



# **Incorporação de Biossensores no Soldado do Futuro**

**Alferes Aluno José Miguel Martinho Silva**

Dissertação para obtenção do Grau de Mestre em

## **Engenharia Eletrotécnica Militar, na especialidade de Transmissões**

Orientadores: Professor Doutor João Paulo Neto Torres  
Professora Doutora Maria João Marques Martins

### **Júri**

Presidente: Major (Doutor) de Transmissões Luís Xavier Mendonça Dias  
Orientador: Professor Doutor João Paulo Neto Torres  
Vogal: Coronel Henrique Martins dos Santos Cunha

**Novembro 2022**



# ΕΠΪΓΡΑΦΕ

*Any sufficiently advanced  
technology is indistinguishable  
from magic.*

---

*Arthur C. Clarke*



# Agradecimentos

A presente dissertação constitui o culminar de seis anos de trabalho e aprendizagem no percurso do mestrado em engenharia eletrotécnica militar, na especialidade de Transmissões da Academia Militar. Desse modo, um conjunto de desafios e obstáculos foram ultrapassados com o apoio de todos os que depositaram a sua fé em mim. Posto isto, apresento o meu profundo reconhecimento a todos os que me acompanharam neste percurso.

Antes de mais, gostaria de agradecer aos meus orientadores, Professor Doutor João Paulo Neto Torres e Professora Doutora Maria João Marques Martins, cujos conhecimentos e experiência foram inestimáveis para a concretização desta dissertação. A sua ajuda, motivação, orientação e empenho verificaram-se cruciais para o desenvolvimento deste trabalho. Foi um privilégio e uma honra ter trabalhado com esta equipa.

Gostaria também de agradecer aos meus pais pela sua amizade, motivação e todo o apoio incondicional ao longo do meu percurso académico. Bem como, à minha namorada pela paciência, motivação, companheirismo, amizade e tempo gasto a ajudar-me.

Estou profundamente grato por ter tantas pessoas na minha vida que me desejam bem e que estiveram sempre prontas a ajudar-me. A todos os meus amigos e camaradas, gostaria de agradecer por estarem presentes quando mais precisava. Estou deveras satisfeito por todos os momentos que a vida académica e militar me tem proporcionado e pela segunda família que a vida castrense me deu.

A todos aqueles que não foram aqui mencionados, mas que tiveram um impacto na minha vida, positivo ou negativo, agradeço-vos por me terem transformado na pessoa que hoje sou.

A todos vós, o meu sincero obrigado!



# Resumo

Atualmente, e cada vez mais, a utilização de biossensores está presente no nosso cotidiano, sendo que a sua aplicação surge em várias áreas da nossa sociedade. Como tal, e dada a sua importância, a evolução dos mesmos é uma grande prioridade da comunidade científica, de forma a estabelecer diversas formas de tirar proveito destes e torná-los cada vez mais eficientes.

Esta dissertação insere-se no estudo de biossensores com recurso a eléctodos pré-gelificados.

Inicialmente, desenvolveram-se testes e experiências com os componentes com o objetivo de comparar, testar e identificar possíveis dificuldades com o microcontrolador da BITalino e os seus sensores, bem como, a compatibilidade com o Arduino Uno e as vantagens e desvantagens da utilização deste.

Este trabalho focou-se na análise da capacidade de extração de informação relativa à qualidade dos treinos, estado emocional dos militares, carga e consciência cognitiva, assim como a condição física do Soldado do Futuro, através dos seus sinais biológicos, extraídos e processados pelos biossensores e microcontrolador da BITalino, de forma automática. Esta análise materializou-se experimentalmente através da classificação de dois estados emocionais, calmo e *stress*, para os quais se atingiu até 98,18% de exatidão.

## Palavras Chave

Biossensores; Microcontrolador; Informação; Automática.



# Abstract

Currently and increasingly, the use of biosensors is present in our daily lives, and its application appears in various areas of our society. As such, and given its importance, its their evolution is a major priority of the scientific community, in order to establish various ways to take advantage of them and make them more efficient.

This dissertation is part of the study of biosensors using pre-gelled electrodes.

Initially, tests and experiments were developed with the components in order to compare, test and identify possible difficulties with the BITalino microcontroller and its sensors, as well as, the compatibility with the Arduino Uno and the advantages and disadvantages of its use.

This work focused on the analysis of the ability to extract information on the quality of training, emotional state of the military, load and cognitive awareness, as well as the physical condition of the Soldier of the Future, through their biological signals, extracted and processed by BITalino's biosensors and microcontroller, automatically. This analysis materialized experimentally through the classification of two emotional states, calm and stress, for which up to 98.18% accuracy was achieved.

## KeyWords

Biosensors; Microcontroller; Information; Automatic.



# Índice Geral

<b>1</b>	<b>Introdução</b>	<b>1</b>
1.1	Enquadramento . . . . .	1
1.2	Motivação . . . . .	2
1.3	Objetivos e tarefas . . . . .	2
1.4	Descrição sumária dos capítulos . . . . .	3
<b>2</b>	<b>Estado da arte</b>	<b>5</b>
2.1	Microcontroladores . . . . .	5
2.2	Transmissão e receção de dados . . . . .	6
2.3	Sensores . . . . .	8
2.3.1	Biossensores . . . . .	9
2.3.2	Eletromiografia . . . . .	12
2.3.3	Eletrocardiograma . . . . .	12
2.3.4	Atividade eletrodérmica . . . . .	13
2.3.5	Eletroencefalografia . . . . .	14
2.3.6	Acelerómetro . . . . .	15
2.4	Atuadores . . . . .	16
2.5	Aprendizagem automática . . . . .	16
2.5.1	Interpretabilidade . . . . .	17
2.5.2	Seleção de características . . . . .	19
<b>3</b>	<b>Descrição física dos dispositivos utilizados</b>	<b>21</b>
3.1	Módulo central . . . . .	21
3.2	Sensores . . . . .	22
3.2.1	Eletromiografia . . . . .	22
3.2.2	Eletrocardiograma . . . . .	24
3.2.3	Atividade eletrodérmica . . . . .	27
3.2.4	Electroencefalografia . . . . .	29
3.2.5	Acelerómetro . . . . .	31

3.2.6	Sensor de luz . . . . .	33
3.2.7	Botão . . . . .	34
3.3	Atuadores . . . . .	34
3.3.1	<i>Light-Emitting Diode</i> . . . . .	34
3.3.2	<i>Buzzer</i> . . . . .	35
3.3.3	<i>Digital-to-Analog Converter</i> . . . . .	35
3.4	Testes e experiências com os componentes . . . . .	36
3.4.1	Projeto 1 . . . . .	37
3.4.2	Projeto 2 . . . . .	37
3.4.3	Conclusões . . . . .	38
<b>4</b>	<b>Testes e desenvolvimento do processo de classificação</b>	<b>39</b>
4.1	Recolha de dados . . . . .	40
4.2	Preparação de dados . . . . .	42
4.2.1	Seleção de características . . . . .	43
4.3	Métodos de aprendizagem e classificação . . . . .	44
4.3.1	Análise discriminante linear . . . . .	45
4.3.2	Regressão logística . . . . .	45
4.3.3	<i>Support vector classification</i> . . . . .	46
4.3.4	Classificador <i>ridge</i> . . . . .	48
4.3.5	Gradiente descendente estocástico . . . . .	49
4.4	Certificação dos algoritmos . . . . .	50
4.5	Conclusões . . . . .	52
<b>5</b>	<b>Conclusão e perspetivas de trabalho futuro</b>	<b>55</b>
	<b>Bibliography</b>	<b>56</b>
<b>A</b>	<b>Código do projeto</b>	<b>65</b>
<b>B</b>	<b>Tabelas de resultados</b>	<b>81</b>

# Índice de Figuras

2.1	Rede móvel associada a uma rede de sensores. . . . .	7
2.2	Esquema de um biossensor. . . . .	10
2.3	Modelo dimensional de emoções. . . . .	11
2.4	Relação entre interpretabilidade e exatidão. . . . .	18
3.1	Módulo central dividido em blocos. . . . .	22
3.2	Sensor para Eletromiografia. . . . .	22
3.3	Posicionamento dos elétrodos do EMG no bíceps braquial (destacado a vermelho) para versão <i>Standard</i> , à esquerda, e para a <i>Assembled</i> , à direita. . . . .	23
3.4	Dados de saída do sensor (sinal adquirido do bíceps braquial através da flexão do cotovelo e antebraço em supinação). . . . .	24
3.5	Sensor para Eletrocardiograma. . . . .	25
3.6	Posicionamento dos elétrodos do ECG conforme a configuração de Einthoven, com o sensor com cabos dos seguintes comprimentos: 1.5cm (+ e -) e 3cm (referência). . . . .	25
3.7	Posicionamento dos elétrodos do ECG conforme a configuração de Einthoven, com o sensor que possui cabos com 30 cm de comprimento (+, - e referência). . . . .	25
3.8	Dados de saída do sensor (sinal adquirido em descanso). . . . .	26
3.9	Sensor para a Atividade Electrodérmica. . . . .	27
3.10	Posicionamento dos elétrodos para a AED. . . . .	28
3.11	Dados de saída do sensor (sinal adquirido em momento de <i>stress</i> de um indivíduo a observar um vídeo de <i>jumpscare</i> ). . . . .	29
3.12	Sensor para Electroencefalografia. . . . .	29
3.13	Posicionamento dos elétrodos para a EEG com a configuração do sistema 10-20. . . . .	30
3.14	Dados de saída do sensor (sinal adquirido em descanso). . . . .	31
3.15	Acelerómetro. . . . .	32
3.16	Dados de saída do sensor em movimento aleatório (A1-Z ligado via UC-E6, A2-X e A3-Y ligados externamente via fios <i>dupont</i> ). . . . .	32

3.17	Sensor de luz. . . . .	33
3.18	Resposta do sensor de luz, num ambiente escuro, com um LED a piscar uma vez. . . . .	34
3.19	Resposta do botão ao ser pressionado. . . . .	34
3.20	LED ligado. . . . .	35
3.21	Buzzer. . . . .	35
3.22	<i>Digital-to-Analog Converter</i> . . . . .	35
3.23	Módulos BITalino, à esquerda, e Arduino Uno, à direita. . . . .	36
3.24	Arquitetura do sistema. . . . .	37
3.25	Arquitetura do sistema. . . . .	37
4.1	Metodologia do processo experimental adotado. . . . .	39
4.2	Alunos em teste, com os sinais biológicos, em tempo real, no monitor. . . . .	40
4.3	Óculos de realidade virtual Pico 2. . . . .	41
4.4	Disposição dos elétrodos. . . . .	41
4.5	Ficheiro .txt produzido pelo <i>software</i> OpenSignals após o término do teste. . . . .	42
4.6	Representação da matriz de trabalho. . . . .	43
4.7	Gráfico comparativo de tempos de leitura, em segundos, de ficheiros com 10 milhões de pontos. . . . .	43
4.8	Diagrama de medidas estatísticas para seleção de características. . . . .	44
4.9	Representação de um exemplo de hiperplano. . . . .	47
4.10	Variação da margem com a mudança de C. . . . .	47
4.11	Função de parábola em duas dimensões. . . . .	49
4.12	Representação da matriz de confusão. . . . .	50
4.13	Esquema de divisão e execução do método <i>k-fold</i> , com $k = 5$ . . . . .	51
A.1	File1.txt e file2.txt após processo descrito. . . . .	65

# Índice de Tabelas

2.1	Gamas de frequência específicas das ondas cerebrais. . . . .	15
3.1	Configurações de Einthoven . . . . .	26
3.2	Configurações para AED. . . . .	27
3.3	Configurações do sistema 10-20. . . . .	30
3.4	Principais recursos das duas plataformas em comparação. . . . .	38
4.1	Resultados finais da análise discriminante linear. . . . .	45
4.2	Resultados finais da regressão logística. . . . .	46
4.3	Resultados finais da SVC. . . . .	48
4.4	Resultados finais do classificador <i>ridge</i> . . . . .	48
4.5	Resultados finais. . . . .	53
B.1	Resultados prévios à seleção de características da análise discriminante linear. . . . .	81
B.2	Resultados prévios à seleção de características da regressão logística. . . . .	81
B.3	Resultados prévios à seleção de características do SVC. . . . .	81
B.4	Resultados prévios à seleção de características do classificador <i>ridge</i> . . . . .	81



# Listagens

A.1	Código de limpeza. . . . .	66
A.2	Produção dos gráficos para os sensores sem filtro. . . . .	66
A.3	Produção dos gráficos para os sensores <i>raw</i> e filtrados (ECG). . . . .	66
A.4	Código para Arduino Uno que permite um LED piscar com o ritmo cardíaco, lido pelo sensor. . . . .	67
A.5	Código para Arduino Uno que permite um buzzer ligar e desligar em resposta a contrações musculares. . . . .	67
A.6	Código de contagem de linhas. . . . .	68
A.7	Código de contagem de tempo. . . . .	69
A.8	Código que cria a matriz de trabalho. . . . .	69
A.9	Código de seleção das 100000 melhores características. . . . .	70
A.10	Código de otimização dos parâmetros da regressão logística. . . . .	70
A.11	Código de otimização dos parâmetros da SVC. . . . .	73
A.12	Código de otimização dos parâmetros do classificador <i>ridge</i> . . . . .	77



# Glossário

OCCIPITOFRONTAL	Músculo constituído por uma porção anterior (frontal), que se insere na pele das sobrancelhas; numa porção posterior (occipital), que se insere na linha suprema nucal; unidas pela aponevrose epicraniana [1]. Tem um papel central na expressão das emoções, nomeadamente da surpresa, porque eleva o supercílio que causa o aparecimento de pregas na pele características dessa emoção.
CORRUGADOR DO SUPERCÍLIO	Músculo de pequenas dimensões com forma piramidal que se insere na parte mesial do arco superciliar e na pele da sobrancelha. Tem como papel puxar as sobrancelhas para a linha média e causa a formação de pregas entre as sobrancelhas [1].



# Acrónimos

<b>ACC</b>	Acelerómetro
<b>ADN</b>	Ácido Desoxirribonucleico
<b>ANOVA</b>	<i>Analysis of Variance</i>
<b>AED</b>	Atividade Eletrodérmica
<b>BD</b>	Braço Direito
<b>BE</b>	Braço Esquerdo
<b>BLE</b>	<i>Bluetooth Low Energy</i>
<b>BUZ</b>	<i>Buzzer</i>
<b>DIY</b>	<i>Do It Yourself</i>
<b>ECG</b>	Eletrocardiograma
<b>EEG</b>	Eletroencefalografia
<b>EMG</b>	Eletromiografia
<b>FNIRS</b>	<i>Functional Near-Infrared Spectroscopy</i>
<b>FPGA</b>	<i>Field-programmable Gate Array</i>
<b>GOx</b>	Glicose Oxidase
<b>IA</b>	Inteligência Artificial
<b>IoT</b>	<i>Internet of Things</i>
<b>LED</b>	<i>Light-Emitting Diode</i>
<b>MCU</b>	<i>Microcontroller Unit</i>
<b>MEMS</b>	<i>Microelectromechanical Systems</i>
<b>PE</b>	Perna Esquerda
<b>PPG</b>	<i>Photoplethysmography</i>
<b>PWM</b>	<i>Pulse-width Modulation</i>

<b>RGP</b>	Resposta Galvânica da Pele
<b>STASS</b>	<i>Standard Architecture for Soldier Systems</i>
<b>SVC</b>	<i>Support Vector Classification</i>
<b>UI</b>	<i>User Interface</i>

# Capítulo 1

## Introdução

Neste capítulo é realizada a introdução da presente dissertação, focada, primeiramente, no enquadramento do tema, de seguida, na motivação para realizar este trabalho e, posteriormente, nas tarefas e objetivos para a sua execução. Por fim, é realizada uma descrição sumária dos conteúdos abordados em cada capítulo.

### 1.1 Enquadramento

A avaliação da condição de um militar pode ser uma tarefa desafiadora na medida em que existem algumas situações complexas nas quais não há a possibilidade de ter um profissional de saúde presente para avaliar a situação médica dos militares e, por vezes, quando há essa possibilidade, pode não haver meios de obtenção da informação fisiológica para ser interpretada por estes em tempo útil. Sendo que, nas situações mais críticas, o tempo para obter o diagnóstico é relativamente limitado.

Através das novas tecnologias é possível desenvolver modelos que, de forma automática, permitam que seja feita uma deteção de anomalias fisiológicas e emocionais. Estes modelos tornam possível alertar os profissionais de saúde da necessidade de realizar testes de despiste em resposta à deteção de alguma anomalia que ocorra, com o objetivo de reduzir os efeitos de problemas detetados de forma tardia. Posto isto, o desenvolvimento de soluções com recurso a modelos de aprendizagem automática, no sentido de facilitar o trabalho dos profissionais de saúde, tem aumentado gradualmente.

Os meios utilizados atualmente para prever anomalias fisiológicas consistem no acompanhamento em situações de elevado esforço físico por equipas médicas e análises ao sangue e à urina. Estes métodos são insuficientes e têm vindo a mostrar-se pouco eficazes na prevenção do agravamento de problemas de saúde, principalmente em ambiente de instrução.

Quanto ao desenvolvimento e inserção deste tipo de tecnologias para fins militares, os estados-membros da União Europeia devem reger-se pela *Standard Architecture for Soldier Systems* (STASS)

[2], por forma a existir estandardização, interoperabilidade, forma de carregamento e portabilidade entre todas as nações pertencentes.

## 1.2 Motivação

Os militares portugueses são destacados, constantemente, para ambientes operacionais onde o seu sucesso depende da sua capacidade de atuar rápida e eficazmente, de modo individual e em equipa. Por esse motivo, os treinos, aos quais são previamente sujeitos, devem ir além das suas capacidades individuais e incluir a interação entre os membros da equipa, tal como se processam em ambiente operacional. Atualmente, o treino e avaliação do desempenho aquando destas interações é realizada, exclusivamente, através da observação, que acarreta inúmeras adversidades.

Através dos sensores do BITalino, é possível retirar os dados biométricos dos indivíduos em treino e obter indicadores que permitem avaliar, otimamente, a qualidade dos treinos, o estado emocional dos militares, a sua carga e consciência cognitiva, assim como a sua condição física. Recorrendo a um *User Interface* (UI), o instrutor, ou responsável pela monitorização do treino, poderá retirar notas e gravar o desempenho dos instruendos, enquanto o treino ocorre [3]. Adicionalmente, este sistema também pode ser utilizado em combate dando informação, em tempo real, aos comandantes da operação e, por sua vez, ao escalão superior. É possível também beneficiar destes sistemas para o aumento da produtividade do dia a dia do militar, através do estudo do seu estado emocional.

A análise visual do indivíduo por parte do instrutor é deveras insuficiente, tornando o estudo destes dados extremamente importante. No treino, em particular, há que ter sempre presente a parte emocional e o estado anímico dos militares, que lhes permite ir mais além do que apenas o seu estado físico lhe permite.

## 1.3 Objetivos e tarefas

No presente trabalho é abordado o tema dos biossensores e as características pelas quais a sua implementação no meio militar é vantajosa, recorrendo a componentes da PLUX Wireless Biosignals S.A.

O principal objetivo deste trabalho foi realizar um estudo sobre as informações que os sensores do *BITalino (r)evolution Plugged Kit* fornecem e efetuar uma extração de sinais fisiológicos permitindo, de forma automática, diferenciar dois estados emocionais distintos, calmo e *stress*, com o intuito de tirar ilações das maneiras de tornar estes sistemas úteis no meio militar. Por forma a atingir estes objetivos, foram conduzidos testes experimentais a par de um estudo teórico aprofundado.

De forma a atingir estes objetivos foram definidas várias tarefas, enumeradas seguidamente.

