem ser necessários para garantir que o dispositivo esteja em conformidade com as normas de medição de som, como a IEC 61672.




Figura 3.6 – Tolerâncias especificadas pela norma IEC 61672–1:2013 mais curva da resposta em frequência do microfone utilizado.

Foi desenvolvido um filtro de equalização para compensar as imperfeições na resposta do microfone, com o objetivo de aproximar o sistema aos requisitos das normas de medição de som, como a IEC 61672.

O objetivo é dar ganho nas baixas frequências e atenuar as altas. Sendo que ideal seria obter um filtro cuja resposta em frequência fosse a inversa à do microfone, isto resultaria numa curva equalizada perfeitamente plana.

Na Figura 3.7 está representada a curva de resposta do microfone aplicando o filtro de equalização, mostrada pela linha azul, que conseguiu corrigir os principais desvios na resposta do microfone, tornando-a mais linear e dentro das faixas de tolerância impostas pela IEC 61672. Tornando assim, o dispositivo mais adequado para a medição precisa de ruídos em diferentes frequências, garantindo que as leituras de som sejam fiáveis e estejam em conformidade com as normas internacionais.




Figura 3.7 – Tolerâncias especificadas pela norma IEC 61672–1:2013, curva da resposta em frequência do microfone utilizado e curva após a equalização.

O script Python com a análise da resposta do microfone em comparação com tolerâncias normativas de Classes 1 e 2, e o desenvolvimento dos filtros digitais para ajustar a resposta do microfone e criar uma curva de equalização encontra-se no anexo A.1.

3.2.1.6.2. *A-weighting*

A ponderação A, ou *A-weighting*, é um conceito importante em acústica que se refere a uma técnica de medição do som que ajusta a sensibilidade das medições para refletir a forma como o ouvido humano (Figura 3.8) percebe os diferentes níveis de pressão sonora em diferentes frequências.




Figura 3.8 – Ouvido humano (Retirada de [29]).

A pressão sonora exercida no diafragma de um microfone em comparação com o tímpano humano pode ser bastante diferente, mesmo no mesmo campo sonoro. Isso ocorre porque o volume de ar no canal auditivo humano tem uma ressonância em torno dos 4000 Hz, o que reforça o nível de som no tímpano em comparação com o diafragma do microfone. Além disso, a presença da cabeça, do tronco e da orelha externa de uma pessoa interfere no campo sonoro, alterando a forma como o som é percebido pelo tímpano. Essas estruturas criam difrações e reflexões que modificam a pressão sonora em relação ao que seria medido diretamente por um microfone.

Outras diferenças na percepção do som devem-se ao órgão auditivo, especificamente a cóclea, e a efeitos psicológicos. A cóclea, responsável por converter as ondas sonoras em sinais neurais, tem maior dificuldade em detectar sons de baixa e muito alta frequência, o que significa que esses sons são percebidos com menos intensidade, apesar da pressão sonora real. Além disso, à medida que os humanos envelhecem, a cóclea tende a sofrer danos, especialmente nas células que detectam sons de alta frequência, resultando numa perda auditiva progressiva para esses sons. A curva logarítmica que caracteriza a intensidade sentida pela cóclea (*loudness*) também influencia a capacidade de distinguir alterações de tom, sendo que variações de tom em frequências mais baixas são mais facilmente percebidas do que em frequências mais altas [30].

Estes conceitos são essenciais para entender que as medições acústicas realizadas com equipamentos, como microfones, podem não refletir perfeitamente a percepção humana do som, devido a fatores fisiológicos e anatómicos. Essas diferenças têm implicações importantes em estudos de acústica, especialmente em contextos que envolvem a percepção humana do som, como na avaliação do conforto acústico, em testes auditivos, ou no desenvolvimento de dispositivos de proteção auditiva. Ao projetar ambientes sonoros ou avaliar riscos de perda auditiva, é crucial considerar essas variações e integrar essas informações com os dados obtidos através de medições acústicas.

A ponderação A é usada para medir o nível de pressão sonora de uma forma que seja mais representativa da audição humana. O ouvido humano é mais sensível a frequências médias, particularmente na faixa dos 500 Hz a 6 kHz, e menos sensível a frequências muito baixas ou muito altas. A ponderação aplica uma curva de filtro que atenua as baixas e altas frequências de modo a refletir essa sensibilidade. Quando um medidor de nível sonoro usa a ponderação A, ele ajusta os valores medidos para que as leituras em decibéis (dB) representem de forma mais precisa o impacto percebido pelo ouvido humano. O resultado dessas medições é expresso em dBA, onde "A" indica que a ponderação A foi aplicada.

É amplamente utilizada em normas internacionais para o controle do ruído no ambiente de trabalho e em ambientes exteriores, ajudando a avaliar os níveis de exposição sonora das pessoas. Em estudos relacionados à saúde ocupacional, engenharia acústica ou avaliação de impactos ambientais, a ponderação A é crucial para avaliar o risco de danos auditivos e o conforto acústico.

A curva de ponderação A (Figura 3.9) mostra decibéis de atenuação ou ganho em cada frequência na faixa da audição humana que é mais tarde aplicado à medição do microfone.




Figura 3.9 – Curva Ponderação A (*A-weighting*).

Além da ponderação A (*A-weighting*), que é a mais utilizada em medições de som para imitar a resposta do ouvido humano a diferentes frequências, existem outras ponderações padrão que servem para diferentes propósitos (Figura 3.10). Cada uma dessas curvas é usada em contextos específicos, dependendo da natureza da medição de som e da frequência de interesse.

A ponderação B foi criada para imitar a resposta auditiva humana a níveis de som moderados (cerca de 70 dB SPL). A curva B é menos utilizada atualmente, pois a ponderação A cobre uma gama mais ampla de intensidades de som de forma mais precisa.

A ponderação C é usada para imitar a resposta humana em níveis de som altos, geralmente

acima de 85 dB SPL. A curva C é muito mais plana que a ponderação A, dando peso quase uniforme a todas as frequências, exceto para as muito baixas (abaixo de 20 Hz) e muito altas (acima de 20 kHz).

A ponderação Z refere-se a uma resposta linear, ou seja, sem ponderação. Esta curva é plana ao longo de todo o espectro de frequências, desde 10 Hz até 20 kHz, e é usada para medições quando se deseja capturar o som como ele é, sem aplicar filtros que simulem a audição humana.




Figura 3.10 – Outras ponderações.

3.2.1.6.3. Cálculo do ruído sonoro

Após a aquisição do sinal amostrado pelo microfone, o próximo passo é o cálculo do valor RMS (*Root Mean Square*) do sinal. O RMS é uma métrica que representa a amplitude média da variação do sinal ao longo do tempo, e é amplamente utilizada para determinar a intensidade do som. Este valor de RMS é então convertido em decibéis (dB), utilizando uma referência estabelecida no *datasheet* do microfone para um nível de pressão sonora de 94 dB SPL que será -26 dBFS.

Essa referência para ser convertida em amplitude absoluta, precisamos de considerar a resolução do ADC que neste caso trata-se de 24 bits, o maior nível de quantificação do ADC que é $V_{FSV} = 2^{23} - 1$ (ou seja, o maior número positivo possível em 24 bits), que equivale a 8388607.

A conversão de -26 dBFS para uma amplitude absoluta pode ser feita com a seguinte equação.

$$Ref_A = (2^{23} - 1) \times 10^{(Ref_{dBFS}/20)} \quad (3.1)$$

Substituindo os valores:

$$Ref_A = (2^{23} - 1) \times 10^{(-26/20)} \cong 420426 \quad (3.2)$$

Portanto, ao aplicar um som de 94 dB SPL ao microfone, a amplitude esperada na saída digital será aproximadamente 420426.

A partir dessa referência, a conversão é feita da seguinte forma:

$$SPL \text{ (dB)} = Ref_{dB \text{ SPL}} + 20 \log_{10} \left(\frac{RMS}{Ref_A} \right) \quad (3.3)$$

Substituindo os valores:

$$SPL \text{ (dB)} = 94 + 20 \log_{10} \left(\frac{RMS}{420426} \right) \quad (3.4)$$

É importante notar que as medições de nível de som só são significativas no contexto da duração da amostragem. Isso ocorre porque o nível de pressão sonora pode flutuar com o tempo, e a forma como essas variações são tratadas durante a medição impacta o valor final. A ponderação temporal (*time weighting*) refere-se à forma como os sonômetros respondem a variações rápidas ou lentas no nível de som, suavizando essas variações para que as leituras sejam mais estáveis. A norma IEC 61672-1 descreve duas ponderações de tempo diferentes, *Fast* (F) e *Slow* (S), cada uma delas é usada em diferentes contextos para medir o som de acordo com suas características temporais [31].

A ponderação *Fast* (Rápida) reage mais rapidamente às mudanças nos níveis sonoros. Utiliza uma constante de tempo de 125 ms, o que significa que o sonômetro se ajusta rapidamente a variações no som. Este tipo de ponderação é útil para capturar mudanças rápidas no ambiente sonoro, como sons de impacto, ou em ambientes onde o nível de ruído flutua frequentemente. No entanto, devido à sua rápida resposta, pode exibir flutuações mais instáveis no valor medido.

A ponderação *Slow* (Lenta) suaviza muito mais as flutuações rápidas de som, utilizando uma constante de tempo de 1 segundo. Esta ponderação é útil quando se deseja uma leitura mais estável, sendo frequentemente utilizada para medir ruídos contínuos ou estáveis, como por exemplo o som de um ventilador ou de uma máquina que opera de forma constante. A leitura "lenta" não reage tão rapidamente às mudanças bruscas, mas é mais adequada para fornecer uma média mais consistente em ambientes com ruídos variáveis, minimizando o impacto de picos momentâneos.

A Figura 3.11 mostra como as diferentes ponderações temporais, *Fast* e *Slow*, influenciam a forma como o nível sonoro é exibido em um sonômetro.




Figura 3.11 – Comparação das Respostas Temporais "Fast" e "Slow" na Medição de Nível Sonoro (Retirada de [31]).

3.2.2. Firmware

O *firmware* do equipamento desenvolvido foi implementado utilizando a linguagem de programação C++, que permite o controle preciso dos recursos de *hardware*.

Além disso, o *firmware* foi desenvolvido sobre o FreeRTOS [32], um sistema operativo em tempo real (RTOS) amplamente utilizado em sistemas embebidos. O FreeRTOS proporciona uma plataforma robusta e leve para o desenvolvimento de aplicações que exigem a execução simultânea de várias tarefas, garantindo que os sensores e outros componentes funcionem de maneira sincronizada e eficiente.

3.2.3. Comunicação

O equipamento foi projetado para oferecer versatilidade em termos de comunicação, suportando dois tipos principais de tecnologias de conectividade: WiFi e LoRa. Esta flexibilidade permite que o dispositivo seja facilmente adaptado a diferentes cenários de implementação, desde redes locais até comunicações de longa distância. No contexto específico deste projeto, a opção utilizada para a comunicação de dados foi o WiFi, com a troca de informações realizada através do protocolo MQTT (*Message Queuing Telemetry Transport*), que é muito utilizado em aplicações de Internet das Coisas devido à sua leveza e eficiência.

3.2.4. Teste Realizado

Foi feito um teste com o sensor ambiental na EST Setúbal, na sala F367 com cerca de 29 m² (Figura 3.12), durante o decorrer de uma aula com aproximadamente 14 alunos. A aula iniciou com as janelas e portas fechadas, e 40 minutos após o início da aula foi aberta uma janela e a porta.



Figura 3.12 – Teste de monitorização ambiental em sala de aula

Na Figura 3.13 está representada a curva de evolução da temperatura ao longo da aula.




Figura 3.13 – Evolução da temperatura em sala de aula.

Inicialmente, portanto às 14:50, a sala encontrava-se com janelas e porta fechadas, situação que contribuiu para um aumento progressivo da temperatura devido à presença de aproximadamente 14 alunos. A temperatura começou em cerca de 20,5°C e atingiu um valor próximo de 23°C passados 40 minutos (15:32), momento em que foi aberta uma janela e a porta da sala.

Após estabelecer um caminho para a circulação do ar, verificou-se uma estabilização da temperatura e um ligeiro decréscimo, resultado da troca de ar entre o interior e o exterior. Este comportamento evidencia a influência da ventilação natural na regulação térmica da sala, reduzindo o impacto do calor gerado pela ocupação.

De acordo com as recomendações para salas de aula, a faixa de temperatura ideal situa-se entre os 20°C e os 24°C.

Na Figura 3.14 está representado a evolução da humidade ao longo da aula.




Figura 3.14 – Evolução da humidade em sala de aula.

Inicialmente, a sala apresentava uma humidade elevada, acima de 75%, devido à ausência de ventilação, com janelas e porta fechadas. À medida que o tempo avançava, observou-se uma redução gradual na humidade, que se tornou mais acentuada a partir das 15:32, momento em que foi aberta uma janela e a porta.

A abertura das vias de ventilação resultou numa diminuição significativa da humidade, atingindo valores próximos de 55% no final do período monitorizado. Este fenómeno reflete o impacto da ventilação natural na renovação do ar e na redução do teor de humidade, principalmente em salas ocupadas.

Considerando que a humidade relativa ideal para salas de aula se situa entre 30% e 60%, verificou-se que, embora os níveis iniciais estivessem fora do intervalo recomendado, a ventilação natural permitiu atingir valores mais adequados. Este resultado realça a importância da ventilação eficaz para assegurar condições ambientais favoráveis ao conforto térmico e à concentração dos alunos. Estratégias como a ventilação periódica podem ser essenciais para manter os níveis de humidade dentro dos limites recomendados ao longo do período de ocupação.

Na Figura 3.15 está representado a evolução da concentração de dióxido de carbono ao longo da aula.




Figura 3.15 – Evolução da concentração de dióxido de carbono em sala de aula em sala de aula.

Inicialmente, com a sala ocupada por 14 alunos e sem ventilação (janelas e porta fechadas), verificou-se um aumento progressivo na concentração de CO_2 , que ultrapassou os 2500 ppm às 15:32. Este valor é consideravelmente superior ao limite recomendado de 1000 ppm, estabelecido para manter uma boa qualidade do ar interior e evitar impactos negativos na saúde e desempenho cognitivo. (Tabela 2.1)

O dióxido de carbono é amplamente utilizado como indicador da eficácia da ventilação em ambientes fechados. Níveis elevados de CO_2 (>1000 ppm) estão associados a sintomas como fadiga, dores de cabeça, dificuldades de concentração e até sonolência, afetando diretamente a produtividade e a capacidade de aprendizagem. Em concentrações ainda mais altas (>2000 ppm), os efeitos adversos tornam-se mais pronunciados, podendo incluir desconforto respiratório e aumento do risco de doenças respiratórias a longo prazo devido à má qualidade do ar interior.

Após a abertura da janela e da porta às 15:32, registou-se uma descida acentuada na concentração de CO_2 , que atingiu valores inferiores a 600 ppm no final do período monitorizado. Este comportamento revela a eficácia da ventilação natural na renovação do ar interior, evidenciando a importância de medidas simples, como a abertura periódica de janelas e portas, para mitigar o acumular de CO_2 e outros poluentes.

Na Figura 3.16 está representado a evolução do ruído ambiente ao longo da aula.




Figura 3.16 – Evolução da ruído ambiente em sala de aula.

O gráfico apresenta variações significativas, com valores oscilando entre 50 dBA e picos acima de 90 dBA. Essa variação reflete a dinâmica de um ambiente de sala de aula, onde a interação entre alunos e atividades específicas pode levar a picos de ruído.

Os níveis de ruído recomendados para salas de aula, de acordo com a Organização Mundial da Saúde (OMS), devem ser inferiores a 35 dBA durante o período de ensino para garantir um ambiente propício à aprendizagem. Contudo, o nível de ruído registado durante este teste permaneceu constantemente acima deste limite, com valores médios frequentemente superiores a 70 dBA, o que pode impactar negativamente a capacidade de concentração e compreensão dos alunos.

Níveis elevados de ruído em salas de aula têm sido associados a dificuldades de comunicação, aumento do esforço cognitivo e, em casos prolongados, até aumento do stress. Para os professores, o ruído elevado pode contribuir para a fadiga vocal e stress ocupacional. Em cenários educativos, esses fatores prejudicam tanto o processo de ensino como o de aprendizagem.

3.3. Controlo de Iluminação

Para o controlo de iluminação no ambiente de sala de aula, foi utilizado um *gateway* da empresa Dynasys, que tem a função de converter mensagens MQTT em comandos DALI (*Digital Addressable Lighting Interface*), permitindo a comunicação eficiente entre dispositivos IoT e os sistemas de iluminação inteligentes.

O DALI é um protocolo de comunicação amplamente utilizado em sistemas de iluminação, oferecendo controlo preciso e endereçável de luminárias. Permite que cada luminária seja controlada individualmente ou em grupos, proporcionando um controlo detalhado da iluminação de um espaço. Este protocolo é bastante aplicado em edifícios inteligentes devido à sua flexibilidade e robustez, podendo ser facilmente integrado em sistemas de automação maiores [33], [34], [35].

O *gateway* da Dynasys funciona como um tradutor entre os dois protocolos, recebendo mensagens MQTT e convertendo-as em comandos DALI. Este processo é fundamental para permitir que dispositivos IoT, como sensores e controladores, interajam com o sistema de iluminação, ajustando automaticamente os níveis de iluminação com base nos dados recolhidos do ambiente, tais como luminosidade e presença. A arquitetura do *gateway* garante uma comunicação eficiente entre os dispositivos IoT e o sistema de iluminação sem a necessidade de uma reconfiguração completa dos sistemas existentes, permitindo uma integração simples e escalável.




Figura 3.17 – Comunicação com controlador DALI.

Capítulo 4

Sistema de monitorização da postura e sinais vitais

O capítulo 4 é dedicado ao desenvolvimento de um sistema de monitorização da postura e de sinais vitais, com o intuito de melhorar o conforto e a saúde dos alunos em ambiente de sala de aula. A postura sentada prolongada, muitas vezes incorreta, pode causar problemas musculoesqueléticos, especialmente em crianças e adolescentes que ainda estão em fase de crescimento. Por essa razão, o sistema desenvolvido neste trabalho visa monitorizar continuamente a postura dos alunos enquanto estão sentados, proporcionando feedback em tempo real para corrigir posturas inadequadas e, assim, prevenir eventuais problemas de saúde a longo prazo.

Este capítulo começa com uma revisão de sistemas de monitorização da postura encontrados na literatura, focando-se em diferentes abordagens e tecnologias utilizadas, como sensores integrados em cadeiras ou sistemas de *machine learning* para análise de dados posturais. Em seguida, é apresentado o sistema de monitorização da postura desenvolvido, incluindo a descrição dos sensores integrados nas cadeiras, que permitem a recolha de dados sobre a distribuição do peso corporal e a pressão exercida durante o tempo em que os alunos estão sentados. O capítulo aborda também o processamento dos dados recolhidos, que envolve técnicas de limpeza e preparação, seguidas pela aplicação de algoritmos de *machine learning* para classificar as diferentes posturas.

Além da monitorização da postura, este sistema inclui a capacidade de medir sinais vitais, como a frequência cardíaca e a oximetria, utilizando sensores não invasivos, o que permite uma análise mais completa do estado físico dos alunos. O capítulo descreve os testes realizados com o sistema e apresenta uma análise detalhada dos resultados obtidos, mostrando o potencial deste sistema em promover uma melhor saúde postural e vital para os alunos em ambientes de ensino.

4.1. Equipamento desenvolvido

A Figura 4.1 ilustra a arquitetura da cadeira desenvolvida para monitorização da postura e dos sinais vitais do estudante. Este sistema é composto por sensores de pressão, um sensor de temperatura e sensores de sinais vitais, além de um leitor RFID para identificação do aluno.

Os sensores de pressão, distribuídos estrategicamente na cadeira, permitem monitorizar a postura do aluno, detetando alterações que possam indicar posições inadequadas ou desconforto ao longo do tempo. O sensor de temperatura fornece informações sobre a condição térmica do utilizador ou do ambiente, enquanto os sensores de sinais vitais capturam dados

relativos ao ritmo cardíaco e aos níveis de oxigenação no sangue (SpO2), permitindo um acompanhamento em tempo real das condições de saúde do utilizador.

Para associar os dados recolhidos a um estudante específico, o sistema inclui um módulo RFID que permite a identificação individual de cada aluno. Assim, ao sentar-se na cadeira e aproximar um cartão RFID, o aluno é automaticamente identificado, e os dados capturados pelos sensores são registados de forma personalizada. O sistema operativo FreeRTOS, implementado no microcontrolador, gere a execução das tarefas em tempo real, garantindo uma resposta eficiente e contínua às mudanças nos sinais monitorizados.




Figura 4.1 – Diagrama de blocos cadeira desenvolvida.

