

Diana Margarida Fernandes Lourenço

Desenvolvimento de Sistema para Recolha, Armazenamento, Processamento e Análise de Sinais Biométricos para Classificação de Processos Fisiológicos

Dissertação apresentada à Universidade de Coimbra para cumprimento dos requisitos necessários à obtenção do grau de Mestre
em Engenharia Biomédica

Setembro de 2016



UNIVERSIDADE DE COIMBRA



FCTUC FACULDADE DE CIÊNCIAS
E TECNOLOGIA
UNIVERSIDADE DE COIMBRA

**Desenvolvimento de Sistema para Recolha,
Armazenamento, Processamento e Análise de
Sinais Biométricos para Classificação de Processos
Fisiológicos**

Diana Margarida Fernandes Lourenço

Dissertação apresentada à Universidade de Coimbra para
cumprimento dos requisitos necessários à obtenção do grau de Mestre
em Engenharia Biomédica

Orientadores :

Professor Doutor Alberto Cardoso

Professor Doutor César Teixeira

27 de Setembro de 2016

Este trabalho foi desenvolvido com a cooperação do:



CENTRO DE INFORMÁTICA E SISTEMAS DA UNIVERSIDADE DE
COIMBRA

Esta cópia da tese é fornecida na condição de que quem a consulta reconhece que os direitos de autor são pertença do autor da tese e que nenhuma citação ou informação obtida a partir dela pode ser publicada sem a referência apropriada.

This copy of the thesis has been supplied on condition that anyone who consults it is understood to recognize that its copyright rests with its author and that no quotation from the thesis and no information derived from it may be published without proper acknowledgement.

Agradecimentos

Em primeiro lugar, quero agradecer aos meus orientadores, Prof. Alberto Cardoso e Prof. César Teixeira por todo o apoio, motivação e todo o conhecimento que me foi dado, ao longo de todo o projeto. Também, tenho de agradecer aos meus colegas do Laboratório de Informática Industrial e Sistemas, em especial ao Vítor Sousa, por toda a paciência e ajuda e mesmo em tempos de convívio.

A todos os meus amigos, que percorreram comigo todo o percurso académico, que com toda a alegria e com lágrimas à mistura me acompanharam nos momentos que considero mais marcantes e que levo para a vida. Com um carinho especial, quero agradecer à Sara Anjo que me acompanhou nestes últimos três anos, como mais ninguém o fez. A todos os meus amigos vianenses, por animarem os fins de semanas, quando estava presente, com a tipicidade que só nós entendemos.

Também devo um especial agradecimento, ao Ricardo Barata, pelo incondicional apoio, paciência e amizade, nas várias etapas destes últimos anos.

Finalmente, um enorme obrigada à minha família, principalmente pais e irmão, pelo interesse, pela compreensão mesmo quando não estavam presentes. A eles devo tudo o que sou, o que tenho e o que me ajudaram a conquistar.

Resumo

O *stress* é um processo fisiológico que pode ser, em caso de perigo, o responsável pela alerta e a fuga. Contudo, nas últimas décadas, esta vertente positiva do *stress* tem sido esquecida devido ao aumento do número de esgotamentos relacionados com a atividade profissional, provocados pelo acumular de *stress*. Para combater isso, hoje em dia, graças ao desenvolvimento de diversas áreas de estudo, é possível criar dispositivos que permitem entender o funcionamento no nosso próprio corpo.

Neste sentido, o objetivo deste projeto é desenvolver um sistema capaz de adquirir, armazenar, processar e analisar sinais biométricos para a deteção de episódios de *stress*. Para isso, foi necessário estudar uma base de dados específica, o desenvolvimento de um algoritmo de deteção destes eventos e um sistema de aquisição de sinais de eletromiografia, condutividade elétrica da mão, respiração e ritmo cardíaco que, neste caso, foi o sistema *e-Health Sensor Platform Complete Kit V2.0*, desenvolvido pela Cooking Hacks.

Apesar de, no sistema final, apenas se considerar em eventos de *stress* e não-*stress*, foram analisadas, ao longo do projeto, a abordagem binária mas também a multiclasse ('baixo *stress*', 'médio *stress*' e 'alto *stress*'). Relativamente aos resultados, estes sugerem que o algoritmo, aplicado na análise dos sinais, tem a capacidade de discriminar a existência ou não de *stress*, no sistema de aquisição final. Por último, este sistema, desenvolvido a partir deste tipo de *kit* de baixo custo, é uma inovação devido ao facto de não existir, até à data e tanto quanto ao nosso conhecimento, nenhum sistema com esta característica para a deteção de *stress* em tempo real.

Keywords: monitorização, deteção de *stress*, sinais fisiológicos, tempo real, Arduino, sensores.

Abstract

Stress is a physiological process that can be, in case of danger, the responsible for fight or flight reaction. However, in the last decades, this positive meaning of the stress has been forgotten due to the increase of burnout cases, caused by accumulated stress. To fight this, nowadays, thanks to the development in different areas of study, is possible design new devices that allow the understanding of the functioning of our own body.

Concerning this problem, the aim of this project is to develop a system able to acquire, store, process and analyze biometric signals for detection and identification of stress episodes. In this regard, it was necessary to study a specific data base, the development of a stress detection algorithm and a signal acquisition system using eletromyography, galvanic skin response, airflow and heart rate, which in this case was the e-Health Sensor Platform Complete Kit V2.0 from Cooking Hacks.

Although, in the final system, only be considered stress and no stress events, has been analysed, during the project, the binary and multi-class approach ('low stress', 'medium stress' and 'high stress'). Regarding the results, these suggest that the applied algorithm, used for the data base analysis, is able to distinguish stress and no stress events, in the final acquisition system. Finally, this system developed from this kind of low-cost kit is an innovation considering that there is no reference about a similiar approach, until now and the best knowledge, for stress detection in real time.

Keywords: monitoring, stress detection, physiologic signals, real time, Arduino, sensors.

Lista de Figuras

1.1	Tarefas do projeto: planeadas e executadas.	3
2.1	Dinâmica fisiológica do <i>stress</i> , mediado pelo sistema nervoso.	11
2.2	Disposição dos elétrodos.	13
2.3	Diferenças no EEG em diferentes estágios do ciclo sono-vigília.	13
2.4	Secção de tecido muscular do miocárdio.	14
2.5	Secção de tecido do músculo esquelético.	14
2.6	Exemplo ilustrativo de um sinal ECG.	14
2.7	Exemplo de um oxímetro de pulso.	15
2.8	Exemplo de um dispositivo de medição do sinal GSR.	16
2.9	Exemplo de um sinal GSR, durante um evento de <i>stress</i>	16
2.10	Exemplo de um sinal respiratório, onde é claro a existência de 3 períodos respiratórios completos.	16
3.1	Vivago <i>CARE watch</i>	21
3.2	Vivago <i>POINT</i>	21
3.3	Algumas das soluções da Intellicare.	22
3.4	Funcionamento do OneCare <i>Sensing</i>	22
3.5	Aplicação HealthyRoad.	23
3.6	Dados estatísticos da aplicação HealthyRoad.	23
3.7	Active Wellness™.	24
3.8	Componentes da Active Wellness™.	24
3.9	Soluções da PLUX: biosignalsplux, BITalino, physioplux e ergoplux.	26
3.10	<i>e-Health Sensor Shield</i>	26
3.11	<i>e-Health Sensor Platform Complete Kit V2.0</i> com os sensores todos ligados à <i>shield</i>	27
3.12	Local de ligação dos sensores.	28
3.13	Montagem da <i>e-Health Sensor Shield</i> com um Arduino.	28
3.14	Montagem da placa adaptadora e a <i>e-Health Sensor Shield</i> com um Raspberry Pi.	28
4.1	Sinais Biométricos do registo <i>drive11</i>	39
4.2	<i>Marker</i> do registo <i>drive05</i>	40
4.3	<i>Marker</i> do registo <i>drive05</i> e respetivo marcador criado para este registo.	41

4.4	Marker do registo <i>drive05</i> e respetivo marcador (multiclasse) criado para este registo.	42
4.5	Registo <i>drive05</i> , com o respetivo marcador multiclasse e intervalos de amostras a serem eliminadas no pré-processamento, no início do registo, aproximadamente aos 2000 segundos e no final do registo.	44
4.6	Ilustração da análise por janelas deslizantes aplicado.	45
4.7	Sinal Resp, no intervalo entre os 40 e 60 segundos, no respetivo domínio da frequência. A área a azul representa metade da área do sinal e f a frequência corresponde a metade da área total.	47
4.8	Exemplo de uma Árvore de decisão.	51
4.9	Representação esquemática de um percetor de multicamada.	52
4.10	Ilustração da análise por janelas deslizantes aplicado, para a gestão dos alarmes, com um intervalo entre alarmes de 10 segundos.	56
4.11	Fluxograma do funcionamento do modo off-line simulado.	57
4.12	Montagem experimental do Arduino, a <i>shield</i> e dos sensores para os sinais a ser medidos (EMG, GSR, Resp e HR).	58
4.13	Fluxograma do funcionamento do modo <i>on-line</i> , com a configuração do processamento no ramo principal.	60
4.14	Fluxograma do funcionamento do modo <i>on-line</i> , com a configuração da aquisição no ramo principal.	61
5.1	Coeficientes de correlação entre cada uma das <i>features</i> e o respetivo marcador binário, representados numa escala de cinzentos.	65
5.2	Coeficientes de correlação entre cada uma das <i>features</i> e o respetivo marcador multiclasse, representados numa escala de cinzentos.	66
5.3	Coeficientes de correlação entre cada uma das <i>features</i> , com as restantes, representados numa escala de cinzentos.	67
5.4	Tempo de cálculo dos grupos de <i>features</i> , em escala logarítmica e em segundos.	71
5.5	Acc das várias metodologias possíveis de serem usadas.	73
5.6	wAcc das várias metodologias possíveis de serem usadas.	74
5.7	Acc e wAcc dos dois classificadores.	77
5.8	Acc geral da metodologia utilizada num contexto binário e multiclasse, com todos os registos.	80
5.9	wAcc geral da metodologia utilizada num contexto binário e multiclasse, com todos os registos.	80
5.10	Acc da metodologia utilizada, sem os registos R5 e R8 para a classificação binária e sem os registos R7 e R8, para classificação multiclasse.	83
5.11	wAcc da metodologia utilizada, sem os registos R5 e R8 para a classificação binária e sem os registos R7 e R8, para classificação multiclasse.	83
5.12	Fluxograma da interface desenvolvida para o modo <i>on-line</i>	89
C.1	Marcador previsto pelo algoritmo usado e o marcador real extraído da base de dados, para uma classificação binária.	112

C.2 Marcador previsto pelo algoritmo usado e o marcador real extraído da base de dados, para uma classificação multiclasse.	113
---	-----

Lista de Tabelas

3.1	Resumo de alguns dispositivos de deteção de processos e de auxílio ao estudo de sinais fisiológicos.	34
3.2	Métodos e algoritmos de classificação usados nos estudos analisados neste capítulo.	35
4.1	Duração, em minutos, dos segmentos de repouso (R), autoestrada (A), cidade (C), dos segmentos sem informação do nível de <i>stress</i> (S) e duração total de cada um dos registos.	40
4.2	Duração, em minutos, dos segmentos sem <i>stress</i> , com <i>stress</i> , sem informação do nível de <i>stress</i> (S) e duração total de cada um dos registos.	42
4.3	Matriz de Confusão.	53
5.1	Número, designação e descrição de cada uma das <i>features</i> calculadas	64
5.2	Resultado da aplicação do algoritmo mRMR, para uma classificação binária.	68
5.3	Resultado da aplicação do algoritmo mRMR, para uma classificação multiclasse.	69
5.4	Designação e parâmetros em avaliação das metodologias avaliadas. .	72
5.5	<i>Accuracy</i> simples das várias metodologias possíveis de serem utilizadas, em percentagem.	73
5.6	wAcc das várias metodologias possíveis de serem usadas, em percentagem.	74
5.7	Sensibilidade e Especificidade, em percentagem, das várias metodologias possíveis de serem usadas.	75
5.8	AUC, em percentagem, das várias metodologias possíveis de serem usadas.	76
5.9	Sensibilidade e Especificidade, em percentagem, dos dois classificadores.	78
5.10	AUC dos dois classificadores.	78
5.11	Razão entre o tempo dispendido e o tamanho da janela (da primeira janela e seguintes), em modo <i>off-line</i> , em percentagem.	79
5.12	Sensibilidade, Especificidade e AUC em contexto binário e multiclasse, com todos os registos.	80
5.13	Acc e wAcc de cada ensaio de teste, em percentagem.	81
5.14	Sensibilidade, Especificidade e AUC, em percentagem, de cada ensaio de teste, para a classeB.	82

5.15	Sensibilidade, Especificidade e AUC, em percentagem, de cada ensaio de teste, para uma classificação multiclasse.	82
5.16	Sensibilidade, Especificidade e AUC, sem os registos R5 e R8 para a classificação binária e sem os registos R7 e R8, para a classificação multiclasse.	83
5.17	Tempo de execução do processamento e análise dos sinais, do 1 ^o ciclo de cálculo e dos restantes ciclos de cálculo, em segundos. . . .	85
A.1	Número e respetivo nome dos registos da base de dados.	103
A.2	Nome e significado das classes usadas.	104
A.3	Número, designação e descrição de cada uma das <i>features</i>	104
A.4	Designação e parâmetros em avaliação das metodologias avaliadas. .	105
B.1	Coefficientes de correlação entre cada uma <i>features</i> e o respetivo marcador binário.	108
B.2	Coefficientes de correlação entre cada uma <i>features</i> e o respetivo marcador multiclasse.	108
B.3	Coefficientes de correlação entre cada uma das <i>features</i> , e as restantes.	109

Lista de Conteúdos

Agradecimentos	ix
Resumo	xi
Abstract	xiii
Lista de Figuras	xiv
Lista de Tabelas	xix
Lista de Conteúdos	xxi
Abreviaturas	xxiii
Glossário	xxiv
1 Introdução	1
1.1 Contextualização	1
1.2 Motivação	2
1.3 Objetivos	2
1.4 Planeamento	3
1.5 Estrutura do Documento	5
1.6 Síntese	5
2 Contextualização da Fisiologia do <i>Stress</i>	7
2.1 Fisiologia do <i>Stress</i>	9
2.2 Técnicas de medição das alterações fisiológicas envolvidos no <i>stress</i>	12
2.3 Síntese	17
3 Sistemas e Métodos de Suporte ao Estudo de Sinais Biométricos	19
3.1 Sistemas de Estudo de Sinais Biométricos	19
3.1.1 Cooking Hacks	26
3.2 Sinais Biométricos e Métodos para Estudo para a Detecção de <i>Stress</i>	28
3.3 Síntese	33

4	Base de Dados e Metodologias de Análise	37
4.1	Base de Dados	37
4.1.1	Descrição da Base de Dados	37
4.2	Metodologias de Análise	40
4.2.1	Pré-processamento	41
4.2.2	Processamento dos Sinais	43
4.2.3	Análise dos dados	50
4.2.4	Métodos de avaliação do desempenho do classificador	52
4.3	Configurações para o estudo da aquisição dos sinais biométricos	54
4.3.1	Modo <i>off-line</i> simulado	55
4.3.2	Modo <i>on-line</i> em tempo real	56
4.4	Síntese	61
5	Apresentação e Discussão dos Resultados Obtidos	63
5.1	Seleção de <i>Features</i>	63
5.1.1	Correlação dos dados	64
5.1.2	mRMR	68
5.1.3	Tempo de Computação	69
5.2	Avaliação da metodologia utilizada	71
5.2.1	Avaliação do uso do PCA	72
5.2.2	Avaliação dos Classificadores	76
5.3	Avaliação da aplicação das metodologias no modo <i>off-line</i> e <i>on-line</i>	79
5.3.1	Resultados <i>off-line</i> simulado	79
5.3.2	Resultados <i>on-line</i>	84
5.4	Síntese	87
6	Conclusão e Trabalho Futuro	91
6.1	Considerações Finais	91
6.2	Trabalho Futuro	92
A	Terminologia usada	103
A.1	Registos	103
A.2	Classes	104
A.3	<i>Features</i>	104
A.4	Metodologias	105
B	Seleção de <i>Features</i>	107
B.1	Correlação	107
C	Resultados gráficos dos ensaios individuais de <i>cross-validation</i> <i>leave-one-out</i>	111
C.1	Resultados binários	112
C.2	Resultados multiclasse	113

Abreviaturas

ANN (*Artificial Neural Network*) Rede Neuronal Artificial

AUC (*Area under ROC curve*) Área sob a curva ROC

DT (*Decision Tree*) Árvore de Decisão

ECG Eletrocardiografia

EEG Eletroencefalografia

EMG Eletromiografia

fGSR (*foot Galvanic Skin Response*) Resposta Galvânica da Pele do pé

GSR (*Galvanic Skin Response*) Resposta Galvânica da Pele

hGSR (*hand Galvanic Skin Response*) Resposta Galvânica da Pele da mão

HR (*Heart Rate*) Ritmo Cardíaco

IRR (*Instantaneous Respiration Rate*) Taxa Respiratória instântanea

K-NN (*K-Nearest Neighbor algorithm*) Algoritmo dos K vizinhos más próximos

mRMR (*minimum Redundancy Maximum Relevance*) Mínima Redundância Máxima Relevância

PCA (*Principal Component Analysis*) Análise das Componentes Principais

Resp Expansão relativa da taxa torácica

RF *Random Forest*

ROC (*Receiver Operating Characteristic*) Características Operacionais do Receptor

RT *Random Tree*

SVM (*Support Vector Machine*) Máquina de Vetores de Suporte

Glossário

Acc *Accuracy* simples.

accuracy Métrica de medição da qualidade dos resultados previstos por um algoritmo de classificação.

aemg Frequência de metade da área da resposta à frequência do sinal EMG.

ahgsr Frequência de metade da área da resposta à frequência do sinal hGSR.

ahr Frequência de metade da área da resposta à frequência do sinal HR.

aresp Frequência de metade da área da resposta à frequência do sinal Resp.

buffer1 Estrutura para armazenar amostras dos sinais temporariamente.

buffer2 Estrutura para armazenar amostras de classificação temporariamente.

emgv Variância do sinal EMG.

hgsrv Variância do sinal hGSR.

hrv Variância do sinal HR.

L100 Razão entre a potência da banda de baixa frequência e a banda de alta frequência para janelas de 100 segundos.

L300 Razão entre a potência da banda de baixa frequência e a banda de alta frequência para janelas de 300 segundos.

M100 Razão entre a potência da soma da banda de baixa frequência com a média frequência e a banda de alta frequência para janelas de 100 segundos.

M300 Razão entre a potência da soma da banda de baixa frequência com a média frequência e a banda de alta frequência para janelas de 300 segundos.

marker Variável que define a separação dos segmentos de condução.

meanemg Média aritmética do sinal EMG.

meanhgsr Média aritmética do sinal hGSR.

meanhr Média aritmética do sinal HR.

meanresp Média aritmética do sinal Resp.

medianemg Mediana do sinal EMG.

medianhgsr Mediana do sinal hGSR.

medianhr Mediana do sinal HR.

medianresp Mediana do sinal Resp.

respv Variância do sinal Resp.

threshold Limiar definido como limite de separação de algo.

wAcc *Weighted accuracy* ou *accuracy* pesada.

Capítulo 1

Introdução

Esta dissertação corresponde ao trabalho de pesquisa e desenvolvimento realizado no Laboratório de Informática Industrial e Sistemas do Departamento de Engenharia Informática, no âmbito da unidade curricular de Projeto do Mestrado Integrado de Engenharia Biomédica, da Universidade de Coimbra.

1.1 Contextualização

Cada vez mais a nossa sociedade tem evoluído no sentido da busca de uma maior longevidade. De facto, segundo o PORDATA e o Instituto Nacional de Estatística (INE), quando uma pessoa, no ano de 2014, atingisse os 65 anos, podia esperar viver mais cerca de 21 anos, se for do sexo feminino, e 17, for do sexo masculino [1]. Em 1970, essa esperança média de vida era reduzida para 15 anos no caso das mulheres e 12 para os homens [1]. Ou seja, em 30 anos houve um aumento da esperança de vida de 7 anos para as pessoas do sexo feminino e de 5 para as pessoas do sexo masculino. Este aumento resulta da contribuição de vários fatores, como o aumento do conhecimento em diversas áreas tais como a Ciência e a Tecnologia, o desenvolvimento económico e da qualidade de vida, a descoberta de novas vacinas e antibióticos, bem como a diminuição da prevalência de doenças infecciosas [2–5].

Para além disto, o desenvolvimento da tecnologia permitiu a criação de dispositivos focados para a monitorização da saúde. Só em aparelhos de monitorização em casa, para pessoas mais idosas e adaptados ao vestuário, espera-se um aumento para 31 milhões, em 2017 [6]. Para este progresso foi bastante importante a criação e/ou o desenvolvimento de áreas de estudo que interligam conhecimentos multidisciplinares como a Engenharia Biomédica ou as Ciências da Saúde.

1.2 Motivação

A Associação Portuguesa de Segurança (APSEI) revelou em Janeiro deste ano que, em resposta a inquéritos realizados a 500 trabalhadores portugueses, o perigo de esgotamento relacionado com a atividade profissional aumentou, em relação a anos anteriores. Este tipo de esgotamento tem um progresso gradual, face aos sucessivos desafios do dia a dia, visto que são estes contínuos episódios de *stress* que provocam uma diminuição do bem-estar [7, 8].

O *stress* não tem só impacto a nível emocional, como também a nível físico. As alterações fisiológicas que ocorrem durante um episódio de *stress*, quando estas são crónicas, resultam no aumento da suscetibilidade a determinadas doenças relacionadas com o sistema circulatório (enfarte), respiratório (asma), gastrointestinal ou neurológico (Alzheimer). Também se pode tornar um indutor de obesidade e consequentemente de diabetes [9].

Neste sentido, a utilização de dispositivos de monitorização pode ser uma mais valia para determinar quais as situações do dia a dia que desencadeiam *stress*, de modo a definir estratégias para as contornar [10].

1.3 Objetivos

O principal objetivo deste projeto consiste no desenvolvimento de um sistema de aquisição, processamento, análise e armazenamento de sinais biométricos

para a deteção de *stress*, em tempo real. Para isso, o sistema necessita de adquirir sinais fisiológicos previamente definidos, extrair informação destes e gerar uma resposta que descreva o estado, relativamente aos dados recebidos. Também, para que a análise seja o mais eficiente possível, deve conter a possibilidade de guardar os dados adquiridos, de modo a ter em conta várias possibilidades de informação para a manifestação do mesmo processo fisiológico. Por fim, é necessário o desenvolvimento de um algoritmo de análise dos sinais, bem como a integração de todas as funções desejadas com o *kit*, da Cooking Hacks.

1.4 Planeamento

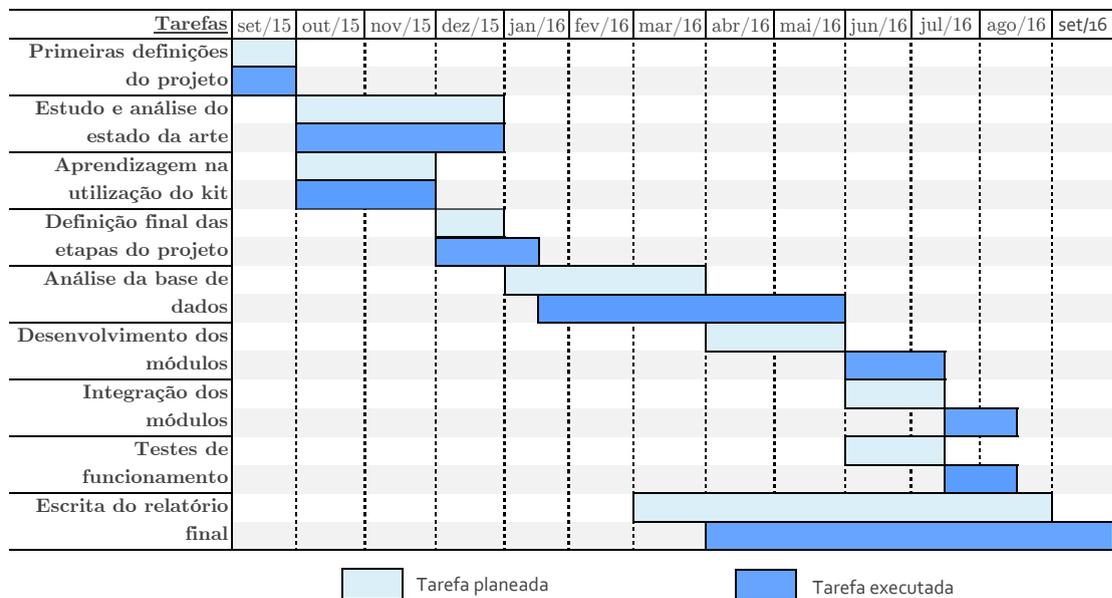


FIGURA 1.1: Tarefas do projeto: planeadas e executadas.

A calendarização do projeto (figura 1.1) é composta por 9 tarefas principais:

1. **Primeiras definições do projeto:** Esta fase foi importante para definir o objetivo principal do projeto, bem como para identificar qual o processo fisiológico a ser estudado, as hipóteses de metodologias a serem implementadas e a definição de etapas de trabalho.

2. **Estudo e análise do estado da arte:** Para poder desenvolver o sistema pretendido, foi indispensável estudar o estado da arte, principalmente o que diz respeito às metodologias adequadas para a deteção de *stress*.
3. **Aprendizagem na utilização do *kit*:** Paralelamente à tarefa anterior, num certo período de tempo, procedeu-se ao estudo do funcionamento da plataforma de aquisição, no que diz respeito ao processo da recolha dos sinais, como também à análise do formato dos mesmos.
4. **Definição final das etapas do projeto:** Após o início da segunda e terceira tarefas, e ao conhecimento que estas proporcionaram, foi possível definir com maior precisão as estratégias a serem implementadas ao longo do projeto.
5. **Estudo dos dados:** Consistiu na implementação de algumas metodologias presentes no estado da arte.
6. **Desenvolvimento dos módulos:** Correspondeu ao estabelecimento do algoritmo de deteção de *stress*, e à integração do mesmo num módulo de processamento e análise, bem como à criação do módulo de aquisição e armazenamento dos sinais.
7. **Integração dos módulos:** Esta fase corresponde à interligação dos vários módulos que compõem o sistema, isto é, à definição da forma os módulos comunicam e se relacionam.
8. **Testes de funcionamento:** Paralelamente à integração, foram realizados os testes para testar e validar a correta aquisição dos sinais, a correta integração dos módulos.
9. **Escrita do relatório final:** Esta etapa correspondeu à escrita do relatório final do projeto.

Analisando a figura 1.1, verifica-se um atraso na definição final das etapas do projeto e da análise da base de dados. Inicialmente, era suposto desenvolver este sistema com uma vertente de deteção de *stress* e outra para deteção de sono.

Contudo, não foi possível considerar esta segunda abordagem dado que não foi encontrada nenhuma base de dados que preenchesse certos requisitos, como um número suficiente de dados e de sinais biométricos, que fosse possível adquirir com o *kit* utilizado. O atraso na definição final das etapas do projeto está relacionado, precisamente, com a pesquisa duma base de dados que servisse para este estudo. Relativamente ao atraso na análise da base de dados do *stress*, tal deveu-se à necessidade de reformulação do algoritmo de processamento e análise dos dados, uma vez que não existe um algoritmo perfeito, passível de ser utilizado em diferentes contextos, sem qualquer tipo de alteração, mesmo em estudos muito semelhantes. Contudo, importa referir que, apesar do atraso real face ao término espectável do projeto, o objetivo deste foi atingido.

1.5 Estrutura do Documento

Este documento está dividido nos seguintes capítulos: no Capítulo 2, é descrito o estado da arte acerca do processo fisiológico em estudo; no Capítulo 3, são apresentados vários sistemas de monitorização e de estudo de sinais fisiológicos, bem como uma revisão do estado da arte; no Capítulo 4, são clarificados todos os aspetos sobre a base de dados usada, o *setup* experimental e as metodologias aplicadas para a análise dos dados; no Capítulo 5, são mostrados e analisados todos os resultados obtidos e, por fim, no Capítulo 6 são apresentadas considerações finais e proposto trabalho futuro.

1.6 Síntese

Este capítulo teve como propósito dar algumas indicações iniciais acerca do projeto, nomeadamente o enquadramento do mesmo e a motivação, bem como a descrição de cada uma das etapas do projeto e dos vários capítulos que constituem este documento. Relativamente à calendarização das etapas do projeto, há que ter em conta que apesar da correta ordem cronológica, por vezes foi necessário

reformular decisões já definidas que não estão consideradas na figura 1.1, para não tornar a figura de difícil interpretação.

Como resultados alcançados neste projeto temos:

- a criação de uma plataforma que integra módulos de aquisição, processamento, análise e armazenamento de sinais fisiológicos;
- o desenvolvimento de um algoritmo de detecção de *stress*, com base em informação extraída de sinais fisiológicos.

Capítulo 2

Contextualização da Fisiologia do *Stress*

De modo a ser possível construir uma plataforma apropriada para a deteção de *stress*, é fundamental perceber o conceito, bem como as suas implicações fisiológicas. Neste capítulo serão abordados vários aspetos como a interpretação do conceito, a dinâmica fisiológica perante um evento que provoca *stress*, consequências fisiológicas desse evento e estratégias de medição das alterações fisiológicas que ocorrem durante este tipo de episódios.