1. Processo de obtenção de informação;
2. Levantamento do estado da arte e compreensão das temáticas em estudo;
3. Testes e experiências com os componentes;
4. Testes e desenvolvimento do processo de classificação;
5. Ajustes e revisão;
6. Conclusão.

## **1.4 Descrição sumária dos capítulos**

Esta dissertação é constituída por 6 capítulos, sumariamente infra descritos.

O capítulo 1, a introdução, enquadra o tema e o seu contexto, a motivação para o desenvolvimento do trabalho nesta área e os objetivos associados.

No estado da arte, correspondente ao capítulo 2, são abordados os conceitos teóricos principais, instrumento base para o progresso deste trabalho, tais como, os sistemas de controlo de sensores (microcontroladores), as redes de comunicação associadas e as diversas utilizações para cada sensor.

O capítulo 3, a descrição física dos dispositivos utilizados, apresenta as ferramentas utilizadas que permitirão atingir o objetivo deste projeto, com as respetivas respostas dos diversos sensores, retiradas na totalidade de testes realizados pelo autor da presente dissertação em si próprio. Bem como, os testes e experiências com os componentes foram feitos com o objetivo de comparar o módulo central Arduino Uno com o BITalino. Para além disso, foram bastante úteis numa adaptação à utilização dos sensores da BITalino, permitindo que no capítulo seguinte a execução da parte da coleção de dados fosse mais fluída.

Por forma a explicitar os testes e desenvolvimento do processo de classificação utilizado são abordados, no capítulo 4, todos os passos desde o processo de recolha de dados até à validação dos modelos de classificação que se mostraram mais adequados ao trabalho desenvolvido.

Por fim, no capítulo 5, a conclusão, é sumariado todo o trabalho desenvolvido neste semestre, as dificuldades sentidas na realização do mesmo e as perspetivas de trabalhos futuros.



## Capítulo 2

# Estado da arte

Neste capítulo são abordados teoricamente os temas em que é baseado o presente trabalho, focando-se no estado da arte das redes de biossensores com utilidade para o Soldado do Futuro e na criação e desenvolvimento da tecnologia, até à atualidade, que permite fazer uma monitorização em tempo real de um indivíduo, bem como as suas diversas aplicações.

### 2.1 Microcontroladores

Um sistema pode ser definido como uma combinação de partes para executar uma tarefa específica [4]. O BITalino é um sistema composto por diversos módulos como, por exemplo, o de controlo, baseado no microcontrolador ATmega328P; o de gestão de energia e o de comunicação, que utiliza *bluetooth* v2.0 da classe 2 para transferir os dados para outro ponto (computador ou telemóvel). A tarefa específica do BITalino é captar e processar sinais biológicos [5]. Pode ser classificado mais especificamente como sistema embebido, isto é, um sistema de controlo de dispositivos técnicos ou de processos associados ao controlo de dispositivos, que recorre, principalmente, a micro-processadores, microcontroladores, *Field-programmable Gate Array (FPGA)*, entre outros, e que se encontram conectados com o objeto a controlar [6]. Este tipo de sistemas podem ser classificados como sistemas de tempo real.

Num sistema de tempo real, a qualidade da resposta depende do intervalo de tempo em que são produzidos os resultados e não dos produtos finais *per si* [7]. Estes sistemas são caracterizados por um grande espetro de complexidade, desde um simples microcontrolador de um sistema de deteção de incêndios até ao amplamente sofisticado, complexo e distribuído sistema de controlo de tráfego aéreo. Outros sistemas de tempo real são os de comando e controlo. Em alguns destes sistemas de tempo real tem sido integrada Inteligência Artificial (IA), conferindo-lhes novas capacidades, aptidão de adaptação e melhoria automática do sistema, com o prejuízo de criação de novos requisitos e complexidades [8].

Uma das formas mais utilizada para desenvolver estas plataformas embebidas é com recurso a microcontroladores, descritos como um dispositivo eletrónico criado com o intuito de controlar de forma automática dispositivos técnicos, através da aplicação de um dado algoritmo. Os controladores programáveis são compostos por diversos componentes, que variam conforme o seu propósito e custo, sendo a maioria dotada de um processador e memória, bem como componentes modulares que implementam funções de entrada e de saída de sinais analógicos e digitais, transmissão e receção de informação e controlo de redes. Desde o final dos anos 70, os microcontroladores têm-se espalhado globalmente [6] e são componentes essenciais nas redes de biossensores, sendo as características que tornam este tema francamente relevante para o projeto a capacidade de captar os dados, executar um pré-processamento e transmitir a informação, através dos seus diversos módulos.

## 2.2 Transmissão e receção de dados

Os avanços tecnológicos estão presentes em diversas áreas, especialmente na saúde e bem estar. Desde o início desta evolução, têm existido amplas mudanças, sendo que a *Internet of Things* (IoT) tem-se tornado num conceito cada vez mais presente no mundo do conforto físico e psicológico.

Kevin Ashton criou o termo IoT em 1999. Através da IoT, os objetos estão cada vez mais ligados, este conceito pode ser descrito como a combinação de esforços humanos e tecnológicos para que haja mais interação entre todos os acontecimentos e os aparelhos em nosso redor, através da Internet [9].


Como tecnologia de recolha, análise e transmissão de dados, a IoT continua a melhorar, sendo que várias aplicações empregues nos sistemas de saúde fazem uso deste recurso e estão cada vez mais presentes no nosso quotidiano. Na IoT, os dispositivos recolhem e partilham informação diretamente entre si e com a *cloud*, tornando mais rápida e precisa a recolha de informação e análise de dados. Com isto, surgem incontáveis possibilidades de elevado interesse nas diversas indústrias, dando azo a criações como, por exemplo, automóveis que sentem o desgaste e agendam a sua manutenção ou comboios que calculam e relatam, dinamicamente, as horas previstas de chegada aos passageiros em espera, entre outros. As comunicações são feitas por meio de dispositivos, de longo e curto alcance, com ou sem fios, em diferentes tipos de ambientes de rede, tais como *intranet*, *extranet* e *internet*.

A IoT pode ser utilizada em diversos cuidados clínicos, por exemplo, em pacientes hospitalizados cujo estado fisiológico requer especial atenção sendo que, através destas tecnologias, podem ser monitorizados continuamente com recurso a métodos não invasivos. Esta situação exige que os sensores recolham informação fisiológica e, posteriormente, a enviem aos prestadores de cuidados para análise e revisão. A utilização desta técnica melhora a qualidade dos cuidados de saúde, eliminando a necessidade de envolver uma recolha e análise de dados ativa. Esta tecnologia fornece os meios para aceder e controlar duas categorias de dispositivos, os que têm inteligência e os que são ativados externamente

através de cabos e/ou *wireless*, estas comunicações devem sempre ser feitas com as medidas de segurança adequadas, conseguir uma conectividade generalizada e uma grande integração, fornecendo serviços tais como monitorização, localização, controlo, relatórios, apoio à decisão, entre outros.

A IoT caracteriza-se por ser um sistema global que, com a passagem dos anos, tem compreendido progressivamente mais dispositivos e aplicações, incluindo sensores, atuadores, microcontroladores e dispositivos de comunicação móvel. A maioria destes são utilizados na monitorização da saúde, diagnósticos e tratamentos personalizados, atempados e convenientes, com a vantagem de redução de custos associados.

Uma rede móvel associada a uma rede de sensores, tal como na figura 2.1, integra tecnologias para transmitir e receber dados, para os quais são, tipicamente, utilizados um de 3 tipos de protocolos de comunicação: *bluetooth*, *zigbee* ou *wi-fi* [10]. Sendo o *bluetooth* o principal foco neste relatório, devido ao módulo central em utilização estar equipado com um bloco de transmissão desta tipologia.



**Figura 2.1:** Rede móvel associada a uma rede de sensores.

O *bluetooth* é uma tecnologia de transferência de dados sem fios, IEEE 802.15.1, que opera na banda de frequência de 2.4 GHz a 2.48 GHz, dividida em 79 canais de 1 MHz de largura, sendo amplamente utilizado para a comunicação contínua de curto alcance, entre dispositivos móveis.

Comparado com outras tecnologias, é das que consome menos energia para comunicar com outros terminais e, uma vez que emprega uma tecnologia de salto de frequência, tem uma resistência relativamente maior à interferência na transmissão de dados.

O BITalino tem na sua composição um módulo *Bluetooth Low Energy* (BLE), desenvolvido como uma atualização do *bluetooth* clássico. Como sugere o nome, BLE é uma tecnologia de comunicação que economiza energia e foi concebida para dispositivos de baixo consumo, tais como redes de sensores. Ao contrário do *bluetooth* clássico, a banda de frequência está dividida em 40 canais de 2 MHz de largura e, em dispositivos BLE, as transferências de dados são feitas através de transmissões curtas, separadas por períodos de espera, o que contribui bastante para a poupança de energia, em comparação com o modo sempre ativo dos dispositivos com *bluetooth* clássico [11].

## 2.3 Sensores

Os sensores estão presentes em todo o lado, o planeta está repleto destes e das suas aplicações. Alteram a nossa vida, facilitando-a e tornando-a mais confortável, através de, por exemplo, aplicações para ligar luzes, ventoinhas e televisões, ajustes automáticos de temperatura, alarmes de incêndio, deteção de objetos nas manobras de um carro, entre tantos outros, com os mais variados níveis de complexidade [12].

Um sensor é um dispositivo que recebe um sinal ou estímulo e tem uma resposta sob a forma de sinal elétrico. Estes dispositivos são úteis num grande espectro de áreas científicas e, por este motivo, existem diversos tipos que respondem a diferentes estímulos como, por exemplo, estímulos físicos, químicos ou biológicos. O sinal de entrada, mecanismos de conversão, custo, precisão e intervalo de sensibilidade, bem como a resposta, podem variar conforme a sua aplicação [13]. Posto isto, destacam-se dois tipos principais de sensores, os passivos e os ativos:

- Um sensor passivo não necessita de uma fonte de energia para produzir o sinal elétrico em resposta ao estímulo, pois este é suficiente para produzi-lo. Isto é, o sensor, através da energia fornecida pelo sinal de entrada, gera os dados de saída, como por exemplo um termopar, um foto-díodo ou um sensor piezoelétrico.
- Um sensor ativo, por outro lado, requer uma fonte de energia externa para o seu funcionamento, denominada como sinal de excitação. Esse sinal é alterado pelo sensor, de forma a produzir o sinal de resposta. Estes sensores são, por vezes, denominados de sensores paramétricos porque as suas propriedades alteram-se em resposta a um evento externo e estas, por sua vez, podem ser convertidas num sinal elétrico. As propriedades do sensor alteram o sinal de excitação e este fornece a informação desejada. Por exemplo, um termistor é um semiconductor sensível à temperatura. Este sensor não gera nenhum sinal elétrico mas, quando uma corrente elétrica, isto é, o sinal de excitação, passa por este, a sua resistência pode ser medida através da variação da corrente e/ou tensão ao longo do termistor. Estas variações, apresentadas em *Ohm*, estão diretamente relacionadas com a temperatura, através da sua função de transferência.

Os sensores podem também ser classificados de acordo com sinal que atua como estímulo, por exemplo térmico, magnético, ótico, mecânico, biológico, químico, entre outros, sendo o foco deste trabalho os biossensores [12].

### 2.3.1 Biossensores


Atualmente, o estudo e aplicação de biossensores tem, cada vez mais, a atenção dos engenheiros. Para além das diversas aplicações clássicas no ramo da medicina, criou-se um novo paradigma que utiliza uma analogia de computação física [14] e pode ser descrita como computação fisiológica. As novas aplicações dos biossensores tornaram-se, por este motivo, um tema de ampla relevância na comunidade dos engenheiros e, por consequência, há grandes evidências de que o estudo dos sinais biológicos e dos seus sensores é um ramo de interesse em crescimento.

O primeiro biossensor foi desenvolvido, em 1962, por Clark e Lyons que imobilizava Glicose Oxidase (GOx), com a finalidade de quantificar a concentração de glicose de uma amostra [15, 16]. Descreveram como fazer melhores sensores eletromecânicos (PH, polarográfico, potenciométrico ou condutométrico), através de um único eléctrodo de oxigénio, acoplado a um contra-eléctrodo.

De acordo com Thevenot, Tóth, Durst e Wilson [17], um biossensor é um sistema integrado com a capacidade de fornecer informação específica quantitativa ou semi-quantitativa, com recurso a um elemento de deteção biológica (recetor bioquímico), que esteja em contacto direto com um transdutor. Um biossensor deve ser distinguido, notoriamente, de um sistema de análise biológica que requer ações adicionais de processamento, como por exemplo a aplicação de um reagente. Além disso, um biossensor deve distinguir-se de uma biosonda, caracterizada pela descartabilidade após uma utilização ou pela falta de capacidade de monitorização contínua.

Todos os biossensores são compostos por dois elementos distintos, presentes na figura 2.2, uma entidade de reconhecimento biológico, na proximidade de um transdutor.

O bioreceptor é caracterizado por ser sensível ao sinal biológico (ex: enzima, Ácido Desoxirribonucleico (ADN), anticorpo), ou seja, deteta o elemento procurado, denominado de analito. O transdutor converte a resposta, resultante da interação do analito com o bioreceptor, num sinal elétrico, sendo a sua intensidade direta ou inversamente proporcional à concentração do analito. Os transdutores eletromecânicos são utilizados, frequentemente, no desenvolvimento de biossensores. Estes sistemas têm bastantes benefícios, tais como: baixo custo, *design* simples e pequenas dimensões. Os biossensores podem também ser baseados em gravimetria, colorimetria ou deteção ótica [18].



**Figura 2.2:** Esquema de um biossensor [18].

Os biossensores têm inúmeras vantagens, sobrepondo-se às análises convencionais, por permitirem que o estudo dos sinais biológicos de um indivíduo seja menos dependente de instalações laboratoriais de análise. Por este motivo, o custo dos processos com recurso a biossensores, comparativamente aos convencionais, torna-os ainda mais apreciados [19].

Apesar da vasta diversidade de biossensores, estes podem ser agrupados em dois grupos distintos, invasivos e não invasivos.

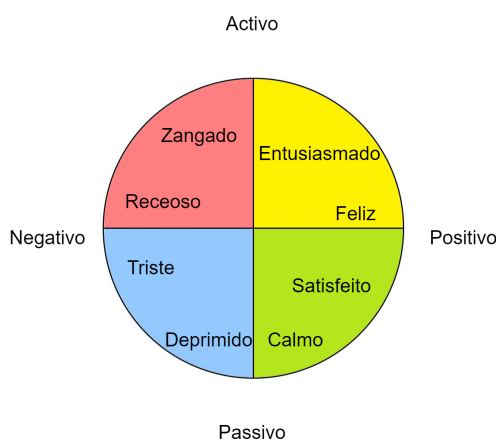
Os sensores invasivos apresentam uma grande variedade de *designs*, por forma a enquadrarem-se em várias necessidades. Contudo, é possível que os sensores invasivos provoquem uma resposta que poderá resultar no seu revestimento com proteínas e outros resíduos biológicos, afetando assim a performance do sensor, mas, mais importante que isto, pode sujeitar o indivíduo a um trauma clínico.

A colocação de sensores à superfície do corpo evita as dificuldades associadas aos métodos invasivos. Porém, o espectro de diferentes tipos de testagem fica limitado aos estímulos que são possíveis captar à superfície da pele [20].

A resposta fisiológica ao *stress* fornece ao organismo algumas capacidades, tais como maior vigilância, energia, regulação fisiológica e ativação imunológica, que ajudam o indivíduo a sobreviver em casos críticos. Até um certo nível, o *stress* pode ser útil em situações exigentes, por exemplo, para realizar um trabalho atempadamente ou para estudar para um exame. No entanto, quando excede determinados níveis ou persiste durante demasiado tempo, pode não ser benéfico, tornando-se prejudicial para a saúde, regulação emocional, produtividade e qualidade de vida. Com base na teorias de Lazarus, o que causa a reação ao *stress* não é apenas o *stress* ambiental, mas também a emoção associada e o seu significado avaliado pela pessoa [21].

A medição do *stress* psicológico é, convencionalmente, realizada recorrendo a três métodos principais. A maioria dos diagnósticos psiquiátricos ou psicológicos de *stress* baseia-se em entrevistas, questionários e testes de auto-avaliação. Embora estes métodos tenham sido validados, para obter resultados mais concretos e fiáveis, há necessidade de medidas objetivas. Na prática, esta última consiste frequentemente em métodos invasivos, ou seja, análise de sangue ou amostras de cortisol, sendo que estas monitorizações não podem ser realizadas a longo prazo e com frequência [22]. Por este motivo, a análise de dados fisiológicos para o reconhecimento do estado de *stress* é feita, cada vez mais frequentemente, pela combinação destes dados captados de uma forma não invasiva, tais como o ritmo cardíaco, atividade respiratória, Atividade Eletrodérmica (AED), temperatura da pele, *Photoplethysmography* (PPG) ou Eletromiografia (EMG) [23].

Os biossensores têm um papel com importância temporalmente crescente na área do reconhecimento de emoções no geral, sendo estas um aspeto importante na comunicação e interação entre pessoas. Apesar das emoções serem intuitivamente conhecidas, é difícil definir precisamente “emoção”. O filósofo grego Aristóteles descrevia as emoções como um estímulo de avaliação de experiências com base no potencial de gerar dor ou prazer. Ao longo dos anos, têm vindo a surgir outras definições, contudo, nos dias de hoje, ainda não há um consenso relativamente a estas [24]. De forma a compreender estas emoções, através de sinais captados por sensores, é necessário fazer uso de estratégias de classificação [25], tal como o modelo dimensional na figura 2.3.



**Figura 2.3:** Modelo Dimensional de Emoções [24].

Apesar da dificuldade de defini-la com precisão, a emoção está sempre presente e é um fator importante na vida humana. O estado emocional das pessoas influencia fortemente a sua forma de comunicar e, também, a sua atuação e produtividade. Desta forma, este é um tema de elevada relevância no meio militar para o aumento da produtividade no dia-a-dia, bem como nas missões em território nacional e no estrangeiro.

### 2.3.2 Eletromiografia

A EMG permite o estudo da atividade muscular de um indivíduo através dos sinais elétricos emitidos pela musculatura esquelética, fornecendo informação sobre a quantidade e qualidade da ativação elétrica gerada pelo músculo [26]. É um dos melhores métodos objetivos e informativos para o estudo da condição funcional do sistema nervoso periférico, permitindo detectar patologias neste. Através da EMG é possível estabelecer a natureza da doença e efetuar um diagnóstico, que permite também controlar objetivamente a eficácia de tratamentos, por forma a prever o tempo e as fases de recuperação do paciente.

No âmbito das lesões musculares, uma quantidade significativa de tratamentos inadequados é realizada devido à gravidade da lesão, erros de diagnóstico e intervenção qualificada tardia. A escolha dos métodos de tratamento e reabilitação para este problema é realizada sem uma avaliação objetiva do estado estrutural-funcional dos músculos. Para resolver este problema, uma solução proposta pela comunidade de investigadores é a utilização de dispositivos de monitorização permanente dos sinais vitais de uma pessoa. Os dispositivos de EMG são os indicados para fazer esta monitorização, porém, estes são no geral construídos com transmissão de dados por fio. Por esse motivo, uma prioridade da investigação sobre dispositivos de EMG é a transmissão de dados via *wireless* [27].

Quanto ao cansaço muscular, se este aumentar abruptamente ou for continuado por um longo período de tempo, serão causadas lesões musculares, sendo que, se tal ocorrer, a função motora irá diminuir [28]. De forma a evitá-lo, o período de descanso deve ser feito num tempo mínimo estabelecido de acordo com o cansaço muscular, que nos dias de hoje pode ser detetado por meio de uma EMG [29].