4.2. Monitorização da Postura

A monitorização da postura é fundamental para identificar e corrigir hábitos posturais inadequados, especialmente em contextos onde as pessoas permanecem sentadas por longos períodos, como nas salas de aula. A adoção de uma má postura pode, ao longo do tempo, causar desconforto, dores musculares e até problemas de saúde mais graves. No caso de crianças e adolescentes, que estão em fase de crescimento, é crucial promover uma postura adequada para prevenir problemas futuros. Neste contexto, sistemas de monitorização da postura, baseados em sensores, que permitem recolher dados em tempo real, oferecendo feedback imediato para que os utilizadores possam ajustar a sua posição de forma mais ergonómica e saudável.

4.2.1. Sitting Posture Monitoring System (SPMS)

O desenvolvimento de SPMS (*Sitting Posture Monitoring System*) refere-se a sistemas que

monitorizam a postura de uma pessoa enquanto sentada. Estes sistemas utilizam sensores integrados nas cadeiras, de forma “invisível”, para monitorizar continuamente a postura sem causar desconforto. Esta abordagem é uma alternativa aos sistemas *wearables*, que podem ser incômodos, e aos sistemas de visão artificial, que têm limitações de privacidade e precisão [36].

A comunidade científica tem explorado o uso de cadeiras inteligentes para monitorizar a postura de pessoas sentadas. As cadeiras possuem sensores integrados no assento e encosto. Esses sensores adquirem informações sobre a distribuição do peso corporal e a pressão exercida por diferentes partes do corpo enquanto uma pessoa está sentada. Com base nesses dados, os algoritmos de *machine-learning* permitem identificar a postura atual da pessoa e fornecer feedback em tempo real sobre a postura adequada. Uma característica importante dos SPMS é a capacidade de detetar várias posturas, incluindo posturas inadequadas que podem aumentar o risco de problemas musculoesqueléticos, como a dor lombar e cervical. Recentemente, houve avanços significativos na integração de algoritmos de *machine-learning* nos SPMS, tornando-os mais eficientes e precisos. Esses avanços têm o potencial de melhorar a saúde e o bem-estar dos utilizadores, reduzindo os riscos associados a posturas inadequadas durante longos períodos sentado.

No contexto dos SMPS, a integração com a Internet das Coisas (IoT) proporciona várias vantagens notáveis. Em primeiro lugar, permite uma monitorização contínua da postura em tempo real, o que possibilita um feedback imediato aos utilizadores sobre a sua postura atual. Ao recolher e analisar dados sobre o comportamento do utilizador ao longo do tempo, os sistemas integrados ao IoT podem fornecer um feedback personalizado e adaptativo. Isto significa que o sistema pode ajustar-se às necessidades individuais de cada utilizador, oferecendo orientações específicas para melhorar a sua postura. Além disso, a integração com o IoT possibilita a recolha e análise de grandes volumes de dados sobre a postura. Com algoritmos avançados de análise de dados, é possível identificar padrões e tendências, fornecendo insights importantes para a otimização do design de cadeiras e a prevenção de lesões relacionadas com a postura. Outra vantagem é que os SMPS integrados ao IoT podem integrar-se facilmente a outros dispositivos e sistemas, como aplicações de saúde e bem-estar, dispositivos de assistência médica e plataformas de gestão de saúde.

Embora os SPMS ainda não tenham sido amplamente comercializados devido ao custo dos dispositivos e aos desafios técnicos associados à sua implementação, continuam a ser feitos estudos para desenvolver métodos mais acessíveis e eficazes para monitorizar e melhorar a postura. Esses esforços podem eventualmente levar à disponibilidade generalizada de SPMS mais acessíveis.

4.2.2. SPMS propostos na literatura

Diversos SPMS foram propostos na literatura (Tabela 4.1), principalmente na última década, variando em tipos de sensores e métodos de classificação. O objetivo é classificar e acompanhar várias posturas sentadas de forma contínua e abrangente. Existem vários tipos de sensores a

serem usados nos SPMS como os *Force-Sensing-Resistor* (FSR), *Inertial-Measurement-Unit* (IMU), acelerômetros, células de carga entre outros.

O autor Pereira et al. (2023) [36] desenvolveu um SPMS utilizando três células de carga na base da cadeira, dispostas de forma triangular, para medir o peso aplicado no ponto central do assento, na parte frontal e nas laterais esquerda e direita. Os modelos foram treinados utilizando conjuntos de dados compostos pelas coordenadas do centro de massa no assento. Para a classificação da postura, os modelos foram treinados e avaliados na classificação de cinco e sete posições. Os resultados demonstram que os modelos treinados alcançaram uma alta precisão (> 97,4%) na classificação de cinco posições sentadas. A classificação de sete posições apresentou um bom desempenho, sendo que o modelo k-NN obteve a melhor precisão (87,5%).

No caso de Roh et al. (2018) [37] desenvolveu um SPMS que identifica um total de seis posições, com quatro células de carga montadas apenas no assento da cadeira. Utilizando a relação de peso corporal medida pelo SPMS obteve-se uma precisão médias de classificação de 97.2%, utilizando um algoritmo de classificação *Support Vector Machine* (SVM).

Existem sistemas que utilizam um misto de diferentes tipos de sensores, um gênero de um SPMS sensorial híbrido, para a classificação da postura como é o caso de Zemp et al. (2016) [38] que colocou numa cadeira de escritório dezasseis sensores FSR, dez no assento, quatro no encosto e três (em série) em cada apoio de braço, juntamente com um IMU na traseira do encosto de modo a avaliar o movimento global da cadeira e o ângulo de encosto. O melhor desempenho foi obtido utilizando o algoritmo de classificação Random Forest (RF), usando os dados dos 16 sensores mais o ângulo do encosto como variáveis independentes (features) para identificação de sete posições, produzindo uma precisão média de classificação de 90.9% para indivíduos com os quais o algoritmo não estava familiarizado. Também é o caso de Jeong et al. (2021) [39] desenvolveu um SPMS que utilizou sistema de sensor que utiliza seis sensores FSR e seis sensores infravermelhos de distância reflexivos em combinação. Os sensores de pressão foram embutidos na almofada do assento para recolher dados de distribuição da pressão da almofada do assento. Os sensores de distância foram colocados no encosto do banco para medir as distâncias do encosto do banco em diferentes locais do plano frontal. Como algoritmo de classificação utilizou o *k-Nearest Neighbor* (k-NN) onde obteve uma precisão média de 92% na classificação de 11 posições.

Tabela 4.1 – Sistemas de monitorização da postura encontrados na literatura (Adaptada a partir de [36]).

Artigos	Tipo de Sensor	Informação fornecida pelos Sensores	Localização dos Sensores	Posições	Método de Classificação	Acurácia média
Martins et al. (2013) [40] [41]	Sensores de pressão piezoelétricos	Mapas de pressão	4 dentro do assento e 4 dentro do encosto	5/8/11	ANN	98.1% / 93.4 / 81.6%
Zemp et al. (2015)[42]	Tapete de sensor de pressão	Parâmetros de distribuição estática	Sobre o assento e encosto	3	-	-
Park et al. (2016) [43]	Fabric pressure and 4-level analog tilt sensors	Leituras de pressão e nível de inclinação	Sensores de pressão na frente e atrás das almofadas esquerda e direita; sensores de inclinação na parte inferior esquerda e direita das almofadas	6	ET	-
Zemp et al. (2016) [38]	FSR & IMU	Média dos dados de força de um segundo divididos pelo peso do corpo do sujeito (para cada FSR) & ângulos do encosto	IMU na traseira do encosto, 10 FSR no assento, 4 FSR no encosto e 3 FSR (em série) em cada braço	7	RF	90.9%
Huang et al. (2017) [44]	Array de sensores foto-resistivos	Mapa de pressão	Sobre o assento	8	ANN	92%
Otoda et al. (2018) [45]	Acelerómetro de 3 eixos	Varição entre o ângulo de inclinação da cadeira ao sentar e o ângulo do estado inicial	6 no lado traseiro do assento e 2 no lado traseiro do encosto	18	RF	80.1%
Roh et al. (2018) [37]	Célula de carga	Body Weight Ratio (BWR)	4 no assento	6	SVM	97.2%
Kim et al. (2018)[46]	Tapete de sensor de pressão	Imagens de mapa de calor da distribuição da pressão corporal	Dentro da almofada do assento da cadeira	5	CNN	95.3%
Ishac et al. (2018)[47]	Array de sensores de pressão de tecido condutivo	Desvio dos erros de valor dos sensores em relação à calibração validada	Almofada colocada sobre o encosto	11	ET	98.1%
Matuska et al. (2020)[48]	FSR	Desvio padrão médio de cinco medições para sensores inferiores	4 colocados no assento, 2 colocados no encosto	9	-	-
Jeong et al. (2021) [38]	FSR e sensores de distância infravermelhos	Diferença de pressão normalizada entre seis sensores, medições de sensores com diferenças pareadas das medições normalizadas de cada tipo de sensor	6 FSR no final da almofada do assento, 6 sensores de distância no encosto	11	k-NN	92.0%
Wan et al. (2021)[49]	Array de sensores de pressão	Valores de pressão regionais do quadril esquerdo, quadril direito e vértebras caudais obtidos da imagem de pressão ao sentar	Sobre o assento	4	SVM	89.6%
Pereira et al (2023) [36]	Célula de carga	Peso aplicado no ponto médio do assento, na frente e nos lados esquerdo e direito, na parte traseira	3 células de carga no assento em configuração triangular	7	kNN	87.5%

4.2.3. SPMS Desenvolvido

Neste estudo, foi desenvolvido um SPMS resultado de uma parceria formada entre as empresas Nautilus [50] e Dynasys [51], sendo que a Nautilus se dedica sobretudo à produção de mobiliário escolar inovador enquanto a Dynasys dedica-se ao desenvolvimento e produção de equipamentos de base eletrónica.

4.2.3.1. Primeiro protótipo

Este sistema consiste numa cadeira, à qual foram adicionados quatro sensores FSR no assento e um no encosto de diferentes formatos (Figura 4.2), pois estes tipos de sensores são bastante comuns neste tipo de soluções. Sendo usados para detetar a aplicação de pressão ou força numa superfície. São sensíveis a variações de pressão, permitindo a deteção de toques leves ou pressões com maior intensidade. Em comparação com outros sensores de pressão, como as células de carga, os sensores FSR tendem a ser mais acessíveis em termos de custo. Os FSR deste tipo são dispositivos de filme espesso de polímero que consistem em duas membranas separadas por um estreito intervalo de ar. Uma das membranas possui dois conjuntos de trilhas interdigitadas, eletronicamente isoladas entre si, enquanto a outra membrana é revestida com uma tinta resistiva especial, com textura. Quanto mais se pressiona, mais pontos da área ativa (*Active Area*) tocam no semicondutor (*Conductive Film*) e isso faz com que a resistência diminua [52], [53].




Figura 4.2 – Tipos de sensores utilizados: (a) Formato circular, fornece uma maior precisão, 4 sensores utilizados no assento; (b) Formato retangular, capta uma área maior, sensor utilizado no encosto; (c) Composição de um sensor FSR (Adaptada a partir de [52], [53]).

A Figura 4.4 mostra a localização dos sensores de pressão numa cadeira, com um posicionamento estratégico baseado em fundamentos científicos para otimizar a medição da

distribuição de peso e pressão exercida pelo corpo humano ao sentar-se. A localização dos sensores é a seguinte:

- Sensores 0 e 1: Estes dois sensores estão posicionados mais próximos um do outro no centro do assento. A escolha deste local deve-se ao fato de que esta é a zona onde os ossos ísquios (ossos do traseiro), apresentado a verde na Figura 4.3, tipicamente entram em contato com a superfície da cadeira. Estes ossos são as principais áreas de apoio quando uma pessoa está sentada, sendo responsáveis pela maior parte da pressão exercida sobre o assento. Medir a pressão nesta área é crucial para avaliar o conforto e a distribuição de peso central do utilizador.




Figura 4.3 – Ossos dos pélvis: Ísquio (Retirada de [54]).

- Sensores 2 e 3: Estes sensores estão posicionados mais à frente e de forma ligeiramente mais ampla, considerando a tendência natural dos utilizadores de abrir ligeiramente as pernas ao sentar. Este posicionamento permite capturar a distribuição de pressão adicional nas áreas onde as coxas entram em contato com o assento. Avaliar a pressão nesta região é importante para garantir que o assento da cadeira suporte adequadamente a parte anterior do corpo, prevenindo desconforto e problemas de circulação nas pernas.
- Sensor 4: Este sensor está localizado no encosto da cadeira. A inclusão deste sensor permite medir a pressão exercida pela parte superior do tronco e pelas costas do utilizador, fornecendo dados adicionais sobre a postura e o conforto ao utilizar a cadeira.



Figura 4.4 – Localização dos sensores

Os sensores FSR foram colados no casco de madeira da cadeira com a fita de dupla-face que existe na face traseira dos sensores. De seguida, a cadeira passou pelo processo de estofagem. Na Figura 4.5 é possível observar a cadeira na fase inicial, com apenas os sensores colocados e após o processo de estofagem.



Figura 4.5 – SPMS: (a) Cadeira com os sensores colocados; (b) Cadeira após a estofagem.

4.2.3.1.1. Recolha de dados

Foram recolhidos dados de 45 indivíduos, dos quais 24 são do género masculino e 21 do género feminino, com idades compreendidas entre 18 e 58 anos. Entre os participantes, há um grupo considerado saudável, ou seja, sem problemas de coluna diagnosticados medicamente. No entanto, dentro deste grupo, algumas pessoas relataram ter dores nas costas. Adicionalmente, existe um grupo menor composto por indivíduos com problemas de coluna identificados medicamente.

De acordo com a Tabela 4.2, que representa os dados estatísticos das recolhas de dados, 39% dos participantes afirmaram ter dores nas costas enquanto sentados. A distribuição dos participantes é detalhada a seguir:

Tabela 4.2 – Dados estatísticos das recolhas.

Observações	Masculino	Feminino	
Saudáveis com dores nas costas	5	7	27 %
Saudáveis sem dores nas costas	16	10	58 %
Não saudáveis	3	4	15 %
Total	24	21	

Na Figura 3.4 estão as distribuições das variáveis demográficas e de saúde dos participantes. A distribuição da idade é fortemente concentrada em 20 anos, indicando que a maioria dos indivíduos no *dataset* são jovens adultos. A maioria dos participantes tem peso entre 60 kg e 80 kg. Existe uma variação considerável, mas a maior parte dos dados está centrada em torno dessa faixa, com alguns indivíduos pesando mais de 80 kg. A altura dos indivíduos varia principalmente entre 1.70 m e 1.85 m. A distribuição é quase simétrica, sugerindo uma variação normal na altura dos indivíduos. A maioria dos participantes no *dataset* não apresenta dor nas costas, enquanto uma proporção menor relatou dor nas costas. Isso sugere que a amostra tem mais indivíduos sem dor nas costas. A maioria dos indivíduos no *dataset* é classificada como saudável, indicando que a amostra predominante não possui patologias associadas à postura.




Figura 4.6 – Distribuição das Variáveis Demográficas e de Saúde.

Tendo isto, deve-se considerar que predominância de participantes de 20 anos pode limitar a aplicação dos resultados a outras faixas etárias. A prevalência de indivíduos saudáveis e a baixa incidência de dor nas costas sugerem que o *dataset* pode não abranger adequadamente a variação em populações com problemas posturais. Embora haja variação no peso e na altura, os dados são principalmente concentrados em faixas específicas, o que pode afetar a análise da postura em populações com diferentes características físicas.

4.2.3.1.2. Procedimento de recolha

Para a recolha de dados, todos os participantes iniciaram por preencher um inquérito anónimo. Neste questionário, forneceram informações como idade, género (Masculino ou Feminino), peso (kg) obtido por meio de uma pesagem numa balança certificada e altura (m). Além disso, responderam a algumas perguntas relacionadas à frequência de dores nas costas enquanto estavam sentados, se tinham algum problema de coluna, e, em caso afirmativo, qual. O objetivo era determinar se os participantes estavam saudáveis ou não. Cada participante recebeu um ID sequencial no inquérito para garantir o anonimato e facilitar a correspondência posterior com os dados recolhidos dos sensores. Estando o inquérito preenchido o participante

deslocava-se para a cadeira para recolher dados em cada uma das 10 posições apresentadas na Figura 4.7.



Figura 4.7 – Posições utilizadas na recolha de dados e a sua respetiva classe: (P1) é a posição “ideal”, onde as costas formam um ângulo de 90° com o solo e o encosto da cadeira é utilizado, sendo a posição com maior probabilidade de as partes-chave do corpo estarem corretamente alinhadas; (P2) inclinada para a frente; (P3) sentado na extremidade da cadeira e encostada; (P4) inclinada para a direita; (P5) inclinada para a esquerda; (P6) pé direito sobre o joelho esquerdo; (P7) pé esquerdo sobre o joelho direito; (P8) perna direita cruzada sobre a esquerda; (P9) perna esquerda cruzada sobre a direita; (P10) sentado na extremidade da cadeira.

O teste iniciava-se na posição 1 (P1) e prosseguia até à posição 10 (P10), seguindo uma ordem predefinida. Em cada posição, eram recolhidas dez amostras de cada sensor. A cadeira transmitia os dados dos sensores via Bluetooth para um computador (Figura 4.8), com uma frequência de amostragem de 8 Hz. Os dados eram recebidos automaticamente e armazenados num ficheiro CSV juntamente com o ID do inquérito previamente preenchido. Após a conclusão da recolha na posição 10, o participante levantava-se da cadeira e voltava a sentar-se, dando início a uma nova série de recolhas. Cada participante completava um total de duas séries.



Figura 4.8 – Recolha de dados via Bluetooth para o PC.

4.2.3.1.3. Processamento e Limpeza de dados

Para além dos dados dos sensores FSR, foram criadas características que pudessem ajudar na classificação para o treino do modelo. Estas novas características consistem em cálculos derivados dos dados dos sensores. Atendendo à posição dos vários sensores apresentados na Figura 4.4, foram calculadas as seguintes características:

Left – Média dos sensores posicionados na lateral esquerda da cadeira.

$$Left = \frac{Sensor0 + Sensor3}{2} \quad (4.1)$$

Right – Média dos sensores posicionados na lateral direita da cadeira.

$$Right = \frac{Sensor1 + Sensor2}{2} \quad (4.2)$$

Front – Média dos sensores posicionados na dianteira da cadeira.

$$Front = \frac{Sensor2 + Sensor3}{2} \quad (4.3)$$

Back – Média dos sensores posicionados na traseira e encosto da cadeira.

$$Back = \frac{Sensor0 + Sensor1 + Sensor4}{3} \quad (4.4)$$

Mean – Média de todos os sensores.

$$Mean = \frac{Sensor0 + Sensor1 + Sensor2 + Sensor3 + Sensor4}{5} \quad (4.5)$$

Com base nas características anteriormente definidas, foram determinadas novas características de modo a estimar as coordenadas do centro de massa e ângulo com o centro da cadeira como ilustrado na Figura 4.9.



Figura 4.9 – Plano 2D do centroide

Atendendo à Figura 4.9 foram calculadas as seguintes métricas:

Mass X – coordenada x do centro de massa.

$$Mass\ X = -Right + Left \quad (4.6)$$

Mass Y – coordenada y do centro de massa.

$$Mass\ Y = -Front + Back \quad (4.7)$$

Center distance – distância ao centro da cadeira

$$Center\ distance = \sqrt{(Mass\ X)^2 + (Mass\ Y)^2} \quad (4.8)$$

Center angle – ângulo ao centro da cadeira

$$Center\ angle = \alpha = \text{atan} \left(\frac{Mass\ Y}{Mass\ X} \right) \quad (4.9)$$

Com as coordenadas do centro de massa é possível representar num plano 2D os agrupamentos por posição (Figura 4.10).




Figura 4.10 – Agrupamentos do centroide para cada posição

Fazendo uma limpeza aos dados, i.e, removendo os *outliers* com base no método Z-Score. O método Z-Score é utilizado para identificar e remover *outliers* num conjunto de dados. No contexto dos SPMS este método é aplicado para limpar os dados das coordenadas do centro de massa (centroides) calculadas para diferentes posições sentadas. Para cada ponto de dado, calcula-se o Z-Score, indica o número de desvios padrão que um ponto de informação está acima ou abaixo da média [55].

A fórmula do Z-Score para uma coordenada X é dada por:

$$Z = \frac{X - \bar{X}}{\sigma} \quad (4.10)$$

- X é o valor individual da coordenada
- $\bar{X}$ é a média dos valores de X
- σ é o desvio padrão dos valores de X

Na Figura 4.11, estão representados os agrupamentos por posição sem *outliers*, i.e, os pontos de dados que possuem um Z-Score maior que um limiar predefinido (neste caso, 0.5) são considerados *outliers* e são removidos do conjunto de dados.