O conceito de *stress* levanta várias questões, quer de linguística quer de significado, que necessitam ser clarificadas. Neste sentido, importa deixar claro que, apesar de em Portugal este termo ter um uso comum no dia a dia, esta palavra é inglesa. Embora muitas palavras estrangeiras sejam adotadas pela Língua Portuguesa, havendo por isso uma adaptação da grafia e da pronúncia, a palavra *stress* continua a ser considerada como um anglicismo e não um estrangeirismo. Segundo Cláudia Pinto, este conceito está generalizado na linguagem do dia a dia visto que não existe nenhuma palavra portuguesa que apresente o mesmo significado [11]. Em relação a este, embora seja normal conotar negativamente o fenómeno de *stress*, devido ao ritmo diário exigente, é incorreto considerar apenas esta perspetiva do termo. Neste sentido, definem-se como *stress* "todas as modificações que têm como

origem um estímulo externo" [12]. Assim, é possível denominar como *stress*, a fuga perante uma situação de perigo ou o início de uma nova etapa de vida, podendo não ter necessariamente consequências negativas. Neste contexto, é possível discriminar *stress* em casos agudos, que ocorrem esporadicamente e num curto espaço de tempo, episódicos, se ocorrem frequentemente e/ou periodicamente, e crónicos, se têm uma incidência a longo prazo e que podem ser prejudiciais. Deste modo, o sentido negativo da palavra surge devido à intensidade deste termo no contexto do trabalho, que desencadeia, por vezes, distúrbios considerados do foro psicológico mas também com consequências no domínio fisiológico como o *burnout*, isto é, esgotamento específico relacionado com a atividade profissional [13]. Por isso, torna-se fundamental motivar e educar as pessoas para controlar situações que lhes possam induzir em excesso o fenómeno de *stress*, proporcionando melhores condições de trabalho ou equilíbrio da exigência e responsabilidade nas várias tarefas diárias.

Tendo em conta a definição de *stress*, importa referir que, pelo facto desta explicação ser relativamente vaga, o uso do conceito pode ser aplicado em várias áreas para além da Psicologia ou da Medicina. Num contexto fisiológico, G.S. Everly and J.M. Lating definem *stress* como uma resposta fisiológica que serve como um mecanismo de mediação que liga qualquer agente desencadeador de *stress* a uma consequência num órgão alvo [14]. Deste modo, o mecanismo desencadeado pelo *stress* é diferente dependendo do agente e do alvo. Assim, numa abordagem biológica mais generalista, entende-se que o agente se refere a qualquer mudança que altere o equilíbrio, químico ou físico, num organismo biológico, enquanto que o alvo corresponde à harmonia de todo o sistema, isto é, à homeostasia [15]. Em termos mecânicos, o *stress* ou tensão refere-se à capacidade de um material se deformar. Neste caso, o agente diz respeito a forças externas e o alvo ao estado inicial, se possuir características elásticas ou atingir um novo estado de equilíbrio de forças, podendo haver rutura ou apenas deformação do material em causa [16]. Neste seguimento, há que ter em conta que, no contexto real, todas estas definições podem interligar-se no mesmo acontecimento. Desde a perceção de um local de perigo até ao deslocamento para um lugar mais confortável, são ações

mediadas por reações biológicas, como a atividade muscular durante o movimento do corpo, e a capacidade de localização espacial através da visão, assim como reações psicológicas, que induzem o medo perante uma situação de ameaça.

Por fim, no âmbito deste projeto, importa ter em mente o conceito de *stress* em termos fisiológicos, isto porque o objetivo deste trabalho reside na deteção de *stress* através de sinais produzidos pelo corpo humano.

2.1 Fisiologia do *Stress*

O *stress*, no âmbito fisiológico, diz respeito a todas as alterações que ocorrem no corpo humano em consequência de um estímulo externo, como já mencionado. Apesar de este poder ter um resultado positivo ou negativo, as alterações fisiológicas são aproximadamente semelhantes, para a maioria das pessoas.

O sistema do corpo humano que regula este processo é o sistema nervoso. Este, anatomicamente, divide-se no sistema nervoso central, constituído pelo encéfalo e medula espinhal, e no sistema nervoso periférico que inclui todos os nervos que se ramificam a partir do sistema central. Ainda no sistema nervoso periférico, existe uma subdivisão em sistema nervoso autónomo, o qual inclui o sistema nervoso simpático, responsável, na maioria dos casos, pela estimulação da atividade, e sistema nervoso parasimpático, que tem uma função inversa. Em termos fisiológicos, os nervos são as estruturas responsáveis pela condução da informação externa ao organismo até ao sistema nervoso central, e que vai ser traduzida numa resposta que é de novo transmitida até aos órgãos alvo, onde é executada. Deste modo, é possível diferenciar os nervos responsáveis pela condução da informação desde os órgãos sensoriais até ao sistema nervoso central, como a via sensorial, e os nervos que têm como função transmitir os impulsos nervosos desde o sistema nervoso central até aos órgãos motores, como a via motora [17].

As respostas motoras têm como finalidade a otimização do funcionamento de alguns órgãos em detrimento de outros menos necessários em cada momento.

Isto não quer dizer que existam órgãos que deixem de funcionar, mas que têm uma redução da atividade metabólica, de modo a elevar o rendimento de outros órgãos ao mais alto nível, numa situação de emergência. Para isso, pode ocorrer alteração da pressão arterial (aumento em certas áreas e redução noutras) aumento do ritmo e débito cardíaco, estimulação do sistema muscular, aumento da produção de glucose e metabolitos, aumento do ritmo respiratório, tudo isto controlado por um aumento de impulsos elétricos que percorrem todo o sistema nervoso [14, 17]. Assim, numa situação de perigo, vários mecanismos são acionados de modo a tornar possível uma rápida e eficiente fuga, se for o caso. Neste sentido, quando uma pessoa se depara perante uma situação de alarme, há de imediato uma ativação do sistema nervoso simpático que provoca a libertação generalizada de uma hormona (norepinefrina) na corrente sanguínea, que estimula quer a atividade do coração quer a vasoconstrição das veias, de modo a aumentar o refluxo de sangue para o coração. Este evento provoca, numa primeira fase, um redirecionamento do sangue das zonas mais periféricas do corpo humano, como a pele, para o interior da caixa torácica. De súbito, há uma imediata injeção de sangue para todos os músculos que necessitem rapidamente de nutrientes para o aumento da sua atividade muscular. Para isso, há um aumento da pressão arterial, bem como de fluxo de sangue para os músculos esqueléticos. Após o início da atividade muscular, e devido à intensidade da mesma, há uma maior produção de resíduos metabólicos que necessitam de ser removidos (como a ureia), bem como um aumento da necessidade de novos nutrientes (como a glucose), pelo que existe um contínuo e elevado fluxo de sangue até o sinal de alerta cessar. Para além disto, os músculos necessitam de maiores quantidade de oxigénio, havendo um aumento do ritmo respiratório. Também, os recetores dos órgãos dos sentidos ficam mais suscetíveis à receção de nova informação, pelo que, deste modo, podem existir variações no diâmetro da pupila ou maior sensibilidade ao tato. De notar que todos os sistemas do corpo humano estão interligados entre si, proporcionando uma eficiente resposta em momento de crise. Contudo, tudo isto só é possível devido à rápida ação do sistema nervoso simpático que fornece uma ativação extra em episódios de *stress*. Esta atividade elétrica adicional corresponde à resposta produzida no sistema nervoso central,

gerada pela situação de alarme (figura 2.1) [17, 18]. Estas alterações fisiológicas

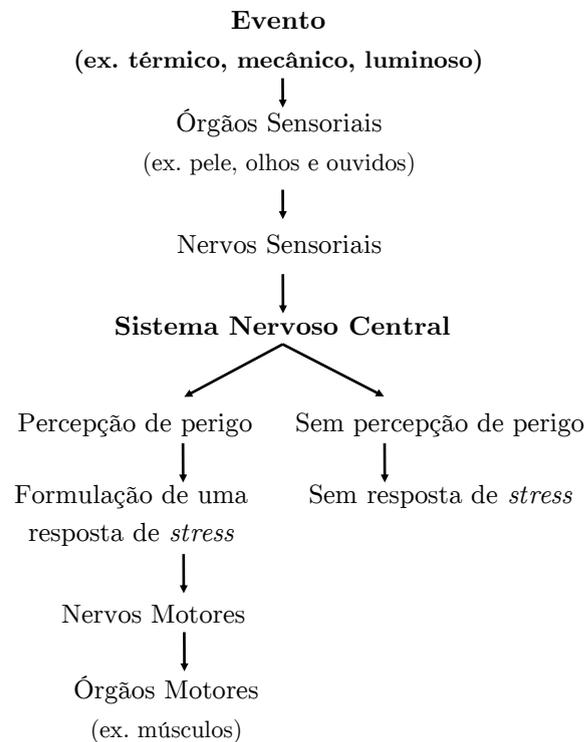


FIGURA 2.1: Dinâmica fisiológica do *stress*, mediado pelo sistema nervoso (Adaptado de: [14]).

são, hoje em dia, possíveis de ser detetadas através da utilização de sensores. Em poucas palavras, estes dispositivos convertem estímulos físicos num sinal elétrico. Um sensor só consegue medir uma forma específica de estímulo externo, isto é, se temos como objetivo a medição de temperatura então, com um sensor capaz de detetar este estímulo, irão ser detetados estímulos desta natureza. No entanto, o sensor é influenciável por outras variáveis presentes no ambiente externo, pelo que é natural a existência de artefactos na informação captada. Além de só medir uma forma específica de estímulos, estes também permitem medir apenas dentro de um certo intervalo de valores (da medida física do estímulo em questão), e num determinado intervalo de frequência. Estes dispositivos apresentam uma estrutura no seu interior que se adapta ao ambiente externo e transmite, sob a forma de sinais elétricos, os estímulos detetados à superfície do sensor. Esta corresponde a uma modificação na forma e/ou posição que é traduzida numa diferença de potencial proporcional à variação da propriedade física do estímulo que está a medir.

O sistema de aquisição associado ao sensor permite fazer uma reconversão deste sinal elétrico para a medida física original sob a forma de valor numérico [19].

Neste sentido, existem inúmeras técnicas de medição de parâmetros fisiológicos, cada um com sensores específicos associados. Como exemplo de medidas fisiológicas possíveis temos a medição do pH sanguíneo; eletroencefalografia, que mede a atividade elétrica do encéfalo; eletrocardiografia, que mede a atividade elétrica do miocárdio ou a medição da pressão relativa dos componentes do ar (P_{O_2}, P_{CO_2}). A próxima secção descreve mais detalhadamente cada uma das técnicas que existem para a medição de sinais relacionados com as alterações fisiológicas durante episódios de *stress*.

2.2 Técnicas de medição das alterações fisiológicas envolvidos no *stress*

Estas técnicas são muito importantes para o estudo não-invasivo da fisiologia humana, uma vez que permitem obter informação sobre o funcionamento dos órgãos, sem necessidade de estar em contacto com os mesmos. Importa referir que, na maioria dos casos, as técnicas traduzem a medição de sinais elétricos em diferentes locais do organismo. Nestes casos, a colocação dos elétrodos é crucial para a eficácia da técnica utilizada.

- **Eletroencefalografia (EEG)**- A eletroencefalografia consiste num exame médico que tem como objetivo a avaliação da atividade elétrica do cérebro. Nesta técnica, os elétrodos são dispostos sobre o escalpe (figura 2.2), sendo, por isso, considerada uma técnica não invasiva. Contudo, existem variações na técnica deste exame que permitem um estudo mais focalizado do encéfalo com introdução dos elétrodos no tecido cerebral, o que torna a técnica invasiva. A eletroencefalografia não-invasiva é um registo complexo, uma vez que regista a acumulação de potenciais elétricos de toda a região cerebral. Como em episódios de *stress* existe uma alteração da atividade cerebral, então o

EEG pode ser utilizado para detetar as variações dessa atividade. Na figura 2.3 é possível verificar a diferença dos sinais EEG em diferentes etapas do ciclo sono-vigília desde um estado mais ativo até um estado de sono profundo [19].

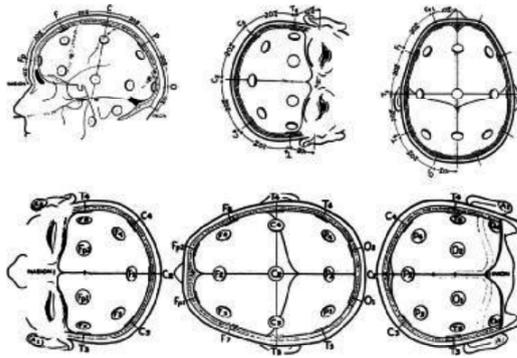


FIGURA 2.2: Disposição dos eletrodos (Retirado de: [19]).

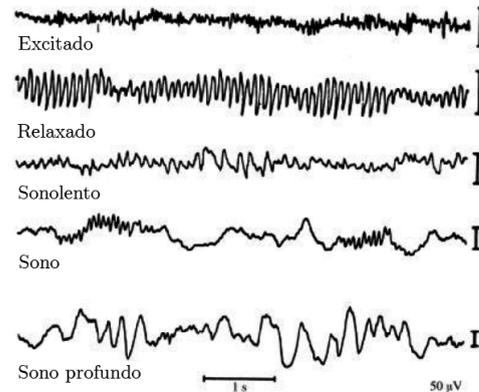


FIGURA 2.3: Diferenças no EEG em diferentes estágios do ciclo sono-vigília (Adaptado de: [19]).

- **Eletromiografia (EMG)**- O EMG mede a atividade muscular. Os músculos são compostos por fibras que, por sua vez, são constituídas por unidades básicas chamadas sarcómeros. Quando um impulso nervoso de um neurónio motor atinge uma fibra muscular, há uma despolarização da área e uma abrupta diminuição do tamanho do sarcómero. Esta cria uma diferença de potencial que se propaga às regiões musculares adjacentes [17]. Uma das desvantagens do EMG reside na necessidade de colocar os eletrodos à superfície o que se traduz num sinal de atividade muscular com artefactos, tanto maior quanto maior for superfície sujeita à medição. Para colmatar este problema existem eletrodos utilizados a nível local, contudo têm um carácter invasivo visto que implica perfurar o tecido muscular até ao local de interesse [19]. Relativamente à colocação dos eletrodos à superfície, esta deve ser estudada *a priori* da medição, uma vez que há diferenças na disposição dos eletrodos para medir a atividade muscular do bíceps ou trapézio, por exemplo [20].
- **Eletrocardiografia (ECG)**- O ECG determina a atividade elétrica do miocárdio. O coração é constituído por um tecido muscular diferente do tecido muscular dos músculos esqueléticos (figuras 2.4 e 2.5).

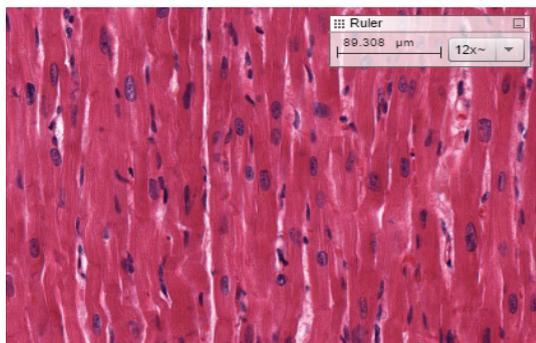


FIGURA 2.4: Secção de tecido muscular do miocárdio (Retirado de: [21]).

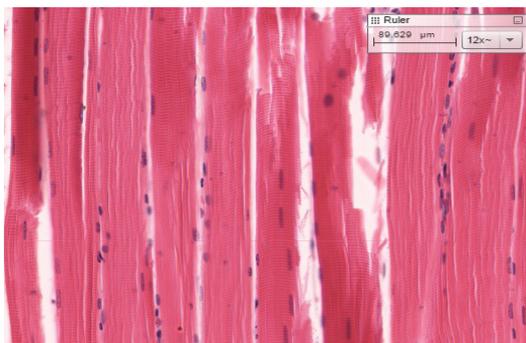


FIGURA 2.5: Secção de tecido do músculo esquelético (Retirado de : [21]).

A estrutura do tecido muscular cardíaco é muito mais desorganizada que a do tecido muscular esquelético. Enquanto que os sarcómeros no tecido muscular esquelético estão dispostos em linha, no tecido muscular cardíaco tal não acontece. É comum, neste tecido muscular, existirem unidades base interligadas com mais do que um sarcómero. Esta estrutura provoca, assim, uma contração do músculo cardíaco como um todo. O sinal ECG (figura 2.6) é representado pela onda P que corresponde à contração das aurículas, pelo complexo QRS que diz respeito à contração muscular (despolarização) dos ventrículos e pela onda T que consiste na repolarização dos ventrículos após a injeção do sangue para o exterior do coração [17].

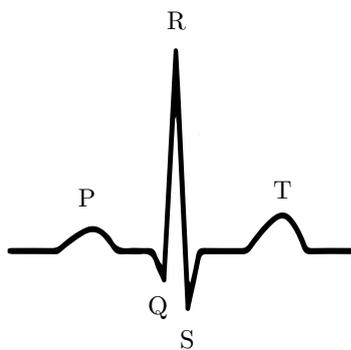


FIGURA 2.6: Exemplo ilustrativo de um sinal ECG (Adaptado de: [17]).

O exame de ECG permite, dependendo da localização dos elétrodos, realizar um estudo mais rigoroso de uma região específica do músculo cardíaco. As derivações de um exame de ECG podem ser: bipolares, em que o potencial elétrico é detetado através de dois elétrodos; aumentadas, com a adição de

um eletrodo com potencial neutro; e precordiais, onde os eletrodos estão dispostos sob o tórax, em locais específicos, em que é captada, em cada um, a diferença de potencial entre o eletrodo terminal e ele próprio [19].

- **Fotopletismograma-** Este método ótico não invasivo permite obter dados relativos ao volume de sangue em circulação no sistema cardiovascular. Este método é incluído num oxímetro de pulso (figura 2.7), o que possibilita a aquisição de outros parâmetros relativos à composição do sangue como pressão de saturação de oxigénio.



FIGURA 2.7: Exemplo de um oxímetro de pulso (Retirado de: [22]).

Este dispositivo é composto por duas divisões em que uma funciona como emissora de luz infravermelha e a outra como recetora dessa luz. A luz infravermelha ao atravessar todos os capilares sanguíneos, dependendo das propriedades físicas e químicas do sangue, pode ser mais ou menos refletida e absorvida pelo que a luz detetada pelo recetor é variável. Como já foi referido, em estado de *stress* existe um aumento do fluxo e ritmo cardíaco, pelo que esta técnica pode ser facilmente utilizada para detetar diferenças entre estados de *stress* e estados relaxados [19].

- **Resposta Galvânica da Pele (GSR)-** Durante a emissão de uma resposta de *stress* há uma descarga elétrica conduzida pelos nervos que pode ser detetada ao nível superficial da pele, com auxílio de sensores específicos (figura 2.8). O sinal captado corresponde à diferença de potencial entre os dois eletrodos utilizados, geralmente nos dedos. Através dos eletrodos são enviados estímulos elétricos imperceptíveis que permitem uma receção

contínua de condutividade elétrica, que pode variar com estados emocionais da pessoa em teste (figura 2.9) [19, 23].



FIGURA 2.8: Exemplo de um dispositivo de medição do sinal GSR (Retirado de: [24]).

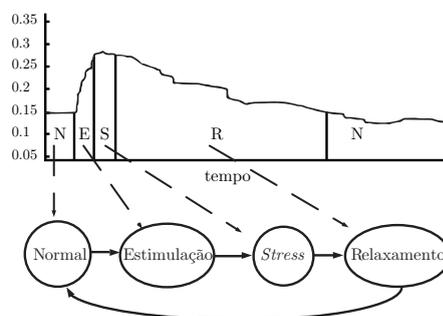


FIGURA 2.9: Exemplo de um sinal GSR, durante um evento de *stress* (Adaptado de: [10]).

- Medição da fluxo respiratório-** Como já foi referido, durante episódios de *stress* o ritmo e a profundidade da respiração é alterada, pelo que a medição de certos parâmetros pode ser importante para detetar diferenças durante ou antes deste tipo de episódios. É possível com recurso a sensores determinar o fluxo respiratório, o que permite discriminar diferenças, quer na quantidade de ar inspirado ou expirado quer no número de respirações num determinado período de tempo (figura 2.10).

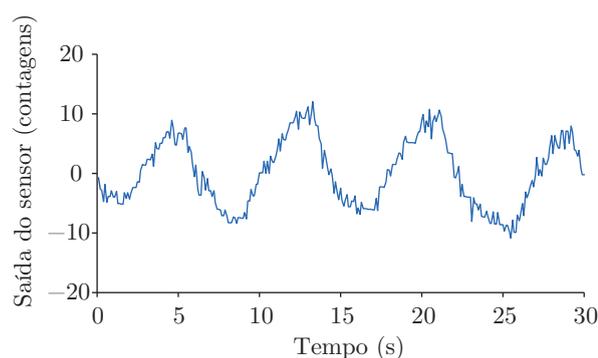


FIGURA 2.10: Exemplo de um sinal respiratório, onde é claro a existência de 3 períodos respiratórios completos (Adaptado de: [25]).

2.3 Síntese

Este capítulo teve como principal objetivo esclarecer o processo fisiológico em causa, bem como descrever, de forma breve, técnicas que podem ser utilizadas para o estudo do mesmo. No capítulo seguinte serão abordados vários dispositivos, que usam algumas destas técnicas médicas para a deteção de *stress*, assim como o sistema de aquisição usado para o desenvolvimento deste projeto.

Capítulo 3

Sistemas e Métodos de Suporte ao Estudo de Sinais Biométricos

No capítulo anterior foram explicados: o conceito de *stress*, as etapas fisiológicas durante este processo, as alterações fisiológicas resultantes no funcionamento do organismo, bem como técnicas médicas de detecção dessas modificações.

No presente capítulo serão abordados sistemas existentes no mercado, que implementam algumas das técnicas médicas já referidas, bem como diferentes estudos realizados sobre detecção de *stress*. Este levantamento de informação é importante de modo a ser possível determinar as etapas necessárias para o desenvolvimento do sistema de detecção de *stress*, que engloba uma fase de recolha de sinais fisiológicos, uma fase de processamento e a análise dos mesmos.

3.1 Sistemas de Estudo de Sinais Biométricos

Hoje em dia, com a valorização da qualidade de vida, mesmo em idades mais avançadas, a tecnologia, movida por estes interesses, aplica os seus conhecimentos com o objetivo de auxiliar as pessoas no entendimento da sua saúde. Para isso, tem-se verificado a interligação de áreas como a Medicina e diversas Engenharias, com a finalidade de se atingir este objetivo: desenvolver dispositivos que permitam

ao utilizador obter conhecimento acerca de uma certa condição física ou patologia, apresentado de uma forma automática. Neste sentido, já é possível ter acesso a diferentes aparelhos, desde os mais simples aos mais complexos. Os mais simples mostram o resultado da medição direta de uma grandeza física ou química como por exemplo, os aparelhos de medição da glicémia ou da tensão arterial. Este tipo de aparelhos têm como função principal a monitorização diária de utilizadores com patologias associadas à regulação dos níveis de glucose no sangue ou distúrbios na pressão arterial, por exemplo. Os dispositivos mais complexos fazem medições de vários parâmetros e processam esses dados, produzindo informação fornecida ao utilizador como é o caso do Vivago *CARE watch*, de que se falará de seguida. Por isto, é possível diferenciar estes aparelhos em plataformas de aquisição (como é o caso dos aparelhos de medição da glicémia) e plataformas de aquisição e análise (como o Vivago *CARE watch*).

Vivago

A Vivago [26] é uma empresa finlandesa que desenvolve soluções relacionadas com cuidados de saúde e bem-estar. Estas soluções vão desde a integração de sistemas de enfermagem, sistemas de emissão de alarmes automáticos, localização espacial e monitorização contínua do bem-estar [26]. Esta dispõe de alternativas para utilização domiciliária ou institucional que podem ser compostas por vários dispositivos, dependendo do caso onde a solução é aplicada. Em termos gerais, a solução consiste num relógio (Vivago *CARE watch*) que recolhe a informação do utilizador, sendo depois enviada para estações (Vivago POINT) que processam a informação e avisam um responsável (previamente definido) em caso de necessidade. O relógio (figura 3.1) permite uma monitorização em tempo real da atividade diária do utilizador. Este apresenta um botão de alarme que pode ser pressionado em caso de emergência, desencadeando o processo de contacto com alguém responsável, um sistema de enfermagem ou familiares mais próximos. Para além disto, em caso de incapacidade de acionar o botão de alarme, por exemplo em casos de desmaio, é capaz de detetar e emitir automaticamente um alarme. Como este tem como objetivo o uso dentro de uma determinada área, quando o



FIGURA 3.1: Vivago *CARE watch* (Retirado de: [26]).



FIGURA 3.2: Vivago *POINT* (Retirado de: [26]).

utilizador excede a mesma ou o retira do pulso, o responsável é notificado. Em termos de especificações do relógio, este é resistente à água, tem autonomia de 2 a 6 meses e conexão sem fios com as estações (Vivago POINT). Este recolhe informação acerca da temperatura, movimentos corporais e condições de bem-estar [27] e envia-as para as estações onde é processada e armazenada. O Vivago *POINT* (figura 3.2), para além de ter características semelhantes a um telefone e ter a capacidade de recolha de informação captada pelo relógio da Vivago, também tem a possibilidade de integração de outros sistemas como alarmes de incêndio ou sistemas de segurança presentes no local onde se insere. Posteriormente, toda a informação recolhida pode ser utilizada para desenvolver o perfil do utilizador e criar relatórios de bem-estar.

Intellicare

A Intellicare [27] é uma empresa portuguesa integrada no Instituto Pedro Nunes que tem como foco o auxílio ao envelhecimento ativo com qualidade de vida. Para isso, dispõe de dispositivos de medição, bem como tecnologias, quer de recolha quer de comunicação entre o utilizador e terceiros. Esta empresa também funciona como distribuidora nacional da empresa Vivago. Contudo apresenta soluções próprias: o OneCare *Sensing* (figura 3.3a), OneCare *Safe* (figura 3.3b) e o OneCare *Dori* (figura 3.3c).

O primeiro, inclui dispositivos de medição arterial, frequência cardíaca, ECG, glicémia, peso, temperatura e outros. A particularidade desta solução é que estes



FIGURA 3.3: Algumas das soluções da Intellicare (Imagens retiradas de: [27]).

dispositivos enviam, após a aquisição, os valores dos parâmetros medidos para um dispositivo móvel e posteriormente para uma base de dados onde podem ser analisados e reconhecidos padrões nos dados (figura 3.4).

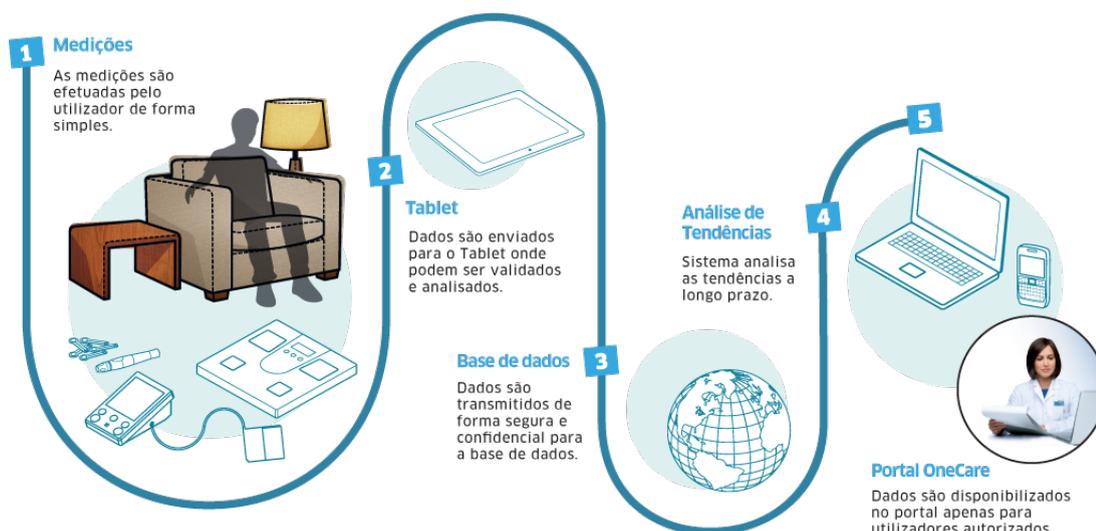


FIGURA 3.4: Funcionamento do OneCare Sensing (Retirado de: [27]).

O OneCare safe funciona como um dispositivo de emergência concedendo um sentimento de segurança ao utilizador. Este permite enviar alertas para alguém responsável, através de um botão de alarme contido no dispositivo, como também pode fazer ligações telefónicas para 3 números predefinidos. Para além disto, quando o utilizador sofre uma queda é emitido automaticamente um alarme para o seu responsável, sem necessidade de premir o botão de alarme.

Por fim, o OneCare Dori tem como função auxiliar o utilizador para a toma correta de medicação, pelo que o responsável e/ou familiares são informados em tempo real, via telemóvel, se o utilizador fez a toma correta dos medicamentos, bem como se fez medições como tensão arterial ou glicémia.

HealthyRoad

A HelthyRoad [28] é uma empresa portuguesa, que aplica tecnologia de reconhecimento facial, em tempo real, para o setor automóvel. A aplicação associada ao sistema (figura 3.5) utiliza a câmara frontal do dispositivo móvel para analisar o comportamento do condutor, com o objetivo de detetar episódios de sonolência ou distração. Nestes casos, é emitido um sinal sonoro e visual de modo a alertar o automobilista. Também, através da monitorização do ritmo cardíaco, é possível a deteção de emoções e *stress*. Para além disso, permite, num ambiente fora da condução, consultar dados relativos às viagens (figura 3.6) como percentagens de períodos de alerta.



FIGURA 3.5: Aplicação HealthyRoad (Retirado de: [28]).



FIGURA 3.6: Dados estatísticos da aplicação HealthyRoad (Retirado de: [29]).

Faurecia

A empresa Faurecia [30] tem como preocupação a satisfação dos condutores, pelo que procura dar-lhes "conforto, prazer, segurança, conectividade" sem comprometer a ecologia do produto [30]. Neste sentido, esta desenvolveu o Active Wellness™ que consiste num novo conceito de assento para os automobilistas.

Para isso, esta empresa aposta em materiais biológicos e leves bem como em tecnologia de aquisição de dados para satisfazer estas necessidades. Dentro das

inovações que apresenta, e tendo em conta o tema do projeto, importa apresentar o assento Active Wellness™ (figura 3.7).



FIGURA 3.7: Active Wellness™ (Retirado de: [31]).

Este tem a capacidade de detetar a sonolência ou *stress* do condutor e desenvolver medidas para eliminar esse estado. Dependendo do estado em que se encontra o condutor, o assento responde ou com uma massagem (figura 3.8b) energética ou relaxante, para além de adaptar o fluxo de ar no sistema de ventilação integrado no próprio assento (figura 3.8c). Para tal, este assento é equipado com sensores de medição do ritmo cardíaco e ritmo respiratório (figura 3.8a). Para a correta análise dos dados recebidos, pelos sensores, é importante o armazenamento de dados com informação médica que dispõe [31].