Para além disso, a comunidade científica tem feito esforços no sentido de ligar as respostas corporais às emoções, um exemplo disso é o estudo realizado por Yang Guangying e Yang Shanxiao [30] que, com apoio do classificador automático, identifica alegria, raiva, tristeza e prazer, tendo assim EMG um papel importante nesta área.

### 2.3.3 Eletrocardiograma

As contrações cardíacas ocorrem devido a um conjunto de impulsos elétricos que se sucedem no coração. O Eletrocardiograma (ECG) é obtido através da monitorização e gravação dessa atividade, que fornece informação sobre a saúde, estrutura cardíaca e respetiva funcionalidade [31].

Com as grandes alterações na sociedade, os cidadãos têm vindo a ser submetidos a um elevado aumento de *stress*, ansiedade, fadiga, entre outros, tornando a população mais suscetível a contrair doenças, sendo as mais comuns associadas ao coração. Dado este problema, as tecnologias têm evoluído no sentido de permitir que cada pessoa possa ter acesso a alguns dos parâmetros que são

indicadores dessas doenças.

O ECG tem grandes custos quando realizado em hospitais, para além disso, obriga-nos a despendere de tempo e é um processo com bastante complexidade. A comunidade científica têm tentado continuamente encontrar uma alternativa para contornar este problema, chegando à conclusão que uma das melhores soluções passa por recorrer à IoT como ferramenta.

Para um número crescente de pessoas, os acessórios estão a tornar-se essenciais no seu quotidiano, alguns deles para a monitorização contínua do ritmo cardíaco.

O ECG é um método preciso para determinar o ritmo cardíaco mas, por norma, não é prático para ser feito no dia-a-dia pois são necessários aparelhos não portáteis. Portanto, a monitorização do ritmo cardíaco feita pelo pulso tornou-se bastante utilizada, sendo baseada em fotopletismografia (do inglês, PPG) nestes dispositivos. Diversos dispositivos comerciais, tais como os relógios da Apple, Garmin ou Samsung, incluem um sensor PPG. No entanto, em comparação com os dados tradicionais do ECG, a estimativa do ritmo cardíaco não é tão precisa, especialmente em movimento, o que acaba sempre por acontecer devido à atividade física do utilizador, reduzindo significativamente a qualidade do sinal PPG [32]. Desta forma, um sensor ECG de pequenas dimensões pode ser uma solução para estes problemas.

### 2.3.4 Atividade eletrodérmica

A AED capta as alterações na condutância da pele resultantes da atividade das glândulas sudoríparas. Healey et al. [33] salientaram a relevância da junção da AED e do ECG como a melhor combinação para a deteção de *stress*, entre outros sinais fisiológicos. Em particular, a AED poderia fornecer uma métrica fiável de *stress* e tem sido utilizada como base fidedigna para comparar o desempenho de outros sinais [34]. Alguns estudos já utilizaram a AED como único sinal de entrada de um classificador supervisionado para discriminar se uma pessoa está em *stress* ou não e para monitorizar a carga cognitiva e tarefas stressantes [35–37].

Esta atividade está associada à reação “lutar ou fugir”, descrita pelo fisiologista Walter Bradford Cannon, em 1927 [38], sendo caracterizada com uma resposta fisiológica automática a um acontecimento stressante ou assustador. Para além disso, Ali Rizwan et al. [39] conduziram um estudo que comprovou que, através de um algoritmo de aprendizagem automática aplicado ao sinal extraído por um sensor de AED, é possível identificar o estado de hidratação, o que é bastante importante no meio militar, visto que a condição física de um indivíduo e a capacidade de dar continuidade prolongada a esforços físicos estão diretamente relacionadas com os seus níveis de hidratação.

A AED salienta-se na medida em que está unicamente sob o controlo do sistema nervoso simpático e, para além disso, é simples de medir com alguns elétrodos nos dedos. Por estas razões, tem uma popularidade crescente como ferramenta do *neuromarketing*. Além do mais, também tem diversas

potenciais aplicações, tanto na investigação como na medicina clínica. Uma barreira à sua utilização é a falta de modelos estatísticos precisos baseados em fisiologia que forneçam uma visão detalhada aos investigadores.

As abordagens existentes à análise da AED tiram partido de impulsos discretos, subidas e descidas notáveis dos dados de saída, chamada Resposta Galvânica da Pele (RGP). Os modelos da AED utilizam métricas, tais como o número e amplitude das flutuações na condutância da pele.

Quando o nervo simpático que enerva as glândulas sudoríparas aumenta os estímulos, devido à atividade simpática, o suor é secretado e difunde-se para cima através da conduta da glândula sudorípara em direção à superfície da pele [40]. Assim, é criado um caminho de resistência reduzida à superfície da pele, que leva ao aumento da condutividade elétrica, a RGP. O aumento é transitório porque quantidades ínfimas de suor evaporam imediatamente após exposição ao ar. A RGP, dada por impulsos, é a forma de correlacionar a AED com a atividade simpática [41].

Apesar dos esforços realizados, existem barreiras metodológicas que impedem a exportação dos estudos baseados unicamente em AED para o nosso dia-a-dia. Primeiramente, os sinais de AED são distorcidos pelo ruído e movimento, cujo espetro de frequências é próximo e sobrepõem-se à banda de frequência da AED. Além de que, no quotidiano, um indivíduo é exposto a múltiplas situações de *stress* que podem ser intervaladas por curtos espaços de tempo, levando a respostas eletrodérmicas sobrepostas. Esta sobreposição é uma das maiores limitações da AED, podendo dar origem a uma conclusão errada através da análise do sinal. Por esse motivo, quando utilizados métodos automáticos de análise através da computação, deve ter-se principalmente em atenção o controlo das características extraídas, mas não só, são também importantes os custos computacionais, o risco de *overfitting* do modelo, a realização de uma classificação imparcial e independente do sujeito. Contudo, apesar de haver vários problemas associados à análise AED extraída no decorrer de um dia de um indivíduo, este método de estudo de *stress* demonstra-se mais preciso quando comparado com os métodos convencionais [42].

### 2.3.5 Eletroencefalografia

A Eletroencefalografia (EEG) permite o estudo da atividade cerebral de um indivíduo através dos sinais elétricos emitidos pelos dois hemisférios do cérebro ao longo do tempo [43]. Este procedimento é considerado excecional para estudar a atividade cerebral devido às suas vantagens, tais como ser um método não invasivo que mede diretamente as atividades neuronais e possuir a capacidade de fazer medições em tempo real, expondo o indivíduo a diferentes situações de forma a obter um bom diagnóstico da sua resposta emocional a estas. Através deste procedimento, é possível relacionar a atividade cerebral direta e particularmente a certas emoções.

Hans Berger, o inventor da EEG, apresentou um método para captar diferentes ondas cerebrais, presentes no cérebro humano. O neuro-sinal, baseado na EEG, é processado em dados com determi-

nadas bandas - *Delta*, *Theta*, *Alpha*, *Beta* e *Gamma*. Estas categorias são determinadas por diferentes potências de ondas cerebrais em gamas de frequência específicas, como se pode verificar na tabela 2.1.

**Tabela 2.1:** Gamas de frequência específicas das ondas cerebrais [44].

Ondas Cerebrais	Frequência [Hz]
<i>Delta</i>	0.1-4
<i>Theta</i>	4-7
<i>Alpha</i>	8-12
<i>Beta</i>	13-30
<i>Gamma</i>	>30

Inúmeras pessoas têm-se dedicado a realizar investigações subordinadas ao estudo das emoções recorrendo à EEG. Um dos resultados com mais relevo é o importante papel da banda de frequência Alpha, sendo que Kostyunina et al. [45] descobriram que diferentes estados emocionais mostram diferentes frequências de pico nesta banda.

A EEG é um dos melhores métodos para monitorização comportamental, emocional, de processos cognitivos, entre outros. A análise destas situações também pode ser realizada através de expressões faciais e da fala. Porém, como a EEG extrai dados fisiológicos diretamente ligados ao sistema nervoso central, a informação é mais fidedigna pois estes sinais fisiológicos não podem ser ocultados, devido à sua natureza proveniente de flutuações internas da informação neuronal. Destaca-se uma das grandes desvantagens da EEG: ser bastante afetada pela movimentação do indivíduo [44].

### 2.3.6 Acelerómetro

Os acelerómetros são dos sistemas micro-eleto-mecânicos mais simples, convertem aceleração linear ou angular numa resposta elétrica através de condensadores que estão associados a cada um dos eixos X, Y e Z [46].

O Acelerómetro (ACC) permite a análise do movimento de um indivíduo e, atualmente, tem desempenhado um papel muito importante no mundo dos desportos e da medicina, principalmente na recuperação de pacientes. Desta forma, pode ser também relevante para uma avaliação de um treino ou exercício militar.

Na atualidade, os fisioterapeutas e médicos avaliam os resultados de reabilitação observando apenas o indivíduo em causa. Cada fisioterapeuta ou médico que avalia o progresso do paciente, fornece o seu próprio diagnóstico, sendo que estes resultados podem ser totalmente diferentes, dando origem a uma tardia avaliação do progresso do paciente. Para além disso, desta forma, não é possível um indivíduo monitorizar os seus progressos sem um profissional das áreas supra-referidas. Utilizando o ACC no processo de reabilitação, podemos melhorar a avaliação dos resultados e aumentar a sua eficiência [47].

No desporto, os treinadores ajudam o atleta dizendo-lhes como melhorar o seu desempenho, mas não têm uma ferramenta para monitorizar constantemente cada movimento do atleta. O ACC pode ser a solução para este problema, ao dar a informação ao formador e a profissionais de saúde relativamente ao estado do atleta. Posto isto, permite que seja feito um treino mais adequado, melhorando as suas capacidades. Desta maneira, podemos dizer que o ACC fornece informações cruciais aos terapeutas, médicos e treinadores na decisão dos métodos de tratamento, reabilitação e formação. Estes sensores, de tamanho reduzido, podem ser acoplados dispersamente pelo corpo, permitindo uma melhor percepção dos movimentos do indivíduo em estudo [48].

## 2.4 Atuadores

Um atuador é uma parte de um dispositivo ou máquina que produz uma resposta quando recebe um sinal de controlo e está principalmente ligado a movimentos físicos, mas também pode ser a reprodução de um som, emissão de luz, entre outros [49]. Estes dispositivos têm diversas funcionalidades e, atualmente, existem inúmeros esforços no desenvolvimento de tecnologias de atuação para utilização em dispositivos tais como: robôs antropomórficos, micro-robôs, robôs micro-cirúrgicos, próteses e órgãos artificiais [50], sendo que também são amplamente utilizados, a par de sensores, na produção de uma resposta ao sinal captado.

Juntamente com os biossensores, os atuadores podem ser úteis na criação de um sinal de aviso ao indivíduo em teste, como por exemplo uma vibração quando o seu ritmo cardíaco está demasiado elevado ou na emissão de uma luz quando os níveis de *stress* se aproximam de níveis considerados críticos.

## 2.5 Aprendizagem automática

A aprendizagem automática, como um ramo da inteligência artificial, tem vindo a desempenhar um papel cada vez mais importante na investigação científica nos últimos anos. Foi descrita por Arthur Samuel, como o campo de estudo que dá aos computadores a capacidade de aprender sem ser explicitamente programados [51].

Os algoritmos de aprendizagem podem ser divididos em vários tipos de modelos de acordo com as características do problema em questão.

A aprendizagem supervisionada consiste num algoritmo que gera uma função para relacionar determinadas características de um conjunto de dados com uma saída desejada. É construído um modelo a partir de conjuntos de dados com o objetivo de fazer previsões em novos dados. Os algoritmos supervisionados podem ser subdivididos em problemas de classificação e regressão. Por um lado, nos

problemas de classificação o objetivo é atribuir um resultado de entre um conjunto de categorias, como por exemplo *stress* ou *calmo*. Por outro lado, a regressão tem como saída final um valor numérico e não uma categoria.

Em contrapartida, na aprendizagem não supervisionada, o modelo a utilizar não tem resultados pre-definidos como referência para aprender. Por consequência, a aprendizagem é focada em encontrar semelhanças nos dados em análise e agrupá-los com base nas mesmas. Os algoritmos não supervisionados podem ser subdivididos em problemas de *clustering* e de associação. Relativamente aos primeiros, estes são utilizados quando se pretende conjuntos distintos de dados. Nos algoritmos de associação, conforme o nome indica, pretende-se revelar associações em grandes conjuntos de dados, um exemplo comum deste sistema é a análise das vendas para encontrar a melhor forma de colocar artigos numa loja.

Através de uma combinação de ambas surge a semi-supervisionada, onde apenas alguns dos dados têm os seus dados de saída identificados. Esta combinação tem, por norma, a quantidade de dados identificados bastante reduzida comparativamente aos não identificados. Esta forma de aprendizagem pode ser útil na medida em que o processamento de grandes quantidades de dados, no caso da aprendizagem supervisionada, pode ser bastante dispendioso ao nível de recursos de processamento e de tempo. Desta forma, através da aprendizagem semi-supervisionada, poupa-se recursos e, para além disso, está menos sujeito ao *overfitting* [52].

### 2.5.1 Interpretabilidade

A gestão da sociedade era feita unicamente por seres humanos, no entanto isso pode vir a mudar. Quando nos candidatávamos a um emprego ou empréstimo, o resultado final dessa candidatura era dado por uma pessoa. Se fôssemos para um hospital, um médico tentaria categorizar a nossa doença e recomendar o tratamento mais adequado. Para decisões como estas, há uma explicação para a decisão tomada.

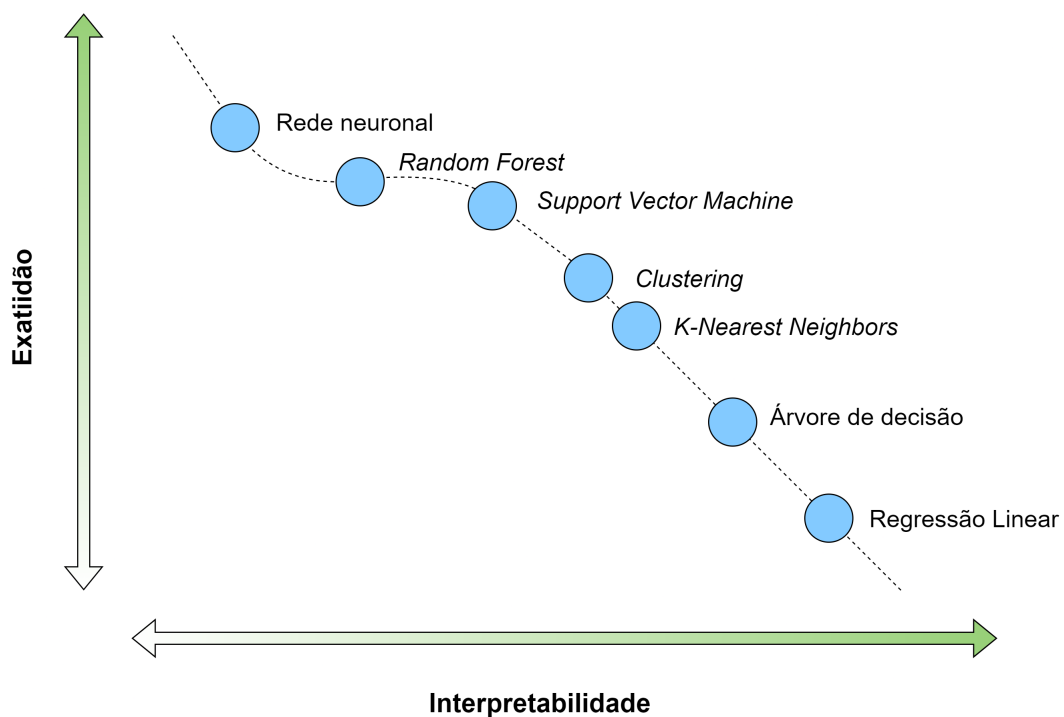
Se um pedido de empréstimo for recusado, por exemplo, é possível compreender o raciocínio de quem tomou essa decisão para que numa próxima candidatura se possa preencher os requisitos necessários. Para além disso, se a decisão for mal tomada, pode ser contestada podendo levar à anulação da mesma. No hospital, a explicação de um médico elucida-nos sobre a nossa condição.

Em contextos sociais, as razões para uma decisão muitas vezes interessam. Por exemplo, causar intencionalmente a morte, comparativamente a involuntariamente, são crimes distintos. No entanto, muitos dos modelos preditivos atuais não são interpretáveis, tornando impossível explicar a tomada de decisão final [53].

Os modelos de aprendizagem automática têm sido utilizados como uma ferramenta de solução de problemas num grande espectro de áreas científicas e da sociedade. No ramo da saúde, surge o

conceito de interpretabilidade a par destes modelos.

Apesar desta ferramenta já ter provado ser útil na área da saúde, a interpretabilidade dos modelos, por vezes, pode ser um impedimento para uma maior adoção da aprendizagem automática em ambientes reais. Nesta área, apenas um alto desempenho das métricas de validação dos modelos não é o suficiente para que haja confiança numa decisão que é feita por uma máquina, visto que esta pode ter implicações diretas na saúde de uma pessoa. Posto isto, há que ser balanceada a interpretabilidade com o desempenho dos modelos de forma a obter o melhor desempenho, cumprindo os requisitos mínimos de interpretabilidade. Esta tarefa torna-se difícil devido à relação entre estes dois objetivos que, tal como se pode observar na figura 2.4, quanto maior a exatidão, menor é a interpretabilidade [54].



**Figura 2.4:** Relação entre interpretabilidade e exatidão [54].

## 2.5.2 Seleção de características

A seleção de características, como uma estratégia de pré-processamento de dados, é uma forma eficaz e eficiente na preparação de dados (especialmente, dados de grande dimensão) para diversos conjuntos de dados e problemas de aprendizagem automática. O objetivo da seleção de características são a construção de modelos mais simples e compreensíveis, bem como, tornar os dados mais limpos, melhorando o desempenho dos modelos de aprendizagem [55].

A seleção das características deve ser distinguida da extração de características. Embora ambas as técnicas sejam utilizadas para reduzir o número de características de um conjunto de dados, a extração de características é uma técnica de redução na dimensionalidade que cria novas combinações de atributos, enquanto a seleção de características inclui e exclui os atributos que estão presentes nos dados sem os alterar [56]. As técnicas de seleção de características são utilizadas principalmente quando a interpretabilidade do modelo é um requisito fundamental.



## Capítulo 3

# Descrição física dos dispositivos utilizados

O *BITalino (r)evolution Plugged Kit* é bastante versátil e útil no que toca à aquisição de dados biométricos. Este kit vem equipado com uma série de ferramentas, nomeadamente:

### **Sensores**

Eletromiografia 3.2.1  
Eletrocardiograma 3.2.2  
Atividade Eletrodérmica 3.2.3  
Eletroencefalografia 3.2.4  
Acelerómetro 3.2.5  
Luz 3.2.6  
Botão 3.2.7

### **atuadores**

LED 3.3.1  
*BUZZER* 3.3.2  
*Digital-to-Analog Converter*

Para além dos sensores e atuadores, vem acompanhado de um módulo central, 5 elétrodos pré-gelificados, uma bateria de 700 *mA* e um cabo de conexão UC-E6 para UC-E6.

### 3.1 Módulo central

O módulo central pode ser descrito separadamente de acordo com os seus 4 blocos funcionais representados na figura 3.1; a vermelho, a *Microcontroller Unit* (MCU) baseada no microcontrolador ATmega328P; a preto, as portas fêmea UC-E6 que são a *interface* de entrada e saída para controlo dos sensores e atuadores; a azul, o bloco de transmissão com um BT121-A que está destinado a aplicações que requerem conectividade tanto BLE como Bluetooth clássico e, a verde, o bloco de alimentação com um interruptor *on/off*, uma entrada microUSB e um ponto de ligação para a bateria LiPo Battery 3.7 V LP553436 700 *mA*.