Figura 4.11 – Agrupamentos do centroide para cada posição sem *outliers* ($Z\text{-Score} \leq 0.5$)

A aplicação do método *Z-Score* permite uma melhor visualização dos agrupamentos de dados. Após a remoção dos *outliers*, os agrupamentos de centroides para cada posição são mais definidos e separados, facilitando a classificação das posturas.

A remoção de *outliers* é crucial para aumentar a precisão dos modelos de *machine learning* que classificam as posturas. Sem os *outliers*, os dados se tornam mais consistentes.

4.2.3.1.4. Treino, Classificação e Validação

Esta fase é crucial, pois envolve a aplicação de técnicas de *machine learning* para identificar e classificar as diferentes posturas com base nos dados dos sensores. Para garantir a precisão e a eficácia do sistema, foram utilizados vários algoritmos de classificação, incluindo o *Support Vector Machine* (SVM), *Random Forest* (RF) e *k-Nearest Neighbors* (k-NN). Cada um destes algoritmos foi treinado e avaliado usando os dados recolhidos, com o objetivo de determinar o hiperplano ou os critérios de decisão que melhor separam as diferentes classes de posturas.

O método *Support Vector Machine* (SVM) [56] é uma técnica de *machine-learning* amplamente utilizada em uma variedade de aplicações. Funciona encontrando um hiperplano que melhor separa os pontos de dados das diferentes classes num espaço de características multidimensional. Durante a fase de treino, o SVM ajusta esse hiperplano de modo a maximizar a margem entre as classes, garantindo assim uma boa capacidade de generalização. Após o treino, o SVM pode classificar novos pontos de dados com base nas características aprendidas no treino. É eficaz em lidar com conjuntos de dados grandes e de alta dimensionalidade.

O método *Random Forests* (RF) [57] é um tipo de modelo *machine-learning*. É composto por múltiplas árvores de decisão, onde cada árvore é treinada com uma amostra aleatória e independente das características dos dados, sendo essas amostras retiradas do conjunto de dados original. Aproveitando o conceito de "sabedoria das multidões", onde a agregação de várias opiniões pode levar a uma decisão mais precisa do que apenas uma opinião individual.

O método *k-Nearest Neighbors* (k-NN) [58] é uma abordagem de classificação não paramétrica amplamente utilizada devido à sua simplicidade e eficácia em muitos casos. Funciona identificando os k vizinhos mais próximos de um novo ponto de dados a ser classificado, com base em alguma medida de distância, como por exemplo a distância euclidiana. A classe desse ponto é então determinada pela classe mais comum entre esses vizinhos, geralmente usando um esquema de votação majoritária. No entanto, a escolha do valor de k é crucial para o desempenho do algoritmo, e pode influenciar significativamente a precisão da classificação. Uma estratégia comum para selecionar o valor ideal de k é testar o modelo com diferentes valores e escolher aquele que resulta na melhor performance, muitas vezes através de técnicas como validação cruzada. Apesar de sua simplicidade, o k-NN pode ser uma ferramenta útil para classificação em muitos cenários, embora seja importante considerar as suas limitações, como a sensibilidade ao ruído e à dimensionalidade dos dados.

O método *Naive Bayes* [59] é uma técnica de *machine-learning* baseada no teorema de Bayes, utilizada em problemas de classificação. Este método parte da suposição de que as diferentes características dos dados são estatisticamente independentes entre si, uma simplificação que, embora nem sempre corresponda à realidade, torna o modelo eficiente e fácil de implementar. Durante a fase de treino, o *Naive Bayes* calcula as probabilidades condicionais de cada classe em relação às características dos dados, permitindo que novas instâncias sejam classificadas com base na classe mais provável. Apesar da sua simplicidade, o *Naive Bayes* apresenta um bom desempenho em diversos cenários, embora a suposição de independência das características constitua a sua principal limitação, podendo não refletir adequadamente a

complexidade dos dados reais.

4.2.3.1.5. Experiência I

Na primeira experiência foram descartados registros duplicados por pessoa. Na Figura 4.12 está representado o *ranking* da importância de características, criado através do método *Information Gain* que é utilizado para medir a importância de um dado atributo em relação à classificação de um conjunto de dados. O cálculo envolve a comparação da entropia do conjunto de dados antes e depois da divisão com base em um atributo específico. A entropia é uma medida da impureza dos dados, indicando o quão misturadas estão as classes no conjunto de dados. Quanto menor a entropia, mais puro é o conjunto de dados. Em outras palavras, a entropia quantifica a incerteza ou a desordem num conjunto de dados, assim, uma menor entropia significa que o atributo utilizado foi eficaz em separar as classes.




Figura 4.12 – Experiência 1: Ranking de características.

Destacaram-se como as 5 melhores características, de acordo com o método *Information Gain*, as seguintes: Mass X, Sensor4, Mass Y, Back e Sensor1. Essas características foram identificadas como as mais relevantes para a classificação das posturas, contribuindo significativamente para a redução da incerteza na previsão das classes.

Para treino foi feita uma divisão do *dataset*, 80% para treino e 20% para teste, o que corresponde a cerca de 36 pessoas para treino e 9 para teste, tendo sempre em conta que os participantes contidos no conjunto de treino não constam no conjunto de testes e vice-versa, de

modo a garantir que o teste era realizado com dados de participantes cujo algoritmo não estava familiarizado.

A Tabela 4.3 apresenta os resultados da Experiência 1 para conjuntos contendo diferentes números de posições (6, 8 e 10), tanto com quanto sem *outliers*. Esta tabela permite observar a variação na acurácia (*accuracy*), precisão (*precision*) e *recall* dos modelos de *machine learning* à medida que o número de posições classificadas aumenta.

A acurácia (*accuracy*) é a proporção de predições corretas (tanto verdadeiros positivos quanto verdadeiros negativos) em relação ao número total de predições. É uma métrica global que fornece uma visão geral da eficácia do modelo.

$$Acurácia = \left(\frac{N^{\circ} \text{ de Predições Corretas}}{N^{\circ} \text{ Total de Predições}} \right) = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.11)$$

Onde:

- *TP* – Verdadeiros Positivos
- *TN* – Verdadeiros Negativos
- *FP* – Falsos Positivos
- *FN* – Falsos Negativos

A precisão (*precision*) é a proporção de verdadeiros positivos em relação ao número total de predições positivas feitas pelo modelo. Esta métrica é particularmente útil quando o custo de falsos positivos é alto.

$$Precisão = \frac{TP}{TP + FP} \quad (4.12)$$

A precisão indica a qualidade das predições positivas do modelo, ou seja, quantas das instâncias previstas como positivas são realmente positivas.

O *recall* (ou Sensibilidade) é a proporção de verdadeiros positivos em relação ao número total de instâncias que são realmente positivas. Esta métrica é crucial quando existe muitos falsos negativos. Indica a capacidade do modelo de encontrar todas as instâncias positivas no conjunto de dados.

Atendendo às posições apresentadas na Figura 4.7, os testes foram realizados considerando as seguintes posições:

- 6 Posições – P1, P2, P3, P4, P5 e P10
- 8 Posições – P1, P2, P3, P4, P5, P8, P9 e P10
- 10 Posições - P1, P2, P3, P4, P5, P6, P7, P8, P9 e P10

Tabela 4.3 – Experiência 1: Resultado dos vários modelos para 6, 8 e 10 posições com e sem *outliers*

Dataset with outliers									
Model	Number of postures								
	6			8			10		
	Accuracy	Precision	Recall	Accuracy	Precision	Recall	Accuracy	Precision	Recall
ANN	90.6%	90.8%	90.6%	84.1%	83.8%	84.1%	73.7%	74.6%	73.7%
Naive Bayes	81.1%	83.3%	81.1%	79.9%	80.8%	79.9%	72.6%	73.2%	72.6%
SVM	88.2%	88.5%	88.2%	83.2%	83.9%	83.2%	70.2%	69.8%	70.2%
kNN	84.2%	84.7%	84.2%	78.8%	78.9%	78.8%	68.8%	68.5%	68.8%
Random Forest	81.5%	81.3%	81.5%	78.5%	78.0%	78.5%	68.5%	69.2%	68.5%

Dataset without outliers									
Model	Number of postures								
	6			8			10		
	Accuracy	Precision	Recall	Accuracy	Precision	Recall	Accuracy	Precision	Recall
ANN	88.8%	90.6%	88.8%	84.8%	85.9%	84.8%	75.9%	75.9%	75.9%
SVM	90.6%	92.5%	90.6%	85.7%	86.7%	85.7%	75.5%	75.7%	75.5%
Naive Bayes	86.4%	87.3%	86.4%	80.9%	81.5%	80.9%	74.6%	73.7%	74.6%
kNN	86.2%	87.0%	86.2%	78.2%	77.9%	78.2%	72.9%	73.2%	72.9%
Random Forest	86.7%	88.2%	86.7%	77.1%	77.4%	77.1%	71.3%	71.8%	71.3%

Quando analisado com dados que contêm *outliers*, o modelo de *Artificial Neural Network* (ANN) obteve a maior precisão para 6 posições (90.6%), e manteve um bom desempenho com 8 posições (84.1%), embora a precisão tenha diminuído para 73.7% ao classificar 10 posições. O modelo *Support Vector Machine* (SVM) também apresentou boa acurácia, com 88.2% para 6 posições, mas mostrou uma queda para 70.2% ao classificar 10 posições. Os modelos *Naive Bayes*, *k-Nearest Neighbors* (k-NN) e *Random Forest* apresentaram desempenho inferior, com precisões variando de 68.5% a 84.2%. Quando os *outliers* foram removidos, tanto o modelo de ANN quanto o SVM mantiveram um desempenho elevado, com o modelo ANN obtendo 88.8% de precisão para 6 posições e o SVM alcançando 90.6%. No entanto, a precisão de ambos o modelo diminuiu gradualmente ao classificar 10 posições. *Naive Bayes*, k-NN e *Random Forest* mostraram uma melhoria no desempenho após a remoção dos *outliers*, mas ainda assim ficaram atrás dos modelos de ANN e SVM.




Figura 4.13 – Experiência 1: Matrizes de confusão para 6,8,10 posições com *outliers*: ANN (tons de azul), SVM (tons de verde).

Com base na análise das matrizes de confusão apresentadas na Figura 4.13, podemos identificar quais posições são mais difíceis de classificar tanto para o modelo de ANN (NN) quanto para o modelo de SVM:

- Posições Cruzadas: Posições como P6 (pé direito sobre o joelho esquerdo) e P7 (pé esquerdo sobre o joelho direito) são frequentemente confundidas. A semelhança nos padrões de pressão gerados por estas posturas dificulta a diferenciação pelos modelos.
- Inclinações Laterais: P4 (inclinado para a direita) e P5 (inclinado para a esquerda) são outra fonte comum de erros de classificação. Quando a inclinação não é muito pronunciada, os padrões de pressão podem ser bastante semelhantes, levando a confusões entre as posições.
- Posições Intermediárias e na Extremidade da Cadeira: Posições como P2 (inclinada para a frente) e P3 (sentado na extremidade da cadeira) também apresentam desafios de classificação. Estas posições podem gerar padrões de pressão semelhantes devido ao posicionamento do corpo na cadeira.

A Figura 4.13 demonstra que, embora tanto a ANN quanto o SVM sejam eficazes na classificação de um número menor de posturas, a precisão dos modelos diminui à medida que a complexidade da tarefa aumenta. Especificamente, as posições cruzadas e inclinadas lateralmente são as mais difíceis de classificar corretamente devido à semelhança nos padrões de pressão que produzem.

4.2.3.1.6. Experiência II

A segunda experiência remete para um processamento dos dados mais focado no domínio do tempo adicionando novas características além das anteriores. Das 10 amostras recolhidas por cada posição é efetuada a média para cada sensor. As características calculadas são as mesmas existentes no método anterior que são calculadas considerando o valor médio de cada sensor. Além destas, foram criadas características que representam a variação de cada sensor ao longo das 10 amostras que são calculadas da seguinte forma:

Exemplificando para o caso do Sensor 0:

$$Sensor0Diff = \sigma = \sum_{n=1}^{10} abs(Sensor0_{[n]} - Sensor0_{[n+1]}) \quad (4.13)$$

Atendendo aos dados apresentados na Figura 4.14, é possível ver que as novas características correspondentes aos sensores no assento da cadeira (Sensor0Diff, Sensor1Diff, Sensor2Diff, Sensor3Diff) não acrescentam grande relevância ao plano de características comparativamente ao método anterior, porém a variação de pressão no sensor das costas (Sensor4Diff) apresenta-se como uma das melhores características. A semelhança da

experiência anterior destacam-se uma vez mais como as 5 melhores características, Mass X, Sensor4, Mass Y, Back e Sensor 1.




Figura 4.14 – Experiência 2: Ranking de características.

Assim como na experiência anterior, para treino foi feita uma divisão do *dataset*, 80% para treino e 20%, tendo sempre em conta que os participantes contidos no conjunto de treino não constam no conjunto de testes e vice-versa, de modo a garantir que o teste era realizado com dados de participantes cujo algoritmo não estava familiarizado. A Tabela 4.4 apresenta os resultados do Método 2 para diferentes números de posições (6, 8 e 10), tanto com quanto sem *outliers*. Este método inclui características adicionais que capturam variações no tempo, oferecendo mais informações para a classificação.

Tabela 4.4 – Experiência 2: Resultado dos vários modelos para 6, 8 e 10 posições com e sem *outliers*

Dataset with outliers									
Model	Number of postures								
	6			8			10		
	Accuracy	Precision	Recall	Accuracy	Precision	Recall	Accuracy	Precision	Recall
ANN	87.9%	89.6%	87.9%	86.0%	87.1%	86.0%	76.0%	78.3%	76.0%
SVM	90.7%	91.6%	90.7%	84.6%	85.7%	84.6%	74.9%	75.9%	74.9%
Naive Bayes	84.1%	86.5%	84.1%	77.6%	78.5%	77.6%	72.6%	74.1%	72.6%
Random Forest	88.8%	89.0%	88.8%	79.7%	79.4%	79.7%	70.4%	70.6%	70.4%
kNN	81.3%	85.8%	81.3%	76.2%	79.6%	76.2%	68.7%	69.9%	68.7%
Dataset without outliers									
Model	Number of postures								
	6			8			10		
	Accuracy	Precision	Recall	Accuracy	Precision	Recall	Accuracy	Precision	Recall
ANN	88.1%	88.7%	88.1%	86.9%	87.8%	86.9%	75.1%	78.2%	75.1%
SVM	91.1%	91.9%	91.1%	83.2%	84.8%	83.2%	74.6%	75.5%	74.6%
Naive Bayes	89.1%	89.9%	89.1%	80.3%	80.5%	80.3%	74.0%	75.5%	74.0%
Random Forest	89.1%	89.1%	89.1%	83.9%	84.2%	83.9%	69.9%	70.3%	69.9%
kNN	83.2%	86.9%	83.2%	78.1%	81.0%	78.1%	68.8%	69.2%	68.8%

Com dados que contêm *outliers*, a ANN manteve um desempenho alto com 6 posições (87.9%) e bom desempenho com 8 posições (86.0%), diminuindo para 76.0% com 10 posições. O SVM exibiu uma alta acurácia de 91.1% para 6 posições, mas também mostrou uma queda para 74.9% ao classificar 10 posições. Os modelos *Naive Bayes*, *Random Forest*, e k-NN mostraram menor precisão, variando entre 68.7% e 88.8%. Com a remoção dos *outliers*, tanto a ANN quanto o SVM mantiveram um bom desempenho, com o SVM atingindo 91.1% para 6 posições e a ANN obtendo 88.1%. Assim como no Método 1, a precisão diminuiu gradualmente ao classificar 10 posições. Os modelos *Naive Bayes*, k-NN, e *Random Forest* mostraram melhorias, mas ainda ficaram atrás dos melhores modelos.




Figura 4.15 – Experiência 2: Matrizes de confusão para 6,8,10 posições com *outliers*: ANN (tons de azul), SVM (tons de verde).

4.2.3.1.7. Experiência III

O objetivo desta experiência é dividir a complexidade do problema de classificação em duas etapas distintas, de modo a melhorar a precisão geral ao especializar os modelos para subconjuntos específicos de posições. Este método baseia-se 3 modelos de *machine learning*, o primeiro que faz uma verificação inicial de modo a identificar se a pessoa está ou não com a perna cruzada, posições P6, P7, P8, P9. Se sim, existe um modelo que classifica entre as posições P6, P7, P8, P9 caso contrário um outro modelo classifica as restantes posições P1, P2, P3, P4, P5 e P10.




Figura 4.16 – Experiência 3: Fluxograma do classificador.

A verificação inicial utiliza uma ANN para determinar se a pessoa está com a perna cruzada. A precisão deste modelo é crucial, pois determina qual dos dois modelos subsequentes será ativado. Com o modelo ANN obtendo uma acurácia de 89.2% e uma precisão de 89.2%.




Figura 4.17 – Experiência 3: Matriz de confusão do modelo ANN para verificação da perna cruzada.

Se a verificação inicial identificar que a pessoa está com a perna cruzada, um modelo especializado entra em ação para classificar entre as posições P6, P7, P8 e P9. Com o modelo ANN obtendo uma acurácia de 83% e uma precisão de 84.3%. Ver Figura 4.18.




Figura 4.18 – Experiência 3: Matriz de confusão do modelo ANN para classificação das posições de perna cruzada (P6, P7, P8 e P9)

Se a verificação inicial identificar que a pessoa não está com a perna cruzada, um modelo diferente classifica entre as posições restantes: P1 (posição ideal), P2 (inclinada para a frente), P3 (sentado na extremidade da cadeira), P4 (inclinado para a direita), P5 (inclinado para a esquerda) e P10 (sentado na extremidade da cadeira sem usar o encosto). Com o modelo ANN

obtendo uma acurácia de 69.7% e uma precisão de 70.1% (Figura 4.19).




Figura 4.19 – Experiência 3: Matriz de confusão do modelo ANN para classificação das posições (P1, P2, P3, P4, P5 e P10).

Combinando os três modelos para a classificação das 10 posições, obtém-se uma acurácia de 77.7%, precisão de 78% e um *recall* de 77.7%. Ver Figura 4.20.




Figura 4.20 – Experiência 3: Matriz de confusão resultante da combinação dos três modelos.

4.2.3.1.8. Comparação entre as experiências

Tabela 4.5 – Comparação entre experiências

Critério	Experiência I	Experiência II	Experiência III
Abordagem	Características básicas	Inclusão de variações temporais	Classificação em duas etapas
Desempenho Geral	Bom com poucos outliers, diminui com mais posições	Melhor que Método I, especialmente sem outliers	Bom para posturas simples, reduz a complexidade geral
Complexidade	Moderada	Moderada a Alta	Alta
Acurácia	Até 90.6% (com 6 posições)	Até 91.1% (com 6 posições)	77.7% (com 10 posições)
Aplicação Prática	Simples implementar	Mais informativo com variações temporais	Divide a complexidade para melhor classificação
Resiliência a Outliers	Melhora sem outliers	Melhora significativamente sem outliers	Estrutura de múltiplas etapas pode reduzir impacto de outliers

O Experiência I é adequado para cenários onde a simplicidade e a rapidez de implementação são importantes, e a quantidade de posições a serem classificadas é pequena.

O Experiência II oferece uma análise mais rica incluindo variações temporais, sendo mais robusto e detalhado, especialmente útil para contextos onde a precisão é crítica e há uma diversidade maior de posturas.

O Experiência III é o mais complexo, mas também o mais versátil, pois reduz a complexidade do problema de classificação ao dividi-lo em etapas especializadas. É ideal para aplicações onde a precisão e a capacidade de lidar com múltiplas posturas complexas são essenciais.

4.2.3.2. Segundo protótipo

O segundo protótipo foi desenvolvido com o objetivo de melhorar a precisão na classificação das posições em que as pernas estão cruzadas, uma vez que estas foram identificadas como as mais críticas no primeiro protótipo. Os resultados obtidos anteriormente revelaram uma precisão inferior a 90% na identificação destas posições, o que foi considerado insatisfatório para garantir a fiabilidade do sistema. Esta limitação é ainda mais evidente quando comparada com a precisão média de cerca de 90% observada nos sistemas semelhantes descritos na Tabela 4.1, baseada em artigos científicos.

Para ultrapassar estas limitações, foram colocados 3 sensores nas costas e 16 sensores de pressão no assento, dispostos em matriz, conforme ilustrado na Figura 4.21. Cada célula da matriz foi numerada de 0 a 15, facilitando a identificação dos dados recolhidos e a análise de padrões específicos.



Figura 4.21 – Localização dos sensores no segundo protótipo

Os sensores foram intencionalmente distribuídos pelo assento, cobrindo toda a área de contacto do utilizador. Esta nova configuração fornece uma imagem com maior resolução dos pontos de pressão associados às diferentes posturas, permitindo assim capturar padrões assimétricos de pressão, característicos das posições das pernas cruzadas, que, devido à sua complexidade, são mais difíceis de distinguir com um número reduzido de sensores.

