



**POLITÉCNICO
DE LISBOA**

Instituto Politécnico de Lisboa

Instituto Superior de Engenharia de Lisboa



**ESCOLA SUPERIOR DE
TECNOLOGIA DA SAÚDE
DE LISBOA**
INSTITUTO POLITÉCNICO DE LISBOA

Escola Superior de Tecnologia de Saúde de Lisboa

Deteção e monitorização de atividade humana através de sensores inerciais e ECG

Élton Coelho dos Santos

Trabalho final de mestrado para a obtenção do grau de mestre em

Engenharia Biomédica

Orientador:

Professor Doutor André Lourenço (ISEL)

Júri

Presidente:

Professor Doutor João Costa (ISEL)

Vogal:

Professor Doutor Pedro Mendes Jorge (ISEL)

Setembro 2021

[Esta página está intencionalmente em branco]

“Optimism is an occupational hazard of programming: feedback is the treatment.”

Kent Beck

[Esta página está intencionalmente em branco]

Agradecimentos

Quando chega o momento dos agradecimentos, sinto vontade de dirigir uma palavra a cada um dos meus familiares, amigos e colegas por se mostrarem sempre interessados no meu trabalho e entre estes um especial obrigado aqueles que me souberam sempre orientar na direcção correcta.

Assim agradeço:

À minha família e aos meus pais namorada e irmão em particular pelo apoio constante que me manteve sempre orientado para o sucesso neste trabalho.

Ao meu orientador Professor Doutor André Lourenço pela disponibilidade, atenção e profissionalismo, no acompanhamento da elaboração da dissertação.

Ao ISEL e em especial à cardioID pela autorização na elaboração desta dissertação.

A todos os meus colegas e amigos em particular Bernardo, Alexandre e Rúben, que demonstraram sempre um especial interesse pela minha pesquisa e por aturarem instantes de inquietação e de alguma insegurança da minha parte em relação ao meu trabalho em momentos mais difíceis.

...a todos

Obrigado

[Esta página está intencionalmente em branco]

Resumo

A monitorização de sinais biológicos é um tema de investigação bastante em foco na comunidade biomédica. Com o avanço da tecnologia, foram desenvolvidas nos últimos anos várias tecnologias *wearable* por forma a monitorizar sinais fisiológicos, desde *smart bands*, *smartwatches* e outras tecnologias como a t-shirt da CardioID para monitorizar o sinal de ECG.

Esta tese tem como principal objetivo detetar e monitorizar atividade humana usando sensores inerciais e sinal cardíaco através de algoritmos de classificação supervisionada. Foi construído um contador de passos usando o sinal do acelerómetro (XYZ), onde foi utilizada uma base de dados conhecida a MHEALTH e também dados recolhidos de um smartphone seguindo dois protocolos distintos previamente definidos como forma de validação do algoritmo desenvolvido. Foram também construídos três algoritmos de classificação que foram desenvolvidos recorrendo unicamente à base de dados MHEALTH e com o foco principal na distinção de três atividades físicas: quando o sujeito está parado, a andar e a correr, respectivamente, através da utilização de três classificadores: *Support Vector Machines* (SVM), *K-nearest neighbors* (KNN) e modelo de *Boosting*.

Foram estudados de forma independente o sinal de acelerómetro (XYZ), onde foram extraídas características no domínio de tempo e no domínio de frequência, o sinal de eletrocardiograma (ECG), onde foram extraídas características usando a biblioteca neurokit e biospy e por fim, fundidas as características do acelerómetro e sinal cardíaco. Os resultados demonstraram que o sinal de acelerómetro é bastante preciso para calcular o numero de passos com dados recolhidos num *smartphone*. A nível dos classificadores de atividade física verificou-se, no que toca ao sinal de acelerómetro, que as características mais precisas foram as do domínio de frequência comparativamente com as características do domínio de tempo. No que toca ao sinal de ECG, foi possível apurar que as características estudadas permitem distinguir as atividades propostas. Em relação aos classificadores foi claro que o SVM e o KNN foram os que obtiveram melhores precisões em todos os algoritmos e que o modelo de *Boosting* foi o que ficou mais aquém da precisão mínima esperada.

Palavras-chave: acelerómetro, classificador de aprendizagem supervisionada, eletrocardiograma.

Abstract

Monitoring of biological signals is an investigation focus in the biomedical community. With the advance of technology, over the last years several wearable technologies were developed to allow the monitoring physiological signals, from smart bands, smartwatches and other technologies like the t-shirt from CardioID to monitor the ECG signal.

This thesis has as its main goal to detect and monitor human activity through the use of inertial sensors and cardiac signal and supervised learning classifiers. As such, four algorithms were built, namely: a step counter using the accelerometer signal (XYZ), in which a data base known as MHEALTH was used, as well as data collected from a smartphone using two distinct protocols previously defined as validation of the developed algorithm. The remaining three algorithms were developed solely through the use of MHEALTH database and with the primary focus being on three physical activities: when the individual is standing still, walking and running, respectively, through the use of three classifiers (by means of sklearn library): Support Vector Machines (SVM), K-nearest neighbors (KNN) and Boosting model.

One of the algorithms in the study only made use of the accelerometer signal (XYZ), where features in the domain of time and frequency were extracted. In another algorithm it was solely used the ECG signal, with extracted features taking advantage of the neurokit and biopsy libraries. At last, the last algorithm used the signals from the accelerometer and the cardiac signal, through a fusion of all the previously studied features in the beforementioned algorithms. The results showed that the accelerometer signal shows good precision in calculating the number of steps through the data collected via a smartphone. Regarding the physical activity classifiers, it was seen that, when it comes to the accelerometer, the most precise features were those in the frequency domain, when compared to those in the time domain. As for the ECG signal, it was possible to ascertain that the studied features allow to distinguish the proposed activities. When it comes to the classifiers, it is clear that the Support Vector Machine was the one that allowed for the best overall precision in all studied algorithms, and that it was the Boosting model the underachiever, as far as precision goes.

Keywords: accelerometer, supervised learning classifier, electrocardiogram.

[Esta página está intencionalmente em branco]

Índice

Agradecimentos	v
Resumo	vii
Abstract	viii
Lista de Figuras	xii
Lista de tabelas	xiv
Lista de abreviaturas	xv
Capítulo 1: Introdução	1
1.1. Contexto e motivação	1
1.2. Objetivos	4
1.3. Estrutura da tese	4
Capítulo 2: Estado da Arte	6
2.1. Sensores fisiológicos	6
2.2. Detecção e classificação de atividades humanas usando sensores fisiológicos	10
Extração de features	13
Modelos de classificação	13
Medidas de avaliação	14
Cross validation e Leave One Out	14
Smartphones e detecção de atividade humana	15
Bases de dados	15
Capítulo 3: Implementação de algoritmos de detecção de atividade	17
3.1. Quantificação de passos – peak detection	17
Pré-processamento	17
Norma do vetor de aceleração	17
Filtragem	18
Resultado final do pré-processamento	19
Algoritmo de peak detection	19
3.2. Detecção automática de atividade usando sinal de acelerómetro	20
Aquisição de sinal	22
Segmentação de sinal	22
Extração de características	23

Características no domínio de tempo ou estatístico:	24
Características no domínio da frequência:.....	25
Classificação	26
3.3. Detecção automática de atividade usando sinal de ECG	27
3.4. Detecção automática de atividade usando acelerómetro e ECG (fusão)	28
Capítulo 4: Resultados e Discussão	30
4.1. Pedómetro – peak detection.....	30
Resultados MHEALTH DATASET	30
Resultados smartphone	31
4.2. Detecção automática de atividade usando sinal de acelerómetro.....	33
4.3. Detecção automática de atividade usando sinal de ECG	40
4.4. Detecção automática de atividade usando acelerómetro e ECG (fusão)	45
Capítulo 5: Conclusões e Trabalho Futuro	47
Referências Bibliográficas	49