(A) Sensores biométricos (a verde) e monitor. (B) Componentes mecânicos da massagem. (C) Ventilação do assento.

FIGURA 3.8: Componentes da Active Wellness™ (Imagens retiradas de: [31]).

PLUX

A PLUX é uma empresa portuguesa, sediada em Lisboa, que tem como objetivos o desenvolvimento de plataformas de monitorização de bio-sinais através

de sensores adaptáveis ao vestuário e *software* de análise dos mesmos [32]. A finalidade das soluções criadas por esta empresa tem unicamente aplicabilidade no domínio da investigação, pelo que esta não se responsabiliza pela sua utilização em ambiente hospitalar para diagnóstico ou prevenção, entre outros. Assim, tem como soluções o biosignalsplux, o BITalino, o physioplux e o ergoplux (figura 3.9). Neste sentido, o physioplux e o ergoplux têm como função a monitorização da recuperação de um utilizador e a prevenção de lesões em trabalhadores, respetivamente.

No que diz respeito às duas soluções restantes, são provavelmente as plataformas com maior semelhança com o sistema de aquisição usado neste projeto [33], uma vez que permitem a aquisição de um maior número de sinais biométricos, através de sensores, o que permite a adaptação a diferentes casos de estudo, o que não acontece com o physioplux e o ergoplux que têm aplicação mais específica.

O biosignalsplux [34] corresponde a uma plataforma mais sofisticada do que a BITalino [35], uma vez que apresenta um maior número de *kits* para investigação e sensores associados, o que proporciona um estudo mais profundo. Neste sentido, a PLUX permite personalizar a escolha dos sensores em cada um dos *kits*. Dentro dos sensores para aquisição, é possível a utilização de acelerómetros, ECG, EMG, GSR e EEG, bem como a medição de parâmetros de respiração, movimento, temperatura e BVP. Relativamente ao BITalino [35], este consiste numa plataforma mais simples e mais económica, não deixando de ser versátil. O BITalino apresenta canais para EMG, GSR, ECG, acelerómetro e fotodíodo. Esta plataforma também é composta por vários *kits*: para fácil utilização da leitura de sinais, com o objetivo de criação de sensores *wearables* ou para a integração com sistemas desenvolvidos pelo utilizador. Qualquer um deles contém uma vasta documentação disponível no *website* [35], para que a adaptação ao sistema seja o mais rápida possível, de modo a promover a aprendizagem e o desenvolvimento de novo conhecimento.



FIGURA 3.9: Soluções da PLUX: biosignalsplux, BITalino, physioplux e ergoplux (Retirado de: [32]).

3.1.1 Cooking Hacks

A marca Cooking Hacks pertence à empresa Libelium que procura aplicar dispositivos de aquisição de dados em cidades, em estações nucleares, no ambiente, nos cursos de água, nos contadores domésticos, no consumo, na logística, na indústria, na agricultura, na pecuária e na saúde [36]. A Cooking Hacks, neste contexto, é uma loja *on-line* que fornece ferramentas, com diferentes níveis de dificuldade, para o desenvolvimento de plataformas inteligentes. Estes *kits* são desenvolvidos com o intuito de proporcionar condições aos investigadores ou interessados na área, para experimentar e desenvolver as suas próprias plataformas inteligentes. Da variada gama de *kits* existentes, a utilizada no âmbito deste projeto foi a *e-Health Sensor Platform Complete Kit V2.0* [33]. Este *kit* tem como

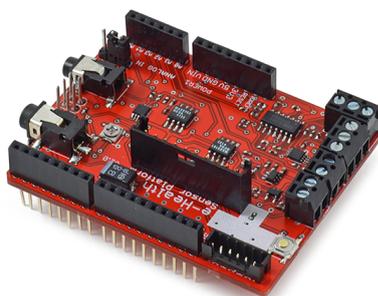


FIGURA 3.10: *e-Health Sensor Shield* (Retirado de: [33]).

elemento principal a *e-Health Sensor Shield* (figura 3.10) visto que é a componente que permite a ligação dos sensores ao Arduino. Embora possa ser utilizado, em substituição do Arduino, um Raspberry Pi, contudo este exige a utilização de uma placa adaptadora [37]. Os dados recolhidos pelos sensores podem ser enviados via Wi-Fi, 3G, GPRS, Bluetooth, 802.15.4, ZigBee ou USB.



FIGURA 3.11: *e-Health Sensor Platform Complete Kit V2.0* com os sensores todos ligados à *shield* (Adaptado de: [33]).

Relativamente aos sensores, o *kit* inclui um medidor de pressão arterial (número 1 da figura 3.11), um oxímetro de pulso (número 2 da figura 3.11), medidor da glicemia no sangue (número 3 da figura 3.11), um sensor de medição da temperatura corporal (número 4 da figura 3.11), elétrodos para ECG (número 5 da figura 3.11), elétrodos para EMG (número 6 da figura 3.11), sensor de medição da respiração (número 7 da figura 3.11), elétrodo para medição de GSR (número 8 da figura 3.11) e um acelerómetro (número 9 da figura 3.11). Cada um destes sensores tem uma ligação física na *e-Health Sensor Shield* que, por sua vez, possui ligações próprias para a conexão ao Arduino ou à placa adaptadora para o uso do Raspberry Pi (figuras 3.13 e 3.14). De notar que, na *e-Health Sensor Shield*, existe um *jumper* que apenas permite a aquisição de sinais de EMG ou ECG, dependendo da posição que apresente.

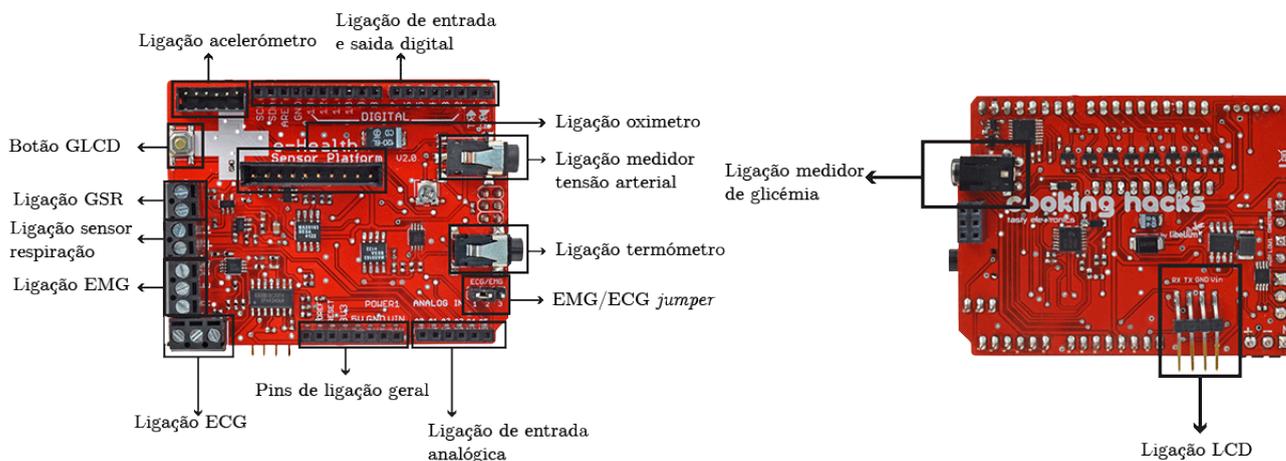


FIGURA 3.12: Local de ligação dos sensores (Adaptado de: [33]).

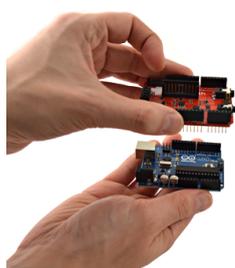


FIGURA 3.13: Montagem da *e-Health Sensor Shield* com um Arduino (Retirado de: [33]).

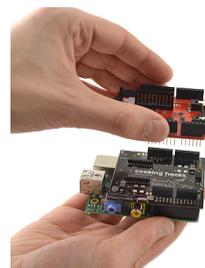


FIGURA 3.14: Montagem da placa adaptadora e a *e-Health Sensor Shield* com um Raspberry Pi (Retirado de: [33]).

3.2 Sinais Biométricos e Métodos para Estudo para a Detecção de *Stress*

Para além dos dispositivos existentes para aquisição e/ou análise de sinais fisiológicos é fundamental estudar o que já foi desenvolvido na análise de sinais e técnicas para a deteção de episódios de *stress*. A dificuldade do estudo deste processo fisiológico reside na forma como cada pessoa responde a um estímulo que pode ou não causar *stress*.

Neste seguimento, Healey e Picard [38] desenvolveram 24 registos de condução automóvel com uma duração de pelo menos 50 minutos, onde foram adquiridos sinais fisiológicos como o ECG, EMG, *foot galvanic skin response* (fGSR), *hand galvanic skin response* e respiração. O sinal do ritmo cardíaco foi desenvolvido com

base no sinal ECG, através da detecção dos picos R do sinal [38]. Estes sinais foram adquiridos em ambiente real, onde foram registadas gravações de vídeo em sincronia com os registos dos sinais fisiológicos, tal como é descrito num estudo anterior [39]. Posteriormente à aquisição dos sinais e das gravações de vídeo, estes foram analisados em conjunto com questionários, respondidos depois da tarefa, sobre o percurso rodoviário, bem como a aplicação de técnicas de análise de dados, com a finalidade de desenvolver uma métrica de *stress*. Os sensores foram dispostos de modo a minimizar o incómodo durante a execução da tarefa bem como a existência de artefactos nos sinais. A análise dos sinais foi sustentada em duas fases: na primeira, foram selecionados intervalos de 5 minutos, onde claramente os voluntários experimentaram (segundo as respostas dos questionários e as gravações de vídeo) níveis de baixo, médio e alto *stress*, com o objetivo de treinar um algoritmo de classificação; e na segunda análise, foi utilizado todo o registo para verificar a relação entre a métrica de *stress*, criada pela análise anterior, e as gravações de vídeo, para que no final fosse desenvolvida uma métrica de *stress* contínua para todo o registo dos sinais. As *features* extraídas para esta segunda análise foram a média e a variância do sinal EMG, hGSR, respiração e ritmo cardíaco. Para além destas, foram desenvolvidas 4 *features* com base no ritmo cardíaco, tendo em conta diferentes bandas de frequência e tamanhos de janela de 100 e 300 segundos. Relativamente às conclusões deste estudo, Healey e Picard mostraram que o sinal GSR e o ritmo cardíaco (HR) são os melhores sinais, de entre os usados, para classificar diferentes níveis de *stress*. Além disso, também se mostrou com este estudo que nem todos os voluntários exprimiam fisiologicamente as mesmas alterações nos sinais, uma vez que, para estes, a correlação entre a métrica desenvolvida e os sinais era reduzida [38].

Com a criação desta base de registos de Healey e Picard, foram desenvolvidas diferentes metodologias com o mesmo objetivo de determinar diferentes níveis de *stress* [40–46]. Em 2011, Akbas [40] utilizou esta base de dados para o estudo do processo fisiológico do *stress* e também desenvolveu novas métricas de avaliação a partir do sinal da respiração e do sinal EMG (taxa de respiração instantânea e

número de contrações por minuto, respetivamente), bem como algumas já desenvolvidas no estudo de Healey e Picard que dizem respeito a *features* estatísticas dos sinais. Este concluiu que as médias dos sinais utilizados e as métricas calculadas, com exceção da taxa respiratória instantânea, estão correlacionadas com os três diferentes níveis de *stress* definidos na base de dados. Por esta razão, o mesmo afirma que o aumento de *stress* provoca um aumento do ritmo cardíaco e da condutividade elétrica da pele. Posteriormente, Avci e Akbas [41] utilizaram novas *features* estatísticas como a mediana, variância, desvio padrão, valor do primeiro e segundo quartis e intervalo inter-quartil, para verificar relações entre estas e os níveis de *stress*. Eles mostraram que todas as *features* estatísticas estavam relacionadas com os diferentes níveis de *stress*, com exceção do IRR. Contudo, neste estudo verifica-se que a variância do IRR também está relacionada com os níveis de *stress*. Além disto, verificaram que a variância é a *feature* mais significativa, quando comparada com outras. Também Singh e Queyam utilizaram a mesma base de dados para relacionar parâmetros fisiológicos com o *stress* do condutor, bem como com as condições de trânsito [42]. Estes concluíram, à semelhança dos anteriores, que os sinais de GSR e HR são os mais relacionados com o nível de *stress* do condutor. Através da análise da correlação, mostraram que as *features* da média do sinal HR e a média do sinal GSR são as que têm maior correlação com a mudança das condições do trânsito, que originam os diferentes níveis de *stress*. Num estudo posterior [43], os mesmos autores construíram uma função que demonstra o nível de *stress*, sendo esta uma combinação lineares de fatores, calculados através de uma regressão. Para além disso, mostram que a utilização dessa função é suficiente, na maioria dos casos, para determinar os diferentes níveis de *stress*. Esta validação foi executada através da comparação de amostras corretamente classificadas, utilizando a função desenvolvida e uma *Artificial Neural Network* (ANN). Deng [44] também utilizou os mesmos dados para avaliar a aplicação da *Principal Component Analysis* (PCA) num conjunto de *features* calculadas. Para tal, foram usados 5 algoritmos de classificação: *Linear Discriminant Function* (LDF), Árvores de Decisão J48, *Support Vector Machine* (SVM), *Naïve Bayes* e *K-nearest neighbor* (K-NN). A utilização do PCA reduziu

de 22 *features* calculadas para 5 e a aplicação dos diferentes classificadores provou um aumento da correta classificação, bem como uma diminuição do tempo computacional. Para além disto, conclui que o SVM foi o classificador com melhores resultados para este estudo. Ghaderi et al [45], aplicaram K-NN e SVM em *features* estatísticas, desenvolvidas a partir dos sinais fisiológicos adquiridos por Healey e Picard [38] com diferentes segmentações de intervalos de tempo (100 seg, 200 seg, 300 seg). Os resultados mostraram uma *accuracy* superior a 98% para as diferentes segmentações. Ainda com a utilização da mesma base de dados de Healey e Picard, temos o trabalho de Keshan e Parimi [46]. Este trabalho teve o mesmo objetivo dos trabalhos anteriores com uma particularidade: a utilização de apenas um sensor (ECG). O propósito seria utilizar um sensor, de modo a minimizar os incómodos na aquisição, mas sem comprometer o sucesso da classificação. Para tal, foram desenvolvidas 14 *features* relacionadas com as ondas que compõem o ECG (2.6). Com a aplicação de algoritmos de classificação (Naïve Bayes, *logistic Regression Multilayer Perceptron*, SVM, K-NN, ZeroR, Árvores de Decisão (DT) J48, *Random Forest* (RF) e *Random Tree* (RT)) disponíveis no software *Waikato Environment for Knowledge Analysis* (WEKA) [47], concluíram que, com a utilização de um único sensor, atingiam uma *accuracy* de 88.24%, para 3 classes, e superior a 60%, com a maioria dos classificadores, com 2 classes. Outros estudos (como [23, 48–50]) construíram os seus próprios dados para a análise do *stress* fisiológico. Zhai et al. [50] utilizaram sinais *blood volume pulse* (BVP), GSR e o diâmetro da pupila para avaliar o estado de *stress* durante a interação com um computador. Para isso, foi definido um protocolo específico que consistiu num teste clínico de *stress*, implementado no computador, enquanto eram adquiridos os sinais biométricos. Posteriormente, foram construídas *features* e realizados testes com classificadores SVM. No final, conclui-se que as alterações destes sinais estão fortemente correlacionados com o estado emocional quando os estímulos de *stress* são apresentados, com uma previsão de *stress* com uma *accuracy* de 80%, usando uma *sigmoid kernel function* [50]. Anos mais tarde, Zhai e Barreto [49] utilizaram os mesmos sinais biométricos, com adição da temperatura da pele, num protocolo diferente de teste e com a aplicação de diferentes classificadores. No

estudo anterior [50] foram usadas SVM com 3 funções *kernel* diferentes, enquanto que neste estudo foram testados classificadores Naïve Bayes, Árvores de Decisão J48 e SVM com função *kernel* não-linear. Com técnicas de *k-fold cross validation* obtiveram valores de *accuracy* de cerca de 79% com Naïve Bayes, 88% para Árvores de Decisão e 90% para SVM, para uma classificação com duas classes.

Moore e Dua [23], procuraram desenvolver um sistema de comunicação em pessoas com incapacidades motoras, que impedia a construção de diálogo, com a utilização do sinal GSR. Este sistema foi criado com um voluntário que foi progressivamente perdendo o controlo dos seus movimentos ao longo do estudo. Inicialmente, num período de tempo onde o doente era capaz de falar, foram feitos testes de desempenho do sistema com tarefas de resposta binária, onde o doente era incentivado a modificar o seu GSR de modo a exibir, no seu registo do sinal, uma resposta positiva ou negativa. Mediante o tipo de resposta e a confirmação do doente, foram definidos *thresholds* do sinal. Contudo, este controlo sob a resposta galvânica da pele teve de ser aprendido e aperfeiçoado, o que consistiu numa dificuldade devido à gradual perda das faculdades motoras do doente. Apesar disso, os autores mostraram que apenas com este sinal seria possível manter uma comunicação com pessoas que apresentam desordens motoras degenerativas, de modo a impedir a degradação da qualidade de vida.

Por fim, Rigas e Goletsis [48] criaram uma metodologia de deteção de eventos de *stress* em tempo real. Esta é baseada no estudo de sinais biométricos como o ECG, GSR e respiração, bem como na informação comportamental de eventos passados. Para o desenvolvimento deste sistema de deteção em tempo real, foram calculadas *features* em intervalos de 10 segundos e registados os sinais biométricos e eventos de condução (ultrapassagens, travagens e outras), sem um percurso rodoviário definido. Numa primeira fase, foram considerados 4 níveis de *stress* (sem existência, baixo, médio e alto), níveis estes determinados através da análise da correlação entre as *features* calculadas e os eventos de condução. A métrica de *stress* criada resultou da convolução de uma janela de *hamming* com a classificação dos 4 níveis em cada um dos registos efetuados anteriormente. Contudo, para uma fase posterior de testes desta metodologia, apenas foram considerados 2

níveis de *stress* ('inexistência de *stress*' e 'com *stress*'). Para além disto, são considerados dois modelos diferentes para a classificação, recorrendo a um classificador bayesiano, em que num primeiro classificador apenas são utilizadas *features* resultantes de sinais fisiológicos e num segundo classificador são consideradas *features* extraídas do veículo. Também os testes foram executados com base em sessões anteriormente registadas pelo mesmo utilizador, isto é, o classificador foi treinado com registos anteriores da mesma pessoa que realiza o teste, obtendo-se resultados de 84% de *accuracy* [48].

3.3 Síntese

A tabela 3.1 serve como um resumo de alguns dispositivos que se encontram no mercado (para deteção de um processo fisiológico ou para manutenção do bem-estar) e de dispositivos de auxílio ao estudo de processos fisiológicos. Verifica-se, numa rápida análise, que existem várias empresas que se preocupam com o impacto da qualidade de vida, bem como a necessidade de procurar adquirir novos conhecimentos acerca da saúde, desenvolvendo plataformas que proporcionem estas condições. No que diz respeito à tabela 3.2, esta representa uma síntese dos métodos e algoritmos de classificação utilizados em estudos para deteção do *stress*. Por fim, neste projeto, foi utilizado o *e-Health Sensor Platform Complete Kit V2.0*, como sistema de aquisição de sinais biométricos, bem como algumas das *features* (média, variância e parâmetros relacionados com o ritmo cardíaco) e algoritmos de classificação (Árvore de Decisão e ANN), presentes neste capítulo.

TABELA 3.1: Resumo de alguns dispositivos de detecção de processos e de auxílio ao estudo de sinais fisiológicos.

Empresa	Público-Alvo	Sinais Fisiológicos	Informação detetada	Outros
Vivago [26] (Finlândia)	Idosos ou dependentes	Temperatura e atividade motora.	Parâmetros de bem-estar.	Botão de alarme e alarmes automáticos.
Intellicare [27] (Portugal)	Idosos ou dependentes	ECG, peso, glicémia e temperatura.	Correta toma de medicação e alarme de quedas.	Botão de alarme.
HealthyRoad [28] (Portugal)	Condutores com smartphones.	HR e reconhecimento facial.	Stress, sonolência e distração.	Emissão de alarmes.
Faurecia [31] (EUA)	Condutores	HR e respiração.	Estado emocional e/ou físico.	Adapta massagem e ventilação ao estado do condutor.
Plux [32] (Portugal)	Investigadores	ECG, GSR, EMG, BVP, EEG, respiração, movimento, e temperatura.	Recuperação motora e outros (dependendo do sistema de análise integrado).	
Cooking Hacks [33] (Espanha)	Investigadores	ECG, EMG, temperatura, posição corporal, glicémia, HR, GSR, respiração, e pressão arterial.	Depende do sistema de análise integrado.	

TABELA 3.2: Métodos e algoritmos de classificação usados nos estudos analisados neste capítulo.

Publicações	Métodos e Algoritmos usados	Sinais Biométricos
Healey et al. [38]	Correlação	ECG, EMG, fGSR, hGSR, e respiração.
Akbas [40]	Correlação	ECG,EMG,CPM, fGSR, hGSR, respiração e IRR.
Avci et al. [41]	Correlação	ECG,EMG,CPM, fGSR, hGSR, respiração e IRR.
Singh et al. [42]	Correlação	HR, Respiração, GSR e EMG
Singh et al. [43]	Modelação e ANN	hGSR, fGSR, EMG, Respiração e HR
Deng et al. [44]	PCA, LDF, DT, SVM, NB e K-NN.	ECG, EMG, fGSR, hGSR e respiração.
Keshan et al. [46]	NB, ANN, SVM, K-NN, ZeroR, DT, RF e RT.	ECG
Zhai et al. [50]	SVM	BVP, GSR e Diâmetro da pupila
Zhai et al. [49]	SVM, NB, DT	BVP, GSR e Diâmetro da pupila
Moore et al. [23]	Método genérico baseado em <i>thresholds</i> .	GSR
Ghaderi et al. [45]	SVM, KNN	fGSR, hGSR, HR, EMG, ECG e respiração.
Rigas et al. [48]	Classificador Bayesiano	ECG, GSR, Respiração

Capítulo 4

Base de Dados e Metodologias de Análise

Neste capítulo serão abordados todos os elementos de suporte e as metodologias utilizados para o desenvolvimento do projeto. Neste sentido, como elementos de suporte temos a base de dados que contém a informação necessária para a análise do nosso caso de estudo, e como metodologias temos vários algoritmos para o pré-processamento dos dados, desenvolvimento de *features* e para a classificação.

4.1 Base de Dados

4.1.1 Descrição da Base de Dados

Os dados utilizados para o estudo do processo fisiológico em causa, encontram-se na base de dados *Stress Recognition in Automobile Drivers*, criada por Healey e Picard [38], no banco de dados PhysioNet [51]. Este conjunto de dados inclui 18 gravações de sinais biométricos, de voluntários saudáveis, enquanto executavam uma tarefa de condução automóvel com uma duração de cerca de 2 horas. Cada registo é composto por dois ficheiros: um com extensão *.dat*, que contém os sinais fisiológicos, e um ficheiro com extensão *.hea*, com informação acerca da estrutura

do ficheiro anterior. Para facilitar o acesso aos dados, utilizou-se a *WFDB Toolbox* [52], disponibilizada no PhysioNet.

Deste modo, os sinais biométricos contidos nos registos são: Eletrocardiograma (ECG); Eletromiograma (EMG); Resposta Galvânica da Pele (GSR) da mão e do pé; Fluxo Respiratório (Resp) e Ritmo Cardíaco (HR), não necessariamente por esta ordem. No entanto, nem todos os ficheiros apresentam toda a informação necessária para o estudo. Neste seguimento, os registos indicados como *drive17a* e *drive17b* contêm apenas a última meia hora de percurso; o *drive01*, *drive03* e *drive13* não contêm informação sobre a existência ou não de *stress*; e o *drive02*, *drive04*, *drive13* e *drive14* têm em falta um ou mais dos sinais biométricos de interesse. Assim, os registos usados para o estudo foram: o *drive05*, o *drive06*, o *drive07*, o *drive08*, o *drive09*, o *drive10*, o *drive11*, o *drive12*, o *drive15* e o *drive16*.

Estes registos foram adquiridos durante uma tarefa de condução, num percurso pré-determinado, na área urbana de Boston, e teve como o objetivo determinar os níveis relativos de *stress*, tendo como análise a informação fisiológica recolhida [38]. Relativamente ao percurso definido no protocolo, este inclui segmentos indutores de diferentes níveis de *stress*. Assim, selecionaram-se segmentos de autoestrada, cidade e ainda um segmento de controlo que consistiu em, aproximadamente, 15 minutos de repouso no início e no final da tarefa [38].

Sinais Biométricos

No que diz respeito aos sinais, estes foram adquiridos com diferentes frequências de amostragem [38]. Contudo, na base de dados, estes apresentam a mesma frequência, a qual corresponde ao sinal com menor frequência de amostragem, isto é, ao sinal EMG com 15.5 Hz (figura 4.1).

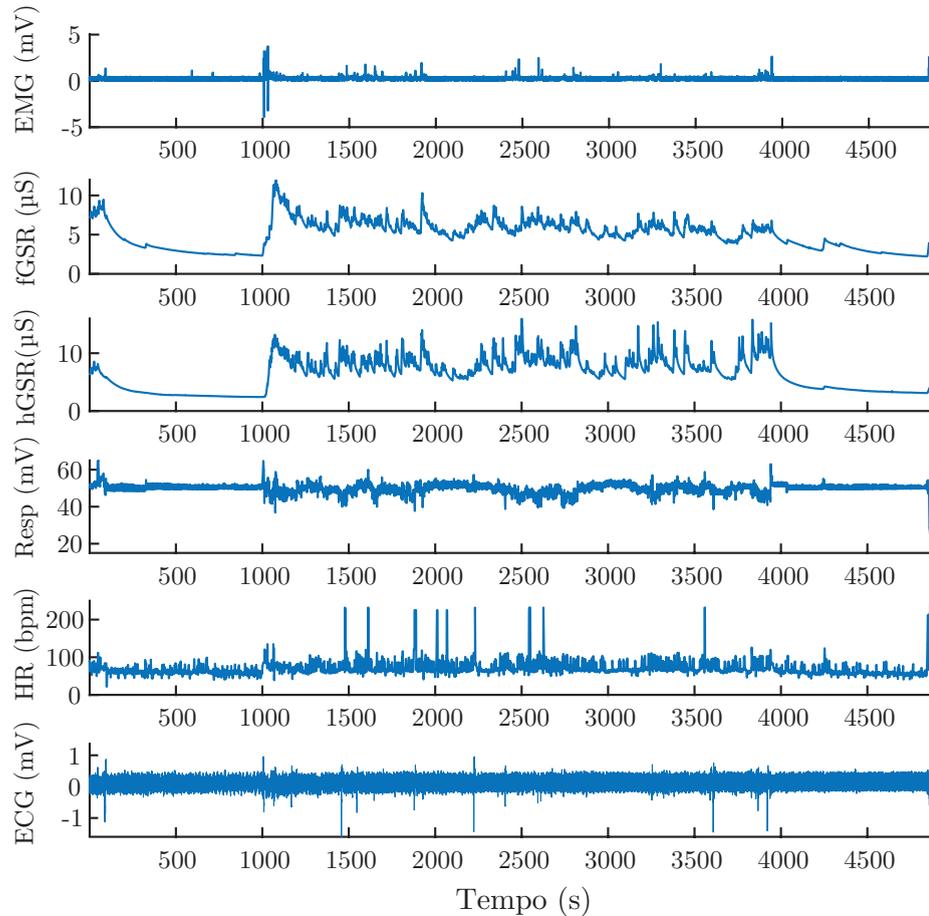


FIGURA 4.1: Sinais Biométricos do registo *drive11* (Dados retirados de: [51]).

Classificação

A métrica do *stress*, denominada como *marker*, representa, segundo Akbas [40], as transições entre os segmentos de repouso, em autoestrada e em cidade, e como existem 7 segmentos conhecidos, assumiu-se que não existe informação do nível de *stress* antes do primeiro pico e depois do último pico do *marker*. Assim, obtêm-se as durações de cada segmento (apresentadas na tabela 4.1), incluindo aqueles para os quais não existe informação acerca do nível de *stress*.

Este *marker* (figura 4.2) foi validado através da classificação de eventos, os quais provocaram maior ou menor nível *stress*, num questionário realizado após a tarefa e em reações gravadas em vídeo durante a mesma [38].

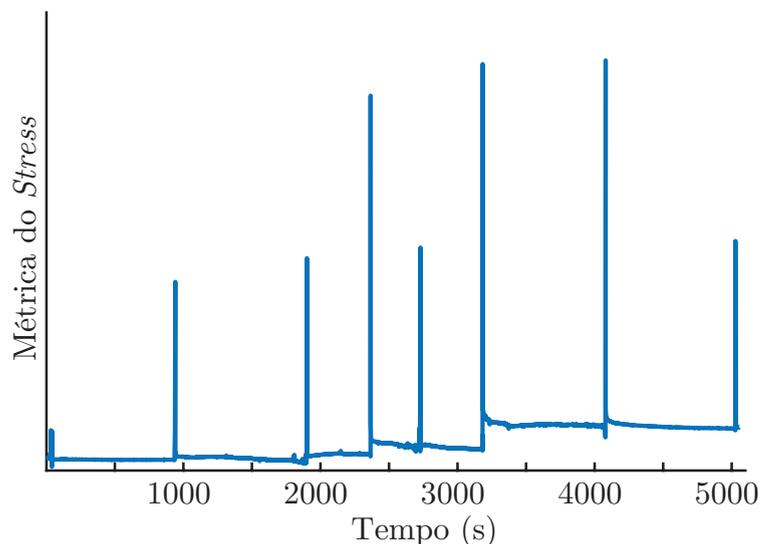

 FIGURA 4.2: *Marker* do registo *drive05* (Dados retirados de: [51]).