4.2.3.2.1. Recolha de dados

Foram recolhidos dados de 42 indivíduos, dos quais 29 são do género masculino e 13 do género feminino, com idades compreendidas entre 19 e 26 anos. Entre os participantes, foi identificado um grupo considerado saudável, ou seja, sem patologias relacionadas à coluna diagnosticadas medicamente. No entanto, dentro deste grupo, alguns indivíduos relataram sentir dores nas costas enquanto sentados. Adicionalmente, foi identificado um grupo menor de

participantes classificados como não saudáveis, apresentando condições patológicas relacionadas à coluna. Este grupo inclui tanto homens quanto mulheres, representando uma menor proporção do total de participantes. Ver Tabela 4.6.

Tabela 4.6 – Dados estatísticos das recolhas.

Observações	Masculino	Feminino	
Saudáveis sem dores nas costas	21	8	69 %
Saudáveis com dores nas costas	5	2	17 %
Não saudáveis	3	3	14 %
Total	29	13	

As distribuições das variáveis demográficas e de saúde dos participantes estão representadas na Figura 4.22. A distribuição da idade é fortemente concentrada em torno dos 20 anos, indicando que a maioria dos indivíduos no *dataset* são jovens adultos, com poucas observações acima dessa faixa etária. Em relação ao peso, a maioria dos participantes tem valores entre 60 kg e 80 kg, com uma leve variação para indivíduos com peso inferior a 60 kg ou superior a 80 kg, mas mantendo uma concentração significativa nesta faixa.

A altura dos participantes apresenta-se distribuída principalmente entre 1.60 m e 1.80 m, com um pico em torno de 1,70 m. A distribuição é quase simétrica, indicando uma variação natural nas alturas dentro do grupo. Quanto à dor nas costas, a maioria dos indivíduos no *dataset* relatou não ter dor nas costas, enquanto uma parcela menor indicou a presença de dor. Este padrão sugere que a amostra é composta predominantemente por indivíduos sem dor nas costas.

Em relação ao estado de saúde, verifica-se que a grande maioria dos participantes é considerada saudável, enquanto apenas uma pequena fração é classificada como tendo condições patológicas. Este padrão reflete um predomínio de indivíduos com boa saúde na amostra analisada.

Por fim, a distribuição da perna dominante indica que a maioria dos participantes é destra, ou seja, possui a perna direita como dominante, enquanto uma menor proporção é composta por indivíduos canhotos, cuja perna dominante é a esquerda. Esse resultado é consistente com a prevalência de destros na população em geral, evidenciando que a amostra segue padrões esperados em termos de lateralidade.




Figura 4.22 – Distribuição das Variáveis Demográficas e de Saúde na segunda recolha de dados.

4.2.3.2.2. Análise de dados

Este capítulo dedica-se à interpretação detalhada dos mapas de pressão obtidos durante os ensaios de diferentes posturas sentadas, utilizando o sistema de monitorização desenvolvido. Estes dados permitem compreender os padrões de distribuição da pressão, as assimetrias e os desvios que podem influenciar a postura correta e o conforto dos utilizadores.

O objetivo desta análise é identificar padrões associados a posturas saudáveis e inadequadas, considerando as forças distribuídas no assento da cadeira e a interação entre o corpo humano e o mobiliário. Este processo é fundamental para a validação do protótipo e para fornecer perspetivas que possam contribuir para melhorias no *design* ergonómico e para a promoção de hábitos posturais saudáveis.

A Figura 4.23 apresenta o mapa de pressão associado à postura P1, considerada ideal.




Figura 4.23 – Mapa de pressão da posição 1 (P1).

O mapa de pressão referente à posição P1 apresenta uma concentração de força na região central do assento, com os maiores valores localizados nesta área. Esse padrão caracteriza uma postura sentada correta, em que a maior parte do peso corporal é equilibradamente suportada pela região central do assento. Nas áreas laterais e dianteiras do assento, os níveis de pressão são consideravelmente mais baixos, refletindo um suporte menor nessas áreas. Além disso, a simetria entre os lados esquerdo e direito é visível, indicando assim um equilíbrio no posicionamento do corpo. No entanto, pequenas diferenças nos valores de pressão entre os quadrantes superiores podem sugerir variações mínimas na postura ou na forma como o peso é distribuído entre as nádegas. As extremidades do assento apresentam os

níveis de pressão mais reduzidos, reforçando a ideia de que o corpo está bem alinhado e centrado e encostado às costas da cadeira.

A Figura 4.24 apresenta o mapa de pressão associado à postura P2, que corresponde à posição inclinada para a frente.




Figura 4.24 – Mapa de pressão da posição 2 (P2).

O mapa de pressão da postura P2 evidencia uma concentração acentuada na área média e posterior do assento. Os valores mais elevados concentram-se nos cantos da frente do assento enquanto as regiões centrais apresentam valores intermediários. Este padrão reflete a transferência do peso corporal para as áreas posteriores das coxas e nádegas, característica desta posição inclinada. Na traseira do assento, os valores de pressão são significativamente mais baixos, indicando uma redução do contato na parte traseira do assento. Isso ocorre devido à inclinação para a frente, que desloca o peso do corpo em direção às áreas médias e posteriores.

A Figura 4.25 apresenta o mapa de pressão associado à postura P3, que corresponde à posição em que o utilizador se encontra sentado na extremidade da cadeira, encostado ao encosto.




Figura 4.25 – Mapa de pressão da posição 3 (P3).

A análise do mapa referente à posição P3 revela uma concentração substancial de pressão na região central e posterior do assento. Os sensores na traseira do assento revelam valores muito baixos ou nulos, refletindo uma ausência de pressão nessa parte. Esse padrão reflete um deslocamento do peso para a parte frontal da cadeira, típico desta postura.

A região central apresenta os valores de pressão mais elevados, indicando que a maior parte do peso corporal é sustentada pelas nádegas e pela base das coxas. Essa distribuição é esperada, dado que o encosto fornece suporte à parte superior do corpo, enquanto os pés permanecem firmemente apoiados no chão, reduzindo ligeiramente a interação com a frente do assento.

A Figura 4.26 apresenta o mapa de pressão associado à postura P4, que corresponde a uma posição inclinada para a direita.




Figura 4.26 – Mapa de pressão da posição 4 (P4).

O mapa de pressão associado à postura P4 apresenta uma distribuição claramente assimétrica. Há uma maior concentração de pressão na lateral direita do assento, enquanto os valores na parte oposta são muito reduzidos. Este padrão reflete um deslocamento do peso corporal para o lado direito, característico desta postura inclinada. Essa assimetria revela um desequilíbrio postural evidente, com os valores no lado direito mais intensos, enquanto o lado esquerdo apresenta níveis muito baixos. Essa configuração pode gerar desconforto e tensões localizadas, especialmente nas regiões lombar e lateral do corpo.

A Figura 4.27 apresenta o mapa de pressão associado à postura P5, que corresponde a uma posição inclinada para a esquerda.




Figura 4.27 – Mapa de pressão da posição 5 (P5).

Na postura P5, o mapa de pressão mostra um padrão similar ao observado na posição P4, mas com os valores máximos concentrados na região superior esquerda do assento. Essa assimetria reflete o deslocamento do peso corporal para o lado esquerdo, enquanto o lado direito exibem valores reduzidos. Esse padrão é característico de uma sobrecarga unilateral, que pode resultar em desconforto e tensões musculares.

A Figura 4.28 apresenta o mapa de pressão associado à postura P6, caracterizada pela posição com o pé direito apoiado sobre o joelho esquerdo.




Figura 4.28 – Mapa de pressão da posição 6 (P6).

A análise desta postura revela uma distribuição assimétrica de pressão, com maior concentração na região inferior direita do assento. Nesta área, os valores máximos foram atingidos, enquanto no lado oposto os valores são mais baixos, mas constantes ao longo da superfície do assento. Este comportamento deve-se ao facto de a perna esquerda do utilizador estar em contacto direto com o assento, enquanto a perna direita se encontra elevada sobre o joelho esquerdo.

A região traseira do assento apresenta valores significativamente reduzidos, indicando um menor suporte nesta área devido ao deslocamento do peso corporal para a parte anterior do assento. Este padrão geral demonstra uma sobrecarga no lado direito do assento, causada pela elevação da perna direita sobre o joelho esquerdo, que transfere o peso corporal de forma desigual e concentra a pressão predominantemente no lado esquerdo do corpo.

A zona central do assento revela uma concentração da pressão principalmente na base das nádegas e na região pélvica, com uma intensidade mais elevada do lado direito. Este padrão é típico da postura cruzada, na qual o peso é distribuído de maneira assimétrica, resultando numa sobrecarga unilateral e num aumento da pressão em áreas específicas.

A Figura 4.29 apresenta o mapa de pressão associado à postura P7, caracterizada pela posição com o pé esquerdo sobre o joelho direito.




Figura 4.29 – Mapa de pressão da posição 7 (P7).

A análise do mapa de pressão, à semelhança da postura anterior, evidencia uma distribuição assimétrica de pressão no assento. A maior concentração de pressão está localizada na região inferior esquerda do assento. Por outro lado, a região inferior direita apresenta valores mais baixos, refletindo o menor suporte nesta área devido à elevação da perna esquerda.

A traseira do assento, apresenta valores de pressão reduzidos. Este padrão demonstra que a maior parte do peso está deslocada para a parte esquerda do assento, sendo esta a área que suporta a maior carga corporal.

A zona central do mapa indica que a base das nádegas e da coxa esquerda suporta a maior parte do peso. Este comportamento é típico de uma postura cruzada, onde o peso é distribuído de forma desigual, gerando uma sobrecarga unilateral na região esquerda do corpo.

A Figura 4.30 apresenta o mapa de pressão associado à postura P8, caracterizada pela posição com a perna direita cruzada sobre a esquerda.




Figura 4.30 – Mapa de pressão da posição 8 (P8).

A análise do mapa de pressão revela uma distribuição assimétrica no assento. A maior concentração de pressão encontra-se na região superior esquerda do assento, formando um género de uma diagonal. Este padrão é causado pelo suporte adicional gerado pela perna esquerda, que está em contacto direto com o assento, enquanto a perna direita cruzada contribui para um deslocamento do peso corporal.

Os valores observados na região frontal direita do assento são mais baixos, refletindo um menor suporte nesta área devido ao desvio do peso para a perna em contacto com o assento. A zona central do mapa mostra valores moderados, sugerindo que o peso está parcialmente distribuído na base das nádegas, mas com um deslocamento acentuado para o lado esquerdo.

Na traseira do assento, os valores de pressão são baixos. Este padrão reflete a redução do contato na parte anterior devido à postura cruzada, que desvia o peso para a parte posterior e lateral do assento.

A Figura 4.31 apresenta o mapa de pressão associado à postura P9, caracterizada pela posição com a perna esquerda cruzada sobre a direita.




Figura 4.31 – Mapa de pressão da posição 9 (P9).

Analisando o mapa é possível observar uma maior concentração de pressão na região direita do assento, onde é atingido os valores mais alto. Assim como na postura 8 é possível visualizar uma diagonal, mas no sentido oposto. Esta elevada concentração reflete o suporte proporcionado pela perna direita, que está em contacto direto com o assento e sustenta a maior parte do peso corporal.

Na região esquerda do assento, os valores de pressão são significativamente mais baixos. Este padrão indica um menor suporte nessa área, decorrente do deslocamento do peso para o lado direito. Na zona central, os valores apresentam uma intensidade elevada e uniforme, indicando que a base das nádegas suporta uma parcela considerável do peso, com um leve desvio para o lado direito.

Na traseira do assento correspondentes à parte anterior da cadeira, os valores de pressão são muito baixos. Este padrão reflete uma redução significativa do contacto nessa área, típica de posturas cruzadas, onde o peso é deslocado para a parte posterior e lateral do assento.

A Figura 4.32 apresenta o mapa de pressão associado à postura P10, caracterizada pela posição em que o utilizador está sentado na extremidade da cadeira




Figura 4.32 – Mapa de pressão da posição 10 (P10).

A análise do mapa de pressão evidencia uma distribuição simétrica do ponto de vista horizontal, mas assimétrica verticalmente e uma deslocação significativa do peso corporal para a parte frontal do assento. A maior concentração de pressão é observada na região frontal do assento, especialmente na área central e ligeiramente deslocada para o lado direito.

Na traseira do assento, os valores de pressão são extremamente baixos, indicando um contacto mínimo com essa área. Este padrão é típico desta postura, onde o utilizador não utiliza o encosto e mantém o peso concentrado na extremidade do assento, criando uma sobrecarga na base das nádegas e na região pélvica.

A zona central apresenta valores moderados, refletindo uma parte considerável do peso concentrada nesta área, mas com um desvio visível para o lado direito do assento, como evidenciado pelos valores mais altos nesta região.

A análise das diferentes posturas comprovou padrões de pressão distintos, refletindo a interação entre o corpo e o assento em cada posição. Em algumas posturas, como a P6 e a P7, seria expectável observar padrões simétricos devido à simples troca de pernas. Contudo, verificaram-se variações nos valores de pressão, possivelmente influenciadas pela predominância de utilizadores destros na recolha de dados, o que pode ter resultado numa maior força ou estabilidade de um dos lados.

De forma geral, as posturas assimétricas demonstraram concentrações de pressão mais elevadas em áreas específicas do assento, sublinhando a importância de corrigir desvios posturais e promover hábitos que favoreçam uma distribuição equilibrada do peso corporal.

4.2.3.2.3. Processamento de dados

Atendendo à posição dos vários sensores apresentados na Figura 4.33, foram calculadas novas características. A Figura 4.33 representa o esquema utilizado para o cálculo das características de posicionamento (*Left*, *Right*, *Front*, e *Back*). Por exemplo, a Figura 4.33(a) representa o cálculo para a característica *Left*, onde é efetuada a média dos sensores posicionados na lateral esquerda da cadeira, dando mais peso aos sensores da extremidade.




Figura 4.33 – Cálculo das características de posicionamento: (a) Left; (b) Right; (c) Front (d) Back.

Left – Média ponderada dos sensores posicionados na lateral esquerda da cadeira,

$$Left = ((Sensor12 + Sensor13 + Sensor14 + Sensor15) \times 0.7 + (Sensor8 + Sensor9 + Sensor10 + Sensor11) \times 0.3)/8 \quad (4.14)$$

Right – Média ponderada dos sensores posicionados na lateral direita da cadeira.

$$Right = ((Sensor0 + Sensor1 + Sensor2 + Sensor3) \times 0.7 + (Sensor4 + Sensor5 + Sensor6 + Sensor7) \times 0.3)/8 \quad (4.15)$$

Front – Média ponderada dos sensores posicionados na dianteira da cadeira.

$$Front = ((Sensor3 + Sensor7 + Sensor11 + Sensor15) \times 0.7 + (Sensor2 + Sensor6 + Sensor10 + Sensor14) \times 0.3)/8 \quad (4.16)$$

Back – Média ponderada dos sensores posicionados na traseira e encosto da cadeira.

$$Back = ((Sensor0 + Sensor4 + Sensor8 + Sensor12) \times 0.7 + (Sensor1 + Sensor5 + Sensor9 + Sensor13) \times 0.3)/8 \quad (4.17)$$

Mean – Média de todos os sensores.

Com base nas características anteriormente definidas, foram determinadas novas características de modo a estimar as coordenadas do centro de massa e ângulo com o centro da cadeira como ilustrado na Figura 4.9. Estas características são iguais às do primeiro protótipo sendo que os cálculos encontram-se apresentados nas equações (4.6), (4.7), (4.8) e (4.9)

Sendo o posicionamento dos sensores de forma matricial, foram definidas novas características, a média de cada linha e coluna. A Figura 4.34 ilustra as representações das linhas e colunas no assento da cadeira.




Figura 4.34 – Linhas e colunas do assento da cadeira.

Exemplificando o cálculo para a linha 1 (Row1), que representa a média dos sensores posicionados na primeira linha. (4.24)

$$Row1 = \frac{Sensor0 + Sensor4 + Sensor8 + Sensor12}{4} \quad (4.18)$$

Com base nas características anteriormente definidas, foram calculadas novas características para estimar o valor de cada um dos dezasseis sensores presentes no assento com base nos valores obtidos das linhas e colunas. A figura exemplifica o cálculo para o S0 (Estimativa do *Sensor0*).




Figura 4.35 – Estimativa do Sensor 0 (S0).

Como se pode verificar na Figura 4.35 o *Sensor0* encontra-se na interseção da primeira linha e primeira coluna sendo obtido através da equação

$$S0 = \frac{Row1 + Column1}{2} \quad (4.19)$$

O cálculo destas estimativas originou novos mapas de pressão que podem ser consultados no anexo A.5.

4.2.3.2.4. Treino, Classificação e Validação

Na Figura 4.36 está representado o ranking da importância de características, criado através do método *Information Gain*, que permite avaliar o impacto de cada característica na distinção das diferentes posturas. Esta análise preliminar foi essencial para reduzir a dimensionalidade dos dados, eliminando informações redundantes ou características irrelevantes, e garantindo que os algoritmos de *machine learning* pudessem focar-se nas variáveis mais significativas.




Figura 4.36 – Protótipo 2: Ranking de características.

Foram selecionadas as 25 características mais relevantes para o processo de classificação, apresentadas no anexo A.10, com base nos valores de *Information Gain* superiores a 0.5. Este critério assegurou que apenas as variáveis com maior influência na diferenciação das posturas fossem consideradas no modelo. Entre estas 25 características, pode-se observar que apenas 10 estão diretamente associadas aos sensores da cadeira, que se encontram no assento, destacando-se como os elementos de maior relevância, e que nenhum dos 3 sensores no encosto foram considerados relevantes na identificação das posturas. Estes sensores,

assinalados a verde na Figura 4.37, foram os considerados mais importantes para a classificação das posturas analisadas.




Figura 4.37 – Sensores com maior importância para a classificação da postura.

Assim como no primeiro protótipo, o conjunto de dados foi dividido em 80% para treino e 20% para teste. Esta divisão foi realizada garantindo que os participantes presentes no conjunto de treino não estivessem no conjunto de teste e vice-versa. Esta abordagem assegura que o modelo é testado com dados completamente novos, provenientes de participantes desconhecidos para o algoritmo, promovendo uma avaliação mais rigorosa e evitando o *overfitting* do modelo aos dados de treino.

Os resultados obtidos, apresentados na Tabela 4.7, mostram o desempenho dos modelos ANN e SVM na classificação de 10 posturas distintas.

Tabela 4.7 – Resultado dos modelos ANN e SVM para a classificação das 10 posições.

Model	10 Positions		
	Accuracy	Precision	Recall
ANN	92.4%	93.4%	92.4%
SVM	89.7%	89.8%	89.7%

A Figura 4.38 ilustra as matrizes de confusão geradas pelos dois modelos, utilizando tons de azul para o modelo ANN e tons de verde para o SVM.




Figura 4.38 – Protótipo 2: Matrizes de confusão para 10 posições: ANN (tons de azul), SVM (tons de verde).

Os resultados obtidos demonstram que o segundo protótipo alcançou os objetivos definidos, com foco principal na melhoria da precisão na classificação de posições com pernas cruzadas, identificadas como as mais críticas no primeiro protótipo. Tanto o modelo ANN como o SVM conseguiram atingir uma precisão média em torno de 90%, conforme observado nos sistemas semelhantes descritos na Tabela 4.1. Este avanço reflete um aumento substancial na fiabilidade do sistema, especialmente na identificação de posturas mais desafiadoras.

Entre as alterações introduzidas no segundo protótipo, destaca-se a expansão significativa no número de sensores utilizados, passando de 4 sensores no assento e 1 no encosto no primeiro protótipo, para 16 sensores no assento e 3 no encosto. Este incremento permitiu uma recolha de dados mais detalhada e precisa, capaz de capturar padrões mais complexos e melhorar a capacidade de classificação das posturas.

Além disso, a análise com a técnica *Information Gain* revelou que apenas 10 sensores desempenhavam um papel determinante na classificação, destacando a importância de priorizar variáveis significativas para maximizar a eficiência do sistema.

Outro progresso importante foi a elevação da precisão na classificação de posições críticas. No primeiro protótipo, estas apresentaram resultados insatisfatórios, enquanto no segundo protótipo, utilizando o modelo ANN, a precisão foi acima dos 90%, superando os valores anteriores e aproximando-se dos padrões esperados na literatura.

As alterações implementadas contribuíram para melhorias expressivas, particularmente na identificação de posturas complexas. A maior densidade de sensores no assento ampliou a resolução e qualidade dos dados.

Atendendo aos resultados obtidos da classificação é possível efetuar uma redução do número de sensores sem degradar o desempenho do sistema.

4.3. Monitorização dos Sinais vitais

Monitorizar o ritmo cardíaco pode ajudar a identificar momentos em que os alunos estão mais atentos ou distraídos. Picos ou quedas no ritmo cardíaco podem indicar níveis de stress ou relaxamento. Estes dados podem ser utilizados pelo docente para ajustar as aulas, tornando-as mais dinâmicas ou tranquilas, conforme necessário. Isto pode melhorar a retenção de informações e o envolvimento dos alunos nas atividades [60].