Lista de Figuras

Figura. 1. Wearable sensors	2
Figura. 2. Smartwatch.....	2
Figura. 3. ECG aplicado em t-shirt	2
Figura. 4. Smartband	3
Figura. 5. ECG aplicado a um cinto	3
Figura. 7. T-shirt da cardioid: a) vista frontal b) forro interno com os elétrodos.....	4
Figura. 8. Definição de cada eixo (XYZ).....	6
Figura. 9. Gráfico de dados extraídos de um acelerómetro durante várias atividades executadas ao longo do tempo.	7
Figura. 10. Sistema de condução de His-Purkinje rhjbfewhbf.	8
Figura. 11. O impulso elétrico, com os seus picos e curvas num ECG.....	9
Figura. 12. ECG com 12 derivações: Seis derivações peitorais (V1 a V6) e seis derivações dos membros (I, II, III, α VR, α VL, α VF).	10
Figura. 13. Diferença de segmentação sem sobreposição(a) e com sobreposição (b).	12
Figura. 14. Aceleração registada nos 3 eixos ao longo do tempo.	17
Figura. 15. Norma do vetor de aceleração.	18
Figura. 16. Filtro de média deslizante.	18
Figura. 17. Norma do vetor de aceleração com filtro de média deslizante com janela de tamanho 5.	19
Figura. 18. Algoritmo de deteção de pico.	20
Figura. 19. Threshold adaptativo. μ_a – média dos últimos k pontos; σ_a – desvio padrão dos últimos k pontos, α – constante de magnitude.	20
Figura. 20. Etapas do sistema proposto, Segmentação, Extração de features e Classificação.	21
Figura. 21. Arquitetura geral do algoritmo de classificação de atividade humana usando o sinal de acelerómetro.....	22
Figura. 22. Arquitetura da fase de pré-processamento do dataset em estudo.....	22
Figura. 23. Exemplo de segmentação de janelas com sobreposição de 50%.	23
Figura. 24. Arquitetura da fase de pré-processamento do dataset em estudo, extração de características.....	23
Figura. 25. Matriz de coordenadas obtida através de acelerómetro.....	24
Figura. 26. Arquitetura da fase de treino do dataset em estudo, classificação e avaliação.	26
Figura. 27. Representação esquemática do método de avaliação cruzada.	27
Figura. 28. Classificação de atividades do estudo.	27

Figura. 29. Processo de segmentação e classificação.	28
Figura. 30. Fluxograma de detecção automática de atividade pelo método de fusão.	29
Figura. 31. Resultados obtidos para a MHEALTH DATASET.	30
Figura. 32. Resultados obtidos para os dados do smartphone segundo o protocolo (a).	31
Figura. 33. Resultados obtidos para os dados do smartphone segundo o protocolo (b).	32
Figura. 34. Sinal Raw obtido de todo o dataset em estudo MHEALTH DATASET.	33
Figura. 35. Módulo do sinal de todo o dataset em estudo MHEALTH DATASET.	33
Figura. 36. Representação de sinal em 60 segundos em que o sujeito está em Inatividade.	34
Figura. 37. Representação de sinal em 60 segundos em que o sujeito está a Andar.	34
Figura. 38. Representação de sinal em 60 segundos em que o sujeito está a Correr.	35
Figura. 39. Representação da Potência espectral em bandas de frequência de 0,2HZ quando o sujeito está em Inatividade.	36
Figura. 40. Representação da Potência espectral em bandas de frequência de 0,2HZ quando o sujeito está a andar.	36
Figura. 41. Representação da Potência espectral em bandas de frequência de 0,2HZ quando o sujeito está a correr.	37
Figura. 42. Representação gráfica da precisão de cada característica usada no modelo de treino (Função do SKLEARN):	38
Figura. 43. Processamento do sinal de ECG usando a biblioteca neurokit, enquanto o individuo está em inatividade.	40
Figura. 44. Processamento do sinal de ECG usando a biblioteca neurokit, enquanto o individuo está a andar.	41
Figura. 45. Processamento do sinal de ECG usando a biblioteca neurokit, enquanto o individuo está a correr.	41
Figura. 46. Distribuição dos intervalos R-R, enquanto o indivíduo está em inatividade.	42
Figura. 47. Distribuição dos intervalos R-R, enquanto o indivíduo está a andar.	43
Figura. 48. Distribuição dos intervalos R-R, enquanto o indivíduo está a correr.	43
Figura. 49. Representação gráfica da precisão de cada característica usada no modelo de treino (Função do SKLEARN).	44

Lista de tabelas

Tabela. 1. Bases de dados usadas em diversos estudos.....	16
Tabela. 2. Resultados da classificação no domínio de tempo.....	38
Tabela. 3. Resultados da classificação no domínio da frequência.	39
Tabela. 4. Resultados da classificação no domínio de tempo + domínio de frequência.	39
Tabela. 5. Resultados da classificação do sinal de ECG.....	45
Tabela. 6. Resultados da classificação o sinal do acelerómetro + o sinal de ECG.....	45

Lista de abreviaturas

ECG	Electrocardiograma
FNSW	Fixed-size Non-overlapping Sliding Window
FOSW	Fixed-size Overlapping Sliding Window
GSR	Galvanic Skin Response
HRV	Heart Rate Variability
Hz	Hertz
ISEL	Instituto Superior de Engenharia de Lisboa
KNN	K-nearest neighbors
LOO	Leave-One-Out
MEMS	Microeletromecânicos
NSA	Nó sinusal
OMS	Organização Mundial de Saúde
SVM	Support Vector Machines

[Esta página está intencionalmente em branco]

Capítulo 1: Introdução

1.1. Contexto e motivação

Durante os últimos anos existiu um grande desenvolvimento dos sistemas informáticos e da microeletrónica, permitindo o aparecimento de dispositivos móveis com características excecionais. O seu elevado poder computacional, pequeno tamanho e baixo custo permitem às pessoas interagir com estes dispositivos na sua vida quotidiana, utilizando-os para um vasto leque de atividades. Consequentemente, isto permitiu o desenvolvimento e o interesse no estudo da Detecção e Reconhecimento de Atividade Humana [1]. Esta é uma área de investigação multidisciplinar que abrange a inteligência artificial, perceção do dispositivo, computação ubíqua e interação humana com computadores, assim como a psicologia e a sociologia.

Um sistema de reconhecimento de atividades tem como objetivo reconhecer as ações ou atividades dos seus utilizadores, observando “discretamente” os seus comportamentos e as características do ambiente em que estão inseridos, tomando medidas necessárias e adequadas como resposta. Por exemplo, num ambiente doméstico, os sistemas de reconhecimento de atividades podem monitorizar as ações dos utilizadores ao longo do tempo, com o objetivo de os lembrar de realizar certas atividades, pode ser bastante útil na monitorização de idosos.

Estes sistemas podem também desempenhar um papel vital ao encorajar um estilo de vida mais saudável entre os utilizadores, sugerindo pequenas modificações de comportamento. Por exemplo, as pessoas podem ser encorajadas a utilizar escadas em vez de um elevador ou a ficar de pé após um longo período em que estiveram sentadas [2]. Para além disso, a maior parte dos pacientes com diabetes, obesidade ou doenças cardíacas são obrigados a seguir uma rotina de exercícios bem definida como parte dos seus tratamentos [3]. Como tal, o reconhecimento de atividades como ciclismo, caminhar ou correr, torna-se bastante útil para fornecer informações úteis ao cuidador sobre o comportamento do paciente. Da mesma forma que pacientes com demências e outras patologias mentais podem ser monitorizados para detetar atividades anormais e assim prevenir comportamentos indesejáveis e com consequências [3].




Figura 1. Sensores vestíveis

O reconhecimento de atividades humanas utiliza sensores sobre e em torno do sujeito para registrar os seus movimentos, enquanto os sistemas especializados monitorizam e aplicam os dados registados para detetar e interpretar as atividades realizadas. Entre as diversas tecnologias utilizadas, a mais prevalente neste tipo de monitorização, ver figura 1 [4]. Tal como o nome indica, estes sensores são concebidos para serem aplicados no corpo e utilizados durante a rotina normal do sujeito, independentemente da sua localização. Assim, medem continuamente dados biomecânicos e fisiológicos, sendo uma alternativa adequada para o reconhecimento das atividades humanas diárias, especialmente atividades físicas.



Figura 3. Smartwatch



Figura 2. ECG aplicado em t-shirt

As atividades físicas como correr e andar requerem movimentos repetitivos e são limitados pela estrutura do corpo. Visto que os *wearable sensors* podem ser integrados em roupa, acessórios ou em dispositivos portáteis, estes apresentam a capacidade de recolher dados provenientes de um padrão de atividade física diária durante um extenso período. Interruptores eletromecânicos, goniómetros, acelerómetros, giroscópios, pedómetros e actómetros têm sido utilizados como *wearable sensors*, podendo ser aplicáveis em smartphones, smartwatches, smartbands ou roupa, como t-shirts [5].

Relativamente à monitorização da atividade humana, os sensores mais utilizados são os acelerómetros, que medem a aceleração ao longo de um ou vários eixos sensíveis e numa determinada gama de frequências. Estes podem ser utilizados para detetar movimentos de queda, análise do movimento corporal e orientação postural de um sujeito [6]. Existem vários tipos de acelerómetros baseados em métodos piezoelétricos, piezorresistivos ou de capacidade variável de transdução. Normalmente todos utilizam o mesmo princípio de funcionamento: uma massa que responde à aceleração fazendo com que uma mola ou um componente equivalente se estique ou comprima proporcionalmente à aceleração medida [7].