TABELA 4.1: Duração, em minutos, dos segmentos de repouso (R), autoestrada (A), cidade (C), dos segmentos sem informação do nível de *stress* (S) e duração total de cada um dos registos. Os intervalos 'N.D.' não estão definidos pelos autores.

Nome Registo	Segmentos de Condução (min)									Duração total (min)
	S1	R1	C1	A1	C2	A 2	C3	R2	S2	
<i>drive05</i>	0,67	15,13	16,00	7,74	6,06	7,56	14,96	15,78	0,37	84,27
<i>drive06</i>	1,63	15,05	14,49	7,32	6,53	7,64	12,29	15,05	0,78	80,78
<i>drive07</i>	1,63	15,04	16,23	10,96	9,83	7,64	10,15	15,03	2,13	88,65
<i>drive08</i>	0,57	15,00	12,31	7,23	9,51	7,64	13,43	15,07	0,44	81,19
<i>drive09</i>	0,96	15,66	19,21	8,47	5,20	7,06	13,21	N.D.	1,11	70,87
<i>drive10</i>	2,58	15,04	15,30	8,66	5,27	7,04	12,06	14,79	0,53	81,28
<i>drive11</i>	1,60	15,02	15,81	7,43	7,15	6,96	11,72	14,99	0,53	81,22
<i>drive12</i>	5,19	15,01	13,41	7,56	6,50	8,06	11,68	15,01	0,66	83,07
<i>drive15</i>	0,37	15,00	12,54	7,24	5,99	6,82	12,12	15,00	2,56	77,64
<i>drive16</i>	0,86	15,01	16,12	7,14	5,12	6,81	13,91	N.D.	0,00	64,97

4.2 Metodologias de Análise

Nesta secção, são apresentados todos os métodos utilizados para a análise dos sinais biométricos disponíveis para o estudo do processo fisiológico em causa.

4.2.1 Pré-processamento

O pré-processamento consistiu no desenvolvimento de um sistema diferente para a classificação dos dados, chamado marcador, remoção de amostras sem informação acerca do nível de *stress* e na correção de defeitos nos sinais.

Marcador: Seguindo as conclusões de Akbas [40], o *marker* representa os segmentos de condução e, conseqüentemente, os diferentes níveis de *stress*. De notar que as durações dos segmentos não são constantes em diferentes registos, uma vez que dependem de fatores extrínsecos ao protocolo definido, tais como as condições do trânsito [38]. Para a construção do marcador foram atribuídos valores para os segmentos de condução. Deste modo, segmentos sem informação do nível de *stress* são atribuídos com o valor de -1, repouso com o valor de 0, autoestrada com valor de 1 e cidade com o valor de 2. Neste seguimento, torna-se possível a criação do marcador (figura 4.3 e 4.4) para ser usado em classificação. Um exemplo de *marker* e o respetivo marcador é ilustrado de seguida (figura 4.3), para uma melhor compreensão do método.

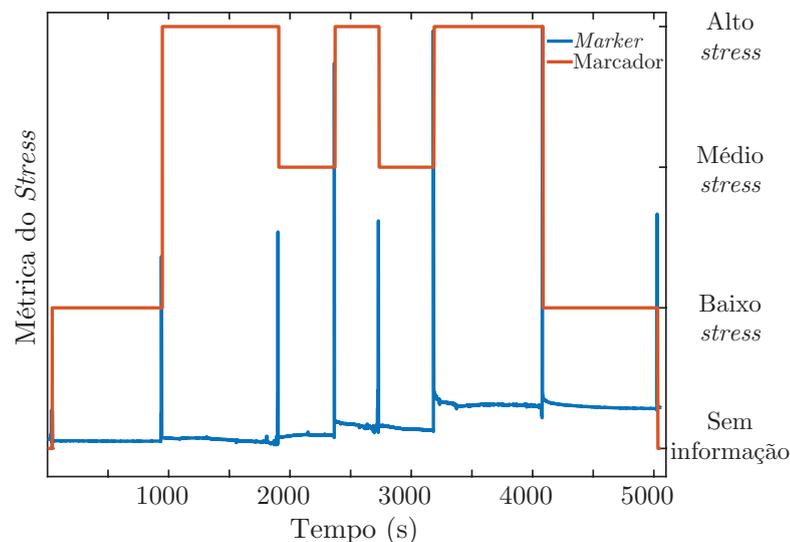


FIGURA 4.3: *Marker* do registo *drive05* e respetivo marcador criado para este registo (Dados retirados de: [51]).

Para além deste, foi desenvolvido um marcador com três níveis: Sem informação, Sem *Stress* (que corresponde aos segmentos de Repouso) e *Stress* (respetivo

aos segmentos de Auto-estrada e Cidade), reduzindo-se assim para 5 segmentos (figura 4.4).

TABELA 4.2: Duração, em minutos, dos segmentos sem *stress*, *stress*, sem informação do nível de *stress* (S) e duração total de cada um dos registos. Os intervalos 'N.D.' não estão definidos pelos autores.

Nome Registo	Segmentos de Condução (min)					Duração total (min)
	S1	Sem <i>Stress</i> 1	<i>Stress</i>	Sem <i>Stress</i> 2	S2	
<i>drive05</i>	0,67	15,13	52,32	15,78	0,37	84,27
<i>drive06</i>	1,63	15,05	48,27	15,05	0,78	80,78
<i>drive07</i>	1,63	15,04	54,81	15,03	2,13	88,65
<i>drive08</i>	0,57	15,00	50,12	15,07	0,44	81,19
<i>drive09</i>	0,96	15,66	53,15	N.D.	1,11	70,87
<i>drive10</i>	2,58	15,04	48,33	14,79	0,53	81,28
<i>drive11</i>	1,60	15,02	49,07	14,99	0,53	81,22
<i>drive12</i>	5,19	15,01	47,21	15,01	0,66	83,07
<i>drive15</i>	0,37	15,00	44,71	15,00	2,56	77,64
<i>drive16</i>	0,86	15,01	49,10	N.D.	0,00	64,97

Deste modo, segmentos sem informação do nível de *stress* são atribuídos com o valor de -1, sem *stress* com o valor de 0 e *stress* com valor de 1. Neste contexto, torna-se possível a criação do marcador para ser usado em classificação. Um exemplo de *marker* e respetivo marcador é ilustrado de seguida (figura 4.4), para uma melhor compreensão do método.

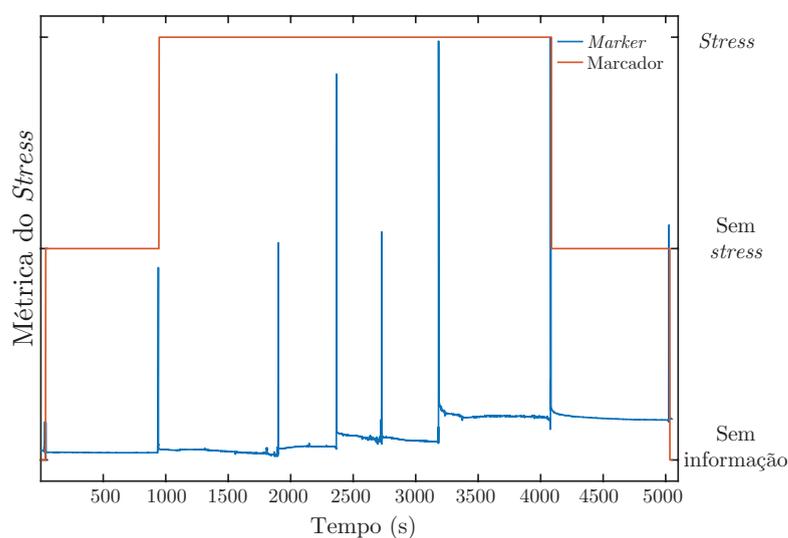


FIGURA 4.4: *Marker* do registo *drive05* e respetivo marcador (multiclasse) criado para este registo (Dados retirados de: [51]).

Sinais: Certos registos, incluídos na base de dados, apresentam frações sem sentido em alguns sinais, provavelmente por deslocação dos elétrodos ou problemas durante a aquisição (ver Figura 4.5 aos 2000 segundos do sinal do ECG e HR). Para contornar esta dificuldade, optou-se por remover as amostras que continham estes problemas, em todos os sinais, incluindo no marcador já criado. Para além disso, foram removidas todas as amostras cujo marcador apresenta valores -1, visto que não têm utilidade para o objetivo em causa. Por motivos de incompatibilidade da plataforma de aquisição da Cooking Hacks, foi necessário optar pela análise do EMG ou ECG, pelo que se escolheu utilizar o EMG por razões de comodidade na aquisição. Por fim, como os sinais de hGSR e fGSR são muito semelhantes e seguem os mesmos princípios físicos, utilizou-se apenas o hGSR pelo mesmo motivo referido anteriormente.

Isto significa que, para a análise do *stress*, serão considerados 4 dos sinais biométricos iniciais: EMG, hGSR, Resp e HR.

4.2.2 Processamento dos Sinais

Extração de *Features*

Uma vez que Healy e Picard obtiveram bons resultados na deteção de *stress* [38], procurou-se extrair dos sinais algumas das *features*, ou variantes, como também se desenvolveram novos atributos, de modo a atingirem-se resultados semelhantes. Assim, foram calculadas as seguintes *features*:

- meanemg
- medianemg
- emgv
- aemg
- meanhgsr
- medianhgsr
- hgsrv
- ahgsr

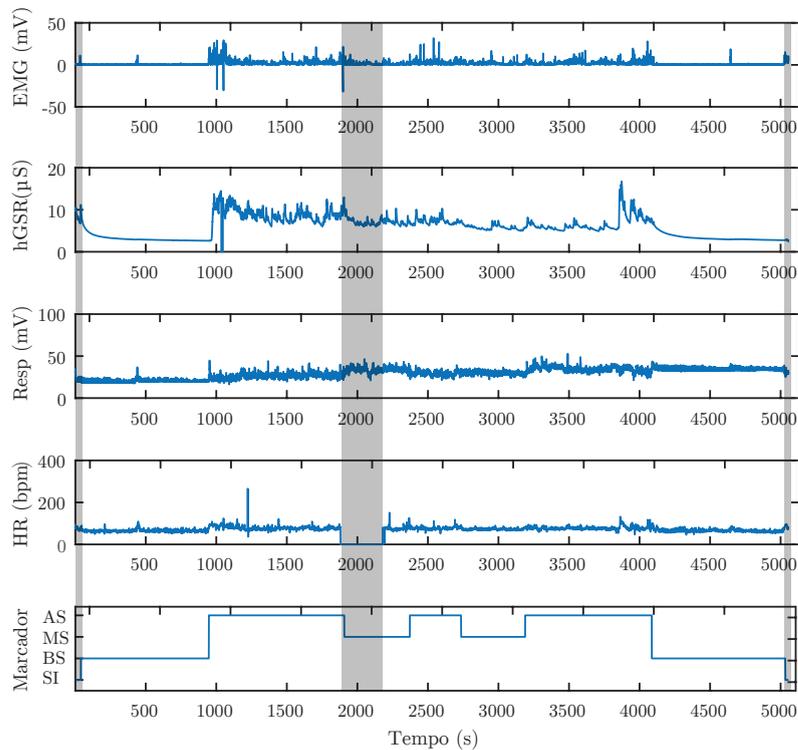


FIGURA 4.5: Registo *drive05*, com o respetivo marcador multiclasse e intervalos de amostras a ser eliminadas no pré-processamento, no início do registo, aproximadamente aos 2000 segundos e no final do registo (a cinzento). No marcador multiclasse estão representados os segmentos de AS (alto *stress*), MS (médio *stress*), BS (baixo *stress*) e SI (sem informação) (Dados retirados de: [51]).

- meanresp
- medianresp
- respv
- aresp
- meanhr
- medianhr
- hrv
- ahr
- L100
- M100
- L300
- M300

Análise por Janelas Deslizantes: Em primeiro lugar, importa esclarecer o método de análise por janelas deslizantes considerado (figura 4.6). Como os sinais fisiológicos são sinais contínuos, procurou-se que as *features* demonstrassem essa continuidade. Por exemplo, o cálculo da média do sinal EMG é feito com um tamanho de janela de 20 segundos e um avanço de janela de 2 segundos. Para a definição do tamanho da janela teve-se em conta o intervalo de tempo até ao primeiro valor de classificação, que se pretendia que não fosse excessivamente longo, embora não possa ser demasiado pequeno para não limitar o conteúdo de informação em cada janela de análise. Relativamente ao passo da janela, como a frequência de amostragem dos dados é de 15,5Hz, então se se considerasse um avanço da janela de 1 segundo (tal como Healey e Picard [38]), implicaria uma aquisição de 15,5 amostras. Contudo, este valor de passo implicaria várias complicações durante a gestão dos dados para o seu processamento, para prevenir perdas de dados, pelo que se optou por evitar estes problemas definindo o passo da janela como 2 segundos. Isto significa que a cada 2 segundos é produzida uma nova amostra para cada *feature*.

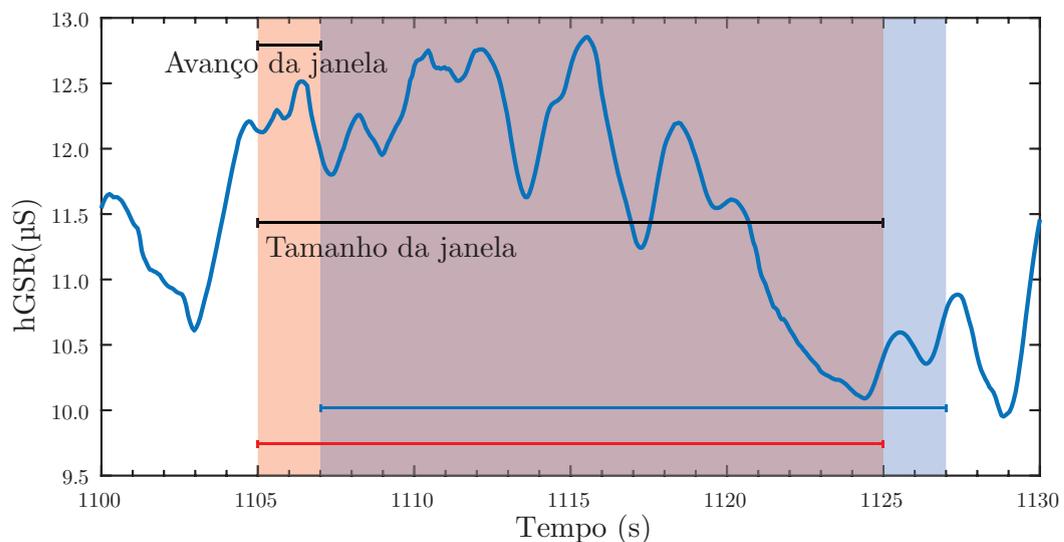


FIGURA 4.6: Ilustração da análise por janelas deslizantes aplicado.

Assim como grupo de *features* calculadas temos:

- **Features Estatísticas:** Correspondem às *features* relativas à média, mediana e variância dos sinais. Para isso, utilizou-se a análise das janelas deslizantes para seccionar as amostras, e posteriormente aplicaram-se os métodos estatísticos em questão. Neste seguimento, a média aritmética das amostras de uma janela, \bar{x} , é calculada através do o quociente entre a soma do valor das amostras e o número de amostras da janela, dado pela equação 4.1.

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (4.1)$$

A mediana, η , diz respeito ao valor médio num conjunto ordenado de valores. Se o número de amostras é ímpar, a mediana representa exatamente o valor central; se, por sua vez, o número de amostra é par, a mediana corresponde à média dos dois valores centrais. Por isso, o domínio dos valores não influencia a mediana, visto que esta é alterada de acordo com a distribuição dos dados [53].

A variância diz respeito ao quadrado do desvio padrão. Esta evidencia os desvios relativamente ao valor esperado, que corresponde à média aritmética.

- **Frequência correspondente a metade da área da resposta em frequência:** Cada sinal pode ser representado no domínio do tempo e no domínio da frequência. Neste sentido, procurou-se fazer uma análise em termos das componentes de frequência do sinal. Para tal, calculou-se a curva de resposta do sinal em frequência e de seguida determinou-se a área total sob a curva, utilizando-se a regra dos trapézios. Dado um sinal contínuo $f(x)$ com um intervalo finito entre a e b , a sua área total é igual a:

$$\int_a^b f(x)dx \approx \frac{b-a}{2n} (f(x_0) + 2f(x_1) + \dots + 2f(x_{n-1}) + f(x_n)),$$

onde n corresponde ao número de divisões [54].

Posteriormente, determina-se a frequência cuja área é metade da área total anteriormente calculada (figura 4.7).

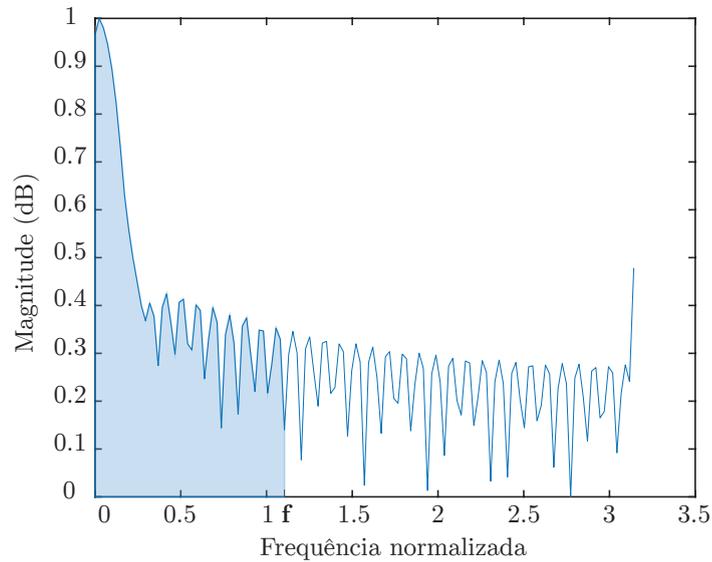


FIGURA 4.7: Sinal Resp, no intervalo entre os 40 e 60 segundos, no respetivo domínio da frequência. A área a azul representa metade da área do sinal e f a frequência corresponde a metade da área total.

- **L100, M100, L300, M300:** O algoritmo para o desenvolvimento destas *features* tem como base alguns dos fundamentos de Healey e Picard [38]:
 - As *features* são calculadas com base no sinal do ritmo cardíaco (HR), derivado do sinal de ECG;
 - O tamanho das janelas é de 100 segundos para as *features* L100 e M100 e de 300 segundos para as *features* L300 e M300 e o passo de 2 segundos;
 - As bandas de frequências consideradas para o sinal HR foram de baixa frequência (BF) (0-0.08Hz), média frequência (MF) (0.08-0.15Hz) e de alta frequência (AF) (0.15-0.5Hz);
 - As fórmulas para o cálculo são $L = \frac{BF}{AF}$, para L100 e L300 e $M = \frac{BF+MF}{AF}$ para M100 e M300.

Neste sentido, o algoritmo define em primeiro lugar o número de janelas que corresponde ao número de índices desde a amostra dos primeiros 100 segundos (ou 300 segundos) até ao final do sinal com um passo de 31 amostras. Ou seja, a primeira janela corresponde aos primeiros 100 segundos (ou 300) do sinal HR e as janelas seguintes têm um avanço de 2 segundos relativamente à janela anterior.

No que diz respeito ao cálculo, cada secção de dados é multiplicada por uma janela de *Hamming* (equação 4.2) [55], e depois é calculada a potência relativa com auxílio de ferramentas do *software* EPILAB [56]. No fim, são aplicadas as fórmulas: $L = \frac{BF}{AF}$ e $M = \frac{BF+MF}{AF}$.

$$w[n] = \begin{cases} 0.54 - 0.46 \cos\left(\frac{2\pi n}{M}\right), & \text{se } 0 \leq n \leq M \\ 0, & \text{caso contrário} \end{cases} \quad (4.2)$$

Seleção de *Features*

A seleção das *features* é um passo importante em análise de dados, uma vez que permite preservar a informação mais relevante, de modo a reduzir o custo computacional, eliminando dados redundantes. Para além disso, pode haver um aumento no desempenho da classificação, uma vez que se elimina informação que pode induzir ao erro. Neste contexto, procurou-se fazer um balanceamento entre a qualidade das *features* (usando a correlação e o algoritmo da mínima redundância máxima relevância (mRMR)) e o tempo de computação, apresentados de seguida.

1. **Correlação:** A correlação mede a relação linear entre duas variáveis [53]. Deste modo, é possível utilizar-se a correlação entre cada *feature* e o marcador, com o objetivo de determinar *features* significativas para a classificação, ou calcular a correlação entre *features* para eliminar *features* muito correlacionadas.
2. **mRMR:** Este algoritmo permite selecionar as *features* com maior relevância face ao marcador, ao mesmo tempo que minimiza a redundância entre *features* [57], por meio do cálculo da informação mútua das variáveis.
3. **Tempo de Computação:** Este método consiste na avaliação do custo computacional na produção das *features*, numa janela de dados. Como o objetivo é colocar a plataforma a adquirir em tempo real, e sabendo que cada nova

janela de dados surge a cada 2 segundos, é indispensável verificar o tempo dispendido apenas para a produção das *features*.

No final, é necessário fazer um balanço entre a qualidade das *features* e o seu respetivo tempo de computação, podendo ter que se ceder ou no desempenho do classificador ou no aumento do tempo de aquisição de novos dados.

Redução da dimensão dos dados

Como método de redução da dimensão dos dados, aplicou-se o PCA.

PCA: Este algoritmo visa reduzir o espaço de representação dos dados, com o mínimo de redundância e sem perda de informação. Para isso, são calculadas as componentes principais na representação inicial, de modo a garantir que a nova projeção dos dados apresente a maior variabilidade possível. Contudo, existe a desvantagem da perda de significado físico das variáveis finais [58].

Normalização

A abordagem usada para a normalização dos dados foi a descrita na equação (4.3), em que Y representa os dados normalizados, X os dados iniciais, μ a média dos dados e σ o desvio padrão dos dados. Esta fase do processamento permite que *features* iguais, em diferentes registos, tenham a mesma importância quando apresentadas a um classificador.

$$Y = \frac{X - \mu}{\sigma} \quad (4.3)$$

Balanceamento dos dados de treino

Este método consiste na divisão equitativa dos dados de treino pelas classes possíveis. Para isso, foi determinado o número de amostras de cada uma das classes, obteve-se o menor valor e escolheu-se aleatoriamente, em cada classe, o

mesmo número de amostras. Muitas vezes, este método pode ser fundamental para evitar fenómenos de *over-predicting*, isto é, o modelo de classificação assumir sempre como saída do modelo, a classe com maior número de amostras nos dados de treino, porque garante o melhor resultado de classificação [59].

4.2.3 Análise dos dados

Tendo a informação mais relevante e de mais rápido processamento selecionada, utilizaram-se métodos de classificação comuns. Estes métodos permitem, em poucas palavras, reconhecer nova informação e fazer previsão sobre a mesma, quando previamente treinados. Para isso, e tendo em conta os algoritmos de classificação utilizados, árvore de decisão e rede neuronal, foi necessário separar os dados para o treino e teste de forma específica, devido à estrutura do classificador.

Árvore de Decisão

Este método de classificação é um método de fácil implementação devido à simplicidade na construção e utilização do modelo, com o auxílio da *Statistics and Machine Learning ToolboxTM* [60], do MATLAB. Este modelo é constituído por nodos internos (representados a negrito, na figura 4.8), ramos e folhas. Os primeiros representam características de decisão, os ramos as hipóteses daquela característica de teste e as folhas correspondem à classificação final [61]. Estas ramificações são definidas aquando do treino do modelo, que estabelece os ramos que devem ser criados de modo a maximizar a probabilidade de uma correta decisão no nodo seguinte. Para tal, são fornecidos ao sistema um conjunto de dados de treino, representado pelo nodo inicial, para o desenvolvimento do modelo. No final de cada ramificação existe um nodo final, denominado por folha, que representa a classe a que pertence [62, 63] a amostra apresentada. Resumindo, a separação dos dados para a aprendizagem deste algoritmo consiste num grupo de dados de treino, que serve para o algoritmo definir as decisões possíveis, e num grupo de dados de teste que tem como função verificar a aprendizagem do algoritmo. O exemplo da

figura 4.8 mostra a facilidade de interpretação do modelo, bem como a facilidade de percepção das características que cada classe apresenta. Na imagem da figura 4.8 está representada a identificação de uma fruta com base nas características de cor, tamanho, forma e sabor.

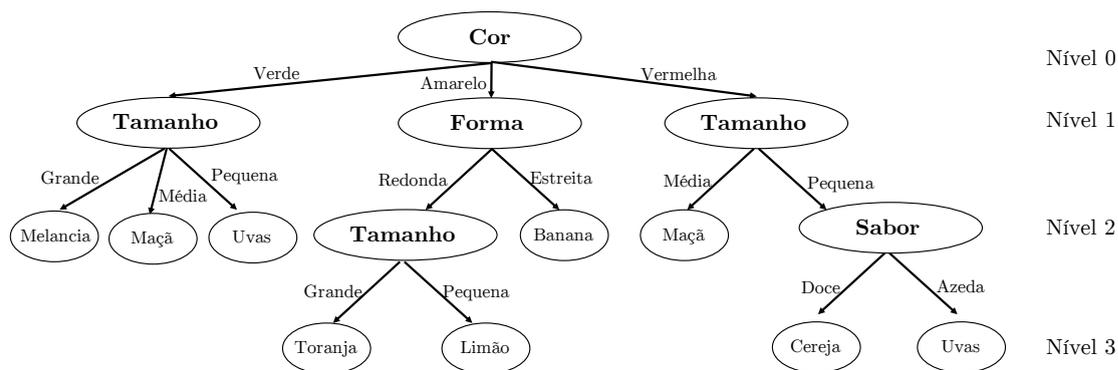


FIGURA 4.8: Exemplo de uma Árvore de decisão (Adaptado de: [62]).

Rede Neuronal Artificial

Este método resulta de uma representação matemática de uma rede de neurónios nos sistemas biológicos. Da mesma forma como os neurónios conduzem informação para o cérebro com o objetivo de a transformar numa resposta, também a rede neuronal artificial segue o mesmo princípio. A estrutura mais simples corresponde a um neurónio, designado por percetrão. Este pode ter vários parâmetros de entrada, cada um com determinado peso, e vários parâmetros de saída, dependendo do número de respostas desejadas. Na entrada do neurónio são somados todos os produtos entre os respetivos parâmetros de entrada e o peso da ligação. Deste modo, a informação proveniente de ligações mais fracas tem menos importância do que dados de ligações mais fortes. Cada neurónio contém uma função matemática associada (função de ativação), a qual é aplicada sob o somatório anterior, produzindo assim uma resposta final. Contudo, isto só acontece no caso do percetrão, uma vez que tem um único neurónio, o que torna a sua computação mais simples mas apenas útil em problemas lineares. Neste caso, devido à complexidade dos dados, é necessário o uso de estruturas mais sofisticadas, com um maior

número de camadas de neurónios, como é o caso de percetrões de multicamada, que apresentam um número variável de neurónios e de camadas de neurónios, o que torna a aprendizagem mais lenta, mas mais eficiente (figura 4.9) [63]. Assim, são necessários três grupos de dados: de treino, para ajustar os pesos entre os neurónios; de validação, que permite verificar quando se deve parar o ajuste dos pesos; e de teste, que tem como função verificar a aprendizagem do algoritmo. No contexto deste projeto, foi utilizado este tipo de estrutura, a *hyperbolic tangent sigmoid* como função de ativação (equação 4.4) e o algoritmo retro-propagação de Levenberg-Marquardt [64] como método de ajuste dos pesos das ligações da rede. Além disto, o controlo do treino das redes está a ser efetuado utilizando o mecanismo de *earlystopping*.

$$Y = \frac{2}{1 + e^{-2n}} - 1 \quad (4.4)$$

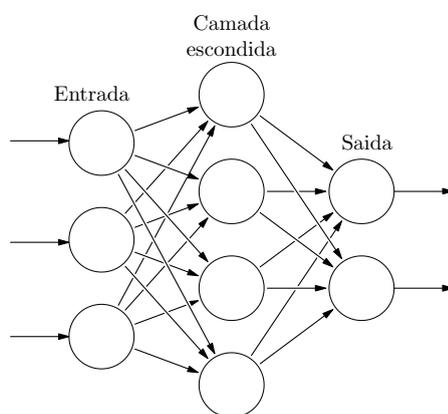


FIGURA 4.9: Representação esquemática de um percetrão de multicamada.

4.2.4 Métodos de avaliação do desempenho do classificador

Estes métodos servem para compreender se o classificador está a fazer uma correta aprendizagem da informação que lhe é fornecida. Para isso, é feito *cross validation*, ou seja, há uma divisão dos dados em dois grupos: 7 registos para treino e 3 registos para teste. Este método de *hold out cross validation* tem como

função avaliar a utilização do PCA e dos algoritmos de classificação, uma vez que vai ser verificada a aprendizagem do classificador em 120 combinações possíveis.

Posteriormente, após definida a metodologia a aplicar, foi aplicado o *leave one out cross validation* de modo a perceber o resultado da classificação numa situação real. Aqui, a divisão dos dados foi de 9 registos para treino e 1 registo para teste. Em cada uma das combinações (10 combinações, neste caso), o classificador é treinado e aplicado nos dados de teste. No final, os dados à saída do classificador são comparados com o marcador para uma avaliação final, com recurso à matriz de confusão (figura 4.3).

TABELA 4.3: Matriz de Confusão.

		Previsto	
		Positivo	Negativo
Real	Positivo	Verdadeiro Positivo (VP)	Falso Negativo (FN)
	Negativo	Falso Positivo (FP)	Verdadeiro Negativo (VN)

Neste sentido, consideram-se como Verdadeiro Positivo todos os dados previstos como positivos e que de facto são positivos relativamente a uma classe, Falso Negativo todos os dados previstos como negativos que contudo são positivos, Falso Positivo todos os dados previstos como positivos não o sendo na realidade e Verdadeiro Negativo como todos os dados previstos como negativo e que de facto são negativos.