O sensor ótico utilizado, ilustrado na Figura 4.39(a), contém 3 tipos de luz: verde, vermelho e infravermelho. O sensor escolhido para a monitorização do ritmo cardíaco na cadeira foi selecionado devido ao seu caráter não invasivo, permitindo ao aluno realizar a medição apenas colocando os dedos sobre o sensor por alguns instantes. Este método é particularmente vantajoso em ambiente de sala de aula, pois minimiza o impacto na atenção dos alunos e reduz o desconforto associado a métodos mais intrusivos de medição, como aqueles que requerem a fixação do sensor ao corpo de forma contínua. Além disso, a escolha por um sensor ótico com capacidade de deteção refletiva, usando luz verde, vermelha e infravermelha, possibilita medições precisas de variações no volume sanguíneo, facilitando a obtenção de dados consistentes de frequência cardíaca, mesmo em condições de movimento moderado do aluno. Aproveitando o facto de este sensor possuir LEDs nas cores vermelha e infravermelha, tornou-se possível também medir a saturação de oxigénio no sangue (SpO₂). A localização estratégica do sensor na parte inferior do assento, com um ligeiro ressalto, permite uma interação fácil e intuitiva, tornando-o adequado para uso rápido e eficiente em contextos educativos (Figura 4.39(b)).




Figura 4.39 – (a) Sensor ótico SFH7072 [61]; (b) Localização do sensor na cadeira.

Este tipo de sistema consiste em LEDs que emitem a luz e um foto-díodo que recebe a luz.

Existem dois tipos de montagem: a transmissiva e a refletiva (Figura 4.40).

No caso transmissivo, o foto-díodo (PD) e o LED são colocados em lados opostos da parte do corpo humano, mais comum o dedo, com o foto-díodo recolhendo a luz residual após a absorção de vários componentes da parte do corpo.

No caso refletivo, o foto-díodo (PD) e o LED estão do mesmo lado e o foto-díodo recolhe a luz refletida de várias profundidades sob a pele. O foto-díodo converte a luz incidente num sinal elétrico proporcional à intensidade de luz.

Sendo que neste caso trata-se da montagem refletiva.




Figura 4.40 – Tipos de montagem: (a) Transmissivo; (b) Refletivo (Adaptado a partir de [62]).

O sinal referido, é conhecido como o sinal de fotopletismograma (*Photoplethysmograph*, PPG) e contém a periodicidade da taxa do pulso. Consiste numa técnica ótica não invasiva usada para medir variações no volume sanguíneo em tecidos microvasculares. Desde o seu desenvolvimento por Hertzman em 1938, o PPG tem sido amplamente utilizado para monitorizar parâmetros fisiológicos como a frequência cardíaca (*Heart Rate*, HR), sendo que neste caso é comumente referido como pulso cardíaco (*Pulse Rate*, PR), e a saturação de oxigénio no sangue. O PPG funciona iluminando a pele com uma fonte de luz e medindo as variações na intensidade da luz refletida ou transmitida, que são causadas por mudanças na perfusão do sangue na área iluminada. Este tipo de tecnologia enfrenta desafios como a sensibilidade a artefactos de movimento, especialmente durante atividades diárias normais.

A luz verde é amplamente utilizada em dispositivos de medição de frequência cardíaca, como *smartwatches*, *wearables* e monitores de *fitness*. A luz vermelha e a infravermelha são comumente utilizadas em oxímetros de pulso para medir a saturação de oxigénio no sangue (SpO₂) e, secundariamente, o ritmo cardíaco. Alguns estudos realizados revelam que luz verde foi considerada a mais adequada para a monitorização do ritmo cardíaco tanto em situações de repouso como em movimento, mostrando maior precisão e menor suscetibilidade a artefactos de movimento em comparação com a luz vermelha e infravermelha [62], [64].

Na Figura 4.41, está representado uma pequena aquisição de dados nos três comprimentos de onda: verde (513-545 nm), vermelho (635-666 nm) e infravermelho (>800 nm), onde é possível ver que o sinal da onda verde está razoavelmente mais limpo do que as ondas vermelhas e infravermelhas que aparentam ter artefactos provocados pela luz artificial (50 Hz). Estando o sensor localizado na parte de baixo do assento está suscetível a apanhar reflexões de luz artificial e natural que adicionam artefactos ao sinal.




Figura 4.41 – Sinal PPG nos três comprimentos de onda (Verde, Vermelho e Infravermelho)

4.3.1. Frequência Cardíaca

Monitorizar o ritmo cardíaco pode ajudar a identificar momentos em que os alunos estão mais atentos ou distraídos. Picos ou quedas no ritmo cardíaco podem indicar níveis de stress ou relaxamento, permitindo que os professores ajustem o ritmo e as estratégias de ensino em tempo real.

Chiovato, A et al. (2021) [60] investigou a viabilidade e eficácia de um dispositivo *wearable* na monitorização da variabilidade da frequência cardíaca (HRV) em tempo real, com o objetivo de avaliar o estado de *mindfulness*, ou atenção plena, dos estudantes.

A variabilidade da frequência cardíaca (HRV) refere-se às variações no intervalo de tempo entre batimentos cardíacos consecutivos e é um indicador da função autonómica cardíaca. Ela reflete a interação dinâmica entre o sistema nervoso simpático e parassimpático, sendo uma

medida importante para avaliar a capacidade do corpo de se adaptar a mudanças físicas e psicológicas.

Existem diferentes métodos para analisar a HRV, incluindo:

- Medições no domínio do tempo: Quantificam a variabilidade do intervalo entre batimentos cardíacos ao longo do tempo, como a média dos intervalos R-R (*Inter-Beat Interval*, IBI) ou a raiz quadrada da média dos sucessivos intervalos de tempo entre batimentos (*Root Mean Square of Successive Differences*, RMSSD).
- Medições no domínio da frequência: Avaliam a distribuição da energia do sinal de HRV em várias bandas de frequência, como as bandas de baixa frequência (*Low Frequency*, LF) e alta frequência (*High Frequency*, HF), que correspondem às atividades simpática e parassimpática, respetivamente.
- Medições não-lineares: Avaliam a complexidade e a imprevisibilidade da série temporal dos batimentos cardíacos, utilizando técnicas como o *plot* de Poincaré e a análise de entropia aproximada.

A HRV pode ser utilizada como um indicador da saúde cardiovascular e do estado de regulação autonómica. A baixa HRV geralmente está associada a um pior estado de saúde e a uma menor capacidade de adaptação a situações de stress, enquanto uma HRV mais alta indica uma maior flexibilidade e resiliência do sistema cardiovascular. No entanto, valores muito altos de HRV também podem estar associados a condições patológicas, especialmente em indivíduos idosos com arritmias cardíacas.

Estes métodos e a interpretação da HRV são úteis em várias aplicações clínicas, incluindo a deteção de diabetes, apneia do sono, enfarte do miocárdio, arritmias cardíacas, hipertensão e transtornos psiquiátricos. A análise de HRV também é utilizada para monitorizar a fadiga e o desempenho em atletas, bem como para avaliar a resposta ao tratamento em diversas condições clínicas [65], [66], [67].

O dispositivo *wearable* desenvolvido por Chiovato, A em forma de boné com tecnologia IoT, permitiu a medição da HRV através de sensores de oximetria, e os dados recolhidos eram enviados para um smartphone via *Bluetooth* e armazenados na nuvem para análise posterior.

Os resultados indicaram que valores elevados de HRV estavam associados a estados mais altos de *mindfulness*, sugerindo que a HRV pode ser um indicador viável do estado de atenção plena dos alunos durante as atividades académicas [60].

Embora a variabilidade da frequência cardíaca (HRV) seja uma métrica importante para avaliar o estado de *mindfulness* e o equilíbrio do sistema nervoso, a tecnologia utilizada neste estudo não permite uma monitorização contínua, pois exigiria que o aluno mantivesse o dedo sob a cadeira durante toda a aula, inviabilizando uma análise detalhada da HRV. Para contornar esta limitação, optou-se por realizar medições pontuais no início e a meio da aula. Com estas medições, é possível obter uma visão geral da resposta do sistema cardiovascular em momentos distintos, permitindo identificar alterações significativas no estado de relaxamento e stress dos alunos ao longo do tempo. Embora esta abordagem não forneça a mesma profundidade que a

monitorização contínua, poderá permitir a avaliação do impacto inicial e acumulado das atividades, contribuindo para um entendimento geral da sua eficácia no contexto educativo.

4.3.1.1. Acondicionamento do sinal PPG

Foi efetuada uma recolha de dados a um sujeito, a uma frequência de amostragem de 100 Hz, durante cerca de dois minutos sendo a frequência cardíaca média de 54 batimentos por minuto (bpm).

A Figura 4.42 apresenta o espectro de frequência do sinal PPG obtido através da Transformada de Fourier (FFT). Esta análise é crucial para entender as diferentes componentes que constituem o sinal PPG, permitindo a identificação das frequências associadas ao batimento cardíaco e a eliminação de interferências indesejadas.




Figura 4.42 – Transformada de Fourier do sinal: Composição do sinal PPG

Da Figura 4.42 uma fração de energia do sinal concentrada nas baixas frequências ($f \leq 0.5$ Hz) e envolvendo a componente DC. Esta energia representa as variações lentas da linha de base do sinal. Estas variações podem estar associadas à respiração, movimento ou outras mudanças lentas na perfusão do tecido. As frequências associadas à respiração normalmente situam-se na faixa de 0.15 Hz a 0.4 Hz. Esta faixa de frequências corresponde aos ciclos respiratórios normais de um ser humano adulto, que respira entre 9 a 24 vezes por minuto, resultando em frequências respiratórias que variam aproximadamente entre 0.15 Hz (9 respirações por minuto) e 0.4 Hz (24 respirações por minuto).

H.S. Shin et al. [68] menciona que a frequência principal num sinal PPG típico se situa em torno de 1 Hz, correspondendo ao ritmo cardíaco. Na Figura 4.42 identifica-se um pico de energia

em torno de 0.86 Hz, que corresponde aproximadamente a 52 bpm. Esta frequência é seguida por duas harmônicas, situadas em 1.72 Hz e 2.58 Hz. A presença de uma segunda harmônica indica que o sinal PPG é bem definido e com pouco ruído.

Aplicando um filtro passa-banda de segunda ordem, entre 0.5 e 10 Hz, permite eliminar interferências indesejadas e melhorar a clareza das medições fisiológicas obtidas através do PPG. A função de transferência do filtro passa-banda *Butterworth* de segunda ordem pode ser representada pela seguinte equação às diferenças (4.20).

$$y[n] = b_0x[n] + b_1x[n - 1] + b_2x[n - 2] - a_1y[n - 1] - a_2y[n - 2] \quad (4.20)$$

Onde:

- $b_0 = 0.0619$
- $b_1 = 0$
- $b_2 = -0.1237$
- $a_1 = -3.1514$
- $a_2 = 0.4311$

Substituindo na equação tem-se (4.21):

$$y[n] = 0.0619 \times x[n] - 0.1237 \times x[n - 2] + 3.1514 \times y[n - 1] - 0.4311 \times y[n - 2] \quad (4.21)$$

Como a filtragem vai ser efetuada num microcontrolador é necessário alterar o cálculo para que os coeficientes deixem de ser flutuantes (com casas decimais) e passem a ser inteiros de modo a reduzir o tempo de processamento. Para isso multiplica-se os coeficientes por 4096 (2^{12}), ficando:

- $b_0 = 253$
- $b_2 = -506$
- $a_1 = -12908$
- $a_2 = 1765$

Por último é feito um deslocamento de 12 bits para a direita, para fazer a divisão, de modo a compensar a multiplicação dos coeficientes feita anteriormente, como mostra a equação (4.22):

$$y[n] = (253 \times x[n] - 506 \times x[n - 2] + 12908 \times y[n - 1] - 1765 \times y[n - 2]) \gg 12 \quad (4.22)$$

A Figura 4.43 representa a FFT do sinal PPG filtrado. Da figura é possível constatar a redução de energia fora da banda de passagem do filtro passa-banda.




Figura 4.43 – Transformada de Fourier: Sinal PPG com filtro passa-banda de 0.5 Hz até 10 Hz.

O código desenvolvido para este estudo encontra-se no A.12.

4.3.1.2. Algoritmo para detecção de picos

Para a detecção dos picos foi utilizado o método de detecção através do *threshold* adaptivo (Figura 4.44). Para detetar a posição do pico, o *threshold* é aumentado ou diminuído com um parâmetro de inclinação fixo. Por exemplo, na detecção dos picos superiores ($V_{\max}$) o valor do *threshold* com o passar do tempo enquanto o limiar é superior à amplitude do sinal original. Se o limiar encontrar o sinal, este, passa a acompanhar a amplitude do sinal até alcançar o ponto de divergência, i.e, a amplitude do sinal passa a ser inferior ao *threshold*. Esse ponto de divergência é então considerado o pico. Após a detecção, o *threshold* é diminuído novamente por um parâmetro de inclinação modificado. Os procedimentos anteriores são repetidos até que cada pico seja encontrado. Na detecção dos picos inferiores ($V_{\min}$) é apenas aplicar a lógica inversa.




Figura 4.44 – Algoritmo de detecção do pico (Adaptada de [68]).

O *threshold* adaptivo (ADT) é dado pela equação (4.23) ADT_n é o valor atual de *threshold*, ADT_{n-1} o valor anterior de *threshold*, s é a sensibilidade de declive/inclinação e PPG_n a amplitude atual do sinal PPG. Quanto maior for a diferença entre o valor anterior de *threshold* maior é o declive/inclinação. s é uma constante que define o quão acentuado será o declive, i.e, quanto maior a sensibilidade menor é o tempo para o *threshold* encontrar a amplitude do sinal PPG.

$$ADT_n = ADT_{n-1} - s \times (ADT_{n-1} - PPG_n) \quad (4.23)$$

Características cardiovasculares, que resultam do envelhecimento, hipertensão e da complacência dos vasos, ou mudanças indesejadas na linha de base, afetam a reflexão da onda e podem aumentar ou reduzir a amplitude da onda refletida. O período refratário foi selecionado de forma adaptativa como 0,4 vezes o intervalo médio do pulso anterior. O cancelamento de picos pelo período refratário é mostrado na Figura 4.45.




Figura 4.45 – Período refratário (Adaptado de [68]).

Na Figura 4.46 (a) apresenta o sinal original, onde é possível ver o sinal PPG com as flutuações na linha de base provocadas essencialmente pela respiração. A Figura 4.46 (b) representa o sinal PPG obtido após a aplicação do filtro passa-banda (0.5Hz – 10 Hz) que estabilizou o sinal face ao original. A Figura 4.46 (c) mostra a aplicação do algoritmo para a deteção dos picos superiores. A Figura 4.46 (d) mostra a aplicação do algoritmo para a deteção dos picos inferiores.




Figura 4.46 – (a) Sinal PPG original; (b) Sinal PPG com o filtro passa-banda aplicado; (c) Deteção dos picos superiores do sinal PPG ($s = 0.0025$); (d) Deteção dos picos inferiores do sinal PPG ($s = 0.0025$).

4.3.2. Oximetria

O princípio da oximetria do pulso baseia-se no facto de que a componente arterial do sangue é pulsátil por natureza. Quando uma luz LED é incidida numa parte do corpo humano, mais comumente no dedo, parte dessa luz é atenuada por vários componentes como tecidos que têm uma componente constante “DC”, e artérias e veias que têm um componente pulsátil “AC”. O objetivo da oximetria de pulso é medir a percentagem de hemoglobina oxigenada (HbO₂) para a hemoglobina total (Hb) (oxigenada mais desoxigenada) no sangue arterial, que é conhecido como SpO₂ (Saturação de oxigénio no sangue). A hemoglobina oxigenada (HbO₂) no sangue é vermelha, enquanto a hemoglobina desoxigenada no sangue tem uma coloração azul escura característica. A propriedade ótica do sangue na região visível/vermelha (ou seja, entre 400 e 700 nm) e infravermelha (ou seja, entre 700 e 1000 nm) dependem fortemente da quantidade de oxigénio transportado pelo sangue.

O método explora o facto de que a hemoglobina total (Hb) tem um coeficiente de absorção ótica maior na região vermelha do espectro, em torno de 660 nm, em comparação com hemoglobina oxigenada (HbO₂), conforme ilustrado na Figura 4.47. Por outro lado, na região infravermelha do espectro, em torno de 940 nm, a absorção ótica da hemoglobina total (Hb) é inferior em comparação com hemoglobina oxigenada (HbO₂) [62], [69].




Figura 4.47 – Absorção da luz vermelha e infravermelha pelo sangue oxigenado e Desoxigenado (Retirada de [69]).

Fazendo medições de luz nos dois comprimentos de onda, geralmente vermelho e infravermelho, que como referido anteriormente têm diferentes coeficientes de absorção para hemoglobina oxigenada e desoxigenada, todas as componentes constantes podem ser canceladas e o valor SpO₂ pode ser estimado.

A parte pulsátil do sinal PPG é considerada como a componente "AC", e a parte não pulsátil, resultante principalmente do sangue venoso, pele e tecido, é referida como a componente "DC", como se pode verificar na Figura 4.48.





Figura 4.48 – Componentes AC e DC no sinal PPG (Retirada de [62]).

Um desvio no brilho do LED ou na sensibilidade do detetor pode alterar a intensidade de luz detetada pelo sensor. Esta dependência da intensidade da luz transmitida ou refletida pode ser compensada usando uma técnica de normalização onde a componente "AC" é dividida pela componente "DC" conforme dado na equação (4.24).

$$Ratio = R_{IR} = \left(\frac{\left(\frac{AC_R}{DC_R} \right)}{\left(\frac{AC_{IR}}{DC_{IR}} \right)} \right) \quad (4.24)$$

Esta normalização ou rácio (*Ratio*) tem uma relação com a saturação de oxigénio no sangue (SpO₂), apresentada na Figura 4.49.



$$R = \frac{AC_{660}/DC_{660}}{AC_{940}/DC_{940}}$$

Figura 4.49 – Curva de calibração típica (Retirada de [62]).

A estimativa típica da saturação de oxigénio no sangue (SpO2) é obtida através da equação (4.25).

$$SpO2\% = A - B \times (R/IR) \quad (4.25)$$

Na equação (4.25), como mencionado anteriormente, o R / IR é baseado numa normalização onde a componente pulsátil “AC” é dividida pela componente não pulsátil “DC” correspondente para cada comprimento de onda, e A e B são coeficientes de regressão linear que estão relacionados com os coeficientes de absorção específicos de hemoglobina total (Hb) e hemoglobina oxigenada (HbO2). Os coeficientes típicos estão apresentados na equação (4.26).

$$SpO2\% = 110 - 25 \times (R/IR) \quad (4.26)$$

A calibração deste sensor foi feita recorrendo um simulador da *BC Biomedical* o *FingerSim* que consiste em três dedos com diferentes níveis de SpO2 80%, 90% e 97% onde foram realizadas medições do rácio em cada um (Figura 4.50).




Figura 4.50 – Teste de calibração:(a) Dedos FingerSim 80%, 90% e 97%; (b) Montagem de Teste.

Para permitir que a rácio (R/IR) seja relacionado à saturação de oxigénio numa ampla faixa, é usada uma curva polinomial de segunda ordem calculada no Excel (4.27).

$$SpO2\% = 3.96 \times Ratio^2 - 42.43 \times Ratio + 121.74 \quad (4.27)$$

A Figura 4.51 apresenta a curva de calibração obtida.




Figura 4.51 – Curva de calibração obtida utilizando o simulador *BC Biomedical FingerSim*.

4.4. Testes realizados

O teste realizado envolveu novamente o simulador de paciente da *BC Biomedical* o *FingerSim* utilizado durante os testes. (Figura 4.52). A utilização deste equipamento garante uma forma controlada para verificar a eficácia e precisão dos algoritmos de medição de frequência cardíaca e SpO₂.



Figura 4.52 – Simulador de Paciente da BC Biomedical.

Na Figura 4.53 estão apresentados os testes realizados utilizando o simulador de paciente, equipado com o dedo artificial que simula um nível de saturação de oxigénio (SpO₂) de 90%. Foram testados diferentes ritmos cardíacos: 80, 120 e 160 batimentos por minuto (bpm).

Na Figura 4.53 (a) apresenta um teste com frequência cardíaca configurada para 80 bpm e saturação de oxigénio mantida em 90%. Observa-se estabilidade na leitura de SpO₂ com pequenas variações iniciais na frequência cardíaca.

Na Figura 4.53 (b) mostra um teste com frequência cardíaca de 120 bpm, mantendo uma leitura estável ao longo do tempo. A saturação de oxigénio apresenta um comportamento consistente, próximo de 90%, com ligeiras flutuações.