Para medir a frequência cardíaca podem ser utilizados sensores de Eletrocardiograma (ECG), úteis na avaliação de doenças cardiovasculares a curto prazo, especialmente para pessoas com problemas cardíacos crónicos. O sinal de ECG fornece informação muito útil sobre a taxa e regularidade dos batimentos cardíacos, que são utilizados no diagnóstico de doenças cardíacas [8].



Figura 5. ECG aplicado a um cinto



Figura 4. Smartband

Esta dissertação enquadra-se em um conjunto de atividades de investigação e desenvolvimento da empresa CardioID (<https://www.cardio-id.com>). Na qual o sinal cardíaco é o foco principal dos vários projetos que decorrem nesta empresa.

Pretende-se então contextualizar a atividade cardíaca na atividade humana de modo a permitir inferir de forma mais informada se o estado cardíaco está diretamente relacionado com as diferentes atividades que o ser humano realiza e deste modo conseguir detetar e monitorizar atividade humana através do sinal cardíaco recorrendo a técnicas de aprendizagem automática.



Figura 6. T-shirt da cardioID: a) vista frontal b) forro interno com os elétrodos.

1.2. Objetivos

Objetivo principal:

Detetar, reconhecer e monitorizar atividades humanas (inatividade, andar e correr) recorrendo a sinais fisiológicos, nomeadamente o sinal de acelerómetro e o sinal cardíaco.

Objetivos específicos:

1. Realização de algoritmos de extração de características e contabilização de passos usando sinais de acelerómetro e sinais cardíacos.
2. Estudo de quais as características mais representativas para a classificação de atividades.
3. Estudo de quais os classificadores que apresentam melhores resultados.
4. Combinação de características de ambos os sinais (acelerómetro e cardíaco).
5. Validação da metodologia realizada com dados reais.

1.3. Estrutura da tese

O documento está organizado da seguinte forma:

No **capítulo 1**, denominado de “Introdução”, contém três secções o primeiro onde se contextualiza e refere a pertinência da tese e em que ambiente foi realizado, nomeadamente com o apoio e envolvimento do ISEL (Instituto Superior de Engenharia de Lisboa) e da empresa CardioID. O segundo subcapítulo é onde são definidos os objetivos deste estudo e por último no terceiro subcapítulo é descrita a estrutura da tese.

No **capítulo 2**, denominado de estado de arte, é realizado um enquadramento teórico do

projeto, onde se descreve o funcionamento base dos sensores usados no estudo, bem como as principais etapas realizadas em estudos como este, demonstrando assim como funciona o trabalho nesta área de estudo.

No **capítulo 3**, denominado de implementação, é onde são descritos os algoritmos realizados neste estudo, suas metodologias e estrutura, e também quais as atividades analisadas.

No **capítulo 4**, denominado de resultados e discussão, são analisados e discutidos os resultados obtidos, com o objetivo de perceber o sinal adquirido, quais as características mais representativas para a classificação bem como os classificadores.

No **capítulo 5**, denominado de conclusões e trabalho futuro, são apresentadas as considerações finais e feito um balanço do trabalho realizado destacando os objetivos propostos, e dando uma visão de trabalho futuro.

Capítulo 2: Estado da Arte

2.1. Sensores fisiológicos

Acelerómetro

Os acelerómetros são dispositivos capazes de medir a aceleração aplicada ao longo de um eixo sensível e sobre uma determinada gama de frequência, através de transdutores. Existem vários tipos de acelerómetros baseados em métodos piezoelétricos, piezorresistivos ou de capacidade variável de transdução [7]. Normalmente todos utilizam o mesmo princípio de funcionamento: uma massa que responde à aceleração fazendo com que uma mola ou um componente equivalente se estique ou comprima proporcionalmente à aceleração medida [7], [9].

Os dados do acelerómetro podem ser visualizados num plano tridimensional ao longo de três eixos (x, y e z) que representam um conjunto de três vetores $acc_i = (x_i, y_i, z_i)$, onde $i = (1,2,3, \dots, n)$.

A frequência de amostragem é medida em Hertz (Hz), ou seja, a quantidade de amostras que o sensor gera em 1 segundo. Inicialmente, a principal função dos acelerómetros inseridos em smartphones e outros dispositivos móveis seria suportar jogos avançados e permitir a rotação automática do ecrã. Atualmente sabe-se que estes sensores podem fornecer informação útil para o reconhecimento de atividade humana [10] como a orientação postural de um sujeito [7], [9]–[11] deteção de quedas [12] e análise do movimento corporal [13].




Figura 7. Definição de cada eixo.

Em comparação com outros sensores para o reconhecimento de atividade humana, os acelerómetros apresentam algumas vantagens. A sua capacidade de responder tanto à frequência como à intensidade do movimento, torna-os superiores aos actómetros ou pedómetros que são atenuados pelo impacto ou pela inclinação [14]. A maioria dos acelerómetros disponíveis podem medir tanto o movimento como a inclinação, o que os torna superiores aos sensores de movimento

que não têm capacidade de medir estas características. Para além disso, devido à tecnologia avançada dos sistemas microelectromecânicos (MEMS), os acelerómetros atuais são mais económicos e de tamanho reduzido mas sempre com capacidade de apresentar um elevado grau de fiabilidade nas medições [15].

Na Figura 8 está representado um exemplo de dados extraídos de um acelerómetro durante várias atividades executadas ao longo do tempo. Na figura 9, o eixo das abcissas representa aquisição das informações das coordenadas x , y e z ao longo do tempo. O eixo das ordenadas mostra a amplitude dos valores das coordenadas. Como pode ser observado, os padrões do sinal variam em diferentes intervalos e isso é devido à execução de diferentes atividades como “andar a pé” ou “andar de comboio” [16].




Figura 8. Gráfico de dados extraídos de um acelerómetro durante várias atividades executadas ao longo do tempo.

Eletrcardiograma (ECG)

O coração humano é um órgão que dispõe de força mecânica para bombear o sangue através do sistema circulatório e chegar a todas as partes do corpo, fornecendo oxigénio e nutrientes para os tecidos e removendo dióxido de carbono e outros resíduos [17]. De acordo com a Organização Mundial de Saúde (OMS), mais de 17 milhões de pessoas perdem a vida todos os anos devido a doenças cardiovasculares, representando cerca de 31% das mortes em todo o mundo [18]. Perante este facto, é fundamental perceber os fenómenos que regulam a função cardíaca quando queremos assegurar o bem-estar humano.

O ECG é o exame médico mais comum em cardiologia, não invasivo e pouco dispendioso [19]. É amplamente utilizado, sendo fundamental para a avaliação cardiovascular, na deteção de doenças cardíacas tais como enfarte do miocárdio e arritmias [20]. Os batimentos cardíacos são controlados por um sistema de condução elétrica que coordena os movimentos das cavidades do coração. O ECG deteta a atividade elétrica do coração relacionada com os movimentos de contração e relaxamento do miocárdio ou das válvulas [21]. A despolarização e repolarização das células do miocárdio resultam em impulsos elétricos que podem ser identificados pelo ECG e permitem avaliar a frequência cardíaca e detetar isquémia (restrição de fluxo sanguíneo para o tecido cardíaco) [20].

O nó sinusal (NSA) funciona como um *pacemaker* natural, sincronizando a despolarização

atrial. Durante a despolarização, existe uma perda de negatividade dos miócitos e conseqüentemente a sua contração [22]. Em repouso, os miócitos do nó SA despolarizam a uma taxa intrínseca entre 60 a 100 batimentos por minuto, que é considerado um ritmo cardíaco normal. Este impulso elétrico é propagado ao longo dos ventrículos pelo nó atrioventricular e a partir daí é transmitido para o septo interventricular (estrutura que separa os ventrículos esquerdo e direito) [22]. Com o objetivo de despolarizar os ventrículos, o impulso propaga-se da esquerda para a direita, ao longo do tecido condutor do sistema de His-Purkinje e termina nas fibras de Purkinje, provocando a contração das células (Figura 10) [20].

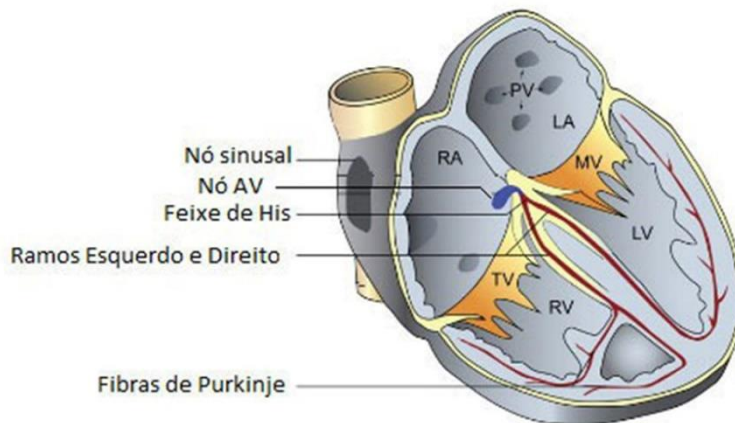


Figura 9. Sistema de condução de His-Purkinje
rhjbfewhbf.