Para avaliação propriamente dita da classificação são utilizadas as seguintes métricas:

1. Sensibilidade e Especificidade:

$$\text{Sensibilidade} = \frac{VP}{VP + FN}$$

$$\text{Especificidade} = \frac{VN}{VN + FP}$$

2. **Accuracy (Acc):**

$$Accuracy = \frac{VP + VN}{VP + FN + FP + VN}$$

3. **Accuracy Pesada (wAcc):** Esta medida tem em conta o número de amostras de cada classe. Segundo Michał Draminski, "considerando-se um problema com c classes, em que n_{ij} corresponde ao número de amostras desde a classe i classificados como sendo da classe j " [65], então:

$$Accuracy \text{ Pesada} = \frac{1}{c} \sum_{i=1}^c \frac{n_{ii}}{n_{i1} + n_{i2} + \dots + n_{ic}}$$

4. **AUC:** Consiste no cálculo da área sob a curva ROC. Esta curva permite visualizar o desempenho do classificador em função de um limiar de separação. Esta representa a taxa de verdadeiros positivos $TVP = \frac{VP}{VP+FN}$, ou sensibilidade, em função da taxa de falsos positivos $TFP = \frac{VN}{VN+FP}$, ou especificidade, à medida que o limiar de separação das classes varia. Assim, num caso de classificação binária o valor de AUC é igual para ambas as classes, enquanto que num caso de classificação multiclasse, o valor de AUC representa a capacidade do classificador discriminar uma determinada classe face às restantes [63].

4.3 Configurações para o estudo da aquisição dos sinais biométricos

Nesta secção, importa esclarecer as configurações desenvolvidas para o estudo da aquisição dos sinais biométricos. Em primeiro lugar, construiu-se um modo *off-line*, que funciona como um simulador de entrada de dados, que se encontram num histórico de armazenamento. O modo *on-line* representa o sistema final, que faz a aquisição dos dados em tempo real, através dos sensores do *kit* utilizado, e que depois os processa e analisa. Os termos *off-line* e *on-line* significam, neste caso, se os dados estão a entrar no sistema de uma forma simulada (*off-line*), ou em tempo real (*on-line*) através de estímulos captados pelos sensores.

4.3.1 Modo *off-line* simulado

Este modo tem como finalidade simular a aquisição dos sinais fisiológicos, de modo a suavizar a adaptação à fase seguinte. Para isso, desenvolveu-se uma fase inicial de pré-aquisição que seleciona um registo para teste e os restantes para o treino, extraíndo as *features* e treinando o algoritmo de classificação a ser usado. A figura 4.11 corresponde ao fluxograma de funcionamento deste modo do sistema.

Análise dos sinais: Para simular a aquisição dos dados, criou-se um vetor designado *buffer1*, o qual reserva uma amostra de dados em cada iteração. A cada ciclo é verificado se o número de amostras contidas no *buffer1* é igual ao número de amostras necessário para o cálculo das *features*, isto é, se tem o número de amostras igual ao número de amostras da janela utilizada. Se o número for insuficiente, é executada uma nova iteração; se a condição for satisfeita, então é accionado o módulo de análise dos sinais. Nesta etapa, são extraídas as *features* já previstas como as mais significativas, em termos de qualidade e tempo de aquisição (4.2.2), e aplicado o modelo de classificação que gera um resultado que se adiciona a um vetor *buffer2*. No fim da classificação da amostra, o vetor *buffer1* necessita de ser redesenhado, de modo a garantir a integridade do sistema nas futuras aquisições.

Gestão da emissão de alarmes: Esta etapa diz respeito ao funcionamento do *buffer2*, que tem uma dinâmica semelhante ao *buffer1*. Contudo, esta tem como objetivo gerir a emissão de informação para fora do sistema acerca da classificação, sob a forma de alarme. Para isso, é utilizado a análise por janelas deslizantes semelhante ao já descrito, com um diferente tamanho da janela e avanço. Da mesma forma que na etapa anterior, quando a condição de igualdade entre amostras do *buffer2* e o número de amostras da janela é alcançada, são eliminadas da estrutura o número de amostras iniciais correspondentes ao avanço da janela. Esta característica do sistema é utilizada quer para o modo *off-line* simulado quer para o modo *on-line* em tempo real. As diferenças são que, para o primeiro modo, o tamanho da janela foi definido para os 40 segundos e o passo para 5 segundos, enquanto no

modo *on-line*, o tamanho da janela de análise das classificações foi definido como 1 minuto e o intervalo entre alarmes com o tempo variável (figura 4.10).

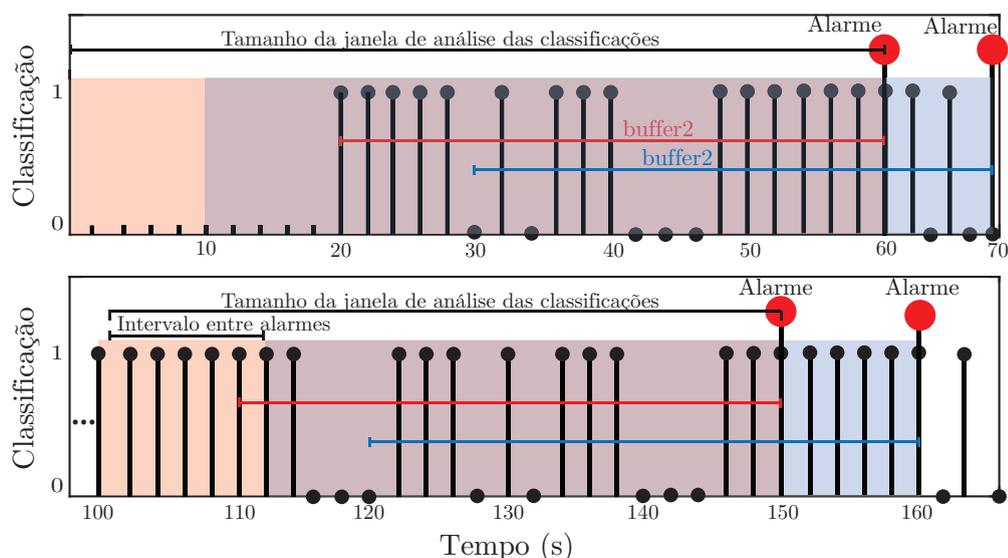


FIGURA 4.10: Ilustração da análise por janelas deslizantes aplicado, para a gestão dos alarmes, com um intervalo entre alarmes de 10 segundos.

No intervalo entre alarmes, há um pormenor a ter em conta, como cada classificação surge a cada 2 segundos, então configurou-se valores pares de intervalos de tempo, entre os 2 e os 42 segundos. Isto acontece porque, para a primeira janela de classificação (imagem superior da figura 4.10) serão geradas 21 amostras (a primeira aos 20 segundos e as seguintes de 2 em 2 segundos), por isso o passo mínimo da janela será 2 segundos, que corresponde ao avanço de uma amostra; enquanto que, o passo máximo será 42 segundos que diz respeito ao avanço das 21 amostras de classificação, que podem estar presentes no `buffer2`.

4.3.2 Modo *on-line* em tempo real

Em primeiro lugar, importa esclarecer o conteúdo de cada módulo da plataforma desenvolvido:

1. **Módulo de Aquisição e Transmissão:** Corresponde à componente física da plataforma (figura 4.12) e à programação da mesma. Relativamente a

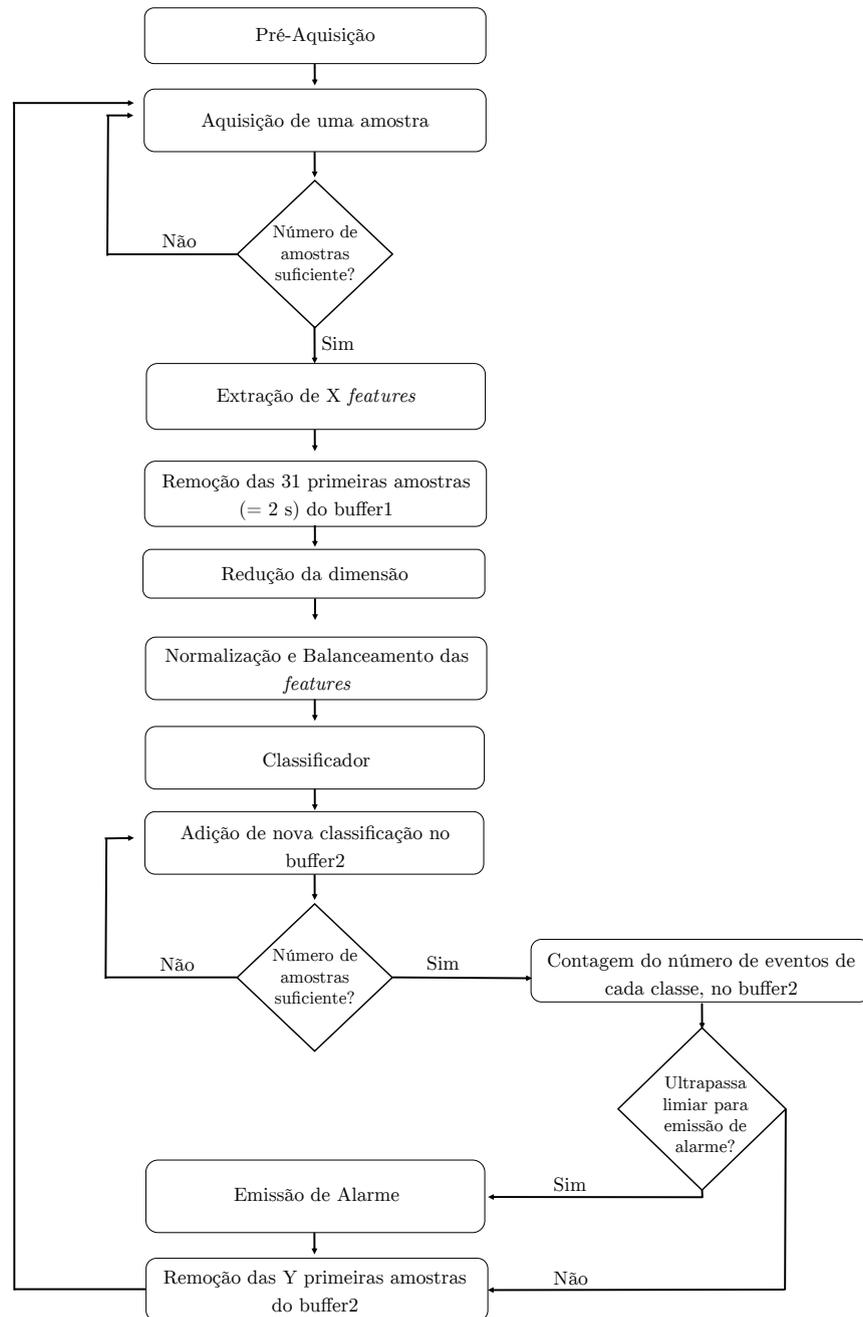


FIGURA 4.11: Fluxograma do funcionamento do modo off-line simulado.

esta, consiste no conjunto do Arduino, a *shield* da Cooking Hacks, os respectivos sensores e o cabo USB. A figura 4.12 mostra a montagem dos sensores utilizados para o nosso sistema.

Relativamente à programação do Arduino, toda a informação necessária encontra-se disponível no tutorial da Cooking Hacks [33]. Neste tutorial



FIGURA 4.12: Montagem experimental do Arduino, a *shield* e dos sensores para os sinais a ser medidos (EMG, GSR, Resp e HR).

estão presentes quais as bibliotecas que devem ser usadas, bem como os comandos para a aquisição de cada um dos dados dos sensores. Para além disto, é preciso aproximar o melhor possível a frequência de amostragem de aquisição do Arduino à frequência de amostragem dos dados de treino (15,5 Hz), com a introdução de um atraso na aquisição, bem como a calibração do sensor para a aquisição do sinal GSR.

2. **Módulo de Processamento e Análise:** Inclui a extração de *features*, normalização e classificação dos dados.
3. **Módulo de Armazenamento:** Consiste em guardar os sinais, após aquisição na plataforma, para serem posteriormente utilizados.

Fluxo dos dados

O modo *on-line* funciona de forma semelhante ao modo *off-line*. Contudo, neste caso, cada iteração não corresponde a uma aquisição de uma amostra, mas sim de um conjunto de amostras, adquiridas em tempo real. Neste sentido, a estrutura do funcionamento deste modo requer a utilização de processos a funcionar em paralelo, uma vez que se está a lidar com o fator tempo, ao contrário do modo

off-line simulado. Para tal, a estrutura será constituída por um ramo central e um ramo periférico, o qual necessita de uma ligação ao primeiro ramo. Assim, é possível seguir uma das duas abordagens: colocar a fase de aquisição no ramo central e a fase de processamento no ramo periférico ou o inverso. A escolha da abordagem utilizada irá depender, em grande parte, do tempo de computação.

1. **Processamento no ramo central:** Este método (figura 4.13) inicia-se com a pré-aquisição que implica a criação e treino do modelo de classificação. De seguida, são recolhidas as amostras do Arduino (que foram previamente adquiridas), correspondentes à primeira janela de dados, através da porta Serial que se mantém aberta até ordem contrária. A informação recolhida é de imediato reservada numa estrutura de armazenamento temporário, para a respetiva análise, e numa estrutura de armazenamento definitivo, para guardar o registo dos dados finais. Posteriormente à aquisição dos dados, ocorre a extração de *features* e classificação da informação que só será revelada para o exterior, após gestão dos alarmes. Logo que seja terminada a fase de processamento, são eliminadas da estrutura de armazenamento temporário as primeiras amostras, correspondentes ao avanço da janela, tal como acontece no modo *off-line* simulado. Como a porta Serial se mantém aberta, então há recolha de informação ao mesmo tempo que acontece a fase de processamento e análise dos sinais, o que implica que, no final de cada iteração, exista um novo conjunto de dados prontos a serem analisados. No momento de finalizar o processo, por ordem do utilizador, a porta Serial é encerrada e, dependendo do momento de término, pode ocorrer a análise da última janela adquirida. A análise do tempo de computação irá incidir no tempo dispendido na fase de análise e classificação, visto que este tempo não pode ser superior a 2 segundos.

Neste sentido, é crucial que cada ciclo de cálculo não ultrapasse certos requisitos. Por exemplo, no primeiro ciclo de cálculo, isto é, o tempo desde o pedido da primeira janela de sinais até à leitura dos novos dados, não pode exceder os 20 segundos enquanto que para os ciclos seguintes (desde o processamento até à leitura dos novos dados) não pode exceder os 2 segundos.

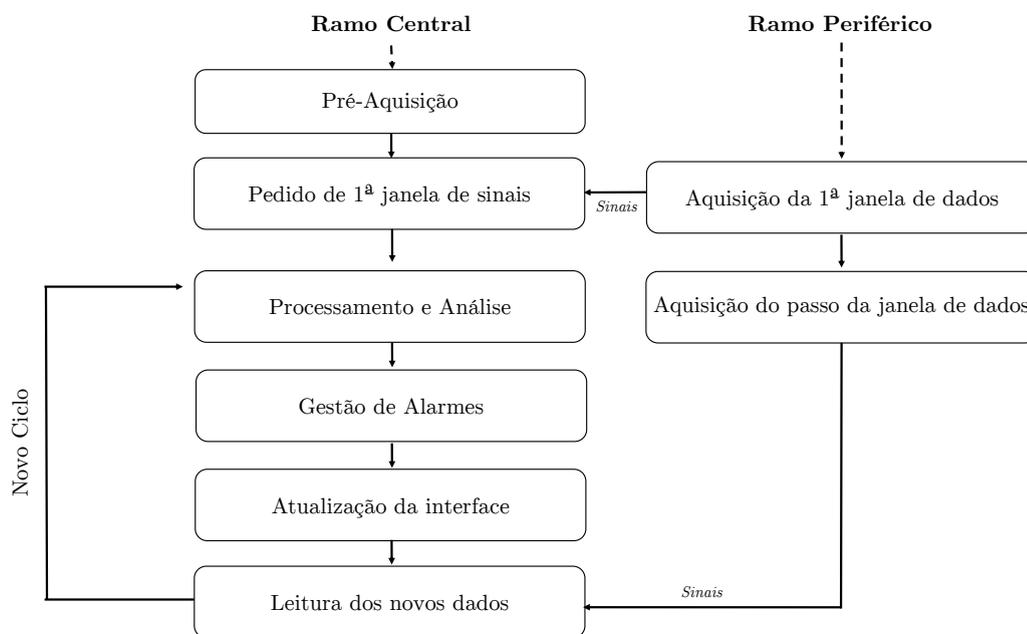


FIGURA 4.13: Fluxograma do funcionamento do modo *on-line*, com a configuração do processamento no ramo principal.

2. **Aquisição no ramo central:** Neste caso, o ramo central apenas é composto pela aquisição dos dados pelo Arduino, e o ramo periféricos consiste no processamento e a análise dos sinais (figura 4.14) . Isto implica que em cada iteração seja criada uma nova ligação *batch*, que permite executar o processamento e análise, ao mesmo tempo que ocorre uma nova aquisição, no ramo central. De modo semelhante ao método anterior, o tempo de computação quer do ramo central quer do periférico, não pode exceder o avanço da janela, por razões diferentes. Se o tempo de aquisição dos dados exceder o avanço da janela, impede o correto processamento dos sinais devido à falta de dados; se, por sua vez, o tempo de processamento e análise for superior ao avanço da janela, irá haver uma acumulação de dados e, por isso, um atraso no tratamento da informação e na emissão de alarmes.

Nesta abordagem, os requisitos de tempo também se mantêm sendo que, neste caso, o primeiro ciclo de cálculo corresponde à aquisição da primeira janela de sinais até à nova aquisição, enquanto que os ciclos seguintes correspondem à criação da ligação *batch* até à aquisição dos novos dados. Por

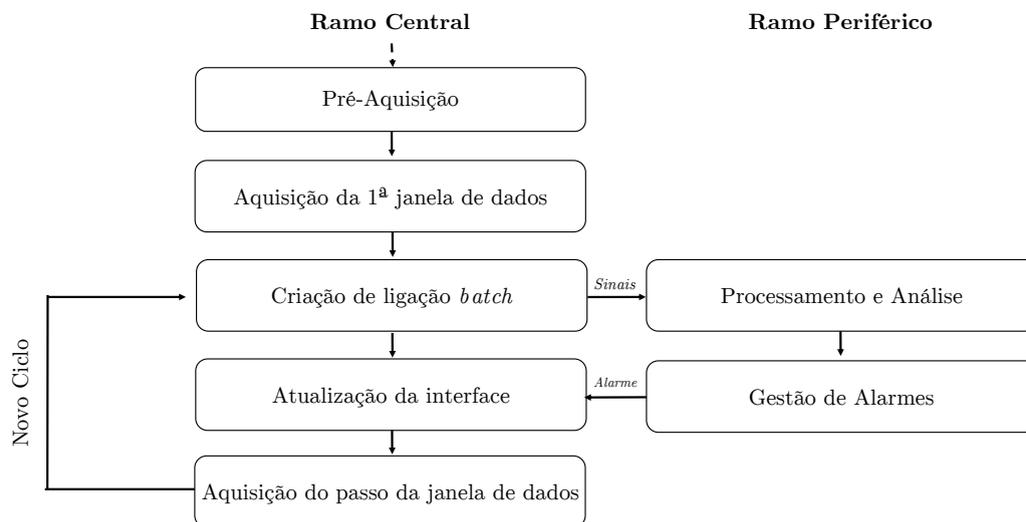


FIGURA 4.14: Fluxograma do funcionamento do modo *on-line*, com a configuração da aquisição no ramo principal.

fim, é aplicado o mesmo procedimento para a gestão dos alarmes como no modo *off-line*.

Depois de selecionada a abordagem a seguir para o modo *on-line*, é desenvolvida a interface que liga todos os módulos constituintes da plataforma.

4.4 Síntese

Em resumo, cada registo foi submetido ao pré-processamento para remover informação sem interesse, processado para extrair informação (num total de 20 *features*, no domínio do tempo e da frequência) e analisado por métodos de classificação. Numa primeira fase, foram selecionadas as *features* mais significativas para a classificação, usando o algoritmo mRMR, tendo em consideração o tempo de aquisição de cada uma das *features* e a correlação entre cada *feature* e o *target* e ainda entre *features*. Depois de descobertas as *features* com maior relevância para a classificação, analisou-se a necessidade de utilização do PCA e também qual o modelo de classificação que aprende com maior desempenho a informação.

Posteriormente, foram estudadas configurações de aquisição de dados num ambiente de simulação de dados já existentes (modo *off-line* simulado), e estruturas de aquisição de dados em tempo real (modo *on-line*) com a utilização do *kit* da Cooking Hacks.

Capítulo 5

Apresentação e Discussão dos Resultados Obtidos

Neste capítulo, serão apresentados e discutidos todos os resultados obtidos ao longo do projeto. Como tal, irão ser apresentados os resultados referentes à aplicação de várias metodologias, bem como avaliações acerca de quais as informações mais relevantes para a deteção do processo fisiológico em causa. Além disto, também é determinada qual a estrutura para a construção do modo *on-line*, que permite um melhor funcionamento do fluxo da informação.

5.1 Seleccção de *Features*

Para esta secção convém ter em mente a informação contida na tabela 5.1. Esta contém o número, designação e respetivo descrição de cada uma das *features*. Esta, e outras informações relevantes neste contexto, encontram-se no apêndice A.

TABELA 5.1: Número, designação e descrição de cada uma das *features* calculadas.¹

Número	Designação	Descrição
1	meanemg	Média aritmética do sinal EMG.
2	medianemg	Mediana do sinal EMG.
3	emgv	Variância do sinal EMG.
4	aemg	Frequência de metade da área da resposta em frequência do sinal hGSR.
5	meanhgsr	Média aritmética do sinal hGSR
6	medianhgsr	Mediana do sinal hGSR
7	hgsrv	Variância do sinal hGSR
8	ahgsr	Frequência de metade da área em resposta à frequência do sinal hGSR
9	meanresp	Média aritmética do sinal Resp.
10	medianresp	Mediana do sinal Resp.
11	respv	Variância do sinal Resp.
12	aresp	Frequência de metade da área da resposta em frequência do sinal Resp.
13	meanhr	Média aritmética do sinal HR.
14	medianhr	Mediana do sinal HR.
15	hrv	Variância do sinal HR.
16	ahr	Frequência de metade da área da resposta em frequência do sinal HR.
17	L100	Razão entre a potência da banda de baixa frequência e a banda de alta frequência para janelas de 100 segundos.
18	M100	Razão entre a potência da soma da banda de baixa frequência com a média frequência e a banda de alta frequência para janelas de 100 segundos.
19	L300	Razão entre a potência da banda de baixa frequência e a banda de alta frequência para janelas de 300 segundos.
20	M300	Razão entre a potência da soma da banda de baixa frequência com a média frequência e a banda de alta frequência para janelas de 300 segundos

¹ Esta informação encontra-se também no Apêndice A.

5.1.1 Correlação dos dados

A figura 5.1 representa um mapa de coeficientes de correlação em que os valores de maior valor, em módulo, correspondem às *features* com maior correlação com o marcador binário do respetivo registo.

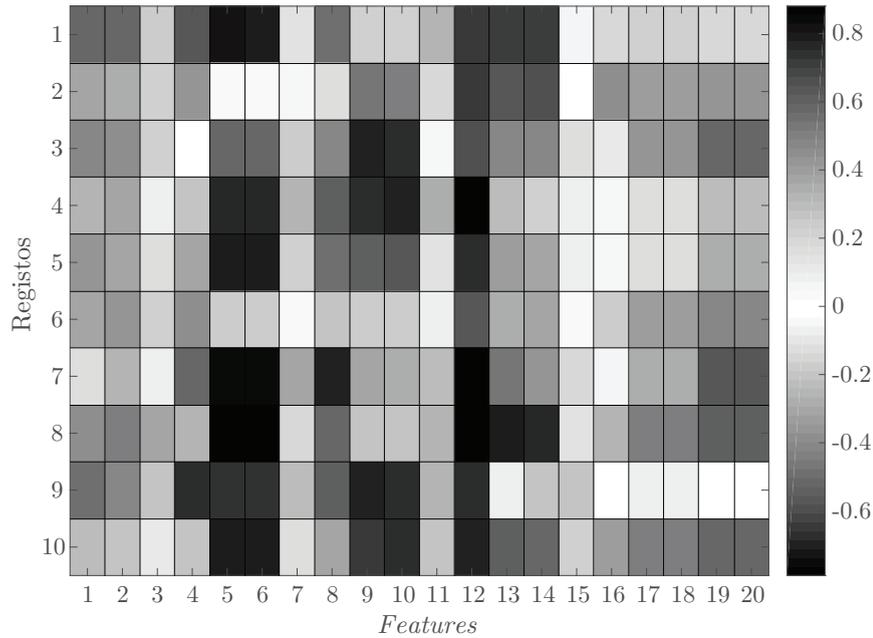


FIGURA 5.1: Coeficientes de correlação entre cada uma das *features* e o respetivo marcador binário, representados numa escala de cinzentos. A terminologia usada, para as *features* e registos, está documentada no apêndice A. Os valores dos coeficientes de correlação estão presentes na tabela B.1.

Nela, consegue-se verificar com clareza que as *features* 5, 6 e 12 se destacam, no geral, com coeficientes de correlação superiores, em módulo. Também é plausível concluir que a semelhança entre as *features* 5 e 6 é elevada uma vez que a escala de cinzentos é igual para as duas *features* em diferentes registos, apesar de existir uma pequena diferença no valor numérico dos coeficientes (tabela B.1). Esta semelhança faz sentido que exista, visto que ambas retratam o mesmo sinal, embora a métrica de construção da *feature* seja diferente. No entanto, o facto de os coeficientes de correlação serem muito próximos, mostra que a média de cada janela se aproxima muito do valor da mediana, na mesma janela. Uma exceção a esta forte correlação destas *features* é o registo 2 e o 6.

Além destas, também as *features* 17 e 18 e as *features* 19 e 20 apresentam valores de coeficientes de correlação, na sua maioria, iguais. Este resultados, bem como o facto de estes valores serem relativamente baixos, mostram que estas *features* são numa primeira análise dispensáveis para a construção do algoritmo de detecção de *stress* porque são redundantes e não se correlacionam, no geral, com os *targets* dos vários registos.

Outras *features* como a 3, 7, 11 e 15 apresentam coeficientes de correlação inferiores a 0,38 (em módulo), o que indica que não são *features* que ajudem na discriminação das classes do marcador.

Relativamente à correlação entre as *features* e o marcador multiclasse (figura 5.2) nota-se uma relação com os resultados anteriores. Verifica-se a forte correlação das *features* 5, 6 e 12, como também se verifica a semelhança entre os coeficientes de correlação entre as *features* 17 e 18 e as *features* 19 e 20. Também, neste caso, nota-se a existência de *features* com menor correlação como as *features* 15 e 16.

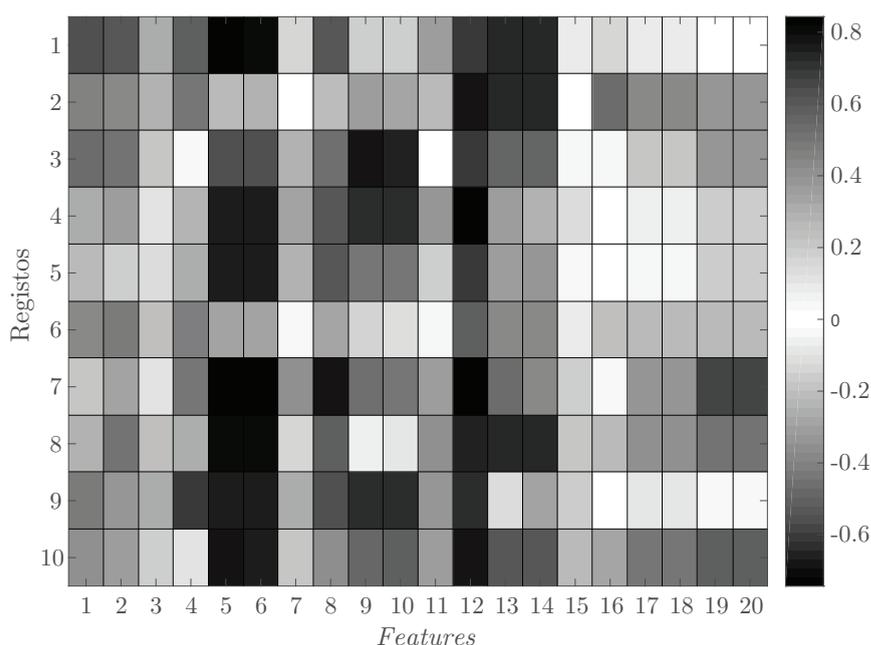


FIGURA 5.2: Coeficientes de correlação entre cada uma das *features* e o respetivo marcador multiclasse, representados numa escala de cinzentos. A terminologia usada, para as *features* e registos, está documentada no apêndice A. Os valores dos coeficientes de correlação estão presentes na tabela B.2.

Para além disto, foi avaliada a correlação entre as várias *features*, isto é, foram correlacionadas cada *features* com as restantes (figura 5.3 e tabela B.3).

Tanto a figura 5.3 como a tabela B.3, permitem tirar algumas conclusões em relação à semelhança entre algumas *features*. Por exemplo, a *feature* 17 e a 18 (tabela 5.1) têm coeficiente de correlação de 1,00 (tabela B.3), tal como ocorre, entre a *feature* 19 e 20. Este facto, já se previa em parte na correlação entre as *features* e o marcador uma vez que apresentavam resultados praticamente iguais.

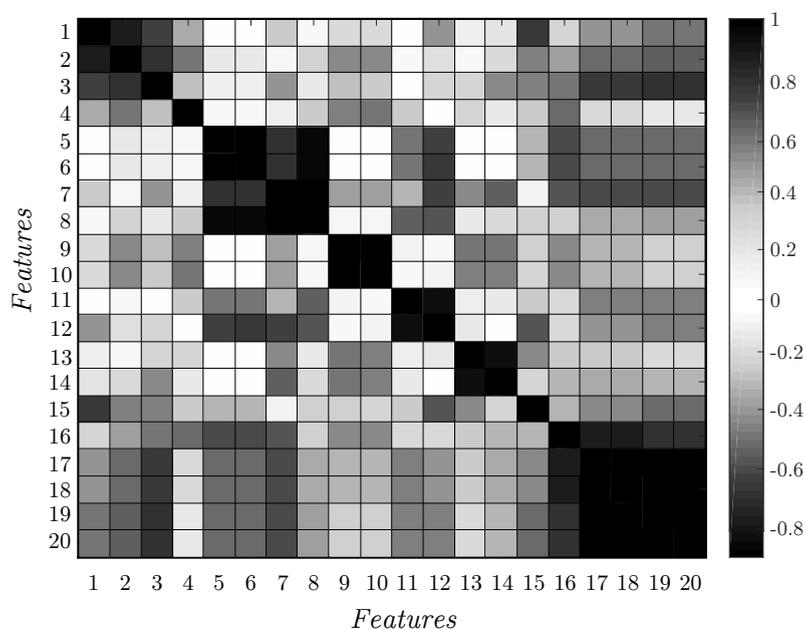


FIGURA 5.3: Coeficientes de correlação entre cada uma das features, com as restantes, representados numa escala de cinzentos. A terminologia usada, para as *features*, está documentada no apêndice A.