Na Figura 4.53 (c) ilustra um teste com frequência cardíaca de 160 bpm. A frequência cardíaca apresenta variações dentro do esperado, mantendo-se próxima do valor configurado.

A saturação de oxigénio permanece estável, com pequenas oscilações.




Figura 4.53 – Gráficos das medições de frequência cardíaca e saturação de oxigénio (SpO_2) durante testes com simulador de paciente.

Os testes realizados demonstram a capacidade do sistema em monitorizar com precisão tanto a frequência cardíaca quanto a saturação de oxigénio em diferentes condições. A estabilidade das leituras, especialmente para a frequência cardíaca, com um erro em torno dos $\pm 2 \text{ bpm}$, confirma a eficácia dos algoritmos implementados. Pequenas variações no SpO_2 , aproximadamente $\pm 1\%$, são normais e esperadas, e não comprometem a fiabilidade geral do sistema. Estes resultados validam a utilização do sistema para monitorização de sinais vitais em ambientes controlados.

4.5. Comunicação

A Figura 4.53 ilustra a arquitetura do sistema de monitorização desenvolvido, realçando o fluxo de comunicação entre os seus principais componentes: a cadeira, o *backend* e a interface de visualização.




Figura 4.53 – Fluxo de comunicação da cadeira com o sistema

Como descrito anteriormente, a cadeira está equipada com sensores de pressão, que monitorizam a distribuição de peso do utilizador, e sensores de sinais vitais, como frequência cardíaca. Estes dados são transmitidos para o sistema central utilizando o protocolo MQTT, conhecido pela sua eficiência em transmissões leves e rápidas.

A comunicação entre a cadeira e o *backend* é bidirecional, permitindo tanto o envio de dados da cadeira para o sistema como a receção de comandos ou atualizações provenientes do

backend. A cadeira envia dois tipos principais de pacotes de dados:

- Pacote de sinais vitais: Enviado quando o utilizador se senta e após cada 45 minutos de permanência sentado.
- Pacote de dados de pressão: Consiste num *array* com dados recolhidos pelos sensores de pressão, enviado a cada segundo, permitindo uma monitorização contínua da postura.

Primeiramente, os dados de pressão recebidos pelo *backend* são analisados pelo classificador de postura, que utiliza algoritmos de aprendizagem para identificar a postura do utilizador. Neste sistema, foram utilizados dois modelos principais, na fase de teste, para a classificação:

- Rede Neural Artificial (ANN): Implementada utilizando a biblioteca *PyTorch* [70] , conhecida pela sua flexibilidade e desempenho na construção de modelos de redes neurais complexos.
- Máquina de Vetores de Suporte (SVM): Implementada com a biblioteca *scikit-learn* [71] , uma ferramenta robusta para tarefas de classificação e regressão.

Em paralelo, os dados dos sinais vitais recolhidos pelos sensores são agregados num pacote único, juntamente com as informações classificadas de postura. Este processo centraliza todas as informações relevantes, que são, em seguida, transmitidas de forma organizada para o *frontend*.

Capítulo 5

Sistema Central – DISPLAY

Este capítulo descreve o Sistema Central - DISPLAY, concebido como o núcleo da rede de sensores implementada. Este sistema centraliza a recolha, processamento e visualização dos dados provenientes dos sensores ambientais e das cadeiras inteligentes, garantindo uma monitorização eficiente e em tempo real dos parâmetros ambientais e posturais em salas de aula. Além disso, o sistema possibilita a atuação em dispositivos conectados, como a regulação das condições de iluminação, promovendo um ambiente otimizado para o ensino e aprendizagem.

Neste capítulo, são detalhados os diversos componentes do sistema central, incluindo a sua arquitetura, hardware, software e funcionalidades principais. O objetivo é apresentar uma visão abrangente do funcionamento do sistema, destacando a sua integração com a rede de sensores e a interface com os utilizadores. Essa centralização é fundamental para garantir a eficiência, escalabilidade e flexibilidade do sistema, atendendo às necessidades específicas de ambientes escolares e outros contextos de aplicação.

5.1. Sistema

O *DISPLAY*, apresentado na Figura 5.1, é o elemento central onde todos os outros dispositivos IoT da sala de aula se conectam. Este equipamento, fixado na parede, fornece uma interface visual intuitiva para monitorizar e controlar as condições ambientais, como qualidade do ar, iluminação e ruído. Permite aos utilizadores acompanhar visualmente os parâmetros recolhidos pelos sensores IoT, além de ajustar as condições da sala conforme necessário. O objetivo é proporcionar um controlo acessível e centralizado.



Figura 5.1 – Sistema DISPLAY.

O DISPLAY, como já mencionado, é o núcleo da rede de sensores, permitindo a monitorização dos parâmetros ambientais e posturais, bem como a atuação nas condições de iluminação da sala de aula. Este sistema centraliza a comunicação e o processamento dos dados recolhidos pelos dispositivos da rede, garantindo uma gestão eficiente e em tempo real.

Os sensores ambientais, distribuídos pela sala, recolhem dados como temperatura, humidade, dióxido de carbono, partículas suspensas, ruído e iluminação. Estes dados são transmitidos para o sistema central, onde são processados e armazenados para análise e visualização. Paralelamente, as cadeiras inteligentes enviam informações relativas à postura e aos sinais vitais dos estudantes, permitindo monitorizar o seu conforto e bem-estar durante as atividades. A rede também possibilita a atuação nas luzes da sala, ajustando a iluminação com base nos dados recolhidos ou nas necessidades específicas do momento.

Toda a comunicação entre os dispositivos da rede é realizada de forma centralizada, garantindo a integração de todos os componentes e possibilitando uma gestão dinâmica do ambiente da sala de aula. Este sistema assegura um ambiente saudável e otimizado, promovendo melhores condições de aprendizagem e bem-estar para alunos e professores.

Todos estes sensores e atuadores estão conectados com o sistema através do protocolo MQTT. O sistema permite um número máximo de 6 sensores ambientais e um total de 30 cadeiras conectados. A Figura 5.2 apresenta a arquitetura do sistema.




Figura 5.2 – Arquitetura do sistema central - DISPLAY.

5.2. Hardware

O sistema DISPLAY utiliza uma Single Board Computer (SBC) com o processador Allwinner A64, um chipset ARM Cortex-A53 de 64 bits, conhecido pela eficiência energética e suporte a resoluções gráficas elevadas. Este sistema inclui um ecrã LCD TFT de 10.1 polegadas com funcionalidade touch para a visualização de dados e interação com o utilizador. Para otimizar o consumo de energia, o sistema integra um sensor de radar que ativa o ecrã apenas na presença de uma pessoa, desligando-o automaticamente na sua ausência, promovendo a eficiência energética.

O sistema utiliza um sistema operativo Linux, o que proporciona flexibilidade e suporte para um vasto conjunto de bibliotecas e ferramentas de software, facilitando a personalização do ambiente de desenvolvimento e a integração de interfaces de utilizador. A escolha do Linux permite também o uso de *frameworks* de desenvolvimento como Qt, que é ideal para aplicações gráficas interativas.

A Figura 5.3 ilustra o diagrama de blocos do hardware do DISPLAY.




Figura 5.3 – Diagrama de blocos do DISPLAY: Hardware.

5.3. Especificações do Sistema

As especificações iniciais impostas para o servidor central, o DISPLAY:

- Ter a capacidade de gerar uma rede WiFi própria, funcionando como um ponto de acesso, para permitir a conectividade dos dispositivos IoT.
- Atuar como servidor, hospedando o *Broker* MQTT, que será responsável por receber e gerir os dados provenientes de todos os equipamentos IoT conectados.
- Para armazenamento e acesso aos dados, ter uma base de dados capaz de armazenar informações dos últimos 30 dias.
- O *Backend* será responsável pelo processamento de todos os dados recebidos e distribuirá as informações para o *Frontend* e GUI, garantindo uma experiência de utilizador integrada e fluida.

- A *Graphical User Interface* (GUI) será fornecida através do *LCD Touch*, permitindo a apresentação de dados em tempo real e oferecendo funcionalidades para controlo da iluminação e outras operações.
- *Frontend* (Página *Web*) – Desenvolver uma página *web* dedicada principalmente para configurações, proporcionando uma interface intuitiva e acessível para ajustes e personalizações do sistema.




Figura 5.4 – Diagrama de blocos do *software* do sistema central - DISPLAY

5.4. Tecnologias Utilizadas e funcionalidades

No cenário cada vez mais dinâmico e interconectado da tecnologia, a escolha das ferramentas certas desempenha um papel fundamental no sucesso e na eficiência dos projetos de desenvolvimento de *software*. Cada tecnologia selecionada desempenha um papel específico e crucial na construção de um sistema robusto e funcional. A Figura 5.5 apresenta as tecnologias utilizadas no desenvolvimento do sistema.




Figura 5.5 – Tecnologias utilizadas no Sistema DISPLAY.

5.4.1. Backend

Para desenvolvimento do *backend* foi utilizado Python [72] que é uma linguagem de programação de uso geral popular por sua simplicidade, legibilidade e ampla gama de bibliotecas. É uma escolha frequente para desenvolvimento *web* e *backend*, e oferece ferramentas poderosas para manipulação de dados, análise e integração com diferentes sistemas.

O *backend* desempenha um papel fundamental na coordenação e execução das operações essenciais que garantem o funcionamento eficiente e coeso do sistema como um todo. A Figura 5.6 apresenta diferentes módulos que compõem o *backend* e suas respectivas funções.




Figura 5.6 – Constituição do *backend*

- **Módulo DB** - Responsável pela interação com o PostgreSQL, o Módulo DB efetua todas as operações relacionadas à manipulação de dados. Isso inclui a inserção de novos dados na base de dados, a elaboração de consultas complexas para recuperar informações específicas e a remoção de dados obsoletos. Garantindo uma comunicação eficiente com a base de dados, esse módulo é essencial para a integridade e a disponibilidade dos dados do sistema.
- **Módulo HTTP** - Atua como um servidor para facilitar a troca de arquivos entre o *backend* e o *frontend*. Ele fornece uma interface para a transferência de dados por meio do protocolo HTTP, permitindo uma comunicação eficaz e segura entre os dois componentes do sistema.
- **Módulo MQTT** - Responsável por lidar com a comunicação assíncrona entre os dispositivos e sistemas por meio do protocolo MQTT. Atua como um cliente MQTT, recebendo e processando dados nos tópicos aos quais está inscrito, além de publicar

configurações relevantes quando necessário. Essa funcionalidade é crucial para garantir uma troca de mensagens eficiente e em tempo real dentro do sistema.

- **Módulo Websocket** - Funciona como um servidor dedicado para facilitar a troca de mensagens e dados em tempo real entre o *backend* e os clientes *frontend*. A tecnologia de *websockets*, que oferece uma conexão bidirecional persistente, permitindo uma comunicação instantânea e de baixa latência. Essa capacidade é fundamental para atualizações em tempo real e interações dinâmicas na interface do utilizador.
- **Módulo Reports** desempenha um papel crucial na análise e apresentação de dados armazenados na base de dados. Ele é responsável por extrair informações relevantes, processá-las e gerar relatórios detalhados e informativos. Esses relatórios são importantes para a tomada de decisões informadas e a compreensão abrangente do desempenho e funcionamento do sistema.

5.4.2. Frontend

O desenvolvimento do *frontend* foi feito em *Vue.js* [73] que é uma *framework* progressiva de JavaScript, amplamente utilizada no desenvolvimento *frontend* de aplicações web. É conhecido pela sua leveza e simplicidade, sendo ideal para dispositivos com menos recursos, como SBCs. Foi projetado para ser uma ferramenta versátil e de fácil integração com outros projetos ou bibliotecas existentes, enquanto proporciona uma abordagem escalável para o desenvolvimento de aplicações complexas.

A *framework* permite que os desenvolvedores criem interfaces de utilizador interativas de forma eficiente, utilizando uma arquitetura baseada em componentes. Cada componente no *Vue.js* é independente e pode conter a lógica, o estilo e a estrutura HTML necessários para uma parte específica da aplicação, o que facilita a manutenção e a escalabilidade do código. Além disso, o *Vue.js* oferece uma documentação abrangente e uma comunidade ativa que suportam o desenvolvimento contínuo e a resolução de problemas comuns, o que torna a curva de aprendizagem menos acentuada para os novos utilizadores.

A aplicação faz uso de várias funcionalidades do *Vue.js*, juntamente com *plugins* como *Vuetify* para o design visual e *Font Awesome* para ícones. A estrutura da aplicação é composta por diversos componentes organizados de forma modular, de forma a facilitar a manutenibilidade e o desenvolvimento incremental.

A aplicação é constituída por diversas vistas (*views*), cada uma representando uma parte

essencial da interface:

- **HomeView.vue**: Página inicial que serve como ponto de entrada do utilizador, apresentando uma visão geral do sistema.
- **DashboardView.vue**: Este componente é responsável por mostrar métricas ou gráficos de desempenho em tempo-real, oferecendo uma visão detalhada do sistema de monitorização.
- **HistoryView.vue**: Apresenta os dados históricos, permitindo ao utilizador visualizar e analisar dados passados.
- **ChairView.vue**:
- **SettingsView.vue**: Permite que o utilizador configure parâmetros importantes para a aplicação.
- **AboutView.vue**: Fornece informações sobre o propósito da aplicação e a sua equipa de desenvolvimento.




Figura 5.7 – Arquitetura do *Frontend*

5.4.3. Interface de Utilizador

No desenvolvimento da interface de utilizador, foi utilizado o Python em conjunto com o Qt, uma poderosa combinação de tecnologias amplamente reconhecidas pela sua flexibilidade e capacidade de criar interfaces gráficas de alta qualidade.

O Qt [74] é uma *framework* amplamente utilizada (GUI) e aplicações multiplataforma. Originalmente desenvolvido em C++, o Qt é reconhecido pela sua robustez, flexibilidade e capacidade de criar interfaces nativas para diversos sistemas operativos, incluindo Windows, macOS e Linux, sem a necessidade de reescrever o código para cada plataforma. Esta característica faz do Qt uma escolha sólida para projetos que necessitam de compatibilidade em diferentes ambientes.

Uma das principais vantagens do Qt é a sua vasta gama de *widgets* e componentes gráficos pré-construídos, que permitem a criação de interfaces complexas e intuitivas com relativamente pouco esforço. Estes *widgets* incluem botões, menus, caixas de diálogo, tabelas, gráficos e

muitos outros elementos necessários para a interação com o utilizador. Além disso, o Qt oferece uma arquitetura baseada em eventos, onde cada interação do utilizador, como um clique ou uma alteração de valor, gera um evento que pode ser tratado de forma eficiente pelo programador, facilitando a criação de aplicações interativas e reativas.

No contexto do desenvolvimento com Python, o Qt pode ser utilizado através de *bindings* como PyQt, que trazem todo o poder do Qt para o ecossistema Python. Estes *bindings* permitem que os programadores beneficiem da simplicidade e da legibilidade do Python enquanto utilizam as ferramentas gráficas sofisticadas e altamente personalizáveis do Qt. Esta combinação torna o desenvolvimento mais rápido e acessível, enquanto mantém a performance e a qualidade das aplicações.

5.4.4. Broker MQTT

No projeto, foi utilizado o Mosquitto como *broker* MQTT, uma escolha popular e eficiente para a implementação de comunicação baseada em protocolos de mensagens na área da Internet das Coisas (IoT).

O Mosquitto [75] é uma das implementações de *broker* MQTT mais conhecidas e amplamente adotadas. É um *software open-source*, extremamente leve e de fácil instalação e configuração, o que facilita o seu uso tanto em ambientes de teste como em implementações mais robustas. Para além disso, suporta diferentes níveis de Qualidade de Serviço (QoS), permitindo ajustar a fiabilidade da entrega de mensagens de acordo com os requisitos do projeto, desde entregas "pelo menos uma vez" até garantias de "exatamente uma vez". Isto torna o Mosquitto uma solução flexível para uma ampla gama de aplicações, desde simples automações domésticas até cenários industriais complexos.

Outro ponto a destacar é a sua compatibilidade multiplataforma, estando disponível para uma variedade de sistemas operativos, incluindo Linux, Windows e macOS, o que permite a sua utilização em diferentes ambientes. Além disso, o Mosquitto oferece suporte a encriptação SSL/TLS, garantindo que as comunicações sejam seguras, especialmente em redes abertas ou sensíveis.

5.4.5. Base de dados

No projeto, foi utilizado o PostgreSQL como sistema de gestão de base de dados (SGBD). O PostgreSQL é uma das bases de dados relacionais de código aberto mais avançadas e amplamente utilizadas, conhecida pela sua robustez, desempenho e conformidade com os padrões SQL.

Uma das principais razões para a escolha do PostgreSQL foi a sua capacidade de lidar com grandes volumes de dados e suportar operações complexas de forma eficiente, o que é essencial em projetos que envolvem a recolha e gestão de grandes quantidades de informação, como os sistemas IoT. Além disso, o PostgreSQL oferece suporte a transações ACID (Atomicidade,

Consistência, Isolamento, Durabilidade), garantindo que as operações na base de dados sejam executadas de forma segura e sem perda de integridade dos dados, mesmo em caso de falhas.

O PostgreSQL destaca-se também pela sua extensibilidade. Os utilizadores podem adicionar novos tipos de dados, funções, operadores e até métodos de indexação personalizados. Este nível de flexibilidade permite adaptar o sistema de base de dados às necessidades específicas de um projeto, tornando-o ideal para casos onde é necessário expandir a funcionalidade padrão de uma base de dados relacional.

Outra característica importante é o suporte a consultas SQL avançadas, incluindo subconsultas, junções complexas e funções agregadas, o que permite a análise eficiente dos dados armazenados. O PostgreSQL também tem um excelente desempenho em operações que envolvem grandes volumes de leitura e escrita de dados, sendo escalável tanto verticalmente (aumentando a capacidade do servidor) como horizontalmente (distribuindo a carga por múltiplos servidores)

5.5. Interface de Utilizador

A interface de utilizador do sistema DISPLAY será fundamental para que professores ou até mesmo alunos interajam de maneira simples e direta com o sistema de monitorização. Essa interface facilitará o acompanhamento em tempo real dos parâmetros ambientais da sala de aula, como temperatura, iluminação, ruído e qualidade do ar. Além disso, permitirá visualizar tendências desses parâmetros por meio de gráficos, auxiliando na identificação de condições ideais para o ambiente académico.

Além da monitorização, a interface permitirá ações diretas, como ligar ou desligar as luzes de maneira prática e eficiente, adaptando-se às necessidades da sala em tempo real. Isso promove uma gestão dinâmica e centralizada, aumentando a eficácia e eficiência no controle do ambiente educacional.

5.5.1. Ecrã Inicial

O ecrã inicial da interface, apresentado na Figura 5.8, será a porta de entrada para o sistema proporcionando uma visão global, clara e imediata das condições ambientais monitorizadas. Concebido para ser intuitivo, este ecrã apresentará as informações de forma organizada e visualmente apelativa, garantindo facilidade de utilização por qualquer utilizador, independentemente do seu nível de familiaridade com o sistema.



Figura 5.8 – DISPLAY: Layout do Ecrã inicial.

Os indicadores essenciais, como temperatura, humidade relativa, níveis de CO₂, iluminação e níveis de ruído, serão exibidos em tempo real, permitindo uma monitorização contínua e eficiente. Além disso, serão destacados alertas para condições fora do padrão através do uso de cores de aviso, como vermelho, facilitando a identificação rápida de situações críticas. A Figura 5.9 ilustra um exemplo do acontecimento.




Figura 5.9 – DISPLAY: Ecrã inicial.

Para maior funcionalidade, o ecrã inicial inclui botões de acesso direto a outras secções do sistema, como gráficos históricos e opções de controlo, como ligar ou desligar luzes, assegurando uma navegação prática e um controlo centralizado.

5.5.2. Gráficos de tendência

A secção de gráficos da interface de utilizador, apresentada na Figura 5.10, é crucial para apresentar de forma detalhada e intuitiva os dados recolhidos pelo sistema, permitindo ao utilizador visualizar e analisar as tendências dos parâmetros monitorizados ao longo do dia. Este ecrã destaca-se pela sua capacidade de proporcionar uma análise rápida e clara, permitindo ao utilizador identificar alterações nos parâmetros em tempo real e adotar medidas corretivas de forma imediata, prevenindo que algum deles ultrapasse os limites desejáveis.




Figura 5.10 – DISPLAY: Gráfico de tendência.

5.5.3. Controlo de Iluminação

A funcionalidade de controlo de iluminação na interface de utilizador, apresentada na Figura 5.11, permite uma gestão eficiente e prática da iluminação da sala de aula, garantindo o conforto visual e a otimização energética. Este sistema foi concebido para ser intuitivo, permitindo ao utilizador ajustar rapidamente os níveis de iluminação conforme as necessidades específicas do ambiente.