Figura 3.1: Módulo central dividido em blocos.

## 3.2 Sensores

Nesta secção é feita uma descrição detalhada de cada sensor, apresentando a forma como devem ser utilizados, as suas funções de transferência, os respetivos sinais em diversos cenários e, por fim, as suas especificações e características.

### 3.2.1 Eletromiografia

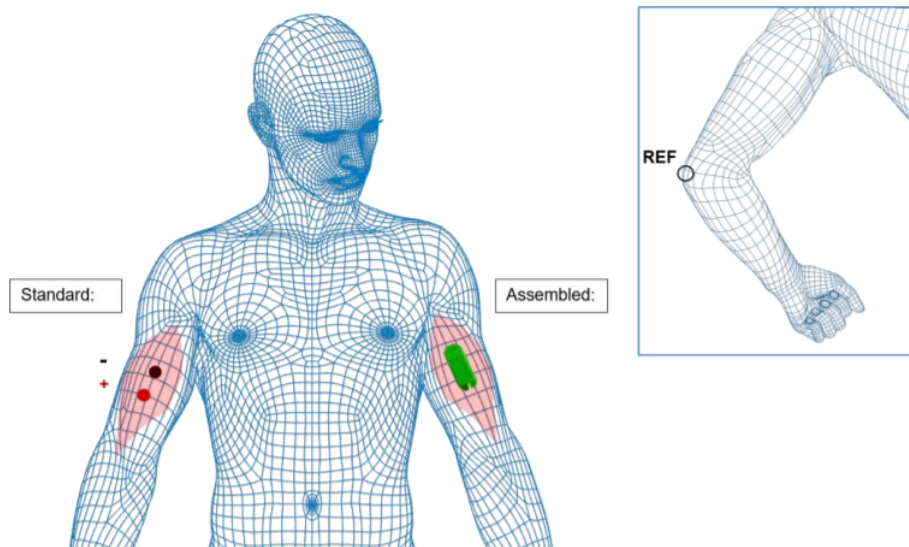
O sensor EMG permite o estudo da atividade muscular de um indivíduo, fazendo a ligação ao mesmo através de elétrodos pré-gelificados ou secos. Tem uma configuração bipolar, ideal para a captação do sinal com baixo ruído, fornecendo assim dados biométricos precisos para o desenvolvimento de projetos [57]. Na figura 3.2 é possível observar o sensor descrito.



Figura 3.2: Sensor para Eletromiografia [57].

Os elétrodos, positivo e negativo, têm de ser colocados ao longo do músculo cuja atividade se quer analisar e, para além disso, o elétrodo de referência numa região de baixa atividade muscular como, por exemplo, o cotovelo ou a clavícula.

Um exemplo de medida pode ser feito no músculo bíceps braquial, destacado a vermelho na figura 3.3.



**Figura 3.3:** Posicionamento dos elétrodos do EMG no bíceps braquial (destacado a vermelho) para versão *Standard*, à esquerda, e para a *Assembled*, à direita [57].

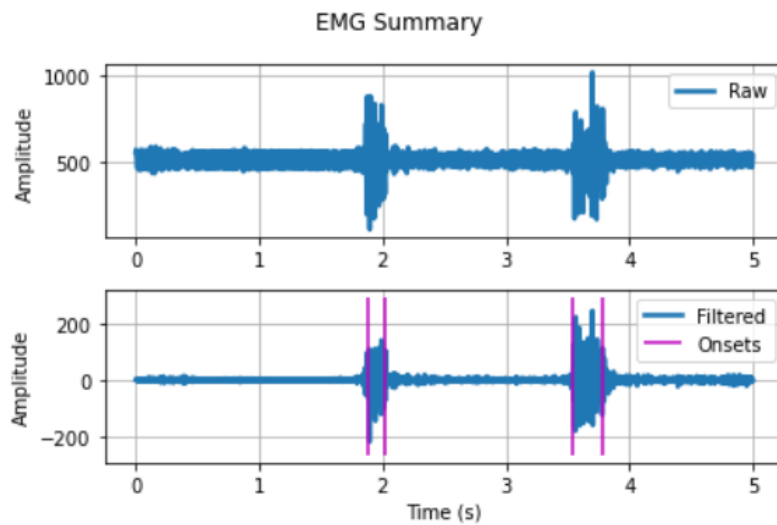
A resposta deste sensor às contrações musculares (que pode ser observada na figura 3.4) é recebida pelo BITalino e varia entre 0 e  $2^n - 1$  ( $n$  = resolução de amostragem), sendo convertida para a unidade original de medida deste sensor [ $mV$ ], usando a seguinte função de transferência 3.1.

$$EMG(mV) = \frac{\left(\frac{ADC}{2^n} - \frac{1}{2}\right) * VCC}{G_{EMG}} * 1000 \quad (3.1)$$

Com:

$EMG (mV)$	Sinal EMG em mili-Volt ( $mV$ )
$ADC$	Dados das amostras do sensor/canal (valor digital)
$n$	Resolução de amostragem
$VCC$	Tensão (3,3 V quando utilizado com o BITalino)
$G_{EMG}$	Ganho (1009)

A função transferência 3.1 dá assim origem à resposta da EMG captada com o *software* Open-Signals [58] para um ficheiro `.txt`, ao qual é feito um ajuste recorrendo ao código de limpeza A.1. Posteriormente, é processado com o código A.3, que dá origem à figura 3.4 com o sinal em estado *raw* e com o sinal filtrado, destacando os momentos de impulsos nervosos.



**Figura 3.4:** Dados de saída do sensor (sinal adquirido do bíceps braquial através da flexão do cotovelo e antebraço em supinação).

#### Especificações:


- Ganho: 1009
- Impedância de entrada:  $10/7,5 \text{ G}\Omega/pF$
- Tensão de entrada: 2,0-3,5V
- Gama de variação:  $\pm 1,64mV (@VCC=3,3V)$
- Consumo:  $0,17mA$
- CMRR:  $86dB$

#### Características:

- Medição diferencial bipolar
- Saída analógica pré-condicionada
- Saída de dados não processados
- Pode ser utilizado com o cabo de dois ou três eletrodos (sendo necessário só um ponto de referência quando se utilizam vários EMGs)
- Alta relação sinal-ruído
- De pequenas dimensões
- Fácil de utilizar

### 3.2.2 Eletrocardiograma

O sensor de baixo ruído da Plux utiliza um tríodo diferencial que permite uma aplicação rápida para a aquisição de dados, sendo possível usar outras configurações para o mesmo propósito. O *design* inovador do sensor analógico tem como sua principal função a análise minuciosa da actividade cardíaca de um indivíduo, através dos dados brutos fornecidos [59].




**Figura 3.5:** Sensor para Eletrocardiograma [59].


Para a aplicação dos elétrodos deste sensor é utilizada a configuração de Einthoven. O triângulo de Einthoven tem três variações diferentes que dependem da posição onde se coloca os elétrodos:

- Derivação D1: medição do Braço Direito (BD) para o Braço Esquerdo (BE)
- Derivação D2: medição do BD para a Perna Esquerda (PE)
- Derivação D3: medição do BE para o PE

Nas seguintes figuras são demonstrados os locais recomendados para se colocar os elétrodos para o ECG, nas diferentes configurações de Einthoven, dependendo dos sensores ECG a utilizar e respectivos tamanhos dos cabos.



**Figura 3.6:** Posicionamento dos elétrodos do ECG conforme a configuração de Einthoven, com o sensor com cabos dos seguintes comprimentos: 1.5cm (+ e -) e 3cm (referência) [59].



**Figura 3.7:** Posicionamento dos elétrodos do ECG conforme a configuração de Einthoven, com o sensor que possui cabos com 30 cm de comprimento (+, - e referência) [59].

Após serem colocados os elétrodos no indivíduo em teste, os cabos dos elétrodos devem ser ligados com uma das configurações presentes na tabela 3.1.

**Tabela 3.1:** Configurações de Einthoven

	Elétrodo Positivo(+)	Elétrodo Negativo(-)	Elétrodo de Referência
Derivação I	BE	BD	PE
Derivação II	PE	BD	BE
Derivação III	PE	BE	BD

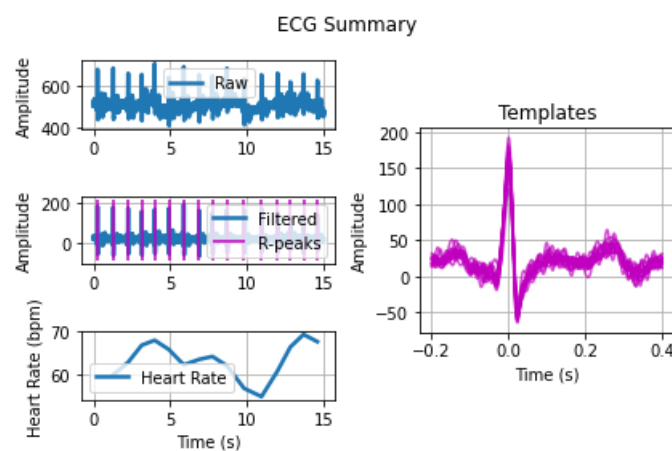
A resposta deste sensor às contrações cardíacas (que pode ser observada na figura 3.8) é recebida pelo BITalino e varia entre 0 e  $2^n - 1$  ( $n$  = resolução de amostragem), sendo convertida para a unidade original de medida deste sensor [ $mV$ ], utilizando a seguinte função de transferência:

$$ECG(mV) = \frac{\left(\frac{ADC}{2^n} - \frac{1}{2}\right) * VCC}{G_{ECG}} * 1000 \quad (3.2)$$

Com:

$ECG(mV)$	Sinal ECG em mili-Volt( $mV$ )
$ADC$	Dados das amostras do sensor/canal (valor digital)
$n$	Resolução de amostragem
$VCC$	Tensão (3,3 V quando utilizado com o BITalino)
$G_{ECG}$	Ganho (1019)

Na seguinte imagem é possível observar a resposta do ECG, retirada com o *software* OpenSignals [58] para um ficheiro .txt, ao qual é feito um ajuste recorrendo ao código de limpeza A.1. Posteriormente, é processado com o código A.3, que dá origem à figura 3.8 com o sinal em estado *raw*, com o sinal filtrado evidenciando os momentos de pico, o batimento cardíaco instantâneo, em destaque, à direita, o momento de batimento.



**Figura 3.8:** Dados de saída do sensor (sinal adquirido em descanso).

### Especificações:

- Ganho: 1019
- Largura de Banda: 0,5-100Hz
- Impedância de entrada:  $\geq 100 G\Omega$
- Gama de variação:  $\pm 1,47mV$  (@VCC=3 V)
- Consumo: 0,5mA
- CMRR: 100dB

### Características:

- Medição diferencial bipolar
- Saída analógica pré-condicionada
- Alta relação sinal-ruído
- Saída de dados não processados com qualidade para avaliação médica
- De pequenas dimensões
- Fácil de utilizar

### 3.2.3 Atividade eletrodérmica

O sensor AED permite, à semelhança da frequência cardíaca, traduzir o nível de entusiasmo, frustração e tédio de um indivíduo, sendo desta forma relevante para o estudo da situação do militar em teste [60], fazendo a ligação ao mesmo através elétrodos pré-gelificados ou secos. Tem uma configuração bipolar, ideal para a captação do sinal com baixo ruído, fornecendo assim dados biométricos precisos para o desenvolvimento de projetos [61]. Na figura 3.9 é possível observar o sensor supra descrito.



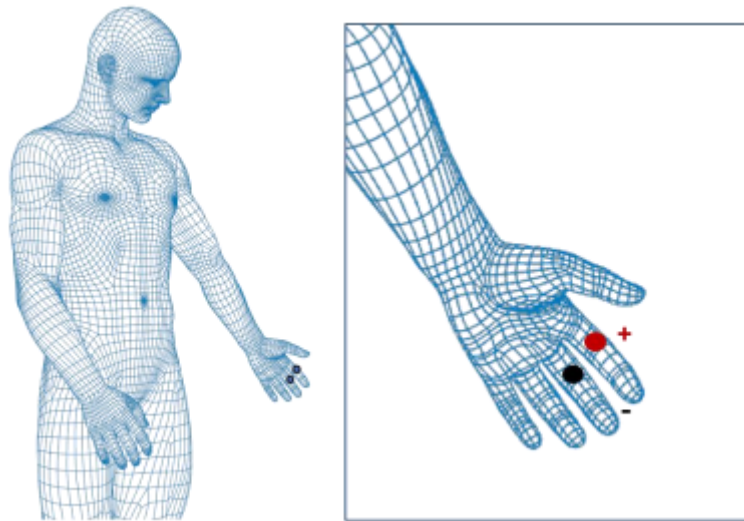
Figura 3.9: Sensor para a Atividade Electrodermica [61].

A aplicação dos elétrodos deste sensor, por norma, é feita entre dois dedos adjacentes de forma a medir a diferença de potencial na pele, porém, pode ser realizada de diversas formas. A diferença de potencial é medida entre os dois elétrodos utilizados (+ & -). Sendo possível fazer esta conexão de duas formas diferentes observáveis na tabela 3.2.

Tabela 3.2: Configurações para AED.

	Elétrodo Positivo(+)	Elétrodo Negativo(-)
Derivação I	dedo indicador	dedo médio
Derivação II	dedo médio	dedo indicador

Na seguinte imagem é possível observar o local preciso onde colocar os elétrodos:



**Figura 3.10:** Posicionamento dos elétrodos para a AED [61].

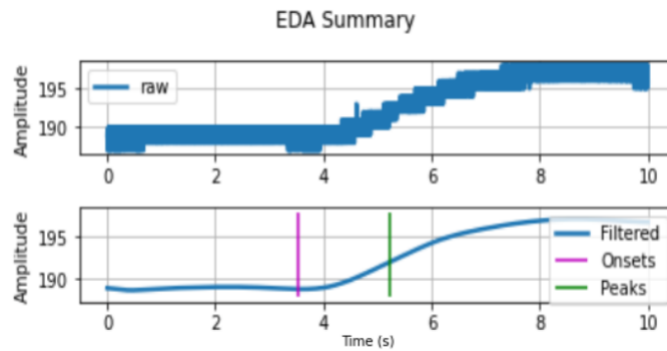
A resposta deste sensor (que pode ser observada na figura 3.11) é recebida pelo BITalino e varia entre 0 e  $2^n - 1$  ( $n$  = resolução de amostragem), sendo convertida para a unidade original de medida deste sensor [ $\mu S$ ], usando a função de transferência 3.3.

$$AED(\mu v) = \frac{ADC}{2^n} * VCC}{G_{AED}} * 10^6 \quad (3.3)$$

Com:

$AED(\mu S)$	Sinal AED em microsiemens ( $\mu S$ )
$ADC$	Dados das amostras do sensor/canal (valor digital)
$n$	Resolução de amostragem
$VCC$	Tensão (3,3V quando utilizado com o BITalino)
$G_{AED}$	Ganho (0,132)

Na imagem 3.11 é possível observar a resposta do AED, retirada com o *software* OpenSignals [58] para um ficheiro .txt, ao qual é feito um ajuste recorrendo ao código de limpeza A.1. Posteriormente, é processado com o código A.3, que dá origem à figura 3.11 com o sinal em estado *raw* e com o sinal filtrado evidenciando o momento de pico, que corresponde ao aumento de *stress*.



**Figura 3.11:** Dados de saída do sensor (sinal adquirido em momento de *stress* de um indivíduo a observar um vídeo de *jumpscare*).

### Especificações:

- Ganho: 0,132
- Largura de Banda: 0-2,8Hz
- Tensão de entrada: 1,8-5,5V
- Impedância de entrada:  $\geq 100\ G\Omega$
- Gama de variação: 0-25 $\mu S$  (@VCC=3,3V)
- Consumo:  $\pm 0,1mA$

### Características:

- Medição diferencial bipolar
- Saída analógica pré-condicionada
- Alta relação sinal-ruído
- Saída de dados não processados com qualidade para avaliação médica
- De pequenas dimensões e leve
- Fácil de utilizar

## 3.2.4 Electroencefalografia

O sensor EEG é um sensor que permite o estudo da actividade cerebral de um indivíduo, fazendo a ligação ao mesmo através eléctrodos pré-gelificados ou secos. Tem uma configuração bipolar, ideal para a captação do sinal com baixo ruído, fornecendo assim dados biométricos precisos para o desenvolvimento de projectos [62]. Na figura 3.12 é possível observar o sensor descrito.



**Figura 3.12:** Sensor para Electroencefalografia [62].


Para a aplicação dos eléctrodos deste sensor é utilizado o sistema 10-20 (observável na figura 3.13)

de forma a medir a diferença de potencial, através da pele, medida entre cada elétrico e o elétrico de referência. Sendo possível fazer esta conexão de duas formas diferentes observáveis na tabela 3.3.

**Tabela 3.3:** Configurações do sistema 10-20.

	elétrico Positivo(+)	elétrico Negativo(-)	elétrico de Referência
Derivação I	FP1-Testa	FP2-Testa	M1-Atrás da orelha
Derivação II	FP2-Testa	FP1-Testa	M1-Atrás da orelha

Na seguinte imagem é possível observar o local concreto onde colocar os elétricos:



**Figura 3.13:** Posicionamento dos elétricos para a EEG com a configuração do sistema 10-20 [62].


A resposta deste sensor (que pode ser observada na figura 3.14) é recebida pelo BITalino e varia entre 0 e  $2^n - 1$  ( $n$  = resolução de amostragem), sendo convertida para a unidade original de medida deste sensor [ $\mu V$ ], utilizando a seguinte função de transferência 3.4.

$$EEG(\mu v) = \frac{(\frac{ADC}{2^n} - \frac{1}{2}) * VCC}{G_{EEG}} * 10^6 \quad (3.4)$$

Com:

EEG ( $\mu V$ )	Sinal EEG em micro-Volt( $\mu V$ )
ADC	Dados das amostras do sensor/canal (valor digital)
$n$	Resolução de amostragem
VCC	Tensão (3,3 V quando utilizado com o BITalino)
$G_{EEG}$	Ganho (41782)

Na imagem seguinte é possível observar a resposta do EEG, retirada com o *software* OpenSignals [58] para um ficheiro `.txt`, ao qual é feito um ajuste recorrendo ao código de limpeza A.1. Posteriormente, é processado com o código A.2, que dá origem à figura 3.14 com o sinal em estado *raw*.



**Figura 3.14:** Dados de saída do sensor (sinal adquirido em descanso).

#### Especificações:

- Ganho: 41782
- Largura de Banda: 0,8-48,23 Hz
- Impedância de entrada:  $\geq 100 G\Omega$
- Gama de variação:  $\pm 37,5 \mu V$  (@VCC=3 V)
- Consumo: 0,5 mA
- CMRR: 100 dB

#### Características:

- Medição diferencial bipolar
- Saída analógica pré-condicionada
- Alta relação sinal-ruído
- Saída de dados não processados com qualidade para avaliação médica
- De pequenas dimensões e leve
- Fácil de utilizar

### 3.2.5 Acelerómetro

O sensor ACC permite acompanhar o movimento de um Soldado e, através da análise deste movimento, é possível retirar conclusões da condição física do militar em teste [63]. O sensor fornece dados de saída correspondentes a cada eixo (X, Y e Z), sendo as aplicações típicas desenvolvidas com este sensor a deteção de postura, contador de passos, atigrafia, deteção de queda, análise de vibração e de impacto. O sensor vem apenas com o eixo Z conectado e, para poder ser lida a saída dos outros eixos, é necessário fazer a conexão externa através de fios *dupont* ou similares a outras entradas do

BITalino [64]. Na figura 3.15 é possível observar o sensor descrito.