Enquanto ocorre a despolarização dos ventrículos, as aurículas começam a recuperar a sua negatividade elétrica interna, um processo chamado repolarização, permitindo aos átrios relaxar. Uma vez totalmente despolarizados, os ventrículos também repolarizam e acabam por relaxar. Todo o processo de despolarização e repolarização pode ser visto no ECG. Cada parte do sistema de condução elétrico do coração pode ser caracterizado por padrões de picos e curvas, como na Figura 10 [20]–[22]. A representação visual do sistema de condução permite a análise da atividade elétrica do coração.

Um ECG deve ser interpretado da seguinte maneira [21]:

- A onda P representa a despolarização da direita e esquerda (contração) dos átrios;
- O complexo QRS representa a despolarização (contração) dos ventrículos;
- O segmento ST representa o período de inatividade entre a despolarização e o início da repolarização ventricular;
- A onda T está relacionada com a repolarização dos ventrículos (relaxamento)




Figura 10. O impulso elétrico, com os seus picos e curvas num ECG.

A direção da deflexão do ECG depende da orientação da propagação relativamente ao eletrodo de deteção [23]. Convencionalmente, quando um impulso elétrico se propaga em direção ao eletrodo, gera uma deflexão para cima ("positiva") em relação à linha de base isoeletrica. Por outro lado, quando o impulso é propagado a partir de um eletrodo, produz uma deflexão para baixo ("negativa") em relação à linha de base. Se a onda de despolarização estiver em ângulo reto com a derivação, é detetada uma deflexão bifásica [20] (Figura 10). O sinal apresentado no ECG é constituído por uma sequência de ondas com morfologia e intantes particulares que transmitem informação [24]. Estas características são utilizadas no diagnóstico de doenças que provocam perturbações na atividade elétrica do coração.

Para se realizar uma interpretação correta do ECG, é importante compreender a vasta gama dos padrões de tempo nos ECG de utentes saudáveis (a ocorrência de batimentos cardíacos sucessivos) e os efeitos das doenças não cardíacas no traçado [20]. A utilização de múltiplas derivações no ECG é essencial para a análise tri-dimensional da atividade elétrica do coração. As 6 derivações peitorais (V1 a V6) detetam voltagens cardíacas transmitidas para o plano horizontal do corpo. A informação detetada nas restantes 6 derivações dos membros (I, II, III, α VR, α VL, α VF) está relacionada com as voltagens elétricas transmitidas para o plano frontal do corpo. A informação destas 12 derivações é combinada para formar um ECG padrão. (Figura 12) [23].




Figura 11. ECG com 12 derivações: Seis derivações peitorais (V1 a V6) e seis derivações dos membros (I, II, III, α VR, α VL, α VF).

Existem várias formas de realizar um ECG. Se for necessário avaliar a atividade elétrica do paciente durante um longo período de tempo, é possível colocar um conjunto de eletrodos no peito do paciente, conectados a um equipamento portátil (com bateria recarregável) durante 24, 48 ou 72 horas [24]. Este teste é conhecido como Holter e o seu objetivo é fazer um estudo contínuo da atividade elétrica do coração e relacioná-la com as atividades realizadas pelo paciente ao longo do dia. No entanto, o sinal bio-elétrico produzido pelo coração apresenta uma intensidade baixa na superfície da pele e nos eletrodos. Posto isto, é necessário filtrar o sinal adquirido (através de filtros passa-alto e passa-baixo) para remover o ruído e depois amplificá-lo de forma que seja possível a sua correta interpretação e análise.

2.2. Detecção e classificação de atividades humanas usando sensores fisiológicos

Atividades humanas

Podemos considerar “atividades humanas” como um conjunto de ações executadas por um indivíduo durante um determinado espaço de tempo (andar, correr, cozinhar, conduzir) [17]. Estas ações são constituídas por uma sequência de eventos e estes eventos são definidos por sequências de dados obtidos através de leituras consecutivas de sensores, num determinado período de tempo. Cada evento, e , possui a forma $e = (t, s, m)$ onde t representa o tempo, s o sensor e m a mensagem do sensor. Assim, um conjunto de atividades pode ser definido como $A = (a_1, a_2, \dots, a_n)$, onde $a_n = (e_1, e_2, \dots, e_k)$ representa a n -ésima atividade e ek o k -ésimo evento [21].

Para além disso, as atividades humanas também podem ser definidas pelo seu nível de

complexidade, como sendo simples ou complexas ([25],[24], [26], [27]). As atividades que podem ser detetadas apenas com a análise dos dados obtidos por um ou mais sensores num curto espaço de tempo são consideradas atividades simples ou de baixo nível (andar, correr ou saltar). Por outro lado, um conjunto de atividades de baixo nível que podem ser detetadas por um longo período de tempo são consideradas atividades complexas ou de alto nível (trabalhar, fazer compras, arrumar a casa).

Aquisição de dados

O processo de reconhecimento de atividade humana é um sistema de reconhecimento de padrões de uso geral inclui um conjunto de etapas desde a recolha de dados até à classificação das atividades. Este processo envolve um conjunto de transformações dos dados brutos extraídos dos sensores para gerar modelos eficientes de classificação. Durante a aquisição dos dados, com o objetivo de serem representativos e obter bons modelos de classificação, devem ser considerados elementos como o tipo, tempo, frequência, posição e orientação do sensor no corpo do utilizador [28].

Lockhart e Weiss [29] propõem três tipos de recolha de dados com base na natureza de recolha dos mesmos:

Natural: utilizadores realizam as suas atividades diárias normalmente e sem intervenção do investigador

Semi-natural: utilizares realizam as suas atividades diárias normalmente, no entanto são incentivados a realizar as atividades propostas no estudo em curso pelo menos uma vez.

Laboratório: utilizadores realizam atividades sistematicamente com instruções definidas e em ambiente controlado.

Segmentação de dados

A segmentação dos dados tem como objetivo separá-los em subgrupos que partilhem as mesmas características. No que toca aos acelerómetros (sensor inercial), os subgrupos são representados por segmentos de sinal num determinado intervalo de tempo. Assim sendo, cada segmento contém características suficientes que permitam o reconhecimento de atividade num determinado momento, ou seja, a análise de dados tem de ser feita exatamente durante um intervalo de tempo de execução de cada atividade [28]. Existem vários métodos de segmentação e a seleção do método mais adequado é crucial, uma vez que este tem um impacto imediato nas features extraídas utilizadas para a classificação das atividades e na exatidão dessa classificação. Portanto, sempre que as features extraídas forem indiferenciáveis, até mesmo o melhor classificador terá um fraco desempenho [30]. Duas das técnicas de segmentação mais utilizadas no reconhecimento de atividade humana são a *Fixed-size Non-overlapping Sliding Window (FNSW)* e a *Fixed-size*

Overlapping Sliding Window (FOSW) [31].

A FNSW é uma técnica simples de segmentação sem sobreposição de dados (Figura 12 a). O ponto final da janela de segmentação N é o ponto de partida para a janela N + 1. Portanto, é possível calcular a quantidade de janelas geradas para um determinado tamanho de conjunto de dados com a seguinte equação:

$$Segmentation_{Windows} = \frac{S}{L_i}$$

Onde S é o número total de amostras de sinal e $L_i = R_{sampling} * WindowSize$, onde $R_{sampling}$ é a taxa de reamostragem de dados utilizada e $WindowSize$ é o tamanho da janela utilizado. Este método apresenta uma desvantagem, pois os dados associados a uma determinada característica (por exemplo, queda) podem ser divididos entre janelas [32].

A FOSW tem como base o método anterior, mas com sobreposição dos dados (Figura 12 b). Aqui os dados sobrepõem da janela N para a N + 1, dependendo da percentagem de sobreposição (chamado deslocamento de janela). Uma sobreposição de 100% corresponde a uma janela estática, sem deslocamento. Neste caso os dados são sempre segmentados no mesmo ponto e para que isto não aconteça, a deslocação tem de ser feita com pelo menos um ponto de dados por segmentação. O número de janelas de segmentação geradas pode ser calculado utilizando a seguinte equação:

$$Segmentation_{Windows} = \frac{S}{L_i - L_i * \frac{P_j}{100}}$$

Onde P_j representa a percentagem de sobreposição utilizada (32).