Esta funcionalidade proporciona um controlo flexível e inteligente da iluminação, contribuindo para a criação de um ambiente mais confortável e eficiente, alinhado às necessidades pedagógicas e ao bem-estar dos ocupantes da sala de aula.



Figura 5.11 – DISPLAY: Controlo de Iluminação.

A Figura 5.12 representa a interface do sistema de controle de iluminação de uma sala de aula, projetada para proporcionar uma gestão eficiente do brilho das luminárias. Os círculos indicam as luminárias instaladas na sala, sendo que o utilizador pode selecionar individualmente ou em grupo as luminárias que deseja ajustar. Esta funcionalidade confere flexibilidade ao sistema, permitindo personalizar a iluminação conforme as necessidades específicas de diferentes áreas da sala. O layout da interface utiliza o quadro da sala de aula como referência central, ajudando o utilizador a orientar-se espacialmente e a identificar rapidamente as luminárias correspondentes a cada área. Na lateral esquerda da interface, encontra-se um *slider* que permite ajustar o brilho das luminárias selecionadas. O utilizador pode aumentar ou diminuir a intensidade luminosa de forma precisa, garantindo um ambiente iluminado de maneira adequada às atividades realizadas na sala de aula. Esta funcionalidade promove não apenas o conforto visual dos ocupantes, mas também a eficiência energética, ao evitar o uso desnecessário de luz.



Figura 5.12 – DISPLAY: Layout do controlo de iluminação.

5.5.4. Código QR para acesso à Página WEB

A integração de um código QR na interface do sistema, apresentado na Figura 5.13, permite um acesso rápido e prático à página web, oferecendo ao utilizador uma forma eficiente de consultar os dados e controlar o sistema a partir de qualquer dispositivo com capacidade de leitura de códigos QR, como *smartphones* ou *tablets*.



Figura 5.13 – DISPLAY: Código QR para acesso á plataforma WEB.

5.6. Plataforma Web

A Plataforma Web desenvolvida, constitui um elemento essencial do sistema, proporcionando uma interface intuitiva e acessível para a visualização, gestão e análise dos dados recolhidos pela rede de sensores. Esta plataforma foi concebida para permitir aos utilizadores monitorizar em tempo real os parâmetros ambientais e posturais, consultar históricos de dados, identificar tendências e interagir com o sistema de forma prática e eficiente. Além disso, a plataforma facilita a tomada de decisões, ao exibir informações de forma clara e organizada.

5.6.1. Dashboard

O Dashboard, ou DashboardView, é o núcleo da aplicação onde todos os parâmetros monitorizados são agregados e apresentados ao utilizador de forma intuitiva. Esta vista destina-se a fornecer uma visão global sobre as condições ambientais e posturais, facilitando a análise em tempo real e a tomada de decisões rápidas.



Figura 5.14 – Vista *Dashboard*

O DashboardView permite visualizar as medições em tempo real dos vários parâmetros ambientais monitorizados com Sensor, tais como, a temperatura, humidade relativa, ruído, iluminação e concentração de dióxido de carbono.

Inclui também gráficos que mostram a evolução dos parâmetros ao longo do presente dia, permitindo identificar tendências e padrões que possam ser usados para otimizar o ambiente de aprendizagem.

A vista inclui indicadores visuais de conformidade, que sinalizam se os valores medidos estão dentro dos intervalos ideais recomendados. Sempre que um parâmetro está fora do intervalo ideal o texto passa a ser apresentado a vermelho indicando ao utilizador que se encontra fora do limite.

5.6.2. Histórico de dados

A página de dados históricos, ou HistoryView, fornece uma visão histórica dos dados recolhidos pelos sensores ao longo do tempo. Esta vista permite que os utilizadores (professores, administradores, ou responsáveis pela manutenção) vejam como os parâmetros monitorizados variaram, possibilitando a análise de tendências.



Figura 5.15 – Vista *History*

A HistoryView mostra gráficos históricos dos parâmetros ambientais. Estes gráficos ajudam a entender como estes fatores variaram ao longo do tempo e a avaliar se houve condições

inadequadas ou flutuações significativas em determinados períodos.



Figura 5.16 – Vista *History*: Gráfico de tendência.

Inclui a funcionalidade de exportação de dados em formatos como CSV. Isto é importante para professores, investigadores ou técnicos que desejem realizar uma análise mais detalhada fora da plataforma ou integrar os dados noutros sistemas. Outra funcionalidade útil é a possibilidade de gerar relatórios com base nos dados históricos. Estes relatórios incluem gráficos e resumos dos parâmetros mais importantes para serem apresentados em reuniões ou documentação de qualidade ambiental.




Figura 5.17 – Exemplo do relatório.

O HistoryView desempenha um papel crucial ao permitir uma análise retrospectiva dos dados recolhidos pelo sistema. Enquanto o DashboardView permite ações e reações em tempo real, a HistoryView ajuda a avaliar a eficácia das medidas tomadas e a compreender o comportamento do ambiente auxiliando deste modo os utilizadores a planear ações corretivas baseadas em padrões observados, tais como melhorar a ventilação em horários específicos ou ajustar a iluminação com base em flutuações diárias.

5.6.3. Dashboard Cadeira

A página para visualização dos dados da cadeira, tem duas secções essenciais: o *Dashboard* e *Postura*.

A secção *Dashboard*, apresentada na Figura 5.18, apresenta os últimos dados relativos aos sinais vitais do aluno, incluindo temperatura, ritmo cardíaco e SpO₂. Além disso, apresenta a postura atual do aluno, bem como a estimativa da localização do centro de massa.




Figura 5.18 – Secção *Dashboard* da Cadeira.

A *Postura*, ilustrado na Figura 5.19, fornece informações detalhadas sobre o tempo total que o aluno passou sentado e apresenta a distribuição percentual desse tempo pelas diferentes posturas.




Figura 5.19 – Secção de *Postura* da Cadeira.

A página apresentada foi desenvolvida com base no primeiro protótipo do sistema. Para integrar as funcionalidades do novo protótipo, será necessário realizar reformulações no software, que ainda se encontram em fase de planeamento e desenvolvimento.

Capítulo 6

Conclusão

A presente dissertação apresenta um trabalho inovador no desenvolvimento de um sistema IoT para monitorização da qualidade ambiental e postural em ambientes escolares, com o objetivo principal de promover um ambiente mais saudável e adequado ao processo de aprendizagem. O trabalho inicia-se com uma introdução que enquadra a problemática, identificando a influência dos parâmetros ambientais e fisiológicos no desempenho académico e na saúde dos alunos. Destaca-se, desde logo, a relevância de fatores como temperatura, humidade, concentração de dióxido de carbono, iluminação e ruído no ambiente escolar, bem como a importância de uma postura correta na prevenção de problemas de saúde a longo prazo.

A análise sobre a influência destes parâmetros, desenvolvida no capítulo seguinte, demonstra que condições inadequadas podem comprometer significativamente o desempenho cognitivo e o bem-estar dos alunos. A revisão da literatura fundamenta a necessidade de intervenção, sublinhando que níveis elevados de dióxido de carbono, iluminação deficiente, excesso de ruído ou temperaturas extremas podem impactar negativamente a capacidade de concentração e aprendizagem. No que diz respeito à postura, são destacados os riscos associados à má postura, reforçando a importância de um sistema que não só monitorize, mas também promova uma postura correta.

No âmbito técnico, o sistema desenvolvido é apresentado como uma solução integrada que reúne diferentes sensores para medir parâmetros ambientais e fisiológicos. Este inclui sensores de dióxido de carbono, partículas suspensas, ruído sonoro, luminosidade, humidade e temperatura, complementados por um módulo de monitorização postural através de cadeiras inteligentes. A conceção deste sistema foi detalhada, abrangendo desde o design de *hardware* até ao *firmware*, com particular ênfase na comunicação eficiente via WiFi e protocolo MQTT. A implementação de normas internacionais, como a IEC 61672 para medições acústicas, assegura a precisão e confiabilidade dos resultados obtidos.

A cadeira SPMS (*Sitting Posture Monitoring System*) foi, sem dúvida, o elemento mais desafiador desta dissertação. Este módulo passou por dois protótipos distintos, com o intuito de melhorar o desempenho do sistema e assegurar uma monitorização precisa da postura e sinais vitais. Embora os resultados obtidos sejam promissores, ainda existem áreas que necessitam de melhorias, especialmente no que diz respeito à monitorização contínua de sinais vitais. A solução implementada, sendo não evasiva, não permite a recolha contínua destes parâmetros tão importantes. No futuro, a utilização de sensores de radar para deteção do ritmo cardíaco poderá ser explorada. Estes sensores, além de não evasivos, podem ser integrados na estrutura da cadeira, permitindo uma monitorização contínua sem qualquer ação por parte do utilizador, o que aumentaria significativamente a eficácia do sistema.

A monitorização da postura e sinais vitais, outro pilar do sistema, é apresentada como uma inovação significativa. Através de cadeiras equipadas com sensores integrados e algoritmos

de classificação de dados baseados em inteligência artificial, foi possível identificar posturas inadequadas. Os testes realizados demonstraram a eficácia do sistema em diferenciar entre diversas posições, contribuindo para a promoção de hábitos posturais saudáveis entre os utilizadores.

Por fim, a integração de um sistema central de visualização de dados, com interface e acesso a relatórios detalhados, reforça a utilidade prática da solução proposta. Este sistema permite uma interação dinâmica com os utilizadores, promovendo uma gestão ativa dos parâmetros ambientais e posturais em tempo real, tornando-o aplicável em múltiplos contextos. Embora o foco inicial deste projeto seja o ensino básico e secundário, o sistema apresenta um potencial significativo para ser adaptado e utilizado em outros contextos, como o ensino superior, onde pode melhorar as condições de estudo e concentração dos estudantes. Em ambientes empresariais, o sistema poderia ser utilizado para criar um ambiente mais saudável, contribuindo para o aumento da produtividade dos trabalhadores e redução de ausências por problemas de saúde. Em hospitais, permitiria monitorizar e controlar fatores ambientais críticos, criando um ambiente menos propício à propagação de vírus e melhorando o conforto dos pacientes e profissionais de saúde. Estas possíveis adaptações demonstram a versatilidade e aplicabilidade do sistema, indo além do ambiente escolar e criando impactos positivos em diferentes setores.

Em resumo, esta dissertação representa um avanço significativo no campo da IoT aplicada à monitorização da qualidade ambiental e postural, oferecendo uma solução tecnológica robusta e versátil para a melhoria da saúde, do desempenho e do bem-estar em múltiplos contextos. O trabalho destaca-se não só pela sua abordagem multidisciplinar, mas também pelo impacto potencial que pode gerar na qualidade de vida dos utilizadores e na eficiência de diferentes sistemas organizacionais. Assim, este sistema abre caminho para futuras investigações e implementações em larga escala, contribuindo para a criação de ambientes mais saudáveis, sustentáveis e produtivos.

Bibliografia

- [1] Toyinbo, O. (2023). Indoor environmental quality, pupils' health, and academic performance—A literature review. *Buildings*, 13(9), 2172. <https://doi.org/10.3390/buildings13092172>.
- [2] Yang, Z., Becerik-Gerber, B., & Mino, L. (2013). A study on student perceptions of higher education classrooms: Impact of classroom attributes on student satisfaction and performance. *Building and Environment*, 70, 171–188. <https://doi.org/10.1016/j.buildenv.2013.08.030>.
- [3] L. Chatzidiakou, D. Mumovic, and J. Dockrell, "The Effects of Thermal Conditions and Indoor Air Quality on Health, Comfort and Cognitive Performance of Students," The Bartlett, UCL Faculty of the Built Environment UCL Institute for Environmental Design and Engineering, London, 2014.
- [4] IQ Home, "Air Quality and CO₂ Levels", visitado a 24 de setembro de 2024, https://www.ighome.org/index.php?route=extension/d_blog_module/post&post_id=17.
- [5] Fonseca Gabriel, M., Paciência, I., Felgueiras, F., et al. (2021). Environmental quality in primary schools and related health effects in children: An overview of assessments conducted in Northern Portugal. *Energy and Buildings*, 250, 111305. <https://doi.org/10.1016/j.enbuild.2021.111305>.
- [6] Organização Mundial da Saúde. WHO - World Health Organization, visitado a 23 de junho de 2024, <https://www.who.int/pt/about>.
- [7] Organização Mundial da Saúde. (2021). WHO global air quality guidelines: particulate matter (PM_{2.5} and PM₁₀), ozone, nitrogen dioxide, sulfur dioxide and carbon monoxide, visitado a 23 de junho de 2024, <https://www.who.int/publications/i/item/9789240034228>.
- [8] Cheryan, S., Ziegler, S. A., Plaut, V. C., & Meltzoff, A. N. (2014). Designing classrooms to maximize student achievement. *Policy Insights from the Behavioral and Brain Sciences*, 1(1), 4–12. <https://doi.org/10.1177/237273221454867>.
- [9] Organização Mundial da Saúde (2010). Noise, visitado a 25 de julho de 2024, <https://www.who.int/europe/news-room/fact-sheets/item/noise>.
- [10] Hutchinson, G., Du, L., & Ahmad, K. A. (2020). Incubator-based sound attenuation: Active noise control in a simulated clinical environment. *PLOS ONE*, 15(7), e0235287. <https://doi.org/10.1371/journal.pone.0235287>
- [11] Leonard, J. (2018, April 4). What is good posture? Medical News Today. 1.
- [12] Casas, A. S., Patiño, M. S., & Camargo, D. M. (2016). Association between the sitting posture and back pain in college students. *Revista Universidad Industrial de Santander Salud*, 48(4), 446–454. <https://doi.org/10.18273/revsal.v48n4-2016003>

- [13] Son, J., & Son, Y.-S. (2019). A correlation analysis of indoor environmental quality and indoor air quality using IoT. *2019 International Conference on Information and Communication Technology Convergence (ICTC)*, Jeju, Korea (South), 977–979. <https://doi.org/10.1109/ICTC46691.2019.8939605>
- [14] Adochiei, F.-C., Rusu-Zagar, G., Patachia, M., Patrascu, L., & Scripcariu, L. (2020). Electronic system for real-time indoor air quality monitoring. *2020 International Conference on e-Health and Bioengineering (EHB)*, Iasi, Romania, 1–4. <https://doi.org/10.1109/EHB50910.2020.9280192>
- [15] Bhattacharya, S., Sridevi, S., & Pitchiah, R. (2012). Indoor air quality monitoring using wireless sensor network. *2012 Sixth International Conference on Sensing Technology (ICST)*, Kolkata, India, 422–427. <https://doi.org/10.1109/ICSensT.2012.6461713>.
- [16] Ali, F. A., Prakash, S., & Mali, S. (2023). IoT-based real-time monitoring system for indoor air quality for human health. *2023 2nd International Conference on Ambient Intelligence in Health Care (ICAIHC)*, Bhubaneswar, India, 1–5. <https://doi.org/10.1109/ICAIHC59020.2023.10431482>
- [17] Zhao, L., Wu, W., & Li, S. (2019). Design and implementation of an IoT-based indoor air quality detector with multiple communication interfaces. *IEEE Internet of Things Journal*, 6(6), 9621–9632. <https://doi.org/10.1109/JIOT.2019.2930191>
- [18] Bosch Sensortec (n.d.). BME680: Integrated environmental sensor, visitado a 8 de dezembro de 2024, <https://www.bosch-sensortec.com/media/boschsensortec/downloads/datasheets/bst-bme680-ds001.pdf>.
- [19] Hölscher, A. (2022). *The Indoor Air Quality Index in HVAC Applications*. SOREL. Visitado a 4 de setembro de 2024, <https://www.sorel.de/en/indoor-air-quality-index-in-hvac-applications>.
- [20] Winsen Sensor (n.d.). MH-Z19C Infrared CO2 Sensor Manual, visitado a 8 de dezembro de 2024, <https://www.winsen-sensor.com/d/files/manual/mh-z19c.pdf>.
- [21] Site CO2Meter.com (2024). *How does an NDIR CO2 sensor work?*, visitado a 4 de setembro de 2024, <https://www.co2meter.com/blogs/news/how-does-an-ndir-co2-sensor-work>
- [22] Vishay (n.d.). VEML6031X00: High Accuracy Ambient Light Sensor Datasheet, visitado a 8 de dezembro de 2024, <https://www.vishay.com/docs/80007/veml6031x00.pdf>.
- [23] [15] Hi-Link Technology (n.d.). 24G Ultra Low-power Radar Sensing Module LD2410S Human Presence Sensing Switch Intelligent Sensor, visitado a 8 de dezembro de 2024, <https://www.hlktech.net/index.php?id=1176>.
- [24] Winsen Sensor (n.d.). ZH06-II Laser Dust Module Manual, visitado a 8 de dezembro de 2024, https://www.winsen-sensor.com/d/files/zh06-ii-laser-dust-module-manual-ver1_2--without-protocol.pdf.

- [25] TDK/InvenSense. (2016). ICS-43434 MEMS Microphone Specification. [Invensense.tdk.com](https://invensense.tdk.com/wp-content/uploads/2016/02/DS-000069-ICS-43434-v1.2.pdf), visitado a 15 de maio de 2024, <https://invensense.tdk.com/wp-content/uploads/2016/02/DS-000069-ICS-43434-v1.2.pdf>.
- [26] Hackaday. (n.d.). ESP32 I²S Sound Level Meter (SLM). [Hackaday.io](https://hackaday.io/project/166867-esp32-i2s-slm)., visitado a 31 de maio de 2024, <https://hackaday.io/project/166867-esp32-i2s-slm>.
- [27] IEC 61672-1:2013, Electroacoustics - Sound level meters - Part 1: Specifications, International Electrotechnical Commission, 2013.
- [28] Chung, K. (2023). Calibration matters: I. Sound level meter basics. *Journal of Communication Disorders*, 101, 106300. <https://doi.org/10.1016/j.jcomdis.2022.106300>
- [29] Ler e Aprender (n.d.). Anatomia do ouvido, visitado a 8 de outubro de 2024, <https://lereaprender.com.br/otite/anatomia-do-ouvido/>.
- [30] Siemens Community (n.d.). What is A-weighting, visitado a 8 de outubro de 2024, <https://community.sw.siemens.com/s/article/what-is-a-weighting>.
- [31] NTi Audio. (n.d.). Fast, Slow, Impulse Time Weighting - What do they mean?. NTi Audio, visitado a 6 de agosto de 2024, <https://www.nti-audio.com/en/support/know-how/fast-slow-impulse-time-weighting-what-do-they-mean>.
- [32] FreeRTOS (n.d.). FreeRTOS Official Website, visitado a 8 de dezembro de 2024, <https://www.freertos.org/>.
- [33] DALI Alliance. (2024). "Introducing DALI". Visitado a 4 de outubro de 2024, <https://www.dali-alliance.org/>.
- [34] Adam, G. K. (2019). DALI LED driver control system for lighting operations based on Raspberry Pi and kernel modules. *Electronics*, 8(9), 1021. <https://doi.org/10.3390/electronics8091021>
- [35] Meyer, L. (2007). *An Introduction to Digital Addressable Lighting Interface (DALI) Systems & Study of a DALI Day Lighting Application*. Kansas State University. visitado a 4 de outubro de 2024, <https://krex.k-state.edu/items/f8ecdec4-da2c-462a-8008-8752be1cbdcd>.
- [36] Pereira, L., & Silva, H. P. da. (2023). A novel smart chair system for posture classification and invisible ECG monitoring. *Sensors*, 23(2), 719. <https://doi.org/10.3390/s23020719>.
- [37] Roh, J., Park, H.-J., Lee, K. J., Hyeong, J., Kim, S., & Lee, B. (2018). Sitting posture monitoring system based on a low-cost load cell using machine learning. *Sensors*, 18(1), 208. <https://doi.org/10.3390/s18010208>
- [38] Zemp, R., Tanadini, M., Plüss, S., Schnüriger, K., Singh, N. B., Taylor, W. R., & Lorenzetti, S. (2016). Application of machine learning approaches for classifying sitting posture based on force and acceleration sensors. *BioMed Research International*, 2016, Article ID 5978489, 9 pages. <https://doi.org/10.1155/2016/5978489>