Figura 3.15: Acelerômetro [64].

A resposta do eixo Z deste sensor (que pode ser observada na figura 3.16) é recebida pelo BITalino e varia entre 0 e  $2^n - 1$  ( $n$  = resolução de amostragem), sendo convertida para a unidade original de medida deste sensor [ $g$ ], recorrendo à seguinte função de transferência 3.5.

$$ACC(g) = \frac{ADC - C_{min}}{C_{max} - C_{min}} * 2 - 1 \quad (3.5)$$

Com:

- $ACC(\mu S)$  Sinal ACC em força-g ( $g$ )
- $ADC$  Dados das amostras do sensor/canal
- $C_{min}$  Valor de calibração mínimo
- $C_{max}$  Valor de calibração máximo

A função de transferência 3.5 dá assim origem a uma resposta similar à que se segue (recorte do software OpenSignals [58]).




Figura 3.16: Dados de saída do sensor em movimento aleatório (A1-Z ligado via UC-E6, A2-X e A3-Y ligados externamente via fios dupont) [58].

### Especificações:

- Gama de variação :  $\pm 3g$
- Largura de Banda:  $0-50Hz$
- Impedância de entrada:  $\geq 100 G\Omega$
- Tensão de entrada:  $1,8-3,6V$
- Consumo:  $0,35mA$

### Características:

- Sensor de 3 eixos
- Saída analógica pré-condicionada
- Tecnologia *Microelectromechanical Systems* (MEMS)
- Saída de dados não processados com qualidade para avaliação médica
- De pequenas dimensões e leve
- Fácil de utilizar

## 3.2.6 Sensor de luz

Este sensor capta a luz em seu redor e a sua utilização comum consiste em fazer uma adaptação activa da luz ambiente ou de ecrãs com base na sua resposta. Na figura 3.17 é possível observar o sensor descrito.




Figura 3.17: Sensor de luz.

A resposta deste sensor (que pode ser observada na figura 3.18) é recebida pelo BITalino e varia entre 0 e  $2^n - 1$  ( $n$  = resolução de amostragem), sendo convertida para a unidade original de medida deste sensor [%], fazendo uso da seguinte função de transferência 3.6.

$$LUX(\%) = \frac{ADC}{2^n} * 100\% \quad (3.6)$$

Com:


$LUX$ (%)	Valor da luz em percentagem (%)
$ADC$	Dados das amostras do sensor/canal
$n$	Número de bits do canal



**Figura 3.18:** Resposta do sensor de luz, num ambiente escuro, com um *Light-Emitting Diode* (LED) a piscar uma vez.

### 3.2.7 Botão

Este sensor responde ao ser pressionado pois é um botão de *pull-down*, ou seja, fica a 0 V em resposta ao sinal externo. Pode ser usado conjuntamente com outros sensores por forma a registar momentos importantes para análise.



**Figura 3.19:** Resposta do botão ao ser pressionado.


## 3.3 Atuadores

Nesta secção é feita uma descrição detalhada de cada atuador, apresentando a sua utilidade em simbiose com os biossensores, assim como é exibida uma figura de cada um.

### 3.3.1 *Light-Emitting Diode*

Este atuador fornece um estímulo visual e pode ser usado como sinal de monitorização, sincronizando-

o de forma a piscar na frequência dos sinais biológicos captados.



**Figura 3.20:** LED ligado.

### 3.3.2 *Buzzer*

O *Buzzer* (BUZ) emite um sinal sonoro que pode ser utilizado como sinal de monitorização, de forma a ativar sincronizadamente um alarme em resposta a sinais biológicos.



**Figura 3.21:** Buzzer.

### 3.3.3 *Digital-to-Analog Converter*

Este atuador tem uma saída analógica controlável que permite acionar outros atuadores básicos e pode ser utilizado para sincronização com os biossensores, através das suas portas de entrada analógicas. Para ser utilizado com o BITalino, tem de se ligar à porta *Pulse-width Modulation* (PWM), com uma resolução de saída de 8 bits. O filtro garante uma saída estável e, por este motivo, um controlo equilibrado dos outros atuadores.



**Figura 3.22:** *Digital-to-Analog Converter*.

### 3.4 Testes e experiências com os componentes

Nos testes e experiências com os componentes o objetivo é realizar pequenos projetos para se perceber melhor as capacidades e possíveis problemas com o controlador da BITalino e os seus sensores, bem como, a compatibilidade com o Arduino Uno e as vantagens e desvantagens da utilização deste microcontrolador, comparativamente ao BITalino.

Os dados de ambos os testes foram retirados na totalidade de experiências realizadas pelo autor da presente dissertação em si próprio.




Figura 3.23: Módulos BITalino, à esquerda, e Arduino Uno, à direita.

### 3.4.1 Projeto 1

Neste primeiro projeto o objetivo foi fazer um *led* piscar ao ritmo dos batimentos cardíacos, lidos pelo sensor. O projeto foi concluído com sucesso, com recurso à montagem 3.24 e o código A.4.

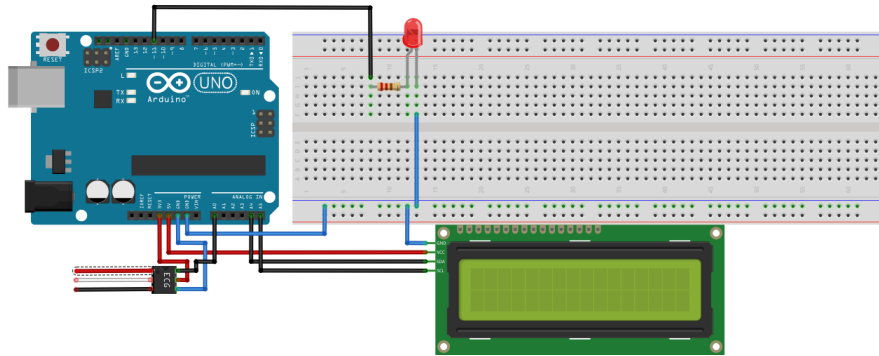


Figura 3.24: Arquitetura do sistema.

### 3.4.2 Projeto 2

Neste projeto o objetivo foi fazer um *buzzer* emitir um sinal sonoro em resposta à contração do bíceps braquial.

Devido ao ruído, as leituras não foram as esperadas, visto que, com pequenos movimentos, o *buzzer* dava falsos alertas. A montagem utilizada está representada na figura 3.25 e o código em A.5.

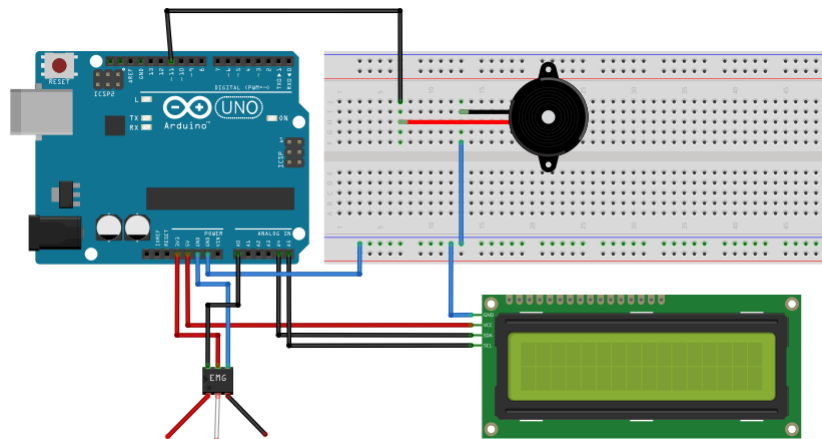


Figura 3.25: Arquitetura do sistema.

### 3.4.3 Conclusões

Embora, atualmente, o Arduino seja a plataforma de *hardware* de baixo custo mais popular dentro da comunidade do *Do It Yourself* (DIY), a aquisição de sinais biológicos requer instrumentação adequada, concebida com requisitos rigorosos em termos de tolerância ao ruído e precisão da taxa de amostragem, sendo que este não foi concebido tendo em conta estes requisitos, específicos da computação fisiológica.

Apesar dos dados recolhidos através de ambas as plataformas preservarem as propriedades da forma de onda, o BITalino é várias ordens de magnitude mais exato que o Arduino, com a vantagem adicional de ser mais robusto ao ruído [65].

Com o resultado dos projetos supra descritos e comparando os recursos de ambos, presentes na tabela 3.4, concluiu-se que o Arduino pode ser utilizado como ferramenta de teste para projetos didáticos, porém não é a melhor ferramenta para estudar os dados fisiológicos.

**Tabela 3.4:** Principais recursos das duas plataformas em comparação [65].

<b>Recurso</b>	<b>BITalino</b>	<b>Arduino Uno</b>
MCU	Atmega328P	Atmega328P
Relógio [MHz]	8	16
Alimentação [V]	3.3	5
Transmissão de dados	Bluetooth+UART	USB+UART+I2C+SPI
Dimensões [cm]	6,0*10,5	5,4*6,8

## Capítulo 4

# Testes e desenvolvimento do processo de classificação

No presente capítulo, são apresentados e descritos todos os passos da metodologia de trabalho representada pelo diagrama 4.1. Na recolha de dados é descrito o grupo de teste, o teste realizado e o local e a razão de colocar os sensores em determinadas partes do corpo. A preparação dos dados consistiu numa descrição do processo de transformação de um conjunto de informação dispersa em ficheiros .txt numa matriz de trabalho. A seleção de características reduz a matriz de trabalho aos dados mais relevantes, de forma a obter uma classificação consideravelmente melhor. Na aprendizagem e classificação são descritos os métodos utilizados, os parâmetros que os otimizam e os resultados a que deram origem. Por fim, a certificação dos algoritmos foca o desenvolvimento da melhor forma de validar, através de várias métricas, a performance dos métodos de classificação num novo conjunto de dados.

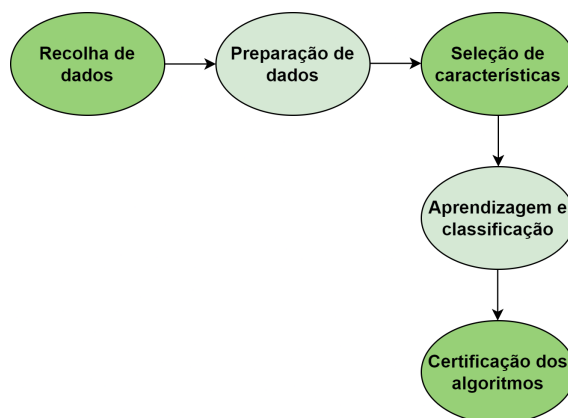


Figura 4.1: Metodologia do processo experimental adotado.

## 4.1 Recolha de dados

Com o objetivo de extrair sinais biológicos para o desenvolvimento dos processos de classificação, foi realizado um teste a 33 alunos, dos quais 29 da Academia Militar e 4 da Academia da Força Aérea. Este teste consistiu na observação de dois vídeos, com 6 minutos cada, tendo o primeiro o objetivo de induzir um estado emocional calmo, na zona verde do modelo dimensional de emoções da figura 2.3, e o segundo de *stress*, na zona do amarelo e vermelho do mesmo modelo.

Estes vídeos foram visualizados pela maioria dos alunos através dos óculos de realidade virtual Pico 2, apresentados na figura 4.3, sendo que apenas 5 dos alunos fizeram o teste observando os vídeos no ecrã de um computador portátil. Nas imagens da figura 4.2, é possível observar o ambiente de teste utilizado.

De referir que 5, dos 33 testes realizados, foram descartados devido a erros ocorridos na realização dos mesmos, pelo que, apenas foram considerados 28 testes.



**Figura 4.2:** Alunos em teste, com os sinais biológicos, em tempo real, no monitor.



**Figura 4.3:** Óculos de realidade virtual pico 2 [66].


Para a obtenção de informação biológica de relevo, o local de colocação dos elétrodos foi bastante importante, na medida em que esta determina tanto a qualidade do sinal, bem como o conforto do indivíduo em teste. Posto isto, os elétrodos foram dispostos conforme a figura 4.4.

Na realização do ECG foram colocados elétrodos, a vermelho na figura, nos pulsos esquerdo e direito (positivo e negativo, respetivamente), por serem partes do corpo mais acessíveis e confortáveis para a sua colocação, do que o peito (local mais comum para a realização deste teste) e a diminuição na amplitude do sinal relativa não ser relevante [67].

Em relação à EMG, os elétrodos foram colocados por cima da sobrancelha, a azul na figura, mais concretamente nos músculos occipitofrontal e corrugador do supercílio, de acordo com Yumiao et al. [68]. Estes fazem referência a um velho ditado chinês, “o amor pode ser transmitido pelas sobrancelhas”, que apoia a tese da importância das sobrancelhas para o reconhecimento de emoções.

Os elétrodos de medição da AED, a verde na figura, foram dispostos na palma da mão esquerda conforme indica o documento da BITalino [61].

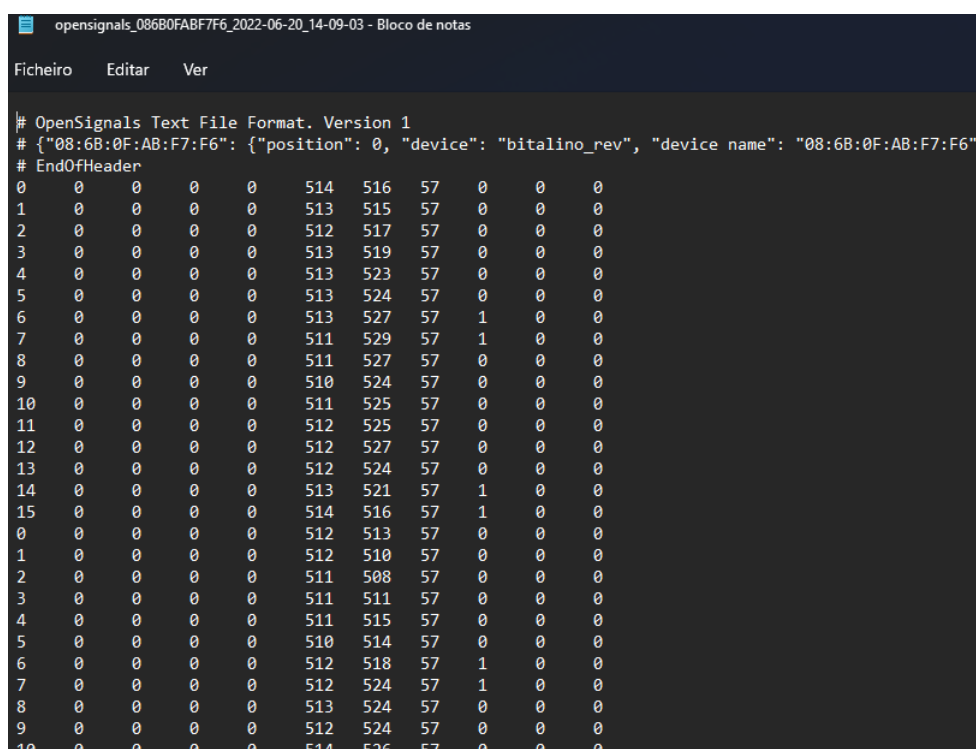
Por fim, a referência, a preto na figura, é colocada no cotovelo por ser uma zona óssea, como indicado nos artigos anteriores supra-referidos.



**Figura 4.4:** Disposição dos elétrodos.

## 4.2 Preparação de dados

Os testes deram origem a ficheiros `.txt` com várias colunas, das quais três são relevantes para o estudo, como se pode observar na figura 4.5, sendo que as colunas correspondem ao EMG, ECG e AED, respetivamente. Os valores foram retirados a uma frequência de 1000  $Hz$ .



```
opensignals_086B0FABF7F6_2022-06-20_14-09-03 - Bloco de notas
Ficheiro  Editar  Ver

# OpenSignals Text File Format. Version 1
# {"08:6B:0F:AB:F7:F6": {"position": 0, "device": "bitalino_rev", "device name": "08:6B:0F:AB:F7:F6"}
# EndOfHeader
0 0 0 0 0 514 516 57 0 0 0
1 0 0 0 0 513 515 57 0 0 0
2 0 0 0 0 512 517 57 0 0 0
3 0 0 0 0 513 519 57 0 0 0
4 0 0 0 0 513 523 57 0 0 0
5 0 0 0 0 513 524 57 0 0 0
6 0 0 0 0 513 527 57 1 0 0
7 0 0 0 0 511 529 57 1 0 0
8 0 0 0 0 511 527 57 0 0 0
9 0 0 0 0 510 524 57 0 0 0
10 0 0 0 0 511 525 57 0 0 0
11 0 0 0 0 512 525 57 0 0 0
12 0 0 0 0 512 527 57 0 0 0
13 0 0 0 0 512 524 57 0 0 0
14 0 0 0 0 513 521 57 1 0 0
15 0 0 0 0 514 516 57 1 0 0
0 0 0 0 0 512 513 57 0 0 0
1 0 0 0 0 512 510 57 0 0 0
2 0 0 0 0 511 508 57 0 0 0
3 0 0 0 0 511 511 57 0 0 0
4 0 0 0 0 511 515 57 0 0 0
5 0 0 0 0 510 514 57 0 0 0
6 0 0 0 0 512 518 57 1 0 0
7 0 0 0 0 512 524 57 1 0 0
8 0 0 0 0 513 524 57 0 0 0
9 0 0 0 0 512 524 57 0 0 0
10 0 0 0 0 514 526 57 0 0 0
```

Figura 4.5: Ficheiro de texto produzido pelo *software* OpenSignals [58] após o término do teste.

A quantidade de valores extraídos foi calculada pelo código A.6, com o intuito de ser utilizado o número máximo de valores de cada teste. Desta forma, as dimensões da matriz onde os dados biométricos foram posteriormente carregados foi preparada para desenvolver os processos de aprendizagem automática.

como se pode observar no código A.8, que cria e guarda a matriz de trabalho, exemplificada na figura 4.6, com dimensões de 56 linhas por 1050000 colunas, num ficheiro `.npy`.



Um dos métodos de seleção de características mais comum consiste na seleção das  $k$  melhores características. Esta técnica pode ser aplicada com recurso à biblioteca `sklearn` [70], como se pode observar no código A.9. Este método retira cada característica do conjunto de dados e compara-o com o resultado. Após ter comparado todos os atributos, são deixadas  $k$  características no novo conjunto de dados resultante.

Este é um dos métodos mais simples, porém, deve ser utilizado antes de se recorrer a métodos de seleção mais complexos, porque, muitas vezes, mostra bons resultados. Este método funciona de acordo com um critério estatístico, que deve ser escolhido de acordo com as características do problema a resolver. De acordo com o diagrama da figura 4.8, dado que o problema de trabalho tem uma entrada numérica e uma saída categórica, as mais adequadas são a *Analysis of Variance* (ANOVA) e a Kendall's.