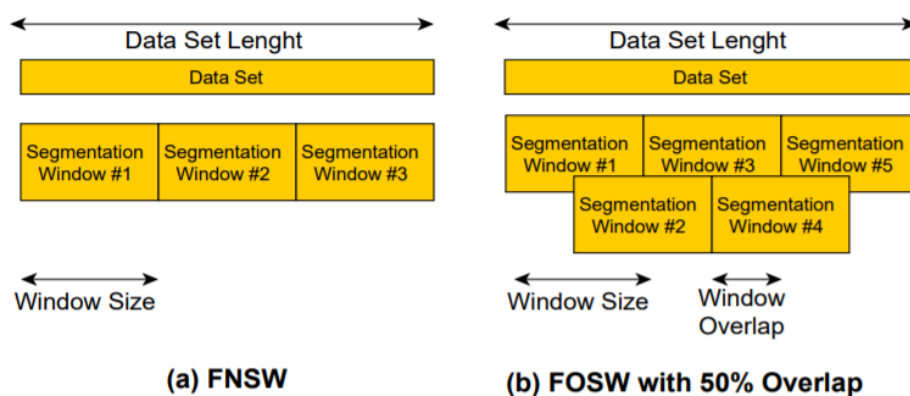


Figura 12. Diferença de segmentação sem sobreposição(a) e com sobreposição (b).

Extração de características

Ao processo de transformação dos dados segmentados damos o nome de extração de features. Este processo é muito importante pois os dados brutos gerados pelo sinal, não são adequados para serem utilizados por algoritmos de aprendizagem automática [33], [34]. Uma feature pode ser definida como um elemento que fornece informação útil acerca dos dados que representa. No estudo do reconhecimento de atividades humanas, as features representam os diferentes padrões de movimento das atividades dos utilizadores. As features são classificadas em diferentes domínios de representação e cada domínio tem um conjunto de fórmulas específicas que extraem informação útil e diferenciada dos sinais de sensores inerciais. Os domínios de features utilizados no reconhecimento de atividade humana são a frequência e o tempo [35].

Modelos de classificação

Os métodos clássicos de classificação de atividades têm as suas vantagens, mas também têm as suas limitações a nível de portabilidade, capacidade de processamento e interpretação de dados, velocidade com que os mesmos são analisados, etc., o que tornou necessário o desenvolvimento de novos métodos computacionais e automatizados. É neste contexto que entra a deteção de atividade automática, possível através do uso de vários algoritmos de reconhecimento de padrões, que combinada com o uso de sensores calibrados para detetar atividades físicas, permite usar os parâmetros de várias técnicas já referidas como ritmo cardíaco [36], *Galvanic Skin Response* (GSR) [37], *Heart Rate Variability* (HRV) [38], ECG [39], entre outros e agrupar por *clusters* (grupos) os diferentes tipos e atividades.

As aplicações possíveis para o desenvolvimento de uma tecnologia que melhor permita identificar as atividades físicas, personalizadas a cada indivíduo são inúmeras e de importância primária, pois propicia a pesquisa um passo mais próximo de um dos objetivos últimos nesta área, o estudo e desenvolvimento de sistemas e dispositivos que podem reconhecer, interpretar, processar e estimular atividades humanas [40] – tornando possível uma ligação mais orgânica entre homem e máquina [41], [42].

A pesquisa sobre monitorização automática de atividades humanas tem aumentado exponencialmente nos últimos anos e percebe-se porquê, pois pensa-se que num futuro próximo, irá possibilitar que cada indivíduo consiga compreender as suas próprias rotinas, o que faz, e o que deveria fazer para melhorar a sua qualidade de vida. Ultimamente esta compreensão de quão importantes são as atividades humanas para nós como um ser humano na sua individualidade, irá dar azo à criação de novas tecnologias integradas com os dispositivos do nosso dia, especialmente os *wearable* com uma variedade de aplicações potenciais deveras excitantes.

Existem muitos métodos de classificação, mas os mais usados para a deteção automática de

actividades, parecem ser os classificadores de Naïve Bayes [43]–[45], árvores de decisão (*decision trees*) [44], [46], [47], redes neuronais artificiais [48]–[50], máquinas de vetores de suporte (*support vector machines*) [43], [50], [51], *random forest* [25], [26], [52], *bagging (bootstrap aggregating)* [27], [53], [54] e qualquer combinação entre os demais. No fim, os métodos e/ou combinações de métodos escolhidos [55]–[58] serão sempre decisão dos analistas de dados e equipas de trabalho, tendo em conta o equipamento disponível (sensores, etc.), programas especializados de análise de dados, capacidade computacional e tema em concreto do estudo.

Medidas de avaliação

Cross validation e Leave One Out

Em qualquer estudo em que temos uma quantidade elevada de dados a analisar, geralmente recorremos ao uso de métodos de aprendizagem automática, havendo assim a necessidade de validar a estabilidade do nosso modelo de aprendizagem. Um erro muito comum ocorre por exemplo quando o nosso modelo está muito bem treinado para os nossos dados, mas apenas para os mesmos (*overfitting*) [59], [60]. É necessário, portanto que o nosso modelo consiga reconhecer corretamente a maior parte dos padrões que se encontram numa matriz de dados, não ficando totalmente dependente dos mesmos dados (ganhando capacidade de generalização) e que ao mesmo tempo seja capaz de filtrar o que é ruído dos dados de interesse.

É aqui que entra o conceito de validação [61], como a capacidade que um modelo matemático/informático tem para decidir se os resultados numéricos obtidos que quantificam a relação teórica entre variáveis é aceitável e descrevem os dados realisticamente. Num modelo de aprendizagem automática um parâmetro, designado de estimação de erro, é fornecido após o treino de um modelo consoante os dados no *input*. Neste processo, obtemos deste modo uma estimativa numérica entre os valores de resposta preditivos contra os atuais, dando-nos uma ideia do quão bem o nosso modelo se comporta com os nossos dados. No entanto, esta técnica de avaliação de dados (validação), tem uma falha: não nos dá indicação do desempenho que o nosso modelo teria com um conjunto de dados completamente novo (após treino do modelo nos dados iniciais), podendo mesmo ser vítima do já referido *overfitting* ou mesmo *underfitting*, quando nem consegue representar corretamente os dados iniciais.

É com esta noção de que é preciso um modelo que consiga generalizar bem para um qualquer conjunto de dados novos, que surge o conceito de *cross validation* [62], [63], como método para contornar o problema referido, através da colocação de parte dos dados para treino e usá-los para a criação do modelo e o restante para validação.

Para colmatar esta limitação dos métodos convencionais de validação, temos um possível solução na forma do método mais extremo de *cross validation* designado de *Leave-One-Out (LOO)* [64]–[66], em que o modelo usa todos os dados disponíveis, deixando um de fora para validação e

iterativamente faz o mesmo com os dados de treino até não haver mais combinações possíveis. Computacionalmente é de longe o método de validação mais exigente, mas o melhor especialmente para os casos em que temos amostras pequenas, como é geralmente o caso para amostras biológicas ou testes com seres humanos.

Smartphones e deteção de atividade humana

O estudo e deteção de atividade humana através do uso de medidas referidas anteriormente, tem sido uma preocupação cada vez maior tanto por parte de investigadores, de prestadores de cuidados médicos e da sociedade em geral. No entanto, as metodologias usadas são, para a maior parte, baseadas em sensores considerados tradicionais e que ainda não são muito portáteis.

Felizmente e com o advento das novas tecnologias de comunicação móveis, nomeadamente as novas gerações de *smartphones*, dotados dos mais variados tipos de sensores (biométricos, de visão, acelerómetros, temperatura, etc.) [67]–[70], tornou-se possível usar os mesmos dispositivos como um meio portátil e acessível à maioria dos indivíduos em países ditos desenvolvidos e em desenvolvimento, que permitiria o estudo de atividade em várias situações como por exemplo, durante o trabalho [71], usando sensores de um modo automático [72] e usando métodos de aprendizagem automática [73]. O uso de telemóveis cada vez mais avançados para o estudo de atividade humana não deixa de existir sem uma ponta de ironia, tendo em conta que a mesma tecnologia contida nos *smartphones* é julgada cada vez mais na nossa sociedade como um problema que afeta uma grande parte da população, isolando-nos cada vez mais do que nos faz humanos, sendo considerado uma fonte de stress e ansiedade [74], de vício e diminuição de produtividade [75], perturbações do sono [76] e inclusive depressão [77] em estudantes universitários [78].