No entanto, também as *features* 5 e 6, bem como as *features* 9 e 10 apresentam coeficiente de 1,00, o que indica que a média e a mediana têm o mesmo valor, relativamente a estes sinais (hGSR e Resp, respetivamente), nas várias janelas de cálculo. Por outro lado, também existem *features* sem qualquer semelhança entre elas como as *features* 1 e 6, ou muito pouca semelhança como as *features* 3 e 11.

A informação retida da correlação entre *features*, permite ter uma ideia de quais as *features* redundantes, que podem ser removidas, como manter *features* que apresentem grande variabilidade relativamente às restantes e com forte correlação com o *target*, o que pode diminuir o tempo de computação ou ainda melhorar os resultados da classificação.

5.1.2 mRMR

Como este algoritmo é baseado na minimização da redundância entre *features* e na maximização da relevância face ao marcador, é necessário analisar os resultados relativamente ao marcador binário e multiclasse.

Assim, temos como resultado do mRMR com o marcador binário a tabela 5.2 e para o marcador multiclasse a tabela 5.3.

TABELA 5.2: Resultado da aplicação do algoritmo mRMR, para uma classificação binária.

1.	meanhgsr	11.	medianhr
2.	meanemg	12.	L300
3.	respv	13.	M300
4.	meanresp	14.	L100
5.	hgsrv	15.	M100
6.	meanhr	16.	aresp
7.	emgv	17.	hrv
8.	medianhgsr	18.	ahgsr
9.	medianemg	19.	aemg
10.	medianresp	20.	ahr

Perante estes resultados consegue-se perceber que apesar de ordem de significância, não ser exatamente a mesma, num caso e no outro, verifica-se uma semelhança se se dividir as listas em dois grupos em que: um grupo corresponde da primeira à décima *feature* e o segundo grupo com as restantes. Com esta divisão, concluí-se que, na maioria dos casos, as *features* estatísticas ocupam o primeiro grupo, ao passo que, *features* como o L100, M100, L300, M300 e *features* da frequência de metade da área da resposta em frequência fazem parte do segundo grupo. Para além disso, é possível comprovar a semelhança entre *features* como a L300 e M300 e as *features* L100 e M100. Como já se mostrou, estas apresentam o valor de coeficiente de correlação de 1,00, uma com a outra, e esta redundância de informação está presente também como resultado deste algoritmo, isto porque surgem no segundo grupo de *features* e com uma ordem de significância adjacente.

TABELA 5.3: Resultado da aplicação do algoritmo mRMR, para uma classificação multiclasse.

1	medianemg	11	L300
2	meanhgsv	12	M300
3	respv	13	mediahr
4	hgsvr	14	L100
5	emgv	15	M100
6	meanresp	16	hrv
7	medianhgsv	17	aresp
8	meanemg	18	aemg
9	medianresp	19	ahgsv
10	meanhr	20	ahr

De notar que, os resultados da correlação e do mRMR estão coerentes, uns com os outros, uma vez que, *features* com coeficientes de correlação mais baixos, surgem em números superiores no resultado da aplicação do algoritmo mRMR. Por exemplo, as *features* 5 e 6 com valores altos de coeficientes de correlação, no marcador binário e multiclasse, aparecem no primeiro grupo de *features* do resultado do mRMR. Casos em que os coeficiente de correlação são baixo, como por exemplo as *features* 15 e 16, no dois marcadores, surgem no segundo grupo no resultado do algoritmo do mRMR.

5.1.3 Tempo de Computação

Para determinar o tempo de cálculo das *features*, numa janela de dados, foram desenhados 4 grupos, em que cada grupo corresponde a um conjunto de *features*. De ter em conta que esta análise não depende se o marcador é binário ou multiclasse. O objetivo é determinar qual o grupo de *features* que apresenta menor tempo de cálculo para uma amostra de dados.

Esta análise foi efetuada com recurso ao modo *off-line* simulado, apenas com as *features* estatísticas e as *features* de frequência correspondente a metade da área

da resposta à frequência. Nesta simulação verificou-se uma demora significativa no processamento e na análise dos dados, o que nos levou a questionar este atraso.

De notar que já nesta simulação, as *features* L100, M100, L300 e M300 não foram incluídas uma vez que a utilização das mesma obrigava à utilização de janelas de 100 e 300 segundos (aproximadamente 1,5 e 5 minutos), o que iria provocar problemas durante a aquisição e na gestão dos dados durante o processamento e análise. Para além disso, verificou-se que na correlação com o *target* apresentavam, em média, um coeficiente abaixo dos 0,50, como também na correlação entre *features* mostrou-se que apresentam uma grande correlação entre L100 e M100 e entre L300 e M300. A acrescentar, também no mRMR encontram-se no segundo grupo com menor significância. Por todas estas razões optou-se logo desde esta fase por não utilizar as mesmas.

Apesar disso, todas as *features* foram analisadas em termos de tempo de cálculo de modo a ser possível ter mais grupos de comparação. Neste contexto os grupos são:

- **Grupo 1:** *Features* Estatísticas;
- **Grupo 2:** *Features* Estatísticas + *Features* de cálculo da frequência correspondente a metade da área da resposta à frequência;
- **Grupo 3:** *Features* Estatísticas + L100, M100, L300 e M300;
- **Grupo 4:** *Features* Estatísticas + *Features* de cálculo da frequência correspondente a metade da área da resposta à frequência + L100, M100, L300 e M300;

Neste sentido, mostra-se os resultados do tempo despendido no cálculo dos grupos de *features*, em escala logarítmica, na figura 5.4.

Analisando a figura 5.4, mostra-se que o cálculo da frequência pertence ao conjunto de *features* que dispende mais tempo de cálculo. Isto é possível concluir, visto que os grupos 2 e 4, onde estas *features* estão incluídas são as que apresentam

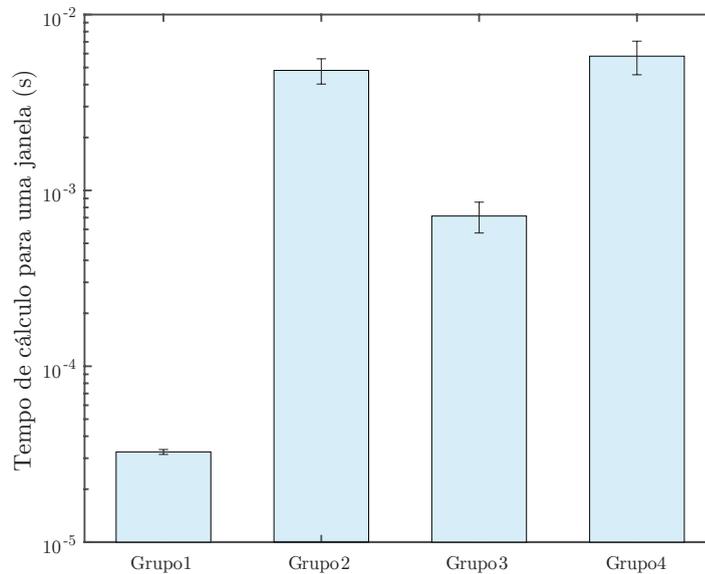


FIGURA 5.4: Tempo de cálculo dos grupos de *features*, em escala logarítmica e em segundos.

maior valor de tempo. De seguida, as *features* L100, M100, L300 e M300 são o segundo conjunto de *features* que necessitam de mais tempo de produção quando comparadas com as *features* estatísticas.

Neste seguimento, e tendo em conta os resultados da correlação, mRMR e tempo de computação selecionaram-se as *features* estatísticas (meanemg, medianemg, emgv, meanhgsr, medianhgsr, hgsrv, meanresp, medianresp, respv, meanhr, medianhr, hrv) para o problema de classificação em causa.

5.2 Avaliação da metodologia utilizada

Para entender qual a metodologia a ser utilizada aquando do modo *on-line* foi preciso testar e avaliar o desempenho dos vários métodos. Estas avaliações foram executas em ambiente de simulação de aquisição de dados, isto é, com a configuração *off-line*. Com a técnica de particionamento dos dados, onde foram selecionados 3 registos para o teste do classificador e os restantes (7 registos) para o treino do modelo de classificação e todas as etapas antecedentes.

No que diz respeito aos testes em causa, procurou-se em primeiro lugar, perceber a necessidade da redução da dimensão dos dados, com o uso do PCA (4.2.2). Posteriormente, determinou-se qual o classificador a ser utilizado: rede neuronal ou árvore de decisão (4.2.3), quer para uma classificação multiclasse quer binária. Apesar de se apresentar sempre as abordagens binária e multiclasse, apenas se utilizou uma destas abordagens para implementar na configuração *on-line*, para a aquisição em tempo real. Contudo, pareceu-nos importante, fazer as duas análises, visto que é um acréscimo de conhecimento acerca de quais os resultados da aplicação de possíveis metodologias (tabela 5.4), em diferentes situações de deteção de *stress*.

TABELA 5.4: Designação e parâmetros em avaliação das metodologias avaliadas.¹

Designação	Redução de dimensão	Classificador	Marcador
M1	PCA	Rede Neuronal	Binário
M2	-	Rede Neuronal	Binário
M3	PCA	Rede Neuronal	Multiclasse
M4	-	Rede Neuronal	Multiclasse
M5	PCA	Árvore de Decisão	Binário
M6	-	Árvore de Decisão	Binário
M7	PCA	Árvore de Decisão	Multiclasse
M8	-	Árvore de Decisão	Multiclasse

¹ Esta informação encontra-se também no Apêndice A.

5.2.1 Avaliação do uso do PCA

Tal como descrito no capítulo 4, e ainda neste capítulo, procurou-se desenvolver várias metodologias e determinar qual delas a mais adequada no contexto deste projeto. Neste sentido são utilizadas as métricas referidas no capítulo anterior para, em primeiro lugar, verificar a necessidade da redução da dimensão dos dados, com o uso do PCA.

Accuracy

- **Simple** No gráfico seguinte, verifica-se que a *accuracy* não varia de modo relevante, quando aplicado o classificador da rede neuronal (M1, M2, M3 e M4) ao passo que melhora cerca de 8% com o classificador da árvore de decisão (M5, M6, M7 e M8) (tabela 5.5 e figura 5.5).

TABELA 5.5: *Accuracy* simples das várias metodologias possíveis de serem utilizadas, em percentagem.

	Rede Neuronal		Árvore de Decisão	
	PCA	S/ PCA	PCA	S/ PCA
Binário	73,195 ± 8,465	72,640 ± 9,770	64,381 ± 8,268	72,701 ± 8,880
Multiclasse	56,253 ± 7,273	55,546 ± 7,344	44,656 ± 7,408	53,373 ± 6,205

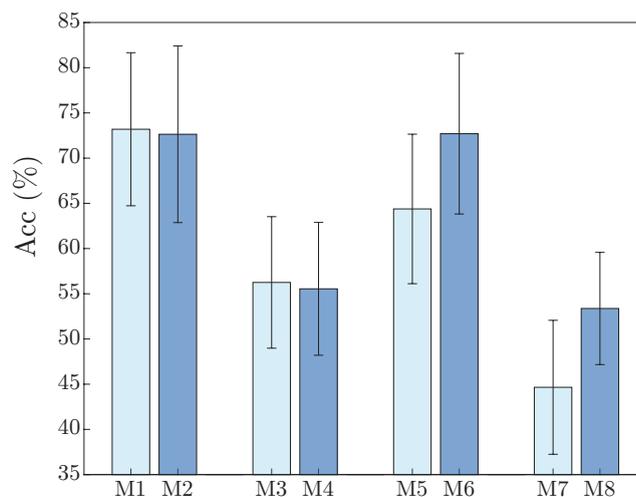


FIGURA 5.5: Acc das várias metodologias possíveis de serem usadas. O azul mais claro representa, neste caso, as metodologias onde são aplicadas o PCA, ao passo que, nas metodologias com azul mais escuro, não há redução da dimensão.

- **Pesada** No que diz respeito à *accuracy* pesada, os resultados são relativamente semelhantes aos anteriores da *accuracy* simples, no que diz respeito à diferença entre a aplicação ou não do PCA (tabela 5.6 e figura 5.6).

Em relação, ao valor de wAcc comparativamente ao valor de Acc, verifica-se que há uma redução de cerca de 1%, na classificação binária, e cerca de 3%, para a classificação multiclasse, no caso da aplicação da rede neuronal (M1,

M2, M3 e M4). Já na árvore de decisão, existem um decréscimo de 3%, para a classificação binária (M5 e M6) e cerca de 2% para a classificação multiclasse, sem utilização de PCA (M8). Já na M7 o decréscimo de *accuracy* é menor do que 1%.

TABELA 5.6: wAcc das várias metodologias possíveis de serem usadas, em percentagem.

	Rede Neuronal		Árvore de Decisão	
	PCA	S/ PCA	PCA	S/ PCA
Binário	72,108 ± 8,129	71,761 ± 9,154	61,793 ± 7,619	70,068 ± 8,491
Multiclasse	52,894 ± 7,333	51,926 ± 7,514	44,600 ± 5,472	51,027 ± 6,211

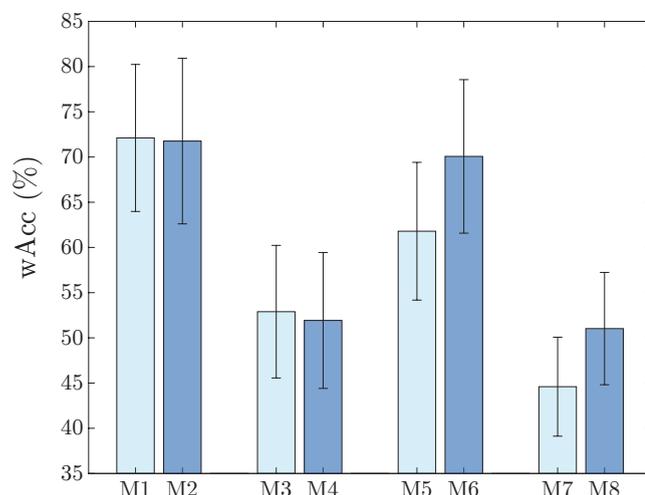


FIGURA 5.6: wAcc das várias metodologias possíveis de serem usadas, em percentagem. O azul mais claro representa, neste caso, as metodologias onde são aplicadas o PCA, ao passo que, nas metodologias com azul mais escuro, não há redução da dimensão.

A redução quer de Acc como wAcc de classificação binária para a multiclasse, resulta do acréscimo da dificuldade que os classificadores têm em prever corretamente a classe final. Também a ligeira redução da *accuracy* simples para a pesada deve-se ao facto de os dados de teste não serem balanceados, fator que só é tido em conta na *accuracy* pesada [65].

Sensibilidade e Especificidade

Na sensibilidade e especificidade (tabela 5.7), quando é aplicada a rede neuronal como classificador, verifica-se que não existe uma grande diferença entre estes parâmetros com o uso ou não de PCA, no caso da utilização da rede neuronal. No entanto, para a árvore de decisão, na classificação binária, visualiza-se um aumento da sensibilidade e especificidade sem a utilização do PCA. Em relação à classificação multiclasse, o uso do PCA reduz a sensibilidade de detecção da classe1 e classe3 e especificidade da classe2. Este resultado deve-se à dificuldade em discriminar a classe relacionada com o alto e o médio *stress*.

TABELA 5.7: Sensibilidade e Especificidade, em percentagem, das várias metodologias possíveis de serem usadas. Para informação da terminologia usada, consulta o apêndice A.

Rede Neuronal				
	PCA		S/ PCA	
	Sens.	Esp.	Sens.	Esp.
ClasseB	$75,83 \pm 16,70$	$68,38 \pm 19,46$	$74,65 \pm 17,22$	$68,87 \pm 18,65$
Classe1	$61,04 \pm 20,44$	$79,78 \pm 16,20$	$67,59 \pm 17,74$	$74,02 \pm 18,49$
Classe2	$36,31 \pm 16,80$	$79,11 \pm 10,20$	$32,08 \pm 15,98$	$82,03 \pm 8,51$
Classe3	$61,33 \pm 16,12$	$74,75 \pm 13,00$	$56,11 \pm 16,86$	$75,71 \pm 12,90$

Árvore de Decisão				
	PCA		S/ PCA	
	Sens.	Esp.	Sens.	Esp.
ClasseB	$70,67 \pm 19,60$	$52,92 \pm 23,77$	$79,29 \pm 16,77$	$60,85 \pm 19,80$
Classe1	$37,60 \pm 25,29$	$84,08 \pm 15,95$	$49,09 \pm 21,03$	$83,94 \pm 15,16$
Classe2	$47,40 \pm 26,53$	$62,77 \pm 21,45$	$42,44 \pm 20,20$	$72,79 \pm 13,44$
Classe3	$48,80 \pm 20,80$	$72,25 \pm 21,05$	$61,55 \pm 18,24$	$73,98 \pm 14,63$

AUC

A métrica da área sob a curva ROC mostra (tabela 5.8), relativamente ao classificador da rede neuronal, mostra uma ligeira diminuição quando não é aplicado o PCA, semelhante ao decréscimo verificado com a *accuracy*. Em relação ao classificador da árvore de decisão, verifica-se uma redução da AUC quando aplicado o PCA, na deteção de *stress* (para a classificação binária) e na deteção de cada uma das classes face às outras (na classificação multiclasse).

TABELA 5.8: AUC, em percentagem, das várias metodologias possíveis de serem usadas.

	Rede Neuronal		Árvore de Decisão	
	PCA	S/ PCA	PCA	S/ PCA
ClasseB	79,32 ± 9,80	78,38 ± 10,44	64,84 ± 8,82	72,21 ± 11,63
Classe1	79,24 ± 10,44	77,46 ± 10,44	63,54 ± 9,31	69,08 ± 12,70
Classe2	61,77 ± 8,30	60,83 ± 8,73	56,19 ± 4,83	62,00 ± 7,73
Classe3	76,10 ± 7,69	73,33 ± 7,79	65,45 ± 6,63	74,63 ± 7,13

Por fim, e tendo os resultados já apresentados, optou-se por não considerar a aplicação do PCA, isto porque, no caso da utilização da árvore de decisão, quer na *accuracy* simples como a pesada há uma diminuição de cerca de 8% e 9%, respetivamente, para a classificação binária, e cerca de 8% e 6%, para a classificação multiclasse. Na classificação com a rede neuronal, o aumento da *accuracy* simples e pesada com a utilização do PCA, não se considerou significativa para a sua posterior utilização, uma vez que o seu aumento é menor que 1% em todas as metodologias (M1, M2, M3 e M4). Estas diferenças entre a utilização ou não também se verificaram, de igual forma, quando analisada a sensibilidade, especificidade e AUC.

5.2.2 Avaliação dos Classificadores

De ter em conta que apenas se considerará, a partir deste momento, as metodologias M2, M4, M6 e M8, uma vez que são as que não apresentam a aplicação

do PCA. Assim, o objetivo é agora determinar qual o algoritmo de classificação que mais se adequa ao problema em questão.

Accuracy

A figura 5.7 mostra os resultados da *accuracy* simples e pesada, respectivamente, nas metodologias selecionadas (M2, M4, M6 e M8). Nelas verifica-se que a utilização da árvore de decisão (M4 e M8) diminuem tanto a *accuracy* simples como a pesada, quando comparada com a aplicação da rede neuronal (M2 e M6).

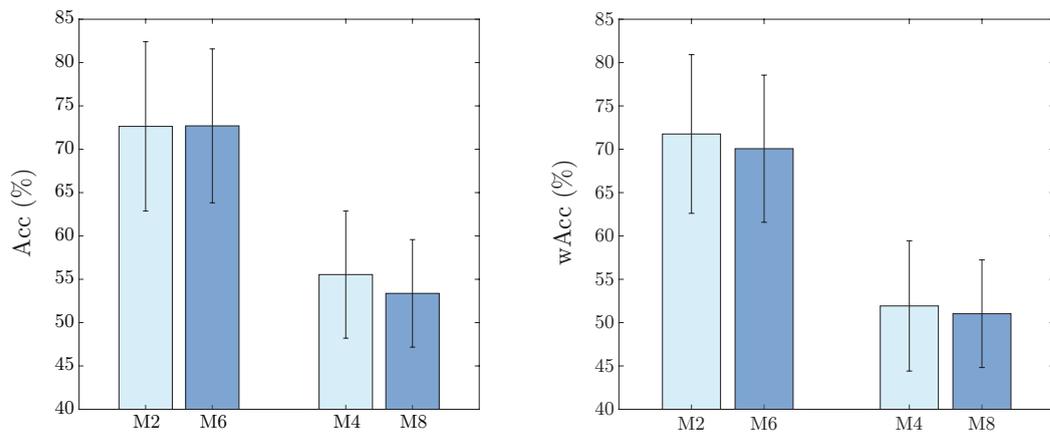


FIGURA 5.7: Acc e wAcc dos dois classificadores. O azul mais claro representa, neste caso, as metodologias onde é aplicada a Rede Neuronal, ao passo que, nas metodologias com azul mais escuro, é utilizada a Árvore de Decisão.

Sensibilidade e Especificidade

Em relação aos parâmetros da sensibilidade e especificidade (tabela 5.9), existe um ligeiro aumento da sensibilidade com o uso do classificador da árvore de decisão e com o marcador binário, contudo com o marcador multiclasse esta conclusão não é tão imediata. Isto porque, há uma diminuição da sensibilidade da classe de 'baixo *stress*' e o inverso para as restantes classes, com a utilização da árvore de decisão. Na especificidade, verifica-se exatamente o contrário.

TABELA 5.9: Sensibilidade e Especificidade, em percentagem, dos dois classificadores.

	Rede Neuronal		Árvore Decisão	
	Sensibilidade	Especificidade	Sensibilidade	Especificidade
ClasseB	74,65 ± 17,22	68,87 ± 18,65	79,29 ± 16,77	60,85 ± 19,80
Classe1	67,59 ± 17,74	74,02 ± 18,49	49,09 ± 21,03	83,94 ± 15,16
Classe2	32,08 ± 15,98	82,03 ± 8,51	42,44 ± 20,20	72,79 ± 13,44
Classe3	56,11 ± 16,86	75,71 ± 12,90	61,55 ± 18,24	73,98 ± 14,63

AUC

Segundo a área sob a curva ROC (tabela 5.10), mostra-se, de novo, um aumento da área, com a utilização do classificador da rede neuronal.

TABELA 5.10: AUC dos dois classificadores.

	Rede Neuronal	Árvore de Decisão
ClasseB	78,38 ± 10,44	72,21 ± 11,63
Classe1	77,46 ± 10,43	69,08 ± 12,70
Classe2	60,83 ± 8,73	62,00 ± 7,73
Classe3	73,33 ± 7,79	74,63 ± 7,13

Tempo de análise, em modo *off-line*

Ainda se determinou o tempo de análise com os dois classificadores (tabela 5.11), de modo a perceber se haveria a hipótese deste ser superior ao tempo de cada janela. Se existisse algum tempo de análise superior ao tempo de aquisição de uma janela, então esse classificador seria automaticamente excluído, uma vez que atrasaria todo o processo. Analisando a tabela, verifica-se que tal não acontece, visto que a percentagem de tempo dispendida para a análise, em todos os casos, é inferior a 1%.

Assim, tendo em conta a *accuracy* simples e pesada, sensibilidade, especificidade e AUC, concluiu-se que a rede neuronal oferecia melhores resultados face à

TABELA 5.11: Razão entre o tempo dispendido e o tamanho da janela (da primeira janela e seguintes), em modo *off-line*, em percentagem.

		Rede Neuronal	Árvore de Decisão
Binário	1^a Janela	0,49	0,13
	Janelas Seguintes	0,62	0,12
Multiclasse	1^a Janela	0,56	0,12
	Janela Seguintes	0,62	0,32

árvore de decisão. Neste sentido, a metodologia a utilizar não inclui a utilização do PCA e aplica como algoritmo de classificação a rede neuronal, ou seja, definiram-se como metodologias a M2 e M6. De ter em conta que aquando da configuração *on-line* em tempo real, apenas uma será considerada contudo no modo *off-line* simulado, procurou-se fazer os estudos de ambas as metodologias.

5.3 Avaliação da aplicação das metodologias no modo *off-line* e *on-line*

5.3.1 Resultados *off-line* simulado

Nesta fase, o objetivo reside em aproximar o máximo possível as metodologias definidas, a uma situação real. Assim sendo, foi aplicada a técnica de *leave-one-out*, isto é, utilizou-se um registo para teste e os restantes para o treino. Esta técnica permite perceber o comportamento do classificador perante nova informação, quer seja para um problema binário ou multiclasse.

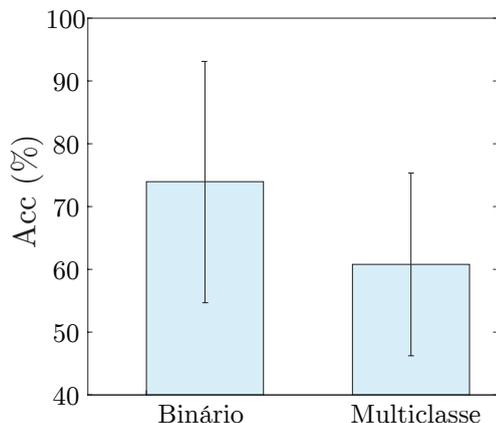


FIGURA 5.8: Acc geral da metodologia utilizada num contexto binário e multiclasse, com todos os registos.

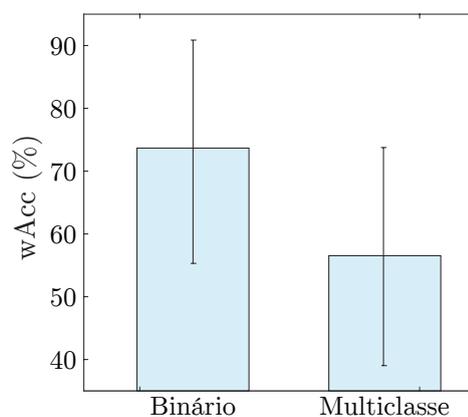


FIGURA 5.9: wAcc geral da metodologia utilizada num contexto binário e multiclasse, com todos os registos.

TABELA 5.12: Sensibilidade, Especificidade e AUC em contexto binário e multiclasse, com todos os registos.

	Sensibilidade	Especificidade	AUC
ClasseB	74,3 ± 28,8	73,0 ± 21,0	78,7 ± 28,1
Classe1	69,0 ± 31,2	80,2 ± 25,0	78,9 ± 20,7
Classe2	35,1 ± 31,8	80,1 ± 10,2	64,0 ± 21,6
Classe3	65,5 ± 21,6	80,0 ± 15,5	82,3 ± 7,3

Assim, relativamente às *accuracy* simples e pesada (figuras 5.8 e 5.9) verifica-se que para uma classificação binária a *accuracy* simples e pesada rondam os 73% enquanto para uma classificação multiclasse 60% e 55%, respetivamente. Para além disso, verifica-se que o desvio padrão destas métricas tem um valor de cerca de 15%, para a *accuracy* simples e 20%, para *accuracy* pesada. Por se considerar estes valores de desvio padrão relativamente altos, procurou-se perceber o comportamento do classificador testando cada um dos 10 registos armazenados para teste. Também na sensibilidade, especificidade e AUC (tabela 5.12) estes desvios padrões têm, em média, um valor de 26%, numa classificação binária, e 21%, numa classificação multiclasse.

Ensaio individuais de *cross-validation leave-one-out*.

Este ensaio tem como função mostrar como as metodologias prevêm a existência de *stress* perante um novo registo de dados. Por isso, foi utilizado um registo para teste e os restantes 9 registos para a formulação da metodologia, segundo a técnica do *leave-one-out*, e avaliados os parâmetros descritos em 4.2.4, para avaliar a *performance* do método. Os alarmes previstos com o algoritmo desenvolvido (no modo *off-line* simulado) e o marcador real, encontram-se no apêndice C, para cada um dos registos de teste, para classificação binária e multiclasse.

De seguida, vão ser mostrados individualmente os resultados para cada um dos registos de teste, para se perceber se os resultados são consistentes para todos os testes.

Accuracy

TABELA 5.13: Acc e wAcc de cada ensaio de teste, em percentagem.

	Binário		Multiclasse	
	Acc	wAcc	Acc	wAcc
R1	78,6	73,2	76,8	72,6
R2	71,6	71,8	51,2	42,6
R3	78,1	80,9	38,8	35,9
R4	77,5	81,8	69,2	65,1
R5	87,9	91,6	66,9	71,1
R6	80,1	74,1	60,8	63,4
R7	81,6	83,9	79,5	79,8
R8	20,8	26,9	37,5	30,6
R9	85,3	83,1	69,0	63,5
R10	78,3	69,4	58,4	40,9

Sensibilidade, Especificidade e AUC

- Classificação Binária

TABELA 5.14: Sensibilidade, Especificidade e AUC, em percentagem, de cada ensaio de teste, para a classeB.

	Sensibilidade	Especificidade	AUC
R1	98,2	48,3	75,4
R2	70,8	72,8	73,5
R3	71,3	90,6	91,5
R4	64,7	98,9	97,3
R5	84,8	98,5	97,7
R6	98,7	49,6	89,5
R7	74,6	93,2	94,2
R8	00,0	53,8	2,9
R9	94,2	71,9	88,6
R10	86,0	52,7	76,9

- Classificação Multiclasse

TABELA 5.15: Sensibilidade, Especificidade e AUC, em percentagem, de cada ensaio de teste, para uma classificação multiclasse.