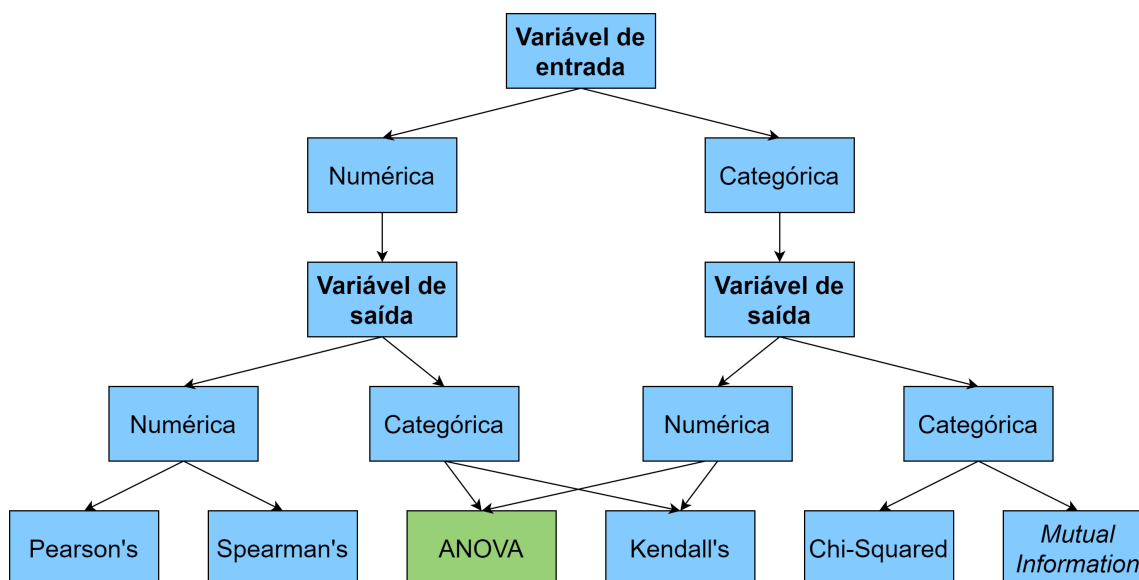


Figura 4.8: Diagrama de medidas estatísticas para seleção de características [71].

Visto que, o método `SelectkBest`, da biblioteca `sklearn` [70], apenas suporta o critério estatístico ANOVA, foi este o aplicado. Este método permite avaliar a dependência da expectativa matemática ou variação do resultado sobre as características selecionadas. Assim, é possível avaliar se esta característica é significativa para a obtenção do resultado.

### 4.3 Métodos de aprendizagem e classificação

Após a seleção de características, foram aplicados diversos algoritmos de classificação para distinguir a observação do primeiro vídeo, codificado com o valor lógico 0, do segundo vídeo, codificado com o valor lógico 1, correspondentes ao estado emocional calmo e *stress*, respetivamente. Para além disso, foram otimizados os parâmetros dos algoritmos que se demonstraram mais adequados a este problema

específico.

### 4.3.1 Análise discriminante linear

A análise discriminante linear é conhecida como uma ferramenta de redução de dimensões, contudo é também um método robusto de classificação. É caracterizado por ser um método simples e por produzir resultados bons e interpretáveis. Quando são abordados problemas reais para serem resolvidos por uma classificação automática, este costuma ser um dos primeiros métodos utilizados para fazer uma avaliação comparativa, antes de serem aplicados outros mais complexos.

Este método pode ser utilizado para classificação supervisionada, considerando um problema genérico de classificação com a variável aleatória  $X$  de uma das  $K$  classes com densidade  $f_k(x)$  em  $\mathbb{R}^p$ . Uma regra discriminante tenta dividir a informação em  $K$  regiões  $\mathbb{R}_1, \dots, \mathbb{R}_k$  que representam as diferentes classes. Através destas regiões, a classificação feita com análise discriminante consiste em alocar  $X$  a  $j$ , se o  $X$  estiver na região  $j$ . Posto isto, é necessário saber a categoria em que o  $X$  está. Para alocar o  $X$  a uma região este método pode seguir duas regras: a maior probabilidade e a bayesiana.

Na regra da maior probabilidade, assumindo que cada classe ocorre com igual probabilidade, o  $X$  é classificado com  $j$  se  $j = \arg \max_i f_i(X)$ .

Na regra bayesiana, sabendo a probabilidade de cada classe,  $\pi_1, \dots, \pi_k$ , o  $X$  é classificado com  $j$  se  $j = \arg \max_i \pi_i f_i(X)$  [72]. Sendo que, a análise discriminante linear aplicada, recorrendo à biblioteca `sklearn` [70], segue a regra bayesiana.

Os resultados obtidos com recurso a este método, bem como os parâmetros otimizantes da mesma, podem ser observados na tabela 4.1. Estes resultados serão explicitados em 4.4.

**Tabela 4.1:** Resultados finais da análise discriminante linear.

tol	Partições ( $k$ )	Solver	Exatidão	Precisão	Sensibilidade	F1 score	Tempo (s)
0,001	5	svd	0,9469	1	0,9142	0,9512	5,15

### 4.3.2 Regressão logística

A regressão logística é um dos modelos lineares estatísticos mais frequentemente utilizados, enquadrado na aprendizagem supervisionada para classificação. Os modelos lineares consistem numa ou mais variáveis independentes que têm uma relação com a variável dependente.

Existem três tipos de regressão logística, o binário, em que as variáveis dependentes podem ter apenas 2 valores possíveis, 1 ou 0; o ordinal, para variáveis com categorias ordenadas; e o multinomial, que é utilizado quando a variável dependente tem três ou mais categorias não ordenadas. Dadas as características do problema a resolver, o tipo que melhor se adequa é o binário [73].

Deste modo, com o objetivo de melhorar os resultados finais, com recurso ao código A.10, foram alteradas as percentagens de treino e teste. Estas percentagens correspondem à quantidade de dados que é utilizada para aprendizagem e, posteriormente, para testar o algoritmo. Atribuindo ao parâmetro  $k$ , que representa o número de conjuntos de dados, os valores 4, 5 e 6, as percentagens utilizadas de treino e teste são, respetivamente, 75% e 25%, 80% e 20% e 83,34% e 16,66%.

Para além disso, variou-se logaritmicamente o parâmetro de regularização,  $C$ , de 0,1 a 1000. Este parâmetro pode ser visto como a capacidade do classificador aceitar classificações erradas no conjunto de dados, de forma a generalizar corretamente com os dados de treino, isto é, valores mais pequenos de  $C$ , traduzem-se numa maior regularização.

Por fim, testou-se várias funções *solver*. Cada *solver* tenta encontrar os pesos dos parâmetros que minimizam uma função de custo, foram testados o *newton-cg*, *lbfgs*, *liblinear*, *sag* e *saga*.

Após realizada a variação de todos os parâmetros supra-referidos, obtiveram-se diversos resultados, sendo que, os 3 melhores resultados podem ser observados na tabela 4.2.


**Tabela 4.2:** Resultados finais da regressão logística.

C	Partições	Kernel	Exatidão	Precisão	Sensibilidade	F1 score	Tempo(s)
1	5	lbfgs	0,9818	0,9714	1	0,9846	10,6247
0,1	5	lbfgs	0,9636	0,9428	1	0,9666	11,8165
100	6	liblinear	0,9629	0,9428	1	0,9686	7,5339

### 4.3.3 Support vector classification

O principal objetivo da *Support Vector Classification* (SVC) é criar uma fronteira num conjunto de dados composto por elementos pertencentes a duas classes diferentes. Esta é uma ferramenta de aprendizagem muito poderosa que se baseia num método estatístico com base na aprendizagem estatística e minimização do erro, a fim de obter a capacidade de identificar a classe de um novo conjunto de dados.

Mais concretamente, através de vetores de características, é criado um hiperplano ou, por vezes, um conjunto de hiperplanos, que atua como um limite entre as classes. Na figura 4.9 é possível observar um exemplo de aprendizagem dos limites de decisão (ou seja, do hiperplano) pela SVC [74].



**Figura 4.9:** Representação de um exemplo de hiperplano.


O hiperplano ideal é representado pela equação 4.1.

$$W^T X + b = 0 \quad (4.1)$$

Com:

- $X$  Vetor de características
- $W$  Vetor normal ao hiperplano
- $b$  Offset do hiperplano com a origem

Posto isto, a fim de melhorar os valores finais de validação, com recurso ao código A.11, foram alteradas as percentagens de treino e teste, tal como na regressão logística (4.3.2). Para além disso, variou-se também logaritmicamente o parâmetro de regularização  $C$  de 0,1 a 1000, sendo que, tal como anteriormente referido, valores mais pequenos deste parâmetro traduzem-se numa maior regularização. É possível observar a variação desta margem na figura 4.10.



**Figura 4.10:** Variação da margem com a mudança de  $C$  [75].

Por fim, testou-se várias funções *kernel*. Este parâmetro foca-se na escolha das fronteiras do hiperplano entre classes e, para este problema, foram testados os *kernel* linear, rbf, sigmoid e poly.

Desta forma, a variação de todos os parâmetros supra-referidos levou a obter diversos resultados, sendo que, os 3 melhores resultados podem ser observados na tabela 4.3.

**Tabela 4.3:** Resultados finais da SVC.

C	Partições	Kernel	Exatidão	Precisão	Sensibilidade	F1 score	tempo(s)
0,1	5	linear	0,9636	0,9428	1	0,9666	1,8947
0,1	6	linear	0,9629	0,9428	1	0,9686	2,6934
0,1	6	polinomial	0,9629	0,9428	1	0,9686	2,3256

#### 4.3.4 Classificador *ridge*

A regressão *ridge* é uma regressão linear, por esse motivo, assume uma relação linear entre as variáveis de entrada e a variável de saída. Com uma única variável de entrada, esta relação é representada por uma linha, sendo que com mais dimensões, esta relação pode ser pensada como um hiperplano que liga as variáveis de entrada à de saída. Os coeficientes do modelo são encontrados através de um processo de otimização que procura minimizar a soma do erro quadrático entre as previsões e os valores de saída.

O regressor de *ridge* tem uma variante classificadora, o `RidgeClassifier`. Este classificador converte, primeiramente, as saídas binárias a classificar em  $\{-1, 1\}$  e, de seguida, trata o problema como uma tarefa de regressão, otimizando o objetivo supra-referido. A classe prognosticada corresponde ao sinal da previsão do regressor.

Este modelo, apesar de não ser muito utilizado, pode levar a bastante bons resultados de validação. Para além disso, a perda de mínimos quadrados penalizada, utilizada pelo `RidgeClassifier`, permite personalizar o método para o problema a resolver com a alteração dos *solvers* (auto, svd, cholesky, lsqr, sparse\_cg, sag e saga) com perfis de desempenho computacionais distintos, bem como, com o parâmetro *Alpha* que corresponde a  $\frac{1}{2C}$ , sendo *C* o parâmetro de regularização utilizado noutros modelos lineares como, por exemplo, a regressão logística e a SVC linear [70].

Foram obtidos diversos resultados, através da variação de todos os parâmetros supra-referidos. Destacam-se os 3 melhores resultados na tabela 4.4.

**Tabela 4.4:** Resultados finais do classificador *ridge*.

C	Partições	Kernel	Exatidão	Precisão	Sensibilidade	F1 score	Tempo(s)
100	6	auto	0,9629	0,9428	1	0,9686	1,1385
100	6	cholesky	0,9629	0,9428	1	0,9686	1,2957
10	6	svd	0,9629	0,9428	1	0,9686	3,6520

### 4.3.5 Gradiente descendente estocástico

Gradiente, em termos simples, significa declive ou inclinação de uma superfície. Portanto, gradiente descendente significa, na sua forma mais literal, descer uma inclinação para atingir o ponto mais baixo dessa superfície.

Na figura 4.11, o ponto mínimo da parábola ocorre em  $x = 1$ . O objetivo do algoritmo de descida de gradiente é encontrar o valor de  $x$  que minimize  $y$ , sendo que  $y$  é denominado como a função objetiva, sobre a qual o algoritmo opera, para encontrar o mínimo absoluto [76].




Figura 4.11: Função de parábola em duas dimensões [76].

O gradiente descendente é um algoritmo de otimização iterativo que encontra o menor valor de uma função. Através de iteração contínua, obtém o gradiente de uma função, aproximando-se gradualmente da solução ótima, por forma a obter o melhor resultado e os respetivos parâmetros. O algoritmo, convencionalmente, treina todas as amostras de cada vez, o que prolonga o tempo de treino.

O gradiente descendente estocástico seleciona, em cada iteração, de forma aleatória, uma amostra para treino. Esta abordagem precisa de menos cálculos, por esse motivo, a velocidade de convergência é mais rápida do que outros algoritmos, resultando num alto desempenho, quer no tempo de aprendizagem, bem como na alocação de recursos computacionais [77].

Como a seleção da amostra é realizada de forma aleatória, os resultados não são re-produzíveis. Para além disso, estes variam significativamente para os mesmos parâmetros utilizados em cada ciclo de treino e teste. Apesar de ser possível obter resultados bons para o problema em questão, cerca de 80% de exatidão, por vezes, a gama da mesma fica entre 55% e 60%.

Destaca-se ainda a rapidez deste método, por ser o único que apresenta as predições em menos de 1 segundo, tornando-o mais rápido que os supra-analisados. No entanto, esta característica

não é condição suficiente para ser o método utilizado para a resolução deste problema, pois não se sobrepõem à aleatoriedade das métricas de validação.

## 4.4 Certificação dos algoritmos

A avaliação dos classificadores é bastante importante no processo de classificação, são através dos métodos de validação escolhidos que o desempenho do modelo é avaliado, permitindo melhorar a sua performance.

Existem diversas formas de avaliar um algoritmo, sendo uma das mais utilizadas, o valor de exatidão. Porém, por si só, pode não ser suficiente para garantir a eficácia dos modelos, na prática ou num novo conjunto de dados. Por esse motivo, foram utilizadas também a precisão, a sensibilidade e o *f1-score*, calculadas através das métricas de confusão, relacionadas com a verdade do conjunto de dados e a previsão do modelo, onde TP, TN, FP, e FN denotam, respetivamente, verdadeiro positivo (*true positive*), verdadeiro negativo (*true negative*), falso positivo (*false positive*) e falso negativo (*false negative*).

A matriz de confusão apresenta os resultados sob a forma de uma tabela com duas entradas, uma com as classes reais e outra com as classes previstas pelo modelo, esta pode ser observada na figura 4.12.

		Classe prevista	
		CALMO	STRESS
Classe real	CALMO	TN	FP
	STRESS	FN	TP

**Figura 4.12:** Representação da matriz de confusão.

No contexto da presente dissertação, os TP são as instâncias classificadas como *stress* e nas quais o indivíduo em teste estava realmente a ver o vídeo que induzia esse estado emocional. Os FP são os casos em que as classes são previstas como *stress*, mas na realidade o indivíduo estava a ver o vídeo que induzia o estado emocional calmo. Por outro lado, os TN correspondem aos casos em que as instâncias foram classificadas como calmo e o vídeo em observação foi o correspondente e os FN são as situações em que as classes são identificadas como calmo, mas na realidade o vídeo era o de *stress*.

Os métodos de avaliação utilizados, calculados através das métricas de confusão supra-referidas, são dados pelas fórmulas seguidamente apresentadas.

$$exatidão = \frac{TP + TN}{TP + FP + TN + FN} \quad (4.2)$$

$$precisão = \frac{TP}{TP + FP} \quad (4.3)$$

$$sensibilidade = \frac{TP}{TP + FN} \quad (4.4)$$

$$f1\_score = 2 * \frac{precisão * sensibilidade}{precisão + sensibilidade} \quad (4.5)$$

Para além destes métodos de avaliação, utilizou-se a técnica de *cross validation*, que consiste em dividir o conjunto de dados em parcelas de dados. Por sua vez, estes dividem-se nos subconjuntos para estimar os parâmetros do modelo e para a validação do mesmo, denominados anteriormente como grupos de treino e teste.

O método usado para aplicar esta técnica foi o *k-fold*, este divide os dados em  $k$  conjuntos do mesmo tamanho e, daí em diante, passa a utilizar um conjunto para teste e os restantes  $k - 1$  para estimar os parâmetros, fazendo-se deste modo o cálculo das métricas de validação do modelo. O processo é realizado  $k$  vezes alternando o conjunto de teste, como é possível observar na figura 4.13 [78].



**Figura 4.13:** Esquema de divisão e execução do método *k-fold*, com  $k = 5$ .

Cada  $k$  vezes que esta técnica é realizada, são calculadas as métricas de validação. Por forma a calcular a média destas de cada iteração, foram criados quatro vetores, correspondentes a cada

métrica, de forma a armazenar estes valores para serem utilizados no término do processo.

## 4.5 Conclusões

Primeiramente, o desenvolvimento dos processos de recolha e preparação dos dados foi ultrapassado sem muitas dificuldades, sendo que o passo mais importante destas tarefas foi a decisão e otimização do local onde colocar os elétrodos. Por esse motivo, foram completados rapidamente com sucesso.

De seguida, no início do desenvolvimento do projeto, como é comum em muitos trabalhos de aprendizagem automática, não se utilizou nenhum método de seleção de características, o que levou a grandes tempos de processamento e maus resultados, sendo que neste tipo de trabalhos são categorizados como maus, todos os resultados abaixo de 60% de exatidão. Os resultados obtidos antes da seleção de características, para os diferentes métodos, podem ser observados nas tabelas B.1, B.2, B.3 e B.4. Através da análise destas tabelas, verifica-se que este passo é crucial para a obtenção de bons resultados de classificação.

Quanto aos métodos de aprendizagem e classificação, foram testados diversos, sendo que foram apresentados nesta dissertação, os cinco melhores. Verificou-se que apesar do número de testes, correspondente às linhas da matriz de trabalho ser reduzido, a quantidade extensa de características quer da matriz completa, com 1050000 colunas, quer da otimizada, com 100000 colunas, levou a que métodos adequados a grandes quantidades de informação fossem mais eficientes e igualmente eficazes.

Por fim, os métodos de validação demonstraram que os resultados foram muito bons, tendo em conta que neste tipo de trabalhos são categorizados como muito bons todos os resultados com exatidão superior a 90%. Estes resultados podem ser observados na tabela 4.5. Pode-se, desta forma, concluir que é possível através destes sensores identificar com elevada exatidão alterações emocionais e retirar a ilação que através destes sensores é possível detetar anomalias físicas, sendo o único obstáculo a estas o ruído associado ao movimento.

**Tabela 4.5:** Resultados finais.

Análise discriminante linear							
tol	Partições	<i>Solver</i>	Exatidão	Precisão	Sensibilidade	F1 score	Tempo (s)
0,001	5	svd	0,9469	1	0,9142	0,9512	5,15
Regressão logística							
C	Partições	<i>Solver</i>	Exatidão	Precisão	Sensibilidade	F1 score	Tempo (s)
1	5	lbfgs	0,9818	0,9714	1	0,9777	10,6247
0,1	5	lbfgs	0,9636	0,9428	1	0,96	11,8165
100	6	liblinear	0,9629	0,9428	1	0,9481	7,5339
Support vector classification							
C	Partições	<i>Kernel</i>	Exatidão	Precisão	Sensibilidade	F1 score	Tempo (s)
0,1	5	linear	0,9636	0,9428	1	0,9666	1,8947
0,1	6	linear	0,9629	0,9428	1	0,9686	2,6934
0,1	6	polinomial	0,9629	0,9428	1	0,9686	2,3256
Classificador ridge							
Alpha	Partições	<i>Solver</i>	Exatidão	Precisão	Sensibilidade	F1 score	Tempo (s)
100	6	auto	0,9629	0,9428	1	0,9686	1,1385
100	6	cholesky	0,9629	0,9428	1	0,9686	1,2957
10	6	svd	0,9629	0,9428	1	0,9686	3,652



## Capítulo 5

# Conclusão e perspetivas de trabalho futuro

Através da elaboração da presente dissertação foi possível colocar em prática alguns dos conhecimentos teórico-práticos adquiridos ao longo do percurso académico na Academia Militar e no Instituto Superior Técnico. Para além disso, ter contacto com as ferramentas OpenSignals [58], Spyder [79] e Scikit-learn [70] foi essencial para o desenvolvimento do produto final.

O principal objetivo do trabalho é explorar a capacidade de, através de modelos de aprendizagem automática, classificar dois estados emocionais, com recurso a dados fisiológicos extraídos por biosensores, e otimizar esta classificação, de forma a obter os melhores resultados de validação no menor tempo possível.