Bases de dados

O estudo da deteção e monitorização de atividade humana é altamente dependente da recolha de dados. Em cada estudo são dados recolhidos em tempo real através de tecnologias portáteis e *wireless*. Estes dados podem ser biológicos, comportamentais ou ambientais e ajudam a perceber e a desenvolver a etiologia da saúde e da doença, particularmente quando integrados com dados provenientes de áreas como a genética, biomarcadores e registos médicos eletrónicos. Para além disso, estes dados também são importantes para compreender as origens de desenvolvimento de doenças em adultos e informar acerca do desempenho de tratamentos e programas de prevenção que sejam personalizados, adaptáveis e sustentáveis para os seus utilizadores [79]. No entanto, todos estes dados recolhidos necessitam de ser armazenados e organizados. Uma base de dados é uma coleção de informação (dados) que está organizada e armazenada eletronicamente num sistema informático. Uma base de dados geralmente é controlada por um sistema de gestão de bases de

dados. Estes dois, juntamente com as aplicações que lhes estão associadas, são referidos como um sistema de base de dados, muitas vezes abreviado para apenas base de dados. Os dados dentro dos tipos mais comuns de bases de dados atualmente em funcionamento são tipicamente modelados em linhas e colunas numa série de tabelas para tornar eficiente o processamento e consulta de dados. Isto permite que os dados sejam facilmente acedidos, geridos, modificados, atualizados, controlados e organizados [80]. Na tabela seguinte, estão representadas algumas bases de dados usadas em diversos estudos avaliando várias atividades e usando sensores inerciais e ECG em vários sujeitos.

Tabela 1. Bases de dados usadas em diversos estudos.

Base de dados	Sensores	Sujeitos	Atividades	Referências
AHA	ECG	155	Arritmia ventricular	[81]
MIT-BIH	ECG	48	Arritmia ventricular	[82]
PTDB	ECG	290	Dormir	[83]
CYBHI	ECG	128	Arritmia ventricular	[84]
UofTDB	ECG	1012	Descansar, estímulos visuais e auditivos	[85]
OPPORTUNITY	A, G, M	12	Beber, limpar, abrir e fechar objetos	[86]
Extra Sensory	A, G, M	60	Correr, andar, falar, comer, ver TV	[87]
UCI-HAR Smartphone	A, G	30	Andar, subir, descer, sentar	[88]
PAMAP2	A, G, M	9	andar de bicicleta, saltar aspirar, andar, correr, sentar, descansar	[89]
USC-HAD	A, G	14	Saltar, andar, correr, dormir, subir e descer	[90]
WISDM e Actitracker	A	29	Jogging, andar, subir, descer	[10]
MHealth	A, G, M, ECG	10	Parado, sentado, deitado, caminhar, Subir escadas, abdominais, elevação frontal de braços, agachamentos, ciclismo, correr, jogging, saltar	[91]
Shoaib	A, G, M	10	Andar, correr, subir, descer, sentar, bicicleta	[92]
UniMib Shar	A	30	Sair e entrar do carro, sentar, levantar, dobrar, falar	[93]

A – ACELEROMETRO , G – GIROSCOPIO, M – MAGNETOMETRO , ECG – ELETROCARDIOGRAMA

Capítulo 3: Implementação de algoritmos de detecção de atividade

3.1. Quantificação de passos – peak detection

O objetivo desta secção é implementar um algoritmo de detecção da atividade física, quantificando o número de passos usando um acelerómetro de um smartphone.

Aquisição de sinal

O dispositivo usado neste projeto para obter os dados necessários foi um smartphone da marca Samsung, o qual usando o seu acelerómetro embutido permitiu registar a aceleração da mão do utilizador nas 3 diferentes direções ao longo do tempo. Na Figura 14, estão registados os primeiros 300 valores de aceleração em cada uma das direções.




Figura 13. Aceleração registrada nos 3 eixos

O movimento que os membros superiores fazem ao longo da passada, pode ser aproximado a uma onda sinusoidal, tal como se vê nos dados a laranja da Figura 14, aceleração no eixo dos y, que representa o movimento para a frente e para trás do braço.

Pré-processamento

Norma do vetor de aceleração

Tendo em conta a Figura 14 anterior, que representa as 3 direções de aceleração foi necessário transformar os 3 sinais diferentes em apenas um, de modo, a ser posteriormente processado pelo algoritmo. Para isto, calculou-se a norma do vetor de aceleração usando a seguinte

fórmula, resultando no sinal da Figura 15.

$$a = \sqrt{(a_x)^2 + (a_y)^2 + (a_z)^2}$$

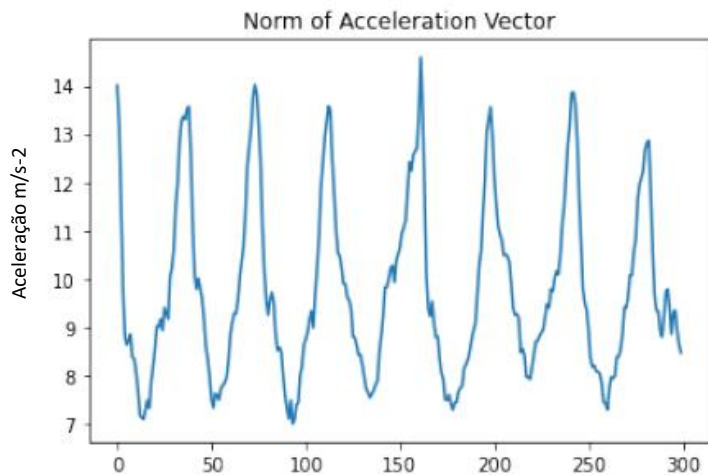


Figura 14. Norma do vetor de aceleração.

Filtragem

Na Figura 15, é possível observar que o sinal ainda apresenta algum ruído, pelo que se aplicou um filtro de média deslizante. De modo a se obter o tamanho da janela que melhor redução de ruído produz, porém sem uma grande mudança de forma do sinal, foram aplicadas janelas de 5, 7 e 11 amostras, gerando os sinais do gráfico da Figura 16. Da análise deste gráfico, o valor que apresenta melhores resultados é o de 5 pontos, apresentando uma grande redução de ruído, no entanto, mantendo a forma do sinal, com as transições rápidas como se pode ver na zona do ponto 40.

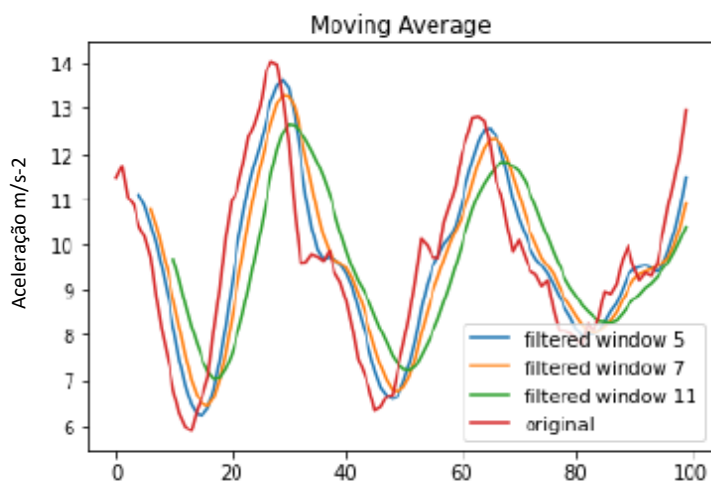


Figura 15. Filtro de média deslizante.

Resultado final do pré-processamento

Resultado do cálculo da norma do vetor e posterior aplicação do filtro de média deslizante, está ilustrado na Figura 17.

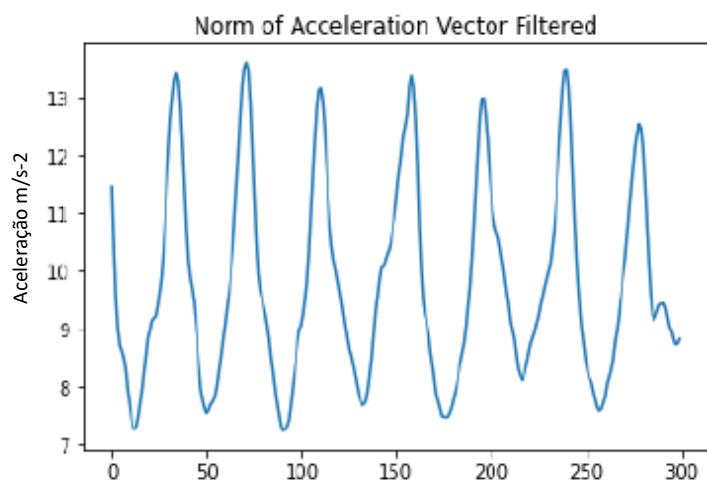


Figura 16. Norma do vetor de aceleração com filtro de média deslizante com janela de tamanho 5.

Algoritmo de peak detection

Sabendo que o sinal a analisar, tem um comportamento sinusoidal, ou seja, apresenta máximos e mínimos consecutivos, implementou-se um algoritmo de detecção de picos e vales, pois cada conjunto de pico e vale corresponde a 1 passo. O algoritmo implementado é constituído por 4 funções principais como representado no fluxograma da Figura 17.