	Sensibilidade			Especificidade			AUC		
	Classe1	Classe2	Classe3	Classe1	Classe2	Classe3	Classe1	Classe2	Classe3
R1	90,1	56,0	71,8	98,7	82,7	85,7	99,1	80,1	88,4
R2	59,8	3,1	64,9	69,6	68,5	92,0	71,6	18,4	90,3
R3	92,4	1,4	14,0	17,4	96,9	90,9	73,4	59,1	66,2
R4	94,0	41,5	59,9	68,1	93,8	89,7	91,4	78,3	82,6
R5	98,3	56,9	58,0	93,7	75,5	79,6	99,5	73,7	78,6
R6	53,5	76,9	59,8	94,8	68,0	82,0	79,2	78,5	79,1
R7	93,7	77,3	68,3	93,8	83,8	94,0	97,0	86,0	91,3
R8	8,8	00,0	83,0	74,4	68,6	63,0	50,5	37,3	79,4
R9	71,6	38,2	80,5	94,7	81,4	78,4	88,1	72,0	85,1
R10	27,8	00,0	94,8	96,7	82,2	44,3	39,2	56,4	82,0

Tendo em conta, estes resultados utilizou-se a *accuracy* pesada como métrica para determinar qual o registo com melhor e pior resultado de classificação. Foi

esta a métrica escolhida visto que tem em conta o não balanceamento dos dados de teste [65] e também porque é mais simples extrair essa informação, quando comparada com a sensibilidade, especificidade e AUC. Assim, os seguintes resultados resultam da remoção do registo com melhor e pior valor de wAcc, ficando assim apenas com 8 registos. Neste sentido, para a classificação binária é excluído o R8 (com 27% de wAcc) e o R5 (com 92% de wAcc) e para a classificação multiclasse o R8 (com 31% de wAcc) e R7 (com 80% de wAcc) (tabelas 5.13).

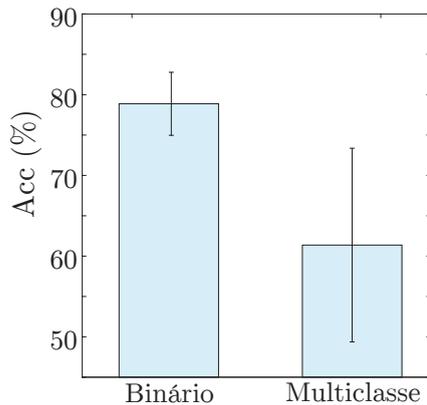


FIGURA 5.10: Acc da metodologia utilizada, sem os registos R5 e R8 para a classificação binária e sem os registos R7 e R8, para classificação multiclasse.

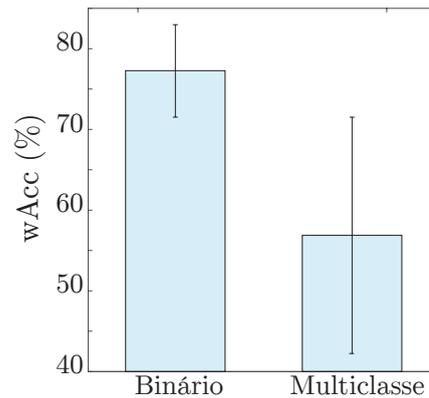


FIGURA 5.11: wAcc da metodologia utilizada, sem os registos R5 e R8 para a classificação binária e sem os registos R7 e R8, para classificação multiclasse.

TABELA 5.16: Sensibilidade, Especificidade e AUC, sem os registos R5 e R8 para a classificação binária e sem os registos R7 e R8, para a classificação multiclasse.

	Sensibilidade	Especificidade	AUC
ClasseB	82,3 ± 13,6	72,3 ± 20,5	85,9 ± 9,2
Classe1	73,4 ± 24,9	79,2 ± 27,8	80,2 ± 19,7
Classe2	34,3 ± 29,5	81,1 ± 10,5	64,5 ± 20,7
Classe3	63,0 ± 23,4	80,3 ± 15,4	81,5 ± 7,5

Com a eliminação destes registos é mostrado que o desvio padrão reduziu, na classificação binária. O mesmo não acontece na classificação multiclasse o que solidifica a ilação referida anteriormente, onde se afirmou que num problema com mais do que uma classe há um aumento da dificuldade de aprendizagem do classificador, o que aumenta o erro de previsão. Assim, como valores finais de *accuracy* simples e pesada, temos para uma classificação binária $78,9 \pm 3,9\%$

e $77,3 \pm 5,7\%$ e para classificação multiclasse $61,4 \pm 12,0\%$ e $56,9 \pm 14,6\%$, respetivamente.

Por esta razão e tendo em conta o maior valor, quer de *accuracy* simples e pesada, bem como de sensibilidade, especificidade e AUC, utilizou-se para o desenvolvimento do modo *on-line* a classificação binária, ou seja, a metodologia M6.

5.3.2 Resultados *on-line*

Nesta etapa, tendo já definida a metodologia a aplicar, importa determinar qual a configuração para este modo: a configuração em que no ramo central ocorre a aquisição dos dados ou o processamento e análise dos dados. Para isso procurou-se determinar qual o tempo gasto durante cada ciclo de funcionamento. Se cada ciclo, em cada uma das configurações, exceder os 2 segundos definidos, então não poderá ser utilizado, uma vez que atrasaria todo o processo.

Aquisição no ramo central

Quando o processamento e análise são executados no ramo periférico é necessário a criação de uma ligação que permita a captura de dados em bloco (*batch*). Contudo, a criação desta conexão exige 2.23 ± 0.11 seg. Como as janelas, excepto a primeira, tem uma duração de 2 segundos, esta opção não se torna viável para a construção do modo *on-line* (Figura 4.14).

Processamento no ramo central

Apesar de se já ter concluído que a anterior configuração não podia fazer parte deste modo, isto não quer dizer que a presente configuração não seja testada. Assim também nesta vertente de funcionamento do modo *on-line*, pretende-se verificar se o tempo necessário para a execução do primeiro ciclo e dos seguintes

são próximos do definido, isto é, 20 segundos e 2 segundos respectivamente (figura 4.13).

TABELA 5.17: Tempo de execução do processamento e análise dos sinais, do 1º ciclo de cálculo e dos restantes ciclos de cálculo, em segundos.

	Tempo
Processamento e Análise	$0,0132 \pm 0,0011$
1º ciclo	$19,4217 \pm 0,0183$
Ciclos seguintes	$1,6748 \pm 0,0002$

Verifica-se pela anterior tabela que os valores de tempo do primeiro ciclo, e dos restantes, não são exatamente os valores esperados. Devido à própria natureza do Arduino, este apresenta uma frequência de amostragem de 333 Hz, o que significa que demora cerca de 3ms a adquirir uma amostra. Ora, como a janela foi definida como tendo 20 segundos ou 310 amostras, seria necessário atrasar entre cada aquisição 62 ms. No entanto, devido às limitações da ligação entre o porta USB e o sistema, quando se faz uma aquisição de uma janela de sinal, esta demora cerca de 42 segundos, o que corresponde a mais do dobro que o pretendido. Por isso, por tentativa erro, foi-se reduzindo o *delay* do Arduino, aplicado entre aquisições, para o valor de 25,5ms. Este valor foi o mais baixo que se pode aplicar, para não ultrapassar o limite dos 20 segundos do primeiro ciclo de aquisição, sendo os valores reais de aquisição os apresentados na tabela 5.17. Por isto, pode-se afirmar que os requisitos são satisfeitos, uma vez que não excedem os tempos de 20 e 2 segundos, para o primeiro, e ciclos restantes. De seguida, desenvolveu-se a interface que serve para interligar os vários módulos da plataforma: o módulo de aquisição e transmissão de sinais, módulo de processamento e análise e o módulo de armazenamento.

Funcionamento da interface Neste sentido, em primeiro lugar o utilizador deve inserir o intervalo de tempo em que deseja ver apresentado o alarme (interface A da figura 5.12). Em relação ao intervalo de tempo possível de definição do alarme, este não pode ser inferior ao passo da janela de classificação, isto é, 2 segundos, como também não pode ser superior ao valor do tamanho definido para

a janela da gestão dos alarmes, que se configurou como 30 segundos. Neste sentido, se o utilizador não seleccionar nenhum valor de tempo e premir o botão 'ok' surgirá uma mensagem de aviso para inserir um período de tempo entre alarmes (interface C da figura 5.12). Se for inserido um valor de tempo, de um dos disponibilizados, e for pressionado o botão 'ok' irá iniciar-se a fase de pré-aquisição. Nesta fase os dados da base de dados são sujeitos à extração de *features* e treino do classificador (interface B da figura 5.12). Após o término desta fase surge uma mensagem que informa o utilizador que o sistema está em condições para começar a aquisição (interface D da figura 5.12). Após premir 'Start' (seta 3 da figura 5.12) o Arduino começa a partir desse instante a enviar, através da porta Serial, valores de cada um dos sensores com uma certa frequência. De notar que, o tempo desde o início da aquisição até ao aparecimento dos sinais corresponde, aproximadamente, ao tempo de aquisição de uma janela, ou seja, 18 segundos, como já se verificou na tabela 5.17. Depois deste tempo de espera, pode surgir os gráficos com os sinais (interface F da figura 5.12) ou uma mensagem de erro (interface G da figura 5.12), pelo facto de os sensores não estarem bem colocados. Se os sensores não foram colocados corretamente logo neste momento, então o sistema apenas permite ao utilizador a opção de 'Nova aquisição' (seta 10 da figura 5.12) que reinicia o sistema (interface A da figura 5.12). Para o aparecimento da primeira classificação dos dados (em '*stress*' ou '*sem stress*') foi definido um intervalo de 1 minuto para aquisição de informação. De realçar que o alarme surge em duas perspetivas diferentes: sob a forma de aviso escrito, ou sob a forma de gráfico que indica em tempo real as classificações finais, já com a gestão de alarmes realizada. O aviso escrito resume-se à palavra "*Stress Detected*", a vermelho ou "*No Stress*" a verde. O gráfico indica em tempo real as classificações de 0 (interface I da figura 5.12) que tem o mesmo significado que o aviso escrito a verde e a classificação com o valor de 1 (interface H da figura 5.12), para o aviso a vermelho. De notar que, nesta perspetiva, é visível a separação de tempo entre os alarmes, definida no início pelo utilizador. Para além disto, pode ainda ocorrer uma deslocação e/ou remoção dos sensores o que impossibilita a correta aquisição dos sinais, por isso, se tal acontecer o sistema informa o utilizador que os sensores não estão colocados corretamente (interface J

da figura 5.12).

A qualquer momento, após o aparecimento da primeira janela de sinais, o utilizador pode terminar este processo no botão de 'Stop' (seta 6 e 6a da figura 5.12). Neste momento, fica disponível a opção de guardar os sinais adquiridos. Configurou-se que este campo não pode ser vazio ou ter o nome 'Filename' (interface N da figura 5.12), definido como nome padrão do ficheiro, de forma a existir uma personalização do ficheiro guardado (interface L da figura 5.12).

Após o correto armazenamento do ficheiro, é possível proceder a uma nova aquisição dos dados (seta 9 e 11 da figura 5.12).

Tolerância a falhas Para além de todas as mensagens de erros que surgem ao longo do sistema, descritas anteriormente, importa descrever com maior detalhe a tolerância a falhas desenvolvida relativamente aos sensores. Analisando-se os sinais quando os sensores estão colocados corretamente e quando não estão, verificou-se que existe uma grande diferença na gama de valores dos sinais do GSR e HR. No primeiro, quando não está ligado ou mal posicionado, os valores alternam entre 0 e 1 ao passo que, que variam entre valores superiores quando o sensor está corretamente colocado. Já o HR toma o valor 0, sempre o sensor está mal colocado ou desligado, e toma valores relativos ao ritmo cardíaco, normalmente entre 60 a 100 num estado normal [66]. Os restantes sinais (Resp e EMG) apresentavam gamas de valores que não permitiam a criação de uma regra que distinguísse claramente os dois estados (ligado e não ligado).

5.4 Síntese

Neste capítulo foram apresentados todos os resultados acerca da metodologia a ser utilizada para a deteção de *stress* em tempo real. Para isso, foi necessário um estudo global dos sinais da base de dados e posteriormente, uma segunda análise com uma simulação de aquisição em tempo real (modo *off-line*) para determinar a

metodologia a aplicar. Por último, foi desenvolvido o modo *on-line* para integração de todos os módulos.

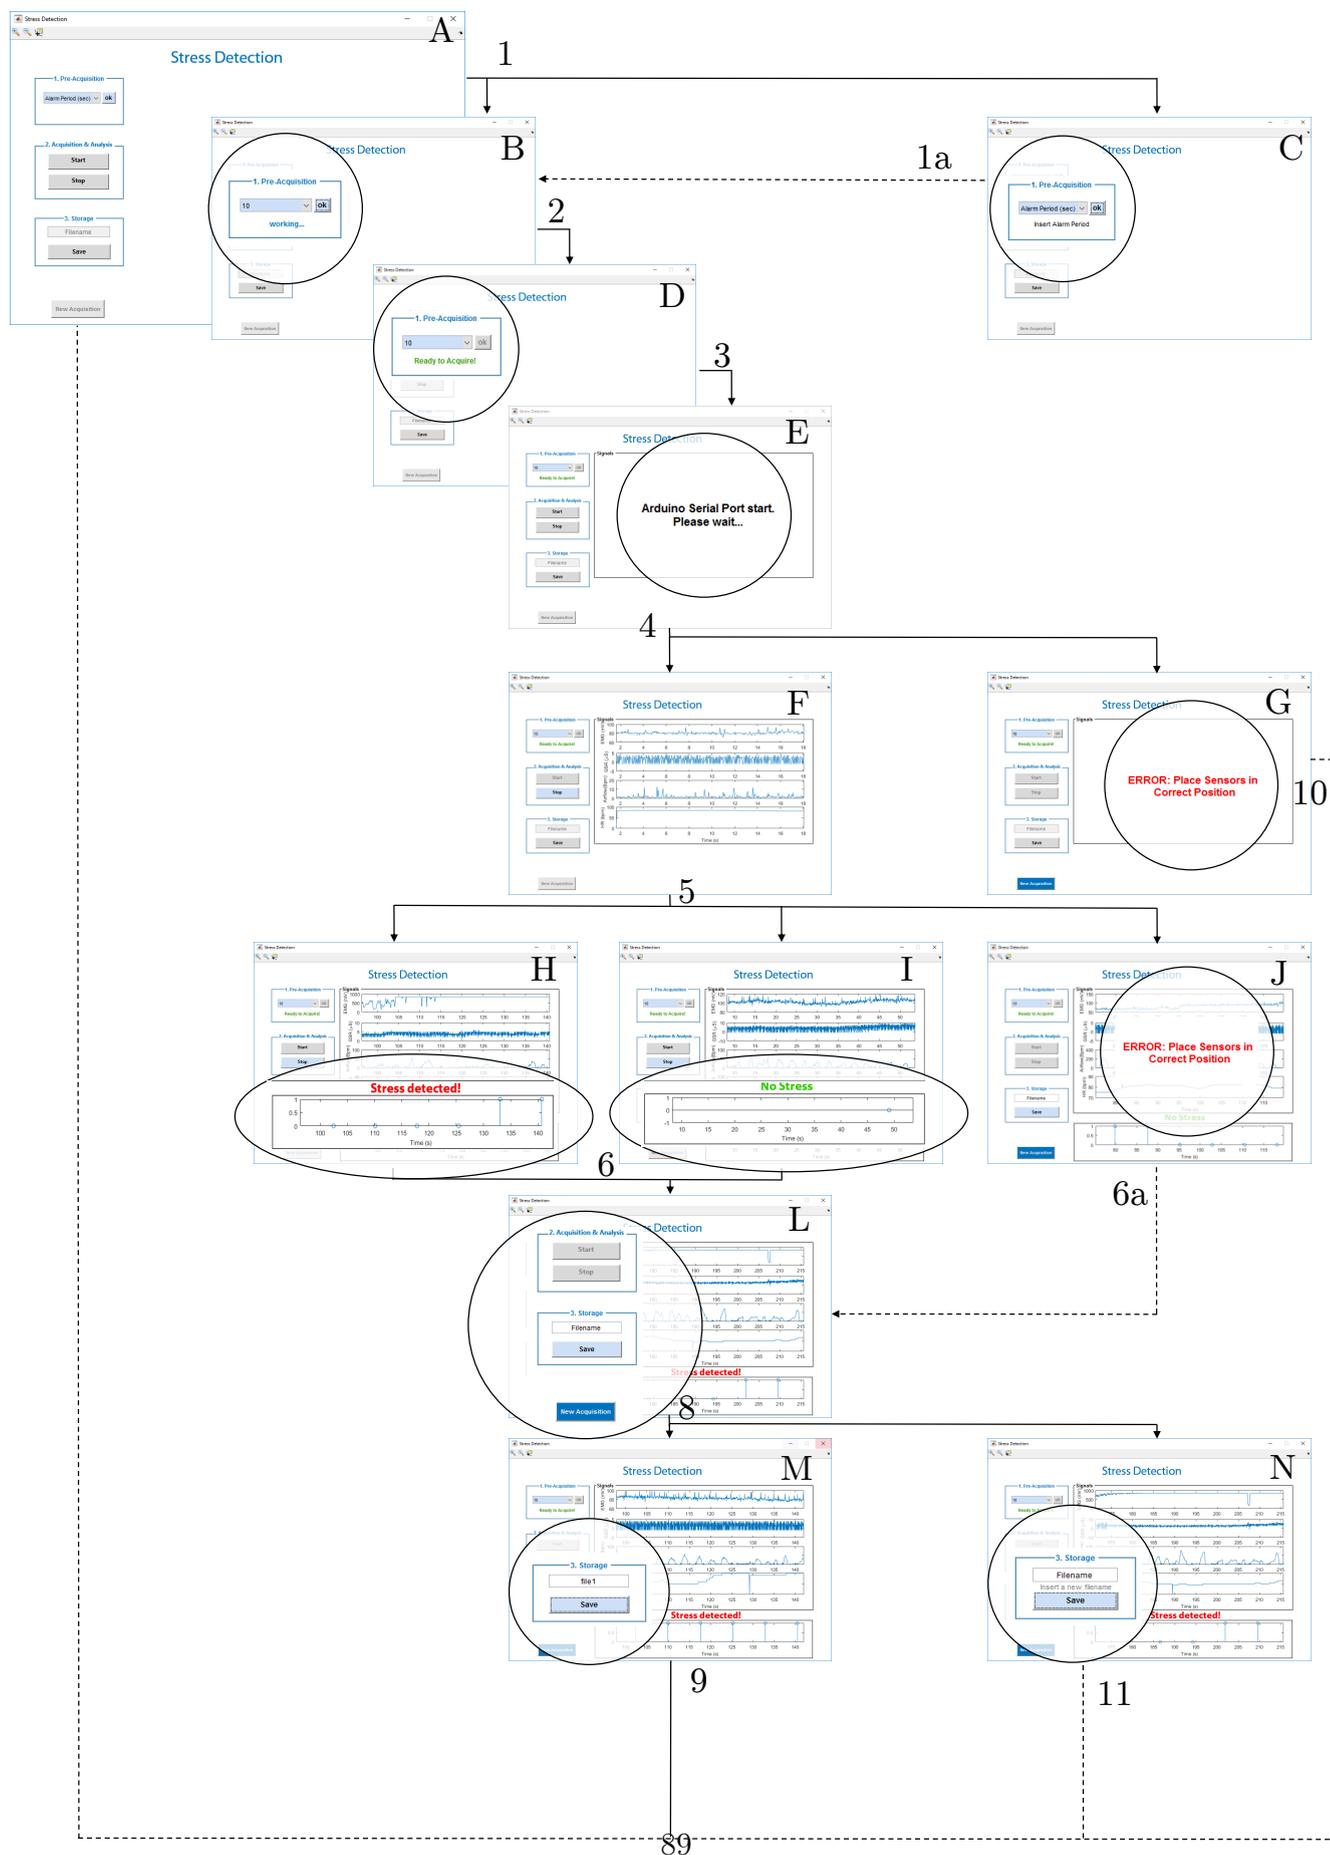


FIGURA 5.12: Fluxograma da interface desenvolvida para o modo *on-line*.

Capítulo 6

Conclusão e Trabalho Futuro

Este capítulo consiste num resumo dos resultados finais deste projeto e algumas propostas de trabalho futuro. Neste sentido, é discutido brevemente o trabalho em si e os resultados finais, bem como possíveis desenvolvimentos do trabalho.

6.1 Considerações Finais

Este projeto teve como principal objetivo o desenvolvimento de uma plataforma para a deteção de *stress*. Neste momento, é possível concluir que este objetivo foi cumprido, uma vez que o sistema criado permite fazer cada uma das funções que foram previamente definidas e consegue detetar estados de existência e inexistência de *stress*. Neste sentido, o sistema permite a fácil integração de nova informação adquirida, visualizar os sinais que estão a ser adquiridos e a respetiva classificação, em tempo real, como também permite gerir o intervalo de ocorrência de alarmes.

Em termos de comparação de resultados finais com os presentes no estado da arte, esta não é possível fazer com clareza, visto que não se encontrou até à data nenhum estudo que aplique a mesma metodologia desenvolvida num sistema

de simulação de aquisição de dados. Face aos resultados finais de *accuracy* simples, estes, apesar de abaixo dos mostrados no estado da arte, são satisfatórios. Isto porque, neste projeto, é utilizado uma análise por janelas deslizantes com um menor intervalo de tempo, como também foi necessária a remoção de *features* que atrasam o fluxo da informação no modo *on-line*, que poderiam auxiliar na discriminação das classes. A acrescentar a isso, também foram usados diferentes algoritmos de classificação, bem como diferentes métodos de avaliação do desempenho do classificador.

Por fim, este projeto mostrou a dificuldade de reconhecer padrões em contexto fisiológico que, por vezes, não estão claramente definidos. Por exemplo, a existência de bradicardia ou taquicardia, que são eventos fisiológicos, que apesar de serem relativamente diferentes de pessoa para pessoa, têm limiares estipulados. Contudo o mesmo não acontece com a existência ou não de *stress* fisiológico, o que tornou este projeto mais desafiante em termos do tratamento da informação. Considero que, seja possível a construção de sistemas para a deteção de *stress* em tempo real, contudo sempre com algumas limitações devido à dificuldade à existência de padrões em sinais fisiológicos, dentro deste caso de estudo.

6.2 Trabalho Futuro

Este projeto abre várias portas para novos projetos futuros, quer no aperfeiçoamento, validação ou adaptação para diferentes processos. Estas diferentes abordagens de trabalhos futuros podem ser no âmbito da melhoria do algoritmo desenvolvido para a deteção de *stress*, com a utilização de novos métodos de processamento dos sinais, na aplicação de diferentes algoritmos de classificação, bem como na utilização de outros intervalos na análise por janelas deslizantes e métodos de gestão de alarmes. Outro aspeto que pode ser melhorado é a integração de todos os sensores num sistema de tolerância a falhas da plataforma final.

Outra vertente consiste na validação do algoritmo no modo *on-line*. Para isso deve ser criado um protocolo específico, em que o *stress* fosse estimulado em

determinados instantes. Tendo esse protocolo estipulado, seria possível fazer a aquisição de vários registos de dados, semelhantes aos adquiridos por Healey e Picard [38], e avaliar-se a metodologia usada num contexto real, com a plataforma criada neste projeto. Neste sentido, seria interessante estudar metodologias de calibração durante esta aquisição, e durante a definição do protocolo, uma vez que os sinais fisiológicos normais variam entre diferentes pessoas.

Por último, este sistema pode ser adaptado na deteção de outros processos fisiológicos ou até mesmo de patologias com base no estudo de sinais fisiológicos disponíveis ou adquiridos com o *kit*.

Bibliografia

- [1] PORDATA INE. Esperança de vida aos 65 anos:total e por sexo, may 2016. URL [http://www.pordata.pt/Portugal/Esperan%C3%A7a+de+vida+aos+65+anos+total+e+por+sexo+\(base+tri%C3%A9nio+a+partir+de+2001\)-419](http://www.pordata.pt/Portugal/Esperan%C3%A7a+de+vida+aos+65+anos+total+e+por+sexo+(base+tri%C3%A9nio+a+partir+de+2001)-419). (Acedido a 11 Set 2016).
- [2] National Science Foundation. Public knowledge about s&t, feb 2014. URL <https://www.nsf.gov/statistics/seind14/index.cfm/chapter-7/c7s2.htm>. (Acedido a 11 Set 2016).
- [3] I. N. E. PORDATA. Consumo final: público e privado em URL <http://www.pordata.pt/Europa/Consumo+final+p%C3%BAblico+e+privado+em+percentagem+do+total-1943>. (Acedido a 11 Set 2016).
- [4] National Institute on Aging. Living longer, jan 2015. URL <https://www.nia.nih.gov/research/publication/global-health-and-aging/living-longer>. (Acedido a 11 Set 2016).
- [5] American Association for the Advancement of Science. Life expectancy around the world has increased steadily for nearly 200 years., 2008. URL <http://www.nature.com/scitable/content/life-expectancy-around-the-world-has-increased-19786>. (Acedido a 11 Set 2016).
- [6] ABIresearch. Home monitoring for seniors will drive 36 million wearable wireless device market, jun 2012. URL <https://www.abiresearch.com/press/home-monitoring-for-seniors-will-drive-36-million-/>. (Acedido a 11 Set 2016).

- [7] APSEI. Mais trabalhadores com sintomas de “burnout”, jan 2016. URL <http://www.apsei.org.pt/atualidade/noticias/mais-trabalhadores-com-sintomas-de-burnout/>. (Acedido a 11 Set 2016).
- [8] RTP Notícias. Síndrome de burnout afeta cada vez mais os portugueses, aug 2015. URL http://www.rtp.pt/noticias/pais/sindrome-de-burnout-afeta-cada-vez-mais-os-portugueses_v852620. (Acedido a 11 Set 2016).
- [9] R. Morgan Griffin. 10 health problems related to stress that you can fix. URL <http://www.webmd.com/balance/stress-management/features/10-fixable-stress-related-health-problems>. (Acedido a 11 Set 2016).
- [10] Jorn Bakker, Mykola Pechenizkiy, and Natalia Sidorova. What’s your current stress level? detection of stress patterns from gsr sensor data. In *2011 IEEE 11th International Conference on Data Mining Workshops*, pages 573–580. IEEE, 2011.
- [11] Cláudia Pinto. Dúvida linguística. FLiP, feb 2005. URL <http://www.flip.pt/Duvidas-Linguisticas/Duvida-Linguistica/DID/897>. (Acedido a 10 Set 2016).
- [12] Priberam. Stress, jul . URL <https://www.priberam.pt/DLP0/stress>. (Acedido a 10 Set 2016).
- [13] A Iacovides, KN Fountoulakis, St Kaprinis, and G Kaprinis. The relationship between job stress, burnout and clinical depression. *Journal of affective disorders*, 75(3):209–221, 2003.
- [14] George S Everly Jr and Jeffrey M Lating. *A clinical guide to the treatment of the human stress response*. Springer Science & Business Media, 2012.
- [15] David S Goldstein and Irwin J Kopin. Evolution of concepts of stress. *Stress*, 10(2):109–120, 2007.

- [16] Roger T Fenner and JN Reddy. *Mechanics of solids*, chapter 1, pages 1–35. CRC Press, 1991.
- [17] John E Hall and Arthur C Guyton. *Textbook of medical physiology.*, chapter 45-61, pages 555–767. Elsevier Inc., 2006.
- [18] Martha Davis, Elizabeth Robbins Eshelman, and Matthew McKay. *The relaxation and stress reduction workbook*, chapter 1, pages 1–3. New Harbinger Publications, 2008.
- [19] John Webster. *Medical instrumentation: application and design*. John Wiley & Sons, 2009.
- [20] P Zipp. Recommendations for the standardization of lead positions in surface electromyography. *European Journal of Applied Physiology and Occupational Physiology*, 50(1):41–54, 1982.
- [21] Robert L. Sorenson T. Clark Brelje. Histology guide virtual histology laboratory, 2014. URL <http://www.histologyguide.org/index.html>. (Acedido a 10 Set 2016).
- [22] Cooking Hacks. Pulse and oxygen in blood sensor (spo2) for e-health platform. URL <https://www.cooking-hacks.com/pulse-and-oxygen-in-blood-sensor-spo2-ehealth-medical>. (Acedido a 10 Set 2016).
- [23] Melody M Moore and Umang Dua. A galvanic skin response interface for people with severe motor disabilities. In *ACM SIGACCESS Accessibility and Computing*, number 77-78, pages 48–54. ACM, 2004.
- [24] Shimmer. Shimmer3 gsr+ unit. URL <http://www.shimmersensing.com/shop/shimmer3-wireless-gsr-sensor>. (Acedido a 10 Set 2016).
- [25] Megan Holtzman, Daphne Townsend, Rafik Goubran, and Frank Knoefel. Breathing sensor selection during movement. In *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pages 381–384. IEEE, 2011.