Primeiramente, foi efetuada a introdução do presente trabalho, enquadrando o tema dos biosensores como tecnologias de interesse para fins militares e definindo os objetivos do mesmo.

Numa segunda fase, para obter bases teóricas, foi estudado o estado da arte dos temas abordados na restante dissertação, nomeadamente, microcontroladores, transmissão e receção de dados, sensores, atuadores e, por fim, aprendizagem automática. Estes conteúdos estão largamente aprofundados e o estudo dos sensores está, maioritariamente, direcionado para os ramos da medicina e do desporto sendo, desta forma, facilmente transposta a sua aplicação no Soldado do Futuro e, conseqüentemente, no meio militar.

Seguidamente, executou-se a descrição individual de cada componente do *BITalino (r)evolution Plugged Kit*, meio de aquisição dos dados biométricos, necessário para a realização de estudos posteriores. Para cada componente, foi realizada uma pequena descrição do mesmo, explicitada a forma de aplicação, apresentados os resultados de teste e referidas as especificações e características.

Foram também feitos alguns testes preliminares com os objetivos de testar a compatibilidade dos

sensores da BITalino com o Arduino Uno e verificar as vantagens e desvantagens da utilização deste microcontrolador, comparativamente ao BITalino. Para além disso, estes testes permitiram uma adaptação à utilização dos sensores, o que levou a uma realização mais fluída dos testes feitos aos alunos.

Por fim, foi necessário efetuar a recolha de dados, através de testes realizados a 33 alunos, com o objetivo de desenvolver processos de classificação. De forma a otimizar as predições obtidas, recorreu-se a diversos modelos de classificação e estes foram analisados, cuidadosamente, através das métricas de validação, para verificar qual a melhor solução para o problema em questão.

Ao longo do desenvolvimento do trabalho surgiram alguns desafios, inicialmente relacionados com a parte prática, mais especificamente, onde e como otimizar o local de colocação dos elétrodos de cada sensor e, após estes serem ultrapassados, surgiram adversidades relacionadas com a obtenção de bons resultados finais de validação, contudo estas adversidades foram superadas.

Pelas razões supra-referidas, o desenvolvimento desta dissertação foi acima de tudo desafiador, visto que permitiu explorar uma área desconhecida para o autor, a bioengenharia, parte integrante do quotidiano e com especial interesse para o meio militar.

Terminado o trabalho, é possível afirmar que todos os objetivos pré-propostos foram cumpridos e a "Incorporação de Biossensores no Soldado do Futuro" é um tema de relevo e bastante atual.

No futuro, seria importante testar os métodos desenvolvidos num ambiente menos controlado, bem como, acrescentar outros sensores ao sistema de análise, tais como o EEG e o *Functional Near-Infrared Spectroscopy* (FNIRS), ideais para acoplar a um capacete. Para o desenvolvimento desta área no meio militar, é bastante relevante não só o estudo dos sensores em conjunto, como realizado neste trabalho, mas também a extração de informação dos sensores individualmente, com destaque na exploração da capacidade do AED de identificar o estado de hidratação dos militares. A par destas propostas, uma classificação multi-classe, invés de binária, apesar de mais complexa, pode tornar-se uma melhor ferramenta de apoio aos profissionais de saúde, salientando que para que estas ferramentas sejam úteis para estes, é necessário ter atenção à interpretabilidade dos modelos.

# Bibliografia

- [1] T. Marur, Y. Tuna, and S. Demirci, "Facial anatomy," *Clinics in Dermatology*, vol. 32, no. 1, pp. 14–23, 2014, red Face Revisited: I. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0738081X13000898>
- [2] J. L. D. Gamella, "Stass ii standard architecture for soldier systems-data management and infrastructure," <https://eda.europa.eu/docs/default-source/documents/stass-ii-information-paper.docx>, 2017, accessed 06/01/2022.
- [3] B. Bracken, "Augmented training by monitoring, extracting, and decoding indicators of cognitive load (medic)," 2019, accessed 10/11/2021. [Online]. Available: <https://cra.com/projects/medic/>
- [4] C. Unsalan, D. Barkana, and H. Gurhan, *Embedded Digital Control with Microcontrollers: Implementation with C and Python*. Hoboken, NJ : Wiley, 2021, 2021.
- [5] H. Plácido da Silva, J. Guerreiro, A. Lourenco, A. Fred, and R. Martins, "Bitalino: A novel hardware framework for physiological computing," pp. 246–253, 2014.
- [6] A. Vassiliev, T. Ivanova, D. Cabezas Tapia, and Q. Luong, "Microcontroller-based embedded system equipment development for research and educational support," in *2016 International Conference on Information Management and Technology (ICIMTech)*, 2016, pp. 219–223.
- [7] J. Stankovic, "Misconceptions about real-time computing: a serious problem for next-generation systems," *Computer*, vol. 21, no. 10, pp. 10–19, 1988.
- [8] J. A. Stankovic, "Real-time and embedded systems," *ACM Comput. Surv.*, vol. 28, no. 1, p. 205–208, 1996, accessed 03/01/2022. [Online]. Available: <https://doi.org/10.1145/234313.234400>
- [9] T. Kramp, R. Kranenburg, and S. Lange, "Introduction to the internet of things," pp. 1–10, 2013.
- [10] Y. E. Gelogo, J.-W. Oh, J. W. Park, and H.-K. Kim, "Internet of things (iot) driven u-healthcare system architecture," in *2015 8th International Conference on Bio-Science and Bio-Technology (BSBT)*, 2015, pp. 24–26.

- [11] P. Czurak, C. Maj, M. Szermer, and W. Zabierowski, "Impact of bluetooth low energy on energy consumption in android os," in *2018 XIV-th International Conference on Perspective Technologies and Methods in MEMS Design (MEMSTECH)*, 2018, pp. 255–258.
- [12] J. Fraden, *Handbook of Modern Sensors: Physics, Designs, and Applications (Handbook of Modern Sensors)*. SpringerVerlag, 2003.
- [13] D. B. Patel, P. G. Sinha, and N. Goel, "Introduction to sensors," 2020.
- [14] D. O'Sullivan and T. Igoe, *Physical Computing: Sensing and Controlling the Physical World with Computers*. Boston, MA, USA: Course Technology Press, 2004.
- [15] A. Sassolas, L. J. Blum, and B. D. Leca-Bouvier, "Immobilization strategies to develop enzymatic biosensors," *Biotechnology Advances*, vol. 30, no. 3, pp. 489–511, 2012. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S073497501100156X>
- [16] S. Nambiar and J. T. W. Yeow, "Conductive polymer-based sensors for biomedical applications." *Biosensors & bioelectronics*, vol. 26 5, pp. 1825–32, 2011.
- [17] D. R. Thevenot, K. Tóth, R. A. Durst, and G. S. Wilson, "Electrochemical biosensors: Recommended definitions and classification," *Pure and Applied Chemistry*, vol. 71, no. 12, pp. 2333–2348, 1999, accessed 21/12/2021. [Online]. Available: <https://doi.org/10.1351/pac199971122333>
- [18] A. Sassolas, L. J. Blum, and B. D. Leca-Bouvier, "Immobilization strategies to develop enzymatic biosensors," *Biotechnology Advances*, vol. 30, no. 3, pp. 489–511, 2012, accessed 15/11/2021. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S073497501100156X>
- [19] A. Turner, I. Karube, and G. Wilson, "Biosensor fundamentals and applications," 1987.
- [20] S. Higson and P. Vadgama, "Biosensors: a viable monitoring technology?" *Medical & biological engineering & computing*, vol. 32, pp. 601–9, 1994.
- [21] R. S. Lazarus, "From psychological stress to the emotions: A history of changing outlooks," *Annual Review of Psychology*, vol. 44, no. 1, pp. 1–22, 1993, accessed 11/01/2022. [Online]. Available: <https://doi.org/10.1146/annurev.ps.44.020193.000245>
- [22] R. W. Picard, S. Fedor, and Y. Ayzenberg, "Multiple Arousal Theory and Daily-Life Electrodermal Activity Asymmetry," *Emotion Review*, pp. 1–14, 2015, accessed 11/01/2022. [Online]. Available: <http://emr.sagepub.com/content/early/2015/02/20/1754073914565517>

- [23] A. Greco, G. Valenza, J. Lazaro, J. M. Garzon-Rey, J. Aguilo, C. De-la Camara, R. Bailon, and E. P. Scilingo, "Acute stress state classification based on electrodermal activity modeling," *IEEE Transactions on Affective Computing*, pp. 1–1, 2021.
- [24] R. Horlings, D. Datcu, and L. Rothkrantz, "Emotion recognition using brain activity," p. 6, 2008.
- [25] Y. Liu, O. Sourina, and M. K. Nguyen, "Real-time eeg-based emotion recognition and its applications," *Transactions on Computational Science*, vol. 12, pp. 256–277, 2011.
- [26] D. K. Noda, G. V. Junior, and P. Marchetti, "Artigo de revisão: A eletromiografia de superfície em estudos relativos à produção de força," 2014, accessed 20/11/2021. [Online]. Available: <https://www.researchgate.net/publication/268870576>
- [27] M. Kuzmynikh, O. Matviyukiv, and M. Lobur, "Analysis of electromyography methods for healthcare monitoring," in *2017 XIIIth International Conference on Perspective Technologies and Methods in MEMS Design (MEMSTECH)*, 2017, pp. 101–104.
- [28] D. Chaffin, "Localized muscle fatigue — definition and measurement," *Journal of occupational medicine. : official publication of the Industrial Medical Association*, vol. 15, pp. 346–54, 1973.
- [29] M. D. F. Ma'as, Masitoh, A. Z. U. Azmi, and Suprijanto, "Real-time muscle fatigue monitoring based on median frequency of electromyography signal," in *2017 5th International Conference on Instrumentation, Control, and Automation (ICA)*, 2017, pp. 135–139.
- [30] G. Yang and S. Yang, "Emotion recognition of electromyography based on support vector machine," in *2010 Third International Symposium on Intelligent Information Technology and Security Informatics*, 2010, pp. 298–301.
- [31] L. S. Lilly, "Pathophysiology of heart disease: A collaborative project of medical students and faculty. 5th ed. baltimore," 2011, accessed 11/11/2021.
- [32] A. Reiss, I. Indlekofer, P. Schmidt, and K. Van Laerhoven, "Deep ppg: Large-scale heart rate estimation with convolutional neural networks," *Sensors*, vol. 19, no. 14, 2019, accessed 12/01/2022. [Online]. Available: <https://www.mdpi.com/1424-8220/19/14/3079>
- [33] J. Healey and R. Picard, "Detecting stress during real-world driving tasks using physiological sensors," *IEEE Transactions on Intelligent Transportation Systems*, vol. 6, no. 2, pp. 156–166, 2005.
- [34] K. Peternel, M. Pogačnik, R. Tavčar, and A. Kos, "A presence-based context-aware chronic stress recognition system," *Sensors*, vol. 12, no. 11, pp. 15 888–15 906, 2012. [Online]. Available: <https://www.mdpi.com/1424-8220/12/11/15888>

- [35] Y. Liu and D. Siqing, "Psychological stress level detection based on electrodermal activity," *Behavioural Brain Research*, vol. 341, 2017.
- [36] C. Setz, B. Arrrich, J. Schumm, R. La Marca, G. Tröster, and U. Ehlert, "Discriminating stress from cognitive load using a wearable eda device," *IEEE Transactions on Information Technology in Biomedicine*, vol. 14, no. 2, pp. 410–417, 2010.
- [37] O. Grigore and I.-V. Bornoiu, "Kohonen neural network stress detection using only electrodermal activity features," *Advances in Electrical and Computer Engineering*, vol. 14, pp. 71–78, 2014.
- [38] W. B. Cannon, "Bodily changes in pain, hunger, fear and rage, an account of recent researches into the function of emotional excitement," 2010.
- [39] A. Rizwan, N. Abu Ali, A. Zoha, M. Ozturk, A. Alomainy, M. A. Imran, and Q. H. Abbasi, "Non-invasive hydration level estimation in human body using galvanic skin response," *IEEE Sensors Journal*, vol. 20, no. 9, pp. 4891–4900, 2020.
- [40] S. Subramanian, R. Barbieri, and E. N. Brown, "A point process characterization of electrodermal activity," in *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2018, pp. 37–40.
- [41] W. Boucsein, *Electrodermal activity*, 2nd ed. Springer Science + Business Media, 2012.
- [42] D. Bach and K. Friston, "Model-based analysis of skin conductance responses: Towards causal models in psychophysiology," *Psychophysiology*, vol. 50, 2012.
- [43] W. O. Tatum, "Handbook of eeg interpretation," 2014.
- [44] M. Ramzan and S. Dawn, "Temporal measures for analysis of emotional states from human electroencephalography signals," in *2019 Twelfth International Conference on Contemporary Computing (IC3)*, 2019, pp. 1–6.
- [45] M. Kostyunina and M. Kulikov, "Frequency characteristics of eeg spectra in the emotions." *Neuroscience and behavioral physiology*, vol. 26 4, pp. 340–3, 1996.
- [46] S. Awasthi and A. Joshi, "Mems accelerometer based system for motion analysis," in *2015 2nd International Conference on Electronics and Communication Systems (ICECS)*, 2015, pp. 762–767.
- [47] C. Glaros, D. Fotiadis, A. Likas, and A. Stafylopatis, "A wearable intelligent system for monitoring health condition and rehabilitation of running athletes," pp. 276 – 279, 2003.

- [48] Y.-C. Kan and C.-K. Chen, "A wearable inertial sensor node for body motion analysis," *IEEE Sensors Journal*, vol. 12, no. 3, pp. 651–657, 2012.
- [49] G. Kapitsaki, A. Achilleos, P. Aziz, and A. Paphitou, "Sensoman: Social management of context sensors and actuators for iot," *Journal of Sensor and Actuator Networks*, vol. 10, p. 68, 2021.
- [50] I. Hunter and S. Lafontaine, "A comparison of muscle with artificial actuators," in *Technical Digest IEEE Solid-State Sensor and Actuator Workshop*, 1992, pp. 178–185.
- [51] G. Wiederhold and J. McCarthy, "Arthur samuel: Pioneer in machine learning," *IBM Journal of Research and Development*, vol. 36, pp. 329 – 331, 1992.
- [52] T. Ayodele, "Types of machine learning algorithms," 2010.
- [53] Z. Lipton, "The mythos of model interpretability," *Communications of the ACM*, vol. 61, 2016.
- [54] M. I. D. Figueiredo, "Interpretabilidade em modelos de avaliação de risco cardiovascular," Master's thesis, INSTITUTO SUPERIOR DE ENGENHARIA DE COIMBRA, 2022.
- [55] J. Li, K. Cheng, S. Wang, F. Morstatter, R. P. Trevino, J. Tang, and H. Liu, "Feature selection: A data perspective," *CoRR*, vol. abs/1601.07996, 2016. [Online]. Available: <http://arxiv.org/abs/1601.07996>
- [56] N. Al Nuaimi, M. Masud, M. Serhani, and N. Zaki, "Streaming feature selection algorithms for big data: A survey," *Applied Computing and Informatics*, vol. ahead-of-print, 2019.
- [57] "Electromyography (emg) sensor user manual," 2020, accessed 14/11/2021. [Online]. Available: <https://bitalino.com/storage/uploads/media/electromyography-emg-user-manual.pdf>
- [58] "Opensignals (r)evolution visualize your biosignals," 2021, accessed 13/11/2021. [Online]. Available: <https://bitalino.com/downloads/software>
- [59] "Electrocardiography (ecg) sensor user manual," 2020, accessed 21/11/2021. [Online]. Available: [https://biosignalsplux.com/downloads/docs/manuals/Electrocardiography\\_\(ECG\)\\_User\\_Manual.pdf](https://biosignalsplux.com/downloads/docs/manuals/Electrocardiography_(ECG)_User_Manual.pdf)
- [60] A. Drachen, G. Yannakakis, L. E. Nacke, and A. L. Pedersen, "Correlation between heart rate, electrodermal activity and player experience in first-person shooter games," pp. 49–54, 2010.
- [61] "Electrodermal activity (eda) sensor user manual," 2020, accessed 5/12/2021. [Online]. Available: <https://bitalino.com/storage/uploads/media/electrodermal-activity-eda-user-manual-reva.pdf>
- [62] "Biosignal acquisition tool-kit for advanced research applications electroencephalography (eeg) sensor user manual," 2020, accessed 21/12/2021. [Online]. Available: [https://biosignalsplux.com/downloads/docs/manuals/Electroencephalography\\_\(EEG\)\\_User\\_Manual.pdf](https://biosignalsplux.com/downloads/docs/manuals/Electroencephalography_(EEG)_User_Manual.pdf)

- [63] S. Awasthi and A. Joshi, "Mems accelerometer based system for motion analysis," in *2015 2nd International Conference on Electronics and Communication Systems (ICECS)*, 2015, pp. 762–767.
- [64] "Accelerometer (acc) sensor data sheet," 2020, accessed 20/12/2021. [Online]. Available: <https://bitalino.com/storage/uploads/media/revolution-acc-sensor-datasheet-revb.pdf>
- [65] J. Guerreiro, A. Lourenco, H. Plácido da Silva, and A. Fred, "Performance comparison of low-cost hardware platforms targeting physiological computing applications," 2013.
- [66] Chinese company pico releases a new standalone vr headset. Accessed 28/05/2022. [Online]. Available: <https://www.scmp.com/abacus/tech/article/3028716/chinese-company-pico-releases-new-standalone-vr-headset>
- [67] A. Němcová, L. Maršánová, R. Smisek, M. Vitek, and J. Kolářová, "Recommendations for ecg acquisition using bitalino," [https://www.researchgate.net/publication/308984068\\_RECOMMENDATIONS\\_FOR\\_ECG\\_ACQUISITION\\_USING\\_BITALINO](https://www.researchgate.net/publication/308984068_RECOMMENDATIONS_FOR_ECG_ACQUISITION_USING_BITALINO), 2016, accessed 10/02/2022.
- [68] Y. Chen, Z. Yang, and J. Wang, "Eyebrow emotional expression recognition using surface emg signals," *Neurocomputing*, vol. 168, 2015.
- [69] "What is .npy files and why you should use them." accessed 27/05/2022. [Online]. Available: <https://towardsdatascience.com/what-is-npy-files-and-why-you-should-use-them-603373c78883>
- [70] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay, "Scikit-learn: Machine learning in Python," *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.
- [71] J. Brownlee. How to choose a feature selection method for machine learning. Accessed 28/08/2022. [Online]. Available: <https://machinelearningmastery.com/feature-selection-with-real-and-categorical-data/>
- [72] Y. Xiaozhou. Linear discriminant analysis, explained. Accessed 15/09/2022. [Online]. Available: <https://towardsdatascience.com/linear-discriminant-analysis-explained-f88be6c1e00b>
- [73] V. V. Putri Wibowo, Z. Rustam, A. R. Laeli, and A. A. Sa'id, "Logistic regression and logistic regression-genetic algorithm for classification of liver cancer data," in *2021 International Conference on Decision Aid Sciences and Application (DASA)*, 2021, pp. 244–248.
- [74] A. Kumar and M. H. Kolekar, "Machine learning approach for epileptic seizure detection using wavelet analysis of eeg signals," in *2014 International Conference on Medical Imaging, m-Health and Emerging Communication Systems (MedCom)*, 2014, pp. 412–416.