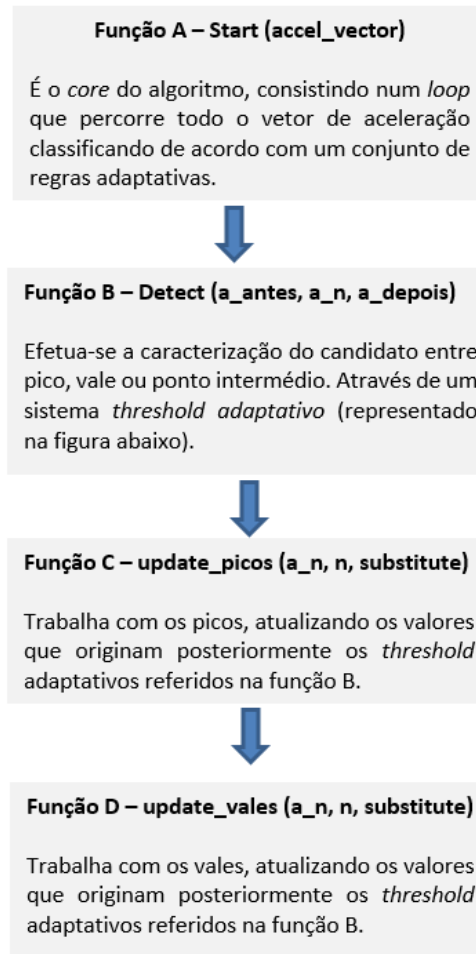


Figura 17. Algoritmo de deteção de pico.

$$\text{Classificação} = \begin{cases} \text{Pico} & |a_n| > \max(|a_{n-1}|, |a_{n+1}|, \mu_a + \frac{\sigma_a}{\alpha}) \\ \text{Vale} & |a_n| < \min(|a_{n-1}|, |a_{n+1}|, \mu_a - \frac{\sigma_a}{\alpha}) \\ \text{Intermédio} & \text{Caso contrário} \end{cases}$$

Figura 18. *Threshold adaptativo*. μ_a – média dos últimos k pontos; σ_a – desvio padrão dos últimos k pontos, α – constante de magnitude.

3.2. Deteção automática de atividade usando sinal de acelerómetro

A deteção e classificação automática de atividade é fundamentado num sistema de reconhecimento de padrões, normalmente dividido em três fases: aquisição de sinal, extração de características e classificação da atividade como representado na Figura 19. Neste estudo, é usada uma abordagem supervisionada, pois são usados dados adquiridos durante atividades previamente

definidas. De seguida são extraídas algumas características, de modo a se perceber quais as características mais distintas de atividade para atividade de modo a tornar a classificação mais eficiente. Posteriormente, usou-se diferentes métodos de classificação, também para se perceber qual o método mais eficiente na deteção das atividades em estudo. Por último foi aplicado uma validação cruzada como método de avaliação da classificação usada.

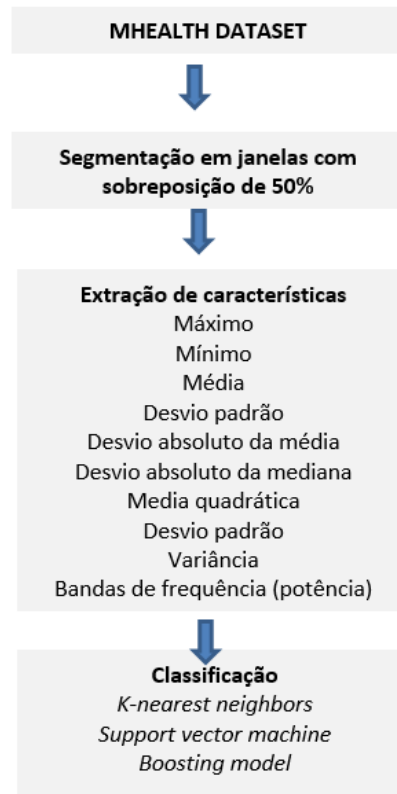


Figura 19. Etapas do sistema proposto, Segmentação, Extração de features e Classificação.

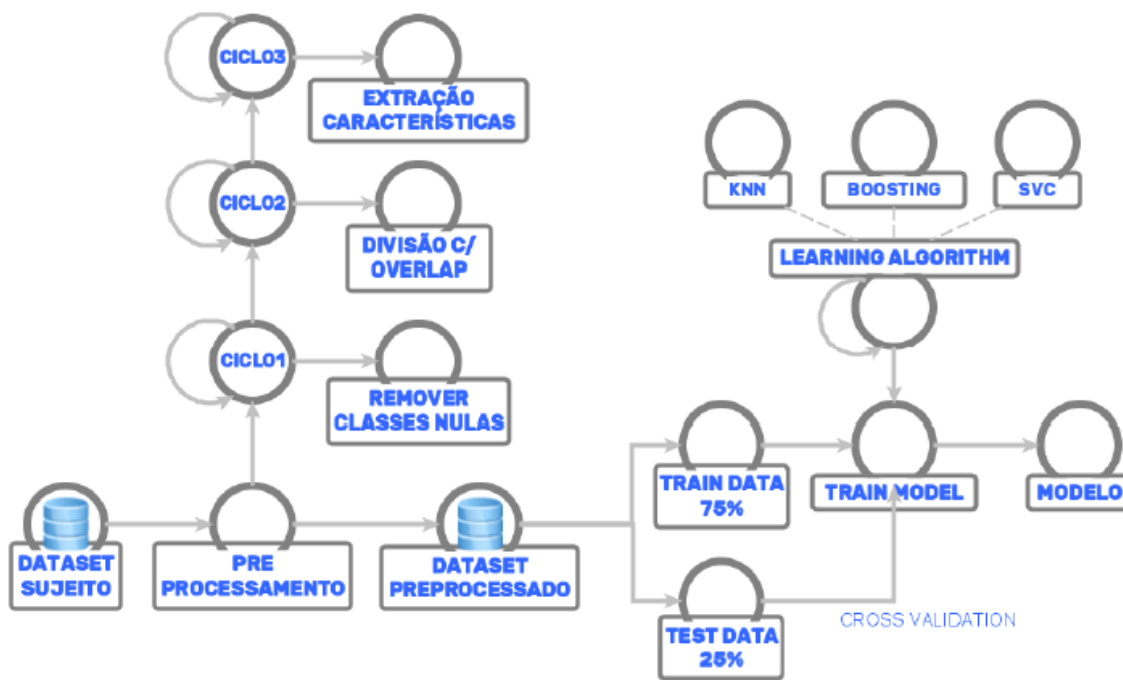


Figura 20. Arquitetura geral do algoritmo de classificação de atividade humana usando o sinal de acelerômetro.

Aquisição de sinal

Neste estudo, não foi necessário adquirir os dados para o estudo, foi usada uma base de dados estudada a MHEALTH DATASET, que contem os dados recolhidos de um acelerômetro nos 3 eixos (XYZ), a uma frequência de amostragem de 50Hz.

Esta base de dados contem um total de 10 sujeitos cada um com 13 atividades diferentes. Neste estudo apenas foram utilizadas 3 atividades. Onde os sujeitos estavam durante 1 minuto em repouso, a andar e a correr.

Segmentação de sinal



Figura 21. Arquitetura da fase de pré-processamento do dataset em estudo.

Para o estudo do sinal realizou-se as seguintes extrações de características:

Adquiriu-se uma matriz através do sinal do acelerómetro, apresentando 3 vetores, correspondendo a um eixo (XYZ).

$$A_{m,n} = \begin{bmatrix} a_{x,1} & a_{y,1} & a_{z,1} \\ a_{x,2} & a_{y,2} & a_{z,2} \\ \vdots & \vdots & \vdots \\ a_{x,n} & a_{y,n} & a_{z,n} \end{bmatrix}$$

Figura 24. Matriz de amostras obtida através de acelerómetro.

Onde $a_{x,t}$, $a_{y,t}$, $a_{z,t}$ são respetivamente a aceleração no tempo dos três eixos do acelerómetro e $(t=1,2,\dots,n)$ ao número de amostras. Foi feita a extração de características em diferentes domínios, nomeadamente no domínio de tempo ou estatístico, e no domínio de frequência.

Características no domínio de tempo ou estatístico:

Foram utilizadas funções das bibliotecas `numpy` e `scipy` para calcular as seguintes características segundo a abordagem proposta [94].