- [26] Vivago. URL <http://www.vivago.com/>. (Acedido a 10 Set 2016).
- [27] Intellicare, 2016. URL <http://www.intellicare.pt/pt/produtos>. (Acedido a 10 Set 2016).
- [28] Lda HealthyRoad Biometric Systems. Healthyroad a safer way to drive. URL <http://www.healthyroad.pt/index.php>. (Acedido a 10 Set 2016).
- [29] Google Play. Healthyroad, aug 2016. URL <https://play.google.com/store/apps/details?id=com.healthyroad.healthydriveapp>. (Acedido a 10 Set 2016).
- [30] Faurecia, . URL <http://www.faurecia.com/en>. (Acedido a 10 Set 2016).
- [31] Faurecia. Active wellness seat-concept, . URL <http://www.faurecia.com/en/innovation/discover-our-innovations/active-wellness>. (Acedido a 10 Set 2016).
- [32] PLUX wireless biosignals S.A. URL <http://www.plux.info/index.php/en/>. (Acedido a 10 Set 2016).
- [33] Cooking Hacks. e-health sensor platform v2.0 for arduino and raspberry pi, aug 2013. URL <https://www.cooking-hacks.com/documentation/tutorials/ehealth-biometric-sensor-platform-arduino-raspberry-pi-medical>. (Acedido a 10 Set 2016).
- [34] Plux. biosignalsplux wearable body sensing platform, . URL <http://biosignalsplux.com/index.php/en/>. (Acedido a 10 Set 2016).
- [35] Plux. Bitalino, . URL <http://biosignalsplux.com/index.php/en/>. (Acedido a 10 Set 2016).
- [36] Libelium. Libelium smart world. URL <http://www.libelium.com/>. (Acedido a 10 Set 2016).
- [37] Cooking. Raspberry pi to arduino shields connection bridge. URL <https://www.cooking-hacks.com/>

- raspberrypi-to-arduino-shield-connection-bridge. (Acedido a 10 Set 2016).
- [38] Jennifer A Healey and Rosalind W Picard. Detecting stress during real-world driving tasks using physiological sensors. *Intelligent Transportation Systems, IEEE Transactions on*, 6(2):156–166, 2005.
- [39] Jennifer Healey, Justin Seger, and Rosalind Picard. Quantifying driver stress: Developing a system for collecting and processing bio-metric signals in natural situations. *Biomedical sciences instrumentation*, 35:193–198, 1999.
- [40] Ahmet Akbas. Evaluation of the physiological data indicating the dynamic stress level of drivers. *Scientific Research and Essays*, 6(2):430–439, 2011.
- [41] Cafer Avcı, Ahmet Akbaş, and Yusuf Yüksel. Evaluation of statistical metrics by using physiological data to identify the stress level of drivers. *3rd International Conference on Environment Chemistry and Biology*, 78, 2014.
- [42] Mandeep Singh and Abdullah Bin Queyam. Correlation between physiological parameters of automobile drivers and traffic conditions. *International Journal of Electronics Engineering*, 5(2):6–12, 2013.
- [43] Mandeep Singh and Abdullah Bin Queyam. A novel method of stress detection using physiological measurements of automobile drivers. *International Journal of Electronics Engineering*, 5(2):13–20, 2013.
- [44] Yong Deng, Zhonghai Wu, Chao-Hsien Chu, and Tao Yang. Evaluating feature selection for stress identification. In *Information Reuse and Integration (IRI), 2012 IEEE 13th International Conference on*, pages 584–591. IEEE, 2012.
- [45] Adnan Ghaderi, Javad Frounchi, and Alireza Farnam. Machine learning-based signal processing using physiological signals for stress detection. In *2015 22nd Iranian Conference on Biomedical Engineering (ICBME)*, pages 93–98. IEEE, 2015.

- [46] N Keshan, PV Parimi, and I Bichindaritz. Machine learning for stress detection from ecg signals in automobile drivers. In *Big Data (Big Data), 2015 IEEE International Conference on*, pages 2661–2669. IEEE, 2015.
- [47] Mark Hall, Eibe Frank, Geoffrey Holmes, Bernhard Pfahringer, Peter Reutemann, and Ian H Witten. The weka data mining software: an update. *ACM SIGKDD explorations newsletter*, 11(1):10–18, 2009.
- [48] George Rigas, Yorgos Goletsis, and Dimitrios I Fotiadis. Real-time driver’s stress event detection. *IEEE Transactions on intelligent transportation systems*, 13(1):221–234, 2012.
- [49] JING Zhai and ARMANDO Barreto. Stress detection in computer users through non-invasive monitoring of physiological signals. *Blood*, 5(0), 2008.
- [50] Jing Zhai, Armando B Barreto, Craig Chin, and Chao Li. Realization of stress detection using psychophysiological signals for improvement of human-computer interactions. In *Proceedings. IEEE SoutheastCon, 2005.*, pages 415–420. IEEE, 2005.
- [51] Jennifer A. Healey. Stress recognition in automobile drivers, jun 2000. URL <https://physionet.org/physiobank/database/drivedb/>. (Acedido a 10 Set 2016).
- [52] PhysioNet. Wfdb toolbox for matlab and octave, feb 2015. URL <https://www.physionet.org/physiotools/matlab/wfdb-app-matlab/>. (Acedido a 10 Set 2016).
- [53] John A.Rice. *Mathematical Statistics and Data Analysis*, chapter 4,10, pages 138–147,392–397. Nelson Education, 2010.
- [54] Doron Levy. *Introduction to Numerical Analysis*, chapter 6, pages 96–104. Department of Mathematics and Center for Scientific Computation and Mathematical Modeling (CSCAMM) University of Maryland, 2010.
- [55] Simon Haykin and Barry Van Veen. *Signals and systems*, chapter 8, pages 635–638. John Wiley & Sons, 2007.

- [56] CA Teixeira, B Direito, H Feldwisch-Drentrup, M Valderrama, RP Costa, C Alvarado-Rojas, S Nikolopoulos, M Le Van Quyen, Jens Timmer, B Schelter, et al. Epilab: a software package for studies on the prediction of epileptic seizures. *Journal of neuroscience methods*, 200(2):257–271, 2011.
- [57] Hanchuan Peng, Fuhui Long, and Chris Ding. Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy. *IEEE Transactions on pattern analysis and machine intelligence*, 27(8):1226–1238, 2005.
- [58] Ian Jolliffe. *Principal component analysis*, chapter 1,2,3, pages 1–61. Wiley Online Library, 2002.
- [59] Gary M Weiss and Foster Provost. The effect of class distribution on classifier learning: an empirical study. *Rutgers Univ*, 2001.
- [60] *Statistics and Machine Learning Toolbox*, (r2016a) edition. URL <http://www.mathworks.com/help/stats/>.
- [61] Feng-Tso Sun, Cynthia Kuo, Heng-Tze Cheng, Senaka Buthpitiya, Patricia Collins, and Martin Griss. Activity-aware mental stress detection using physiological sensors. In *International Conference on Mobile Computing, Applications, and Services*, pages 211–230. Springer, 2010.
- [62] Richard O Duda, Peter E Hart, and David G Stork. *Pattern classification*, chapter 8, pages 3–22. John Wiley & Sons, 2012.
- [63] JP Marques De Sa. *Pattern recognition: concepts, methods and applications*, chapter 4,5, pages 130–207. Springer Science & Business Media, 2001.
- [64] Ananth Ranganathan. The levenberg-marquardt algorithm. *Tutorial on LM algorithm*, 11(1):101–110, 2004.
- [65] Michał Damiński, Alvaro Rada-Iglesias, Stefan Enroth, Claes Wadelius, Jacek Koronacki, and Jan Komorowski. Monte carlo feature selection for supervised classification. *Bioinformatics*, 24(1):110–117, 2008.

- [66] American Heart Association, apr 2016. URL http://www.heart.org/HEARTORG/Conditions/More/MyHeartandStrokeNews/All-About-Heart-Rate-Pulse_UCM_438850_Article.jsp#.V81Tf5grLIU. (Acedido a 10 Set 2016).

Apêndice A

Terminologia usada

Este apêndice serve como uma compilação das várias designações, bem como do respetivo significado, usadas ao longo do documento. Neste sentido, estão incluídas as terminologias e o significados dos registos da base de dados, das classes definidas para a classificação binária e multiclasse, das *features* extraídas dos sinais e das metodologias abordadas para a análise das *features*.

A.1 Registos

TABELA A.1: Número e respetivo nome dos registos da base de dados.

Designação	Nome
R1	<i>drive05</i>
R2	<i>drive06</i>
R3	<i>drive07</i>
R4	<i>drive08</i>
R5	<i>drive09</i>
R6	<i>drive10</i>
R7	<i>drive11</i>
R8	<i>drive12</i>
R9	<i>drive15</i>
R10	<i>drive16</i>

A.2 Classes

TABELA A.2: Nome e significado das classes usadas.

Designação	Significado
ClasseA	Classe de 'ausência de <i>stress</i> ', para classificação binária.
ClasseB	Classe de ' <i>stress</i> ', para classificação binária.
Classe1	Classe de 'baixo <i>stress</i> ', para classificação multiclasse.
Classe2	Classe de 'médio <i>stress</i> ', para classificação multiclasse.
Classe3	Classe de 'alto <i>stress</i> ', para classificação multiclasse.

A.3 Features

TABELA A.3: Número, designação e descrição de cada uma das *features*.

Número	Designação	Descrição
1	meanemg	Média aritmética do sinal EMG.
2	medianemg	Mediana do sinal EMG.
3	emgv	Variância do sinal EMG.
4	aemg	Frequência de metade da área da resposta em frequência do sinal hGSR.
5	meanhgsr	Média aritmética do sinal hGSR
6	medianhgsr	Mediana do sinal hGSR
7	hgsv	Variância do sinal hGSR
8	ahgsv	Frequência de metade da área em resposta à frequência do sinal hGSR
9	meanresp	Média aritmética do sinal Resp.
10	medianresp	Mediana do sinal Resp.
11	respv	Variância do sinal Resp.
12	aresp	Frequência de metade da área da resposta em frequência do sinal Resp.
13	meanhr	Média aritmética do sinal HR.
14	medianhr	Mediana do sinal HR.
15	hrv	Variância do sinal HR.
16	ahr	Frequência de metade da área da resposta em frequência do sinal HR.
17	L100	Razão entre a potência da banda de baixa frequência e a banda de alta frequência para janelas de 100 segundos.
18	M100	Razão entre a potência da soma da banda de baixa frequência com a média frequência e a banda de alta frequência para janelas de 100 segundos.
19	L300	Razão entre a potência da banda de baixa frequência e a banda de alta frequência para janelas de 300 segundos.
20	M300	Razão entre a potência da soma da banda de baixa frequência com a média frequência e a banda de alta frequência para janelas de 300 segundos

A.4 Metodologias

TABELA A.4: Designação e parâmetros em avaliação das metodologias avaliadas.

Designação	Redução de dimensão	Classificador	Marcador
M1	PCA	Rede Neuronal	Binário
M2	-	Rede Neuronal	Binário
M3	PCA	Rede Neuronal	Multiclasse
M4	-	Rede Neuronal	Multiclasse
M5	PCA	Árvore de Decisão	Binário
M6	-	Árvore de Decisão	Binário
M7	PCA	Árvore de Decisão	Multiclasse
M8	-	Árvore de Decisão	Multiclasse

Apêndice B

Seleção de *Features*

B.1 Correlação

Neste apêndice encontram-se, de forma mais detalhada, os valores dos coeficientes de correlação no caso binário e multiclasse entre as *features* e os vários marcadores binários e multiclasse, respectivamente, e ainda os coeficientes de correlação entre cada uma das *features*. Para mais informação acerca da terminologia usada em cada uma das tabelas, consultar o apêndice A.

TABELA B.1: Coeficientes de correlação entre cada uma *features* e o respetivo marcador binário.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
R1	0,59	0,57	0,25	-0,56	0,81	0,79	0,14	-0,50	0,22	0,21	0,32	-0,65	0,71	0,72	0,06	0,19	0,21	0,21	0,20	0,20
R2	0,37	0,34	0,22	-0,36	0,03	0,04	-0,03	-0,12	-0,45	-0,45	0,19	-0,65	0,64	0,65	-0,03	0,45	0,39	0,39	0,42	0,42
R3	0,47	0,45	0,23	0,01	0,58	0,58	0,24	-0,40	-0,70	-0,67	-0,04	-0,59	0,48	0,48	-0,13	0,10	0,42	0,42	0,57	0,57
R4	0,31	0,38	0,08	-0,20	0,76	0,76	0,33	-0,53	-0,68	-0,69	0,34	-0,78	0,29	0,22	0,10	-0,05	-0,13	-0,13	-0,22	-0,22
R5	0,42	0,37	0,15	-0,30	0,78	0,78	0,23	-0,50	-0,55	-0,56	0,14	-0,67	0,40	0,37	0,08	-0,05	-0,13	-0,13	-0,28	-0,28
R6	0,38	0,42	0,21	-0,38	0,24	0,24	0,04	-0,20	-0,19	-0,16	-0,07	-0,56	0,36	0,36	0,03	0,25	0,39	0,39	0,49	0,49
R7	0,16	0,31	0,08	-0,50	0,85	0,84	0,38	-0,70	-0,31	-0,28	0,28	-0,79	0,53	0,42	0,20	0,06	-0,28	-0,28	-0,56	-0,56
R8	0,44	0,51	0,37	-0,25	0,88	0,88	0,18	-0,50	-0,19	-0,20	0,32	-0,76	0,79	0,77	0,14	0,31	0,51	0,51	0,60	0,60
R9	0,56	0,49	0,28	-0,67	0,74	0,73	0,30	-0,53	-0,70	-0,68	0,32	-0,68	0,08	0,26	-0,19	0,02	-0,08	-0,08	-0,01	-0,01
R10	0,29	0,26	0,12	0,27	0,80	0,79	0,17	-0,30	-0,65	-0,67	0,25	-0,70	0,61	0,59	0,21	-0,34	-0,43	-0,44	-0,52	-0,52

TABELA B.2: Coeficientes de correlação entre cada uma *features* e o respetivo marcador multiclasse.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
R1	0,64	0,62	0,30	-0,51	0,83	0,81	0,17	-0,54	0,18	0,18	0,35	-0,61	0,74	0,74	0,07	0,16	0,09	0,08	0,02	0,02
R2	0,46	0,43	0,28	-0,44	0,27	0,28	0,01	-0,21	-0,30	-0,29	0,26	-0,67	0,73	0,74	0,00	0,52	0,44	0,44	0,39	0,39
R3	0,54	0,51	0,22	0,03	0,63	0,62	0,28	-0,45	-0,68	-0,65	0,02	-0,60	0,57	0,56	-0,05	-0,03	0,21	0,21	0,38	0,38
R4	0,32	0,37	0,12	-0,24	0,75	0,75	0,34	-0,52	-0,63	-0,64	0,38	-0,74	0,35	0,28	0,14	0,00	-0,07	-0,07	-0,15	-0,15
R5	0,25	0,18	0,14	-0,26	0,76	0,76	0,28	-0,54	-0,42	-0,42	0,18	-0,60	0,36	0,39	0,04	-0,01	-0,02	-0,02	-0,16	-0,16
R6	0,44	0,48	0,25	-0,42	0,35	0,35	0,04	-0,29	-0,13	-0,11	-0,04	-0,52	0,43	0,43	0,09	0,23	0,26	0,26	0,25	0,25
R7	0,22	0,35	0,11	-0,43	0,84	0,84	0,41	-0,69	-0,47	-0,44	0,37	-0,74	0,53	0,44	0,19	0,05	-0,33	-0,33	-0,58	-0,58
R8	0,29	0,50	0,23	-0,26	0,80	0,80	0,16	-0,50	-0,06	-0,08	0,42	-0,67	0,74	0,72	0,20	0,25	0,40	0,40	0,51	0,51
R9	0,49	0,39	0,30	-0,62	0,76	0,75	0,32	-0,56	-0,64	-0,63	0,38	-0,64	0,14	0,33	-0,16	0,01	-0,09	-0,09	0,03	0,03
R10	0,40	0,37	0,18	0,12	0,77	0,76	0,21	-0,36	-0,49	-0,50	0,36	-0,68	0,61	0,61	0,27	-0,29	-0,43	-0,43	-0,51	-0,51

TABELA B.3: Coeficientes de correlação entre cada uma das *features*, e as restantes.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
1	1,00	0,85	0,73	-0,33	0,01	0,00	-0,22	0,06	0,24	0,24	-0,03	0,48	-0,08	0,19	-0,66	0,27	0,48	0,48	0,56	0,56
2	0,85	1,00	0,77	-0,47	0,17	0,16	-0,05	-0,21	0,51	0,51	0,07	0,23	0,06	0,24	-0,45	0,44	0,60	0,60	0,63	0,63
3	0,73	0,77	1,00	-0,26	-0,09	-0,09	-0,38	0,16	0,35	0,35	-0,01	0,27	0,26	0,52	-0,43	0,58	0,74	0,74	0,79	0,79
4	-0,33	-0,47	-0,26	1,00	0,07	0,07	-0,09	0,33	-0,45	-0,47	-0,24	0,04	0,28	0,17	0,32	-0,49	-0,16	-0,16	-0,11	-0,11
5	0,01	0,17	-0,09	0,07	1,00	1,00	0,76	-0,84	0,02	0,00	0,57	-0,62	0,04	-0,02	0,39	0,58	0,50	0,50	0,50	0,50
6	0,00	0,16	-0,09	0,07	1,00	1,00	0,77	-0,84	0,01	-0,01	0,57	-0,63	0,04	-0,02	0,39	-0,58	-0,51	-0,51	0,50	0,50
7	-0,22	-0,05	-0,38	-0,09	0,76	0,77	1,00	-0,90	-0,34	-0,34	0,39	-0,61	-0,41	-0,52	0,10	-0,54	-0,57	-0,57	-0,58	-0,58
8	0,06	-0,21	0,16	0,33	-0,84	-0,84	-0,90	1,00	-0,05	-0,05	-0,53	0,66	0,16	0,25	-0,20	0,30	0,41	0,41	0,45	0,45
9	0,24	0,51	0,35	-0,45	0,02	0,01	-0,34	-0,05	1,00	1,00	0,11	0,08	0,57	0,57	0,30	0,51	0,39	0,39	0,30	0,30
10	0,24	0,51	0,35	-0,47	0,00	-0,01	-0,34	-0,05	1,00	1,00	0,08	0,10	0,55	0,55	0,27	0,52	0,40	0,40	0,31	0,31
11	-0,03	0,07	-0,01	-0,24	0,57	0,57	0,39	-0,53	0,11	0,08	1,00	-0,81	0,13	0,15	0,33	-0,18	-0,43	-0,43	-0,44	-0,44
12	0,48	0,23	0,27	0,04	-0,62	-0,63	-0,61	0,66	0,08	0,10	-0,81	1,00	-0,11	0,03	-0,56	0,24	0,48	0,48	0,54	0,54
13	-0,08	0,06	0,26	0,28	0,04	0,04	-0,41	0,16	0,57	0,55	0,13	1,00	1,00	0,94	0,52	0,32	0,32	0,32	0,24	0,24
14	0,19	0,24	0,52	0,17	-0,02	-0,02	-0,52	0,25	0,57	0,55	0,15	0,03	0,94	1,00	0,28	0,40	0,43	0,43	0,39	0,39
15	-0,66	-0,45	-0,43	0,32	0,39	0,39	0,10	-0,20	0,30	0,27	0,33	-0,56	0,52	0,28	1,00	-0,30	-0,42	-0,42	-0,51	-0,51
16	0,27	0,44	0,58	-0,49	0,58	-0,58	-0,54	0,30	0,51	0,52	-0,18	0,24	0,32	0,40	-0,30	1,00	0,85	0,85	0,78	0,78
17	0,48	0,60	0,74	-0,16	0,50	-0,51	-0,57	0,41	0,39	0,40	-0,43	0,48	0,32	0,43	-0,42	0,85	1,00	1,00	0,98	0,98
18	0,48	0,60	0,74	-0,16	0,50	-0,51	-0,57	0,41	0,39	0,40	-0,43	0,48	0,32	0,43	-0,42	0,85	1,00	1,00	0,98	0,98
19	0,56	0,63	0,79	-0,11	0,50	0,50	-0,58	0,45	0,30	0,31	-0,44	0,54	0,24	0,39	-0,51	0,78	0,98	0,98	1,00	1,00
20	0,56	0,63	0,79	-0,11	0,50	0,50	-0,58	0,45	0,30	0,31	-0,44	0,54	0,24	0,39	-0,51	0,78	0,98	0,98	1,00	1,00

Apêndice C

Resultados gráficos dos ensaios individuais de *cross-validation* *leave-one-out*

Neste apêndice estão presentes os resultados gráficos, relativos ao teste de cada um dos registos, quando aplicado o algoritmo de classificação desenvolvido. Assim, são apresentados os resultados da classificação binária e da classificação multiclasse, para cada um dos registos de teste.

C.1 Resultados binários

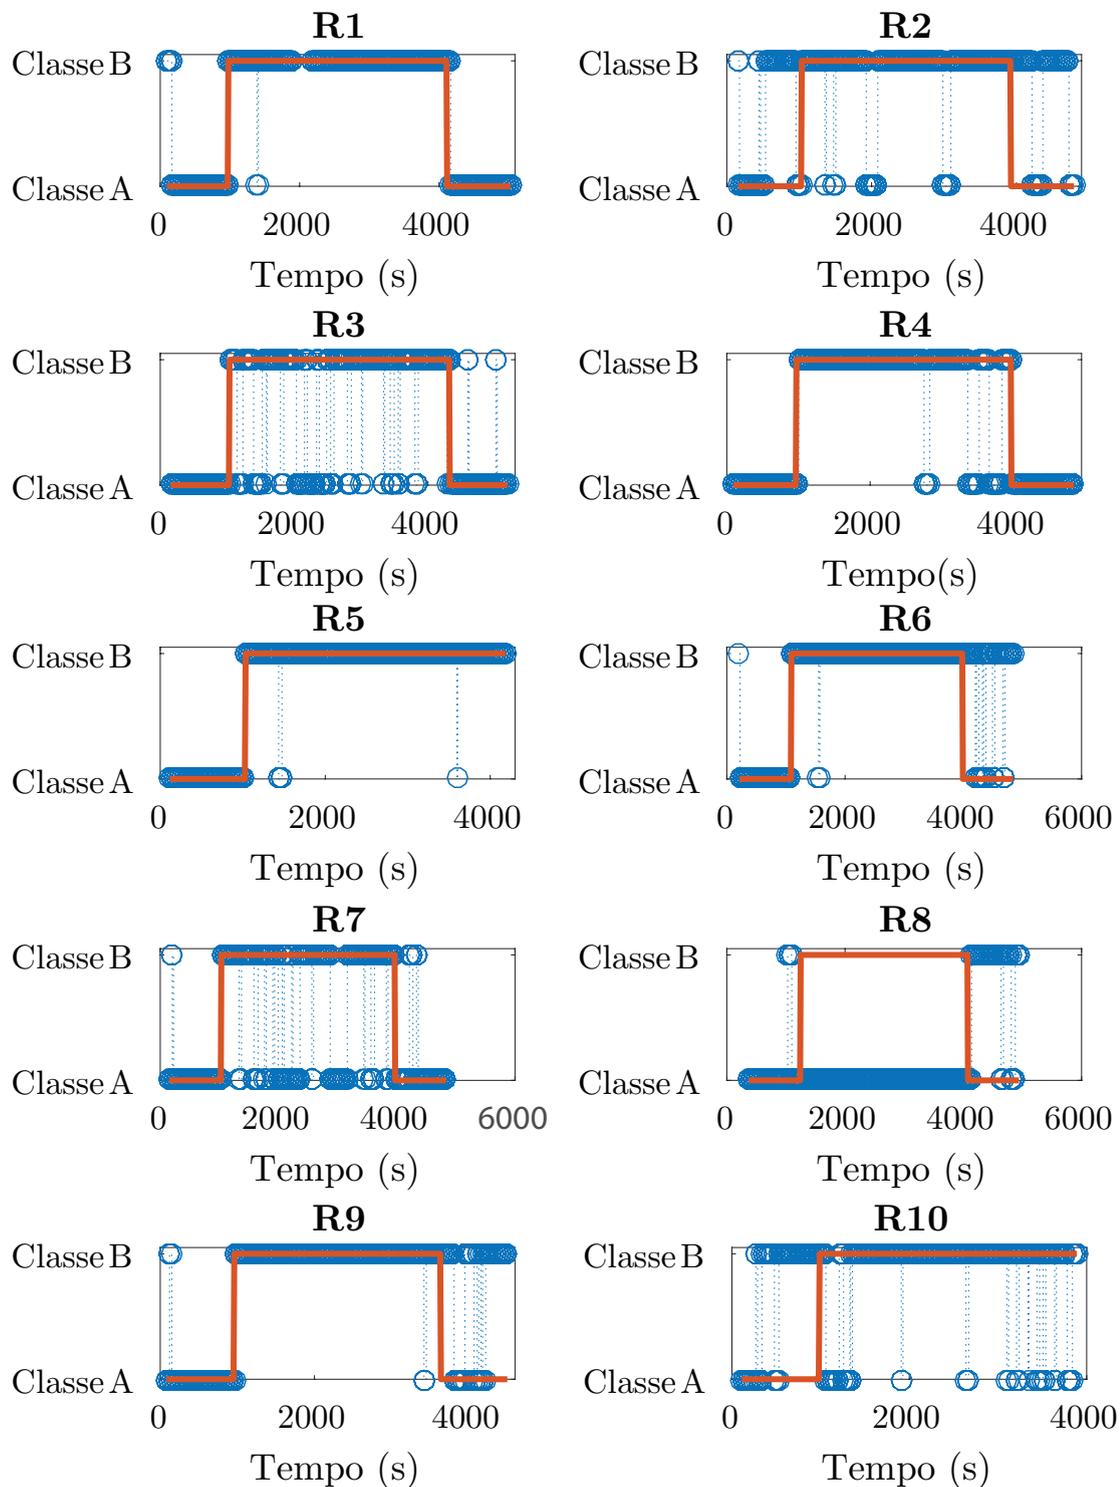


FIGURA C.1: Marcador previsto (a azul) pelo algoritmo usado e o marcador real (a laranja) extraído da base de dados, para uma classificação binária.

C.2 Resultados multiclasse

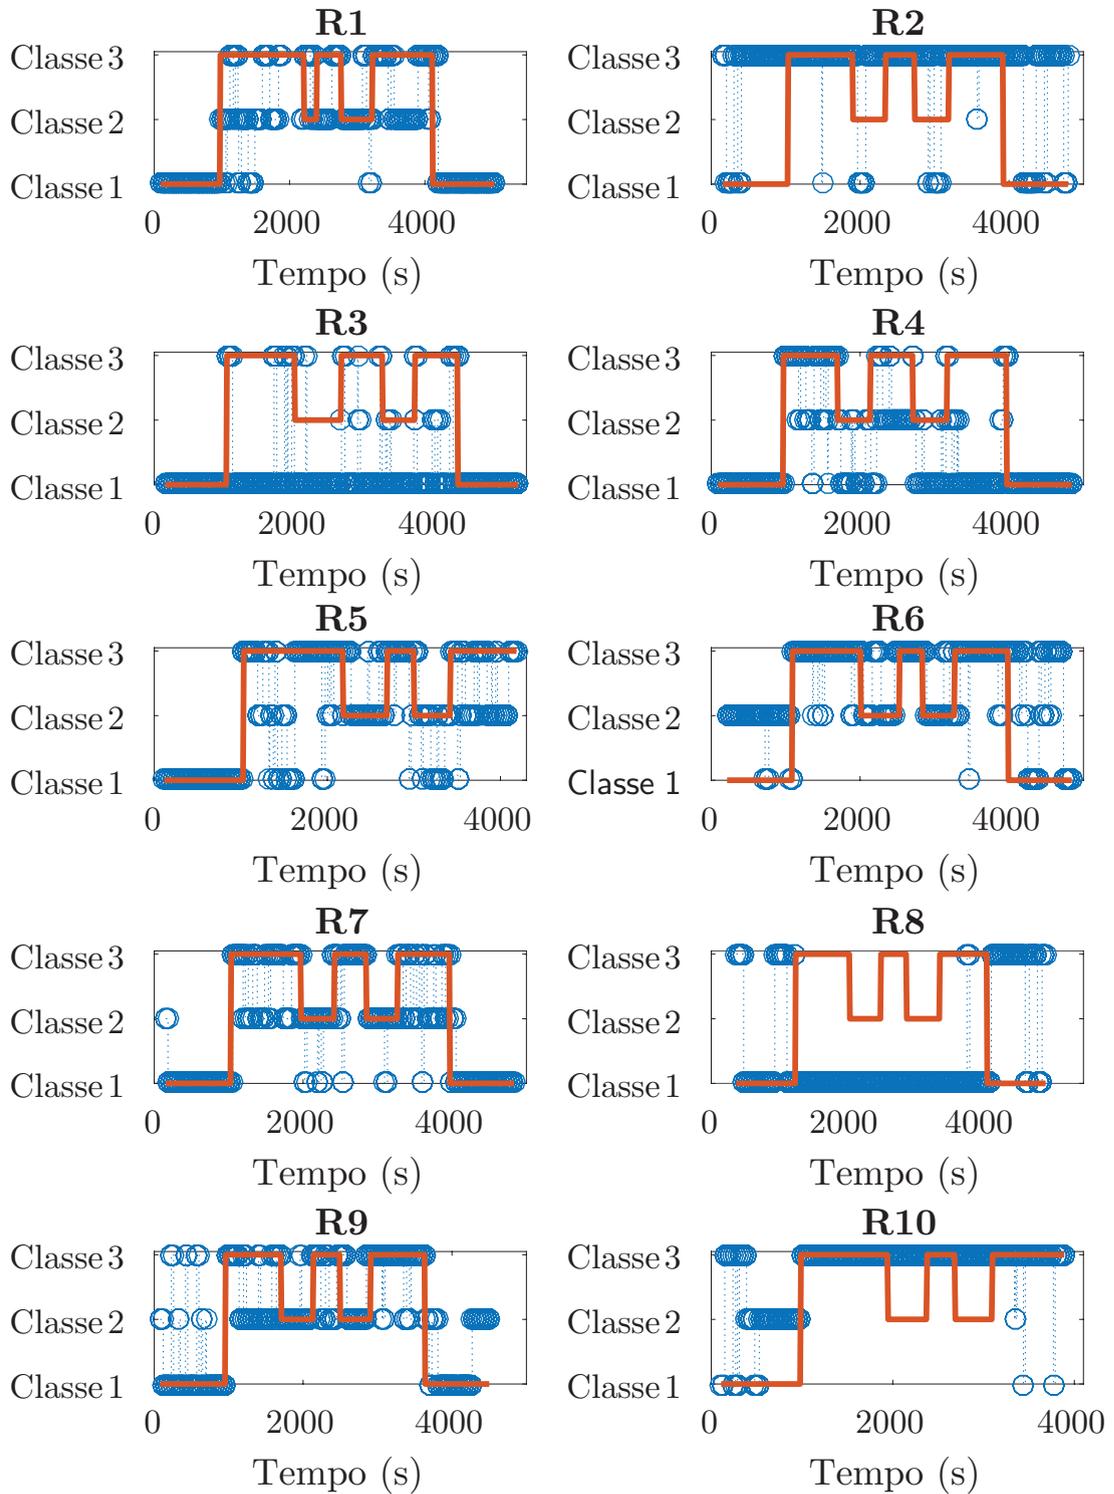


FIGURA C.2: Marcador previsto (a azul) pelo algoritmo usado e o marcador real (a laranja) extraído da base de dados, para uma classificação multiclasse.