- [39] Jeong, H., & Park, W. (2021). Developing and evaluating a mixed sensor smart chair system for real-time posture classification: Combining pressure and distance sensors. *IEEE Journal of Biomedical and Health Informatics*, 25(5), 1805–1813. <https://doi.org/10.1109/JBHI.2020.3030096>
- [40] Martins, L., Lucena, R., Belo, J., Santos, M., Quaresma, C., Jesus, A. P., & Vieira, P. (2013). Intelligent chair sensor. *Engineering Applications of Neural Networks. Communications in Computer and Information Science*, 182–191. https://doi.org/10.1007/978-3-642-41013-0_19
- [41] Martins, L., Lucena, R., Belo, J., Almeida, R., Quaresma, C., Jesus, A. P., & Vieira, P. (2013). Intelligent chair sensor—Classification and correction of sitting posture. In *Proceedings of the IFMBE Proceedings XIII Mediterranean Conference on Medical and Biological Engineering and Computing 2013* (pp. 1489–1492). Seville, Spain, 25–28 September 2013. https://doi.org/10.1007/978-3-319-00846-2_368.
- [42] Zemp, R., Taylor, W. R., & Lorenzetti, S. (2015). Seat pan and backrest pressure distribution while sitting in office chairs. *Applied Ergonomics*, 53, 1–9. <https://doi.org/10.1016/j.apergo.2015.08.004>.
- [43] Park, M., Song, Y., Lee, J., & Paek, J. (2016). Design and implementation of a smart chair system for IoT. In *Proceedings of the 2016 International Conference on Information and Communication Technology Convergence (ICTC)*, Jeju Island, South Korea, 19–21 October 2016. <https://doi.org/10.1109/ICTC.2016.7763406>
- [44] Huang, M., Gibson, I., & Yang, R. (2017). Smart chair for monitoring of sitting behavior. *KnE Engineering*, 2, 274. <https://doi.org/10.18502/keg.v2i2.626>
- [45] Otda, Y., Mizumoto, T., Arakawa, Y., Nakajima, C., Kohana, M., Uenishi, M., & Yasumoto, K. (2018). Census: Continuous posture sensing chair for office workers. In *Proceedings of the 2018 IEEE International Conference on Consumer Electronics (ICCE)*, Las Vegas, NV, USA, 12–14 January 2018. <https://doi.org/10.1109/icce.2018.8326275>
- [46] Kim, Y. M., Son, Y., Kim, W., Jin, B., & Yun, M. H. (2018). Classification of children's sitting postures using machine learning algorithms. *Applied Sciences*, 8(8), 1280. <https://doi.org/10.3390/app8081280>
- [47] Ishac, K., & Suzuki, K. (2018). LifeChair: A conductive fabric sensor-based smart cushion for actively shaping sitting posture. *Sensors*, 18(7), 2261. <https://doi.org/10.3390/s18072261>
- [48] Matuska, S., Paralic, M., & Hudec, R. (2020). A smart system for sitting posture detection based on force sensors and mobile application. *Mobile Information Systems*, 2020, 1–13. <https://doi.org/10.1155/2020/6625797>
- [49] Wan, Q., Zhao, H., Li, J., & Xu, P. (2021). Hip positioning and sitting posture recognition based on human sitting pressure image. *Sensors*, 21(2), 426. <https://doi.org/10.3390/s21020426>

- [50] Nautilus – Intelligent Furniture, Site oficial da empresa Nautilus, visitado a 6 de junho de 2024, <https://www.nautilus.pt/>.
- [51] Dynasys – shaping the future with technology, Site oficial da empresa Dynasys, visitado a 6 de junho de 2024, <https://www.dynasys.pt/pt/>.
- [52] How Does a Force Sensing Resistor (FSR) Work?, Site oficial da Tekscan – Pressure Mapping, Force Measurement & Tactile Sensors, visitado a 20 de abril de 2024, <https://www.tekscan.com/blog/flexiforce/how-does-force-sensing-resistor-fsr-work>.
- [53] Force Sensing Resistor (FSR) – Overview, visitado a 20 de abril de 2024, <https://learn.adafruit.com/force-sensitive-resistor-fsr/overview>.
- [54] Site KENHub, Anatomia Pelve, visitado a 2 de setembro de 2024, <https://www.kenhub.com/pt/library/anatomia/pelve>.
- [55] Data Science. O que é um Z-Score? Visitado a 28 de setembro de 2024, <https://datascience.eu/pt/matematica-e-estatistica/o-que-e-um-z-score/>.
- [56] M. V., & T. D. (2023). An effective approach for newspaper article classification using multi-class support vector machine in comparison with binary classifier to improve accuracy. *2023 Eighth International Conference on Science Technology Engineering and Mathematics (ICONSTEM)*, Chennai, India. <https://doi.org/10.1109/ICONSTEM56934.2023.10142872>.
- [57] Breiman, L. (2001). Random forests. *Machine Learning*, 45, 5–32. <https://doi.org/10.1023/A:1010933404324>
- [58] Zhang, Z. (2016). Introduction to machine learning: k-nearest neighbors. *Annals of Translational Medicine*, 4(11), 218. <https://doi.org/10.21037/atm.2016.03.37>.
- [59] ScienceDirect. (n.d.). Naive Bayes. Visitado a 26 de dezembro de 2024, <https://www.sciencedirect.com/topics/mathematics/naive-bayes>.
- [60] Chiovato, A., Demarzo, M., & Notargiacomo, P. (2021). Evaluation of mindfulness state for students using a wearable measurement system. *Journal of Medical and Biological Engineering*, 41(5), 690–703. <https://doi.org/10.1007/s40846-021-00658-4>
- [61] Site oficial da empresa OSRAM, OSRAM BIOFY®, SFH 7072, visitado a 28 de julho de 2024, <https://ams-osram.com/products/multi-chips/optical-modules/osram-biofy-sfh-7072>.
- [62] Tamura, T., Maeda, Y., Sekine, M., & Yoshida, M. (2014). Wearable photoplethysmographic sensors—Past and present. *Electronics*, 3(2), 282–302. <https://doi.org/10.3390/electronics3020282>.
- [63] Maeda, Y., Sekine, M., Tamura, T., Moriya, A., Suzuki, T., & Kameyama, K. (2008). Comparison of reflected green light and infrared photoplethysmography. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2008, 2270–2272. <https://doi.org/10.1109/IEMBS.2008.4649649>

- [64] Lee, J., Matsumura, K., Yamakoshi, K., Rolfe, P., Tanaka, S., & Yamakoshi, T. (2013). Comparison between red, green, and blue light reflection photoplethysmography for heart rate monitoring during motion. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2013, 1724–1727. <https://doi.org/10.1109/EMBC.2013.6609852>
- [65] Nayak, S. K., Pradhan, B., Mohanty, B., Sivaraman, J., Ray, S. S., Wawrzyniak, J., Jarzębski, M., & Pal, K. (2023). A review of methods and applications for a heart rate variability analysis. *Algorithms*, 16(9), 433. <https://doi.org/10.3390/a16090433>
- [66] Sammito, S., Thielmann, B., & Böckelmann, I. (2024). Update: Factors influencing heart rate variability—a narrative review. *Frontiers in Physiology*, 15, 1430458. <https://doi.org/10.3389/fphys.2024.1430458>
- [67] Shaffer, F., & Ginsberg, J. P. (2017). An overview of heart rate variability metrics and norms. *Frontiers in Public Health*, 5, 258. <https://doi.org/10.3389/fpubh.2017.00258>
- [68] Shin, H. S., Lee, C., & Lee, M. (2009). Adaptive threshold method for the peak detection of photoplethysmographic waveform. *Computers in Biology and Medicine*, 39(12), 1145–1152. <https://doi.org/10.1016/j.compbiomed.2009.10.006>
- [69] Xie, Y., Gao, Y., Li, Y., Lu, Y., & Li, W. (2017). Development of wearable pulse oximeter based on Internet of Things and signal processing techniques. *2017 European Modelling Symposium (EMS)*, Manchester, UK, 249–254. <https://doi.org/10.1109/EMS.2017.49>
- [70] Site PyTorch. (2024), PyTorch - An open source machine learning framework, visitado a 30 de novembro de 2024, <https://pytorch.org/>.
- [71] Site Scikit-Learn. (2024), Scikit-Learn - Machine Learning in Python, visitado a 30 de novembro de 2024, <https://scikit-learn.org/stable/>.
- [72] Site Python Software Foundation, About Python Software Foundation, visitado a 3 de setembro de 2024, <https://www.python.org/psf/about/>.
- [73] Site Vue.js, The Progressive JavaScript Framework, visitado a 3 de setembro de 2024, <https://vuejs.org/>.
- [74] Site Qt. (2024), Qt - Cross-platform software development for embedded & desktop, visitado a 9 de setembro de 2024, <https://www.qt.io/>.
- [75] Site Mosquitto. (2024), Eclipse Mosquitto - An open source MQTT broker, visitado a 9 de setembro de 2024, <https://mosquitto.org/>.

Anexo I

Equalização

Este anexo contém o script Python desenvolvido que realiza a análise da resposta de um microfone em comparação com tolerâncias normativas de Classes 1 e 2, definidas em diferentes frequências. Além disso, contém o desenvolvimento dos filtros digitais para ajustar a resposta do microfone e criar uma curva de equalização baseada na combinação desses filtros.

```
import numpy as np
import matplotlib.pyplot as plt

# Definir frequências padrão para tolerâncias das Classes 1 e 2 e as
# tolerâncias correspondentes
frequencies_corrected = np.array([10, 12.5, 16, 20, 25, 31.5, 40, 80, 100,
800, 1000, 1250, 1600, 2000, 2500, 3100, 4000, 5000, 6300, 8000, 10000, 12500,
16000, 20000])

# Resposta do microfone em frequências específicas (dB)
mic_frequencies = np.array([10, 20, 30, 40, 50, 60, 70, 80, 90, 100, 200, 300,
2000, 3000, 4000, 5000, 6000, 7000, 8000, 9000, 10000, 20000])
mic_response = np.array([-26, -13, -8, -6, -4, -3, -2.5, -2, -1.5, -1, -0.25,
0, 0, 0, 0.5, 1, 1.5, 2, 2.5, 3, 3.5, 10])

# Tolerâncias corrigidas para a Classe 1 (em dB)
tolerances_class1_positive_corrected = np.array([3.0, 2.5, 2.0, 2.0, 2.0, 1.5,
1.0, 1.0, 1.0, 1.0, 0.7, 1.0, 1.0, 1.0, 1.0, 1.0, 1.0, 1.0, 1.5, 1.5, 2.0,
2.5, 2.5, 3.0])
tolerances_class1_negative_corrected = np.array([-np.inf, -np.inf, -np.inf, -
2.0, -1.5, -1.5, -1.0, -1.0, -1.0, -1.0, -0.7, -1.0, -1.0, -1.0, -1.0, -1.0, -
1.0, -1.5, -2.0, -2.5, -3.0, -5.0, -16.0, -np.inf])

# Tolerâncias corrigidas para a Classe 2 (em dB)
tolerances_class2_positive_corrected = np.array([5.0, 5.0, 5.0, 3.0, 3.0, 3.0,
2.0, 2.0, 1.5, 1.5, 1.0, 1.5, 2.0, 2.0, 2.5, 2.5, 3.0, 3.5, 4.5, 5.0, 5.0,
5.0, 5.0, 5.0])
tolerances_class2_negative_corrected = np.array([-np.inf, -np.inf, -np.inf, -
3.0, -3.0, -3.0, -2.0, -2.0, -1.5, -1.5, -1.0, -1.5, -2.0, -2.0, -2.5, -2.5, -
3.0, -3.5, -4.5, -5.0, -np.inf, -np.inf, -np.inf, -np.inf])

# Criar gráficos das tolerâncias e da resposta do microfone
plt.figure(figsize=(6, 5))

# Tolerâncias da Classe 1 (positiva e negativa) em azul
```



```

plt.plot(frequencies_corrected, tolerances_class1_positive_corrected,
label='Class 1 Positive Tolerance', color='blue', linestyle='--')
plt.plot(frequencies_corrected, tolerances_class1_negative_corrected,
label='Class 1 Negative Tolerance', color='blue', linestyle='--')

# Resposta do microfone em verde
plt.plot(mic_frequencies, mic_response, label='Microphone Response',
color='green', linestyle='-')

# Faixa de tolerância da Classe 1 preenchida com transparência
plt.fill_between(frequencies_corrected, tolerances_class1_positive_corrected,
tolerances_class1_negative_corrected, color='blue', alpha=0.2, label='Class 1
Tolerance Range')

# Faixa de tolerância da Classe 2 preenchida com transparência vermelha
plt.fill_between(frequencies_corrected, tolerances_class2_positive_corrected,
tolerances_class2_negative_corrected, color='red', alpha=0.2, label='Class 2
Tolerance Range')

# Configurações do gráfico
plt.xlabel('Frequency (Hz)')
plt.ylabel('Response (dB)')
plt.xscale('log') # Escala logarítmica para frequência
plt.xlim([10, 20000]) # Limites de frequência
plt.ylim([-20, 10]) # Limites de amplitude
plt.grid(True, which='both', linestyle='--', linewidth=0.5) # Grade para
maior clareza
plt.legend() # Legenda do gráfico
plt.show()

# Filtros Digitais

fs = 48000 # Frequência de amostragem (em Hz)

# Frequências e respostas de filtros definidos manualmente
filter_frequencies = np.array([10, 20, 30, 40, 50, 60, 70, 80, 90, 100, 200,
300, 2000, 3000, 4000, 5000, 6000, 7000, 8000, 9000, 10000, 20000])
filter1_response = np.array([0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0.5, 1,
1.5, 2, 2.5, 3, 3.5, 10])
filter2_response = np.array([-25, -13.5, -8, -6, -4, -3, -2.5, -2, -1.5, -1, -
0.5, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0])

# Interpolação da resposta do filtro para mais frequências
freq_range = np.logspace(np.log10(filter_frequencies[0]),
np.log10(filter_frequencies[-1]), num=1000)
interp_response = np.interp(freq_range, filter_frequencies, filter1_response)

# Projeto do filtro 1

```



```

b1, a1 = signal.iirdesign(wp=[3/(fs/2), 5000/(fs/2)], ws=[1/(fs/2),
22000/(fs/2)],
                        gpass=1, gstop=3, output='ba')

# Resposta em frequência do filtro 1
w, h1 = signal.freqz(a1, b1, worN=8000)

# Interpolação da resposta do filtro 2
interp_response = np.interp(freq_range, filter_frequencies, filter2_response)

# Projeto do filtro 2
b2, a2 = signal.iirdesign(wp=[140/(fs/2), 14000/(fs/2)], ws=[1/(fs/2),
22000/(fs/2)],
                        gpass=1, gstop=3, output='ba')

# Resposta em frequência do filtro 2
w, h2 = signal.freqz(b2, a2, worN=8000)

# Combinação dos filtros 1 e 2
b_combined = np.convolve(a1, b2)
a_combined = np.convolve(b1, a2)

print("\nCoeficientes do filtro combinado (b_combined, a_combined):")
print("b_combined:", b_combined)
print("a_combined:", a_combined)

# Resposta em frequência do filtro combinado
w, hf = signal.freqz(a_combined, b_combined, worN=8000)
w = w * fs / (2 * np.pi) # Converter para Hz

# Interpolação da resposta do microfone para a grade de frequências `w`
interp_mic_response = np.interp(w, mic_frequencies, mic_response)

# Curva de equalização: somar a resposta do microfone e a resposta do filtro
combinado
equalization_curve = interp_mic_response + 20 * np.log10(np.abs(hf))

# Gráfico da resposta do microfone, filtro e curva de equalização
plt.figure(figsize=(6, 5))
plt.fill_between(frequencies_corrected, tolerances_class1_positive_corrected,
tolerances_class1_negative_corrected, color='b', alpha=0.2, label='Class 1
Tolerance Range')
plt.fill_between(frequencies_corrected, tolerances_class2_positive_corrected,
tolerances_class2_negative_corrected, color='red', alpha=0.2, label='Class 2
Tolerance Range')
plt.plot(w, interp_mic_response, 'g', label=' Microphone Response')
plt.plot(w, equalization_curve, 'blue', label='Equalization Curve',
linestyle='--')
plt.xscale('log')

```

```
plt.xlim([10, 20000])
plt.ylim([-20, 20])
plt.xlabel('Frequency (Hz)')
plt.ylabel('Response (dB)')
plt.grid(which='both', linestyle='--', linewidth=0.5)
plt.legend()
plt.show()
```

Anexo II


Mapa de Pressão - Posturas

Este anexo contém o mapa de pressão considerando as estimativas calculadas de cada sensor presente no assento do segundo protótipo.

Tabela 6.1 – Mapa de pressão com base na estimativa dos sensores.











Ranking de Características

Este anexo contém a tabela com 25 características mais relevantes/importantes para a classificação da postura no segundo protótipo.

Tabela 6.2 – *Ranking* com as 25 melhores características.

Feature	Info. gain
Sensor7	0.785
Sensor15	0.767
Mass X	0.755
Sensor11	0.712
Row4	0.688
Center Distance	0.685
Sensor3	0.65
Sensor13	0.621
Mass Y	0.598
S12	0.597
Sensor8	0.586
Sensor9	0.572
Sensor5	0.561
Back	0.553
S15	0.553
S13	0.553
Row1	0.541

Sensor1	0.541
Left	0.535
Sensor4	0.526
S7	0.525
S4	0.519
Right	0.517
S5	0.514
Row2	0.513

Anexo III

Acondicionamento do Sinal

O anexo representa a análise e o processamento do sinal PPG verde. O script em Python tem técnicas essenciais, como normalização, FFT, e filtragem passa-banda Butterworth (0.5 Hz a 10 Hz).

```
"""
Autor: Francisco Gervásio
Objetivo: Processamento e análise de sinais - Este código realiza a leitura de
dados de um sinal da coluna "Green" de um ficheiro CSV, que representa o sinal
PPG. Ele realiza normalização, cálculo da Transformada Rápida de Fourier
(FFT), aplica filtros de banda passa e plota os resultados para análise. O
objetivo é observar a componente de baixa frequência (entre 0.5 Hz e 10 Hz) do
sinal.
"""

import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from scipy.signal import butter, filtfilt

# Carregamento do ficheiro CSV
file_path = 'longlongtest.csv' # Nome do ficheiro CSV
data = pd.read_csv(file_path)

# Extração da coluna 'Green' do ficheiro CSV
green_signal = data['Green'].values

# Normalização do sinal 'Green'
# O sinal é escalonado para o intervalo [0, 1] para facilitar a análise
normalized_green_signal = (green_signal - np.min(green_signal)) /
(np.max(green_signal) - np.min(green_signal))

# Plot do sinal 'Green' normalizado
plt.figure(figsize=(10, 6))
plt.plot(normalized_green_signal, color='green')
plt.title('Sinal Green Normalizado')
plt.xlabel('Tempo')
plt.ylabel('Amplitude Normalizada')
plt.grid(True)
plt.show()

# Cálculo da Transformada Rápida de Fourier (FFT) do sinal normalizado
sampling_rate = 100 # Taxa de amostragem (em Hz), ajustar conforme necessário
```

```

fft_values = np.fft.fft(normalized_green_signal)
fft_freq = np.fft.fftfreq(len(normalized_green_signal), d=1/sampling_rate)

# Filtragem das frequências para o intervalo de interesse (0 Hz a 10 Hz)
mask = (fft_freq >= 0.05) & (fft_freq <= 4)
filtered_fft_values = fft_values[mask]
filtered_fft_freq = fft_freq[mask]

# Plot do espectro de magnitude da FFT filtrada
plt.figure(figsize=(10, 6))
plt.plot(filtered_fft_freq, np.abs(filtered_fft_values))
plt.title('FFT do Sinal Green (0 Hz a 10 Hz)')
plt.xlabel('Frequência (Hz)')
plt.ylabel('|Y(f)|')
plt.grid(True)
plt.show()

# Configuração do filtro passa-banda Butterworth (0.5 Hz a 10 Hz)
lowcut = 0.5 # Frequência de corte inferior (em Hz)
highcut = 10.0 # Frequência de corte superior (em Hz)
nyquist = 0.5 * sampling_rate # Frequência de Nyquist
low = lowcut / nyquist
high = highcut / nyquist

# Design do filtro Butterworth de ordem 2
b, a = butter(2, [low, high], btype='band')

# Aplicação do filtro passa-banda ao sinal normalizado
filtered_signal = filtfilt(b, a, normalized_green_signal)

# Plot do sinal 'Green' após a filtragem
plt.figure(figsize=(10, 6))
plt.plot(filtered_signal, color='green')
plt.title('Sinal Green Filtrado (0.5 Hz a 10 Hz)')
plt.xlabel('Tempo')
plt.ylabel('Amplitude')
plt.grid(True)
plt.show()

# Cálculo da FFT do sinal filtrado
fft_values_filtered = np.fft.fft(filtered_signal)
fft_freq_filtered = np.fft.fftfreq(len(filtered_signal), d=1/sampling_rate)

# Filtragem das frequências do espectro do sinal filtrado (0 Hz a 10 Hz)
mask_filtered = (fft_freq_filtered >= 0.05) & (fft_freq_filtered <= 4)
filtered_fft_values = fft_values_filtered[mask_filtered]
filtered_fft_freq = fft_freq_filtered[mask_filtered]

# Plot do espectro FFT do sinal filtrado

```

```
plt.figure(figsize=(10, 6))
plt.plot(filtered_fft_freq, np.abs(filtered_fft_values))
plt.title('FFT do Sinal Green Filtrado (0.5 Hz a 10 Hz)')
plt.xlabel('Frequência (Hz)')
plt.ylabel('|Y(f)|')
plt.grid(True)
plt.show()
```