- [75] C. Dabakoglu. What is support vector machine (svm)? - with python. Accessed 10/09/2022. [Online]. Available: <https://medium.com/@cdabakoglu/what-is-support-vector-machine-svm-fd0e9e39514f>
- [76] A. V. Srinivasan. Stochastic gradient descent — clearly explained. Accessed 16/09/2022. [Online]. Available: <https://towardsdatascience.com/stochastic-gradient-descent-clearly-explained-53d239905d31>
- [77] X. Wang, L. Yan, and Q. Zhang, "Research on the application of gradient descent algorithm in machine learning," in *2021 International Conference on Computer Network, Electronic and Automation (ICCNEA)*, 2021, pp. 11–15.
- [78] "Cross-validation: evaluating estimator performance." accessed 28/07/2022. [Online]. Available: [https://scikit-learn.org/stable/modules/cross\\_validation.html](https://scikit-learn.org/stable/modules/cross_validation.html)
- [79] P. Raybaut, "Spyder-documentation," *Available online at: pythonhosted.org*, 2009.
- [80] C. Carreiras, A. P. Alves, A. Lourenço, F. Canento, H. Silva, A. Fred *et al.*, "BioSPPy: Biosignal processing in Python," 2015–, accessed 06/01/2022. [Online]. Available: <https://github.com/PIA-Group/BioSPPy/>





Seguem-se os códigos utilizados e referidos na presente dissertação.

**Listagem A.1:** Código de limpeza.

```
1 import numpy as np
2
3 AUX = np.loadtxt('file1.txt')
4
5 with open('file2.txt','w') as file2:
6     file2.write('# Simple Text Format
7     \n# Sampling Rate (Hz):= 1000.00 \n# Resolution:= 12
8     \n# Labels:= ECG\n')
9
10    for c in range(10000):
11        a = AUX[c,5]
12        file2.write(str(a))
13        file2.write('\n')
14 pass
```

**Listagem A.2:** Produção dos gráficos para os sensores sem filtro [80].

```
1 import numpy as np
2 import pylab as pl
3 from biosppy import storage
4
5 signal, mdata = storage.loadtxt('./file2.txt')
6 Fs = mdata['sampling_rate']
7 N = len(signal) # number of samples
8 T = (N - 1) / Fs # duration
9 ts = np.linspace(0, T, N, endpoint=False) # relative timestamps
10 pl.plot(ts, signal, lw=2)
11 pl.grid()
12 pl.show()
```

**Listagem A.3:** Produção dos gráficos para os sensores *raw* e filtrados (ECG) [80].

```
1 from biosppy import storage
2 from biosppy.signals import ecg
```

```

3
4 # load raw ECG signal
5 signal, mdata = storage.loadtxt('./file2.txt')
6
7 # process it and plot
8 out = ecg.ecg(signal=signal, sampling_rate=1000., show=True)

```

**Listagem A.4:** Código para Arduino Uno que permite um LED piscar com o ritmo cardíaco, lido pelo sensor.

```

1
2 #include <Wire.h>
3 #include <LiquidCrystal_I2C.h>
4 int sensorValue;
5 int a;
6 LiquidCrystal_I2C lcd(0x27, 16, 2);
7 void setup(){
8     lcd.begin();
9     lcd.backlight();
10    pinMode(12, OUTPUT);
11    Serial.begin(115200);           // serial port to 115200
12 }
13 void loop(){sensorValue = analogRead(0);
14 Serial.print("Val=");
15 Serial.print(sensorValue, DEC);
16 Serial.println(" ");
17 lcd.setCursor(0,0);
18 lcd.print("Val=");
19 lcd.print(sensorValue,DEC);
20 lcd.print(" ");
21 lcd.println(" ");
22 lcd.print(" ");
23 delay(10);
24 a=(sensorValue*255)/680;
25 analogWrite(10,a);
26 }

```

**Listagem A.5:** Código para Arduino Uno que permite um buzzer ligar e desligar em resposta a contrações musculares.

```
1 #include <Wire.h>
2 #include <LiquidCrystal_I2C.h>
3 int sensorValue;
4 int a;
5 LiquidCrystal_I2C lcd(0x27, 16, 2);
6 void setup(){
7   lcd.begin();
8   lcd.backlight();
9   pinMode(12, OUTPUT);
10  Serial.begin(115200);           // serial port to 115200
11 }
12 void loop(){sensorValue = analogRead(0);
13 Serial.print("Val=");
14 Serial.print(sensorValue, DEC);
15 Serial.println(" ");
16 lcd.setCursor(0,0);
17 lcd.print("Val=");
18 lcd.print(sensorValue,DEC);
19 lcd.print(" ");
20 lcd.println(" ");
21 lcd.print(" ");
22 delay(10);
23 if(sensorValue>270) {
24 tone(12,1500);
25 delay(10);
26 }
27 else {
28   noTone(12);
29 }
30 }
```

**Listagem A.6:** Código de contagem de linhas.

```
1 fname = input("Nome do ficheiro : ")
2 infile=open(fname)
3
```

```

4 numLines = 0
5
6 for line in infile:
7     numLines += 1
8 print("Linhas: ", numLines)

```

**Listagem A.7:** Código de contagem de tempo.

```

1 import timeit
2 start = timeit.default_timer()
3
4 # Codigo aqui
5
6 stop = timeit.default_timer()
7
8 print('Time: ', stop - start)

```

**Listagem A.8:** Código que cria a matriz de trabalho.

```

1 import numpy as np
2
3 b = []
4 z = 0
5 e = np.zeros([56,1050000])
6
7 def createmat(file, inicio, fim):
8     AUX = np.loadtxt(file)
9
10    for c in range(inicio, fim):
11        b.append(AUX[c, 5])
12    for c in range(inicio, fim):
13        b.append(AUX[c, 6])
14    for c in range(inicio, fim):
15        b.append(AUX[c, 7])
16 fname = []
17 a = 4
18 index = 0
19 for w in range(0, 28):

```

```

20     fname.append(str(a)+'.1.txt')
21     fname.append(str(a)+'.2.txt')
22     a=a+1
23     if a == 16:
24         a=a+2
25
26 for w in range(0,56):
27     createmat(fname[index], 10000, 360000)
28     index=index+1
29
30 d = np.asarray(b)
31
32 for x in range(0,56):
33     for y in range(0,1050000):
34         e[x,y] = d[z]
35         z=z+1
36
37 np.save('mat.npy',e)

```

**Listagem A.9:** Código de seleção das 100000 melhores características.

```

1 from sklearn.feature_selection import SelectKBest, f_classif
2 import numpy as np
3
4
5 x_train = np.load('fullymat.npy')
6 y_train = np.load('y56.npy')
7 y_train = y_train.reshape(56,)
8
9 X_new = SelectKBest(score_func = f_classif, k=100000).fit_transform(x_train,y_train)
10
11
12 np.save('kbestmat.npy',X_new)

```

**Listagem A.10:** Código de otimização dos parâmetros da regressão logística.

```

1 import numpy as np
2

```

```

3 from sklearn.model_selection import KFold
4
5 from sklearn.linear_model import LogisticRegression
6
7 import statistics
8 from sklearn.metrics import accuracy_score
9 from sklearn.metrics import precision_score
10 from sklearn.metrics import recall_score
11 from sklearn.metrics import f1_score
12
13
14 x_train = np.load('kbestfullymat.npy')
15 y_train = np.load('y56.npy')
16 y_train = y_train.reshape(56,)
17
18
19 c = [0.1 , 1 , 10 , 100 , 1000]
20 k = ['newton-cg', 'lbfgs', 'liblinear', 'sag']
21 n = [4 , 5 , 6]
22 AUXc = [0 , 0 , 0]
23 AUXk = [0, 0 , 0]
24 AUXs = [0 , 0 , 0]
25
26 AUXacc = [0 , 0 , 0]
27 AUXp = [0 , 0 , 0]
28 AUXr = [0 , 0 , 0]
29 AUXf = [0 , 0 , 0]
30 AUXa = [0 , 0 , 0]
31 AUXv = [0 , 0 , 0]
32 AUXmean = []
33 # k fold, separa a matriz original em n grupos
34 # testa e valida z vezes, sem repetir valores
35 for z in n:
36     acc_score=[]
37     p_score=[]
38     r_score=[]
39     f_score=[]
40     a_score=[]

```

```

41
42 kf = KFold(n_splits=z, shuffle=True, random_state=3)
43 for x in c:
44     for y in k:
45
46         for train, fit in kf.split(x_train):
47
48             x_train80= x_train[train]
49             x_train20= x_train[fit]
50             y_train80= y_train[train]
51             y_train20= y_train[fit]
52
53             #Support Vector Classifier
54             clf = LogisticRegression( C=x , solver=y,max_iter=1000)
55             clf.fit(x_train80,y_train80)
56             prediction = clf.predict(x_train20)
57             print (prediction)
58
59             acc = accuracy_score(prediction,y_train20)
60             precision = precision_score(prediction,y_train20)
61             recall = recall_score(prediction,y_train20)
62             f1 = f1_score(prediction,y_train20)
63
64             acc_score.append(acc)
65             p_score.append(precision)
66             r_score.append(recall)
67             f_score.append(f1)
68
69             mean_acc = statistics.mean(acc_score)
70             mean_p = statistics.mean(p_score)
71             mean_r = statistics.mean(r_score)
72             mean_f = statistics.mean(f_score)
73
74             AUXmean.append(mean_acc)
75             AUXmean.append(mean_p)
76             AUXmean.append(mean_r)
77             AUXmean.append(mean_f)
78

```

```

79     mean_val = statistics.mean(AUXmean)
80     AUXmean = []
81
82     if mean_val > AUXv[0]:
83         AUXc[0] = x
84         AUXk[0] = y
85         AUXs[0] = z
86
87         AUXacc[0] = mean_acc
88         AUXp[0] = mean_p
89         AUXr[0] = mean_r
90         AUXf[0] = mean_f
91
92         AUXv[0] = mean_val
93     elif mean_val > AUXv[1]:
94         AUXc[1] = x
95         AUXk[1] = y
96         AUXs[1] = z
97
98         AUXacc[1] = mean_acc
99         AUXp[1] = mean_p
100        AUXr[1] = mean_r
101        AUXf[1] = mean_f
102
103        AUXv[1] = mean_val
104    elif mean_val > AUXv[2]:
105        AUXc[2] = x
106        AUXk[2] = y
107        AUXs[2] = z
108
109        AUXacc[2] = mean_acc
110        AUXp[2] = mean_p
111        AUXr[2] = mean_r
112        AUXf[2] = mean_f
113
114        AUXv[2] = mean_val

```

**Listagem A.11:** Código de otimização dos parâmetros da SVC.

```
1 import numpy as np
2
3 from sklearn.model_selection import KFold
4
5 from sklearn.svm import SVC
6
7 import statistics
8 from sklearn.metrics import accuracy_score
9 from sklearn.metrics import precision_score
10 from sklearn.metrics import recall_score
11 from sklearn.metrics import f1_score
12
13
14 x_train = np.load('kbestfullymat.npy')
15 y_train = np.load('y56.npy')
16 y_train = y_train.reshape(56,)
17
18
19 c = [0.1 , 1 , 10 , 100 , 1000]
20 k = ['linear', 'poly', 'rbf', 'sigmoid']
21 n = [4 , 5 , 6]
22 AUXc = [0 , 0 , 0]
23 AUXk = [0, 0 , 0]
24 AUXkf = [0 , 0 , 0]
25
26 AUXacc = [0 , 0 , 0]
27 AUXp = [0 , 0 , 0]
28 AUXr = [0 , 0 , 0]
29 AUXf = [0 , 0 , 0]
30 AUXa = [0 , 0 , 0]
31 AUXv = [0 , 0 , 0]
32 AUXmean = []
33 # k fold, separa a matriz original em n grupos
34 # testa e valida z vezes, sem repetir valores
35 for z in n:
36     acc_score=[]
37     p_score=[]
```

```

38     r_score=[]
39     f_score=[]
40     a_score=[]
41
42     kf = KFold(n_splits=z,shuffle=True,random.state=3)
43     for x in c:
44         for y in k:
45
46             for train, fit in kf.split(x_train):
47
48                 x_traink= x_train[train]
49                 x_test= x_train[fit]
50                 y_traink= y_train[train]
51                 y_test= y_train[fit]
52
53                 #Support Vector Classifier
54                 s_clf = SVC( C=x , kernel=y)
55                 s_clf.fit(x_traink,y_traink)
56                 prediction = s_clf.predict(x_test)
57                 print (prediction)
58
59                 acc = accuracy_score(prediction,y_test)
60                 precision = precision_score(prediction,y_test)
61                 recall = recall_score(prediction,y_test)
62                 f1 = f1_score(prediction,y_test)
63
64                 acc_score.append(acc)
65                 p_score.append(precision)
66                 r_score.append(recall)
67                 f_score.append(f1)
68
69                 mean_acc = statistics.mean(acc_score)
70                 mean_p = statistics.mean(p_score)
71                 mean_r = statistics.mean(r_score)
72                 mean_f = statistics.mean(f_score)
73
74                 AUXmean.append(mean_acc)
75                 AUXmean.append(mean_p)

```

```

76     AUXmean.append(mean_r)
77     AUXmean.append(mean_f)
78
79     mean_val = statistics.mean(AUXmean)
80     AUXmean = []
81
82     if mean_val > AUXv[0]:
83         AUXc[0] = x
84         AUXk[0] = y
85         AUXkf[0] = z
86
87         AUXacc[0] = mean_acc
88         AUXp[0] = mean_p
89         AUXr[0] = mean_r
90         AUXf[0] = mean_f
91
92         AUXv[0] = mean_val
93     elif mean_val > AUXv[1]:
94         AUXc[1] = x
95         AUXk[1] = y
96         AUXkf[1] = z
97
98         AUXacc[1] = mean_acc
99         AUXp[1] = mean_p
100        AUXr[1] = mean_r
101        AUXf[1] = mean_f
102
103        AUXv[1] = mean_val
104    elif mean_val > AUXv[2]:
105        AUXc[2] = x
106        AUXk[2] = y
107        AUXkf[2] = z
108
109        AUXacc[2] = mean_acc
110        AUXp[2] = mean_p
111        AUXr[2] = mean_r
112        AUXf[2] = mean_f
113

```

```
114 AUXv[2] = mean_val
```

**Listagem A.12:** Código de otimização dos parâmetros do classificador *ridge*.

```
1 import numpy as np
2
3 from sklearn.model_selection import KFold
4
5 from sklearn.linear_model import RidgeClassifier
6
7 import statistics
8 from sklearn.metrics import accuracy_score
9 from sklearn.metrics import precision_score
10 from sklearn.metrics import recall_score
11 from sklearn.metrics import f1_score
12
13
14 x_train = np.load('kbestfullymat.npy')
15 y_train = np.load('y56.npy')
16 y_train = y_train.reshape(56,)
17
18
19 c = [ 0.001, 0.01, 0.1 , 1 , 10 , 100 , 1000]
20 k = ['auto', 'svd', 'cholesky', 'lsqr', 'sparse_cg', 'sag', 'saga']
21 n = [4 , 5 , 6]
22 AUXc = [0 , 0 , 0]
23 AUXk = [0, 0 , 0]
24 AUXs = [0 , 0 , 0]
25
26 AUXacc = [0 , 0 , 0]
27 AUXp = [0 , 0 , 0]
28 AUXr = [0 , 0 , 0]
29 AUXf = [0 , 0 , 0]
30 AUXa = [0 , 0 , 0]
31 AUXv = [0 , 0 , 0]
32 AUXmean = []
33 # k fold, separa a matriz original em n grupos
34 # testa e valida z vezes, sem repetir valores
```

```

35 for z in n:
36     acc_score=[]
37     p_score=[]
38     r_score=[]
39     f_score=[]
40     a_score=[]
41
42     kf = KFold(n_splits=z,shuffle=True,random_state=3)
43     for x in c:
44         for y in k:
45
46             for train, fit in kf.split(x_train):
47
48                 x_train80= x_train[train]
49                 x_train20= x_train[fit]
50                 y_train80= y_train[train]
51                 y_train20= y_train[fit]
52
53                 #Support Vector Classifier
54                 clf = RidgeClassifier(alpha=x , solver=y)
55                 clf.fit(x_train80,y_train80)
56                 prediction = clf.predict(x_train20)
57                 print (prediction)
58
59                 acc = accuracy_score(prediction,y_train20)
60                 precision = precision_score(prediction,y_train20)
61                 recall = recall_score(prediction,y_train20)
62                 f1 = f1_score(prediction,y_train20)
63
64                 acc_score.append(acc)
65                 p_score.append(precision)
66                 r_score.append(recall)
67                 f_score.append(f1)
68
69                 mean_acc = statistics.mean(acc_score)
70                 mean_p = statistics.mean(p_score)
71                 mean_r = statistics.mean(r_score)
72                 mean_f = statistics.mean(f_score)

```

```

73
74     AUXmean.append(mean_acc)
75     AUXmean.append(mean_p)
76     AUXmean.append(mean_r)
77     AUXmean.append(mean_f)
78     mean_val = statistics.mean(AUXmean)
79     AUXmean = []
80
81     if mean_val > AUXv[0]:
82         AUXc[0] = x
83         AUXk[0] = y
84         AUXs[0] = z
85
86         AUXacc[0] = mean_acc
87         AUXp[0] = mean_p
88         AUXr[0] = mean_r
89         AUXf[0] = mean_f
90
91         AUXv[0] = mean_val
92     elif mean_val > AUXv[1]:
93         AUXc[1] = x
94         AUXk[1] = y
95         AUXs[1] = z
96
97         AUXacc[1] = mean_acc
98         AUXp[1] = mean_p
99         AUXr[1] = mean_r
100        AUXf[1] = mean_f
101
102        AUXv[1] = mean_val
103    elif mean_val > AUXv[2]:
104        AUXc[2] = x
105        AUXk[2] = y
106        AUXs[2] = z
107
108        AUXacc[2] = mean_acc
109        AUXp[2] = mean_p
110        AUXr[2] = mean_r

```

```
111         AUXf[2] = mean_f
112         AUXv[2] = mean_val
```

## Apêndice B

# Tabelas de resultados

Neste apêndice são apresentadas as tabelas com os resultados dos classificadores, antes de aplicado o método de seleção de características SelectkBest.

**Tabela B.1:** Resultados prévios à seleção de características da análise discriminante linear.

tol	Partições ( $k$ )	Solver	Exatidão	Precisão	Sensibilidade	<i>F1 score</i>	Tempo ( $s$ )
0,001	5	svd	0,4969	0,2738	0,5	0,3388	53,7445

**Tabela B.2:** Resultados prévios à seleção de características da regressão logística.

C	Partições ( $k$ )	Solver	Exatidão	Precisão	Sensibilidade	<i>F1 score</i>	Tempo ( $s$ )
1	5	lbfgs	0,4818	0,6295	0,5048	0,5149	126,4903
0,1	5	lbfgs	0,4818	0,5723	0,5192	0,4884	131,5099
100	6	liblinear	0,4462	0,4654	0,5112	0,3765	84,0587

**Tabela B.3:** Resultados prévios à seleção de características do SVC.

C	Partições ( $k$ )	Kernel	Exatidão	Precisão	Sensibilidade	<i>F1 score</i>	Tempo ( $s$ )
0,1	5	linear	0,4106	0,5342	0,362	0,4132	19,3378
0,1	6	linear	0,374	0,4654	0,4495	0,3505	20,5125
0,1	6	polinomial	0,3575	0,5	0,1777	0,2584	21,1884

**Tabela B.4:** Resultados prévios à seleção de características do classificador *ridge*.

Alpha	Partições ( $k$ )	Solver	Exatidão	Precisão	Sensibilidade	<i>F1 score</i>	Tempo ( $s$ )
100	6	auto	0,374	0,4654	0,4495	0,3505	9,2309
100	6	cholesky	0,374	0,4654	0,4495	0,3505	8,0035
10	6	svd	0,374	0,4654	0,4495	0,3505	46,2642