- Média

O cálculo da média de cada componente é calculado da seguinte fórmula usando a biblioteca `numpy`: `mean`

- Mediana:

O cálculo da mediana de cada componente é calculado da seguinte fórmula usando a biblioteca `numpy`: `median`

- Desvio absoluto da média:

O cálculo do desvio absoluto da média de cada componente é calculado da seguinte fórmula:

$$\frac{\sum_{i=1}^N |s_i^2 - \text{mean}(s)|}{N}$$

- Desvio absoluto da mediana:

O cálculo do desvio absoluto da mediana de cada componente é calculado da seguinte fórmula:

$$\text{median}(|s - \text{median}(s)|)$$

- Raiz quadrada média:

O cálculo da raiz quadrada média de cada componente é calculado da seguinte fórmula:

$$\sqrt{\frac{1}{N} \sum_{i=1}^N s_i^2}$$

- Desvio Padrão:

O cálculo do desvio padrão de cada componente é calculado da seguinte fórmula:

$$\sqrt{\text{var}}$$

- Variância:

O cálculo do desvio padrão de cada componente é calculado da seguinte fórmula:

$$\text{mean}(|s - \text{mean}(s)|)^2$$

Características no domínio da frequência:

- Transformada Rápida de Fourier:

O cálculo da transformada rápida de Fourier (FFT), refere-se a um modo da transformada discreta de Fourier (DFT), sendo calculada usando simetrias nos termos do cálculo. A transformação é mais eficiente quando o 'N' é elevado a 2.

$$X_k = \sum_{n=0}^{N-1} x_n e^{-j \frac{2\pi}{N} kn}$$

- Densidade espectral de potência:

O espectro do sinal de acelerómetro decompõe o conteúdo do processo em frequências diferentes, sendo possível identificar periodicidades. A análise neste estudo focou-se em bandas de frequência de 0,2Hz, que estão representadas na fórmula seguinte como f_i . Sendo a potência em cada banda calculada por:

$$P(f_i) = \sum_{k \in f_i} |X_k|^2$$

Classificação

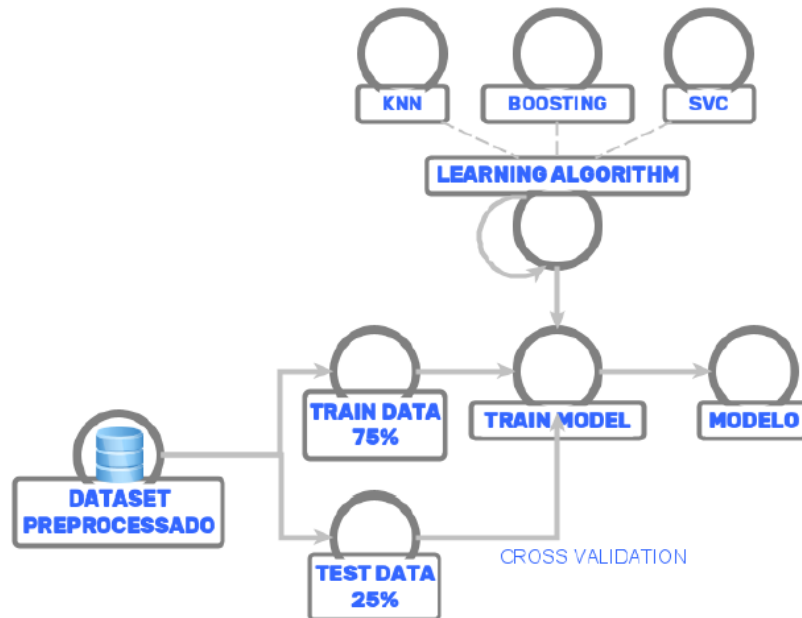


Figura 25. Arquitetura da fase de treino do dataset em estudo, classificação e avaliação.

Na classificação foi usado o método da aprendizagem automática supervisionada [3], [4]. Com o objetivo de se compreender como criar métodos de modo a melhorar o desempenho das máquinas em diversas tarefas, através do conceito de “treino”. Neste estudo, foi realizada a classificação supervisionada e usados três classificadores, nomeadamente, K-Nearest Neighbors (KNN) , Support Vector Machines (SVM) e Boosting Model [95].

Neste projeto usou-se a validação cruzada com K-Fold como método de avaliação de resultados. Onde os dados são divididos aleatoriamente em K conjuntos de igual tamanho, para se realizar uma aprendizagem de K iterações onde são usados k-1 conjuntos para treino e 1 para validação. O processo é repetido para as K amostras, e é avaliado com a média adquirida nos K testes realizados (Figura 27).




Figura 26. Representação esquemática do método de avaliação cruzada.

Como referido anteriormente as atividades consideradas neste estudo são:

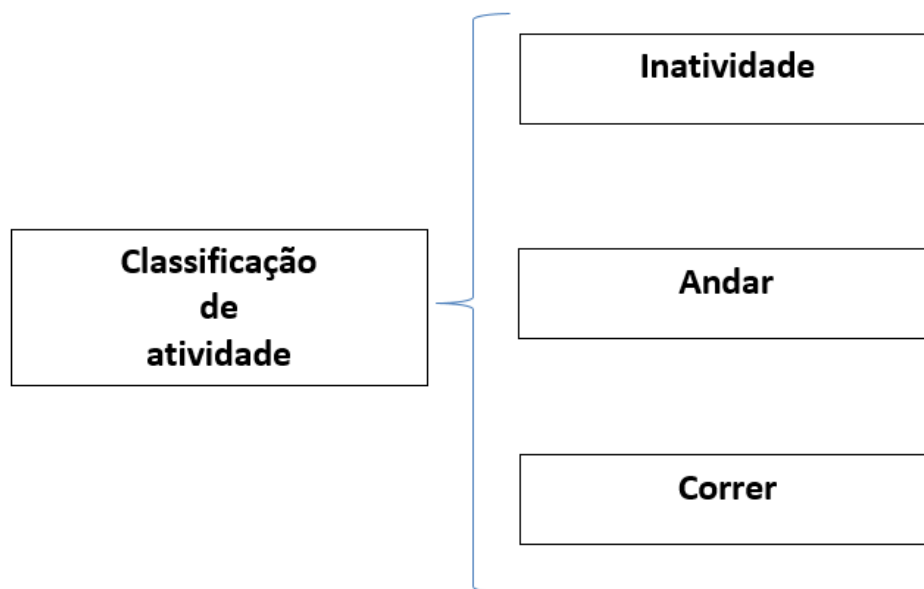


Figura 27. Classificação de atividades do estudo.

3.3. Deteção automática de atividade usando sinal de ECG

Este estudo segue a mesma abordagem que foi esquematizada no subcapítulo 3.2, mas em vez de ser utilizado um sinal proveniente do acelerómetro, é usado um sinal proveniente de um eletrocardiograma. A base de dados utilizada foi a mesma do ponto anterior (MHEALTH DATASET). Conta com alguns pontos que diferem a abordagem do ponto anterior, desde as bibliotecas usadas para processar o sinal, que neste caso foram o biospy e o neurokit. E em relação à base de dados ter uma frequência de amostragem de 50Hz foi necessário um redimensionamento do sinal para 100Hz para conseguir ser processado nas bibliotecas acima referidas.

Todo o processo de segmentação e de classificação seguiu a mesma metodologia esquematizada no ponto anterior.

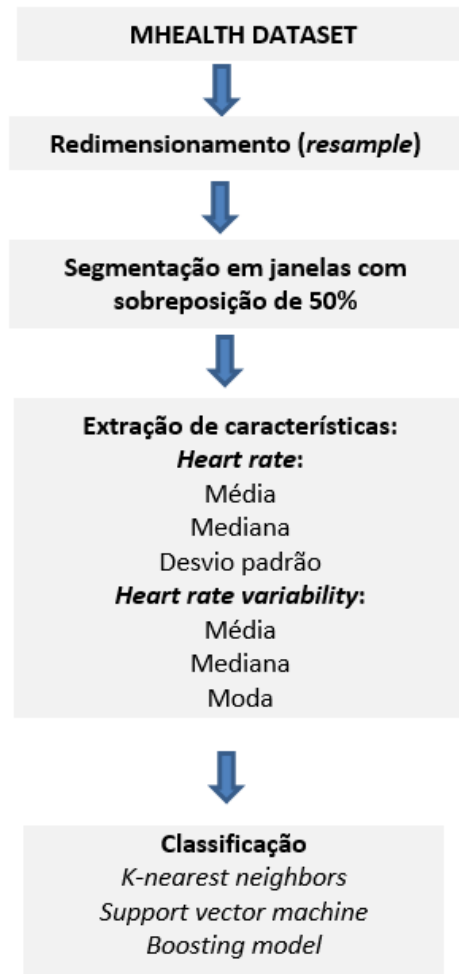


Figura 28. Processo de segmentação e classificação.

3.4. Detecção automática de atividade usando acelerómetro e ECG (fusão)

De seguida é apresentado o fluxograma completo relativo à deteção automática de atividade usando ambos os sinais, nomeadamente o sinal de acelerómetro e sinal cardíaco, combinando assim as características extraídas de ambos os sinais como representado no ponto 3.2 e 3.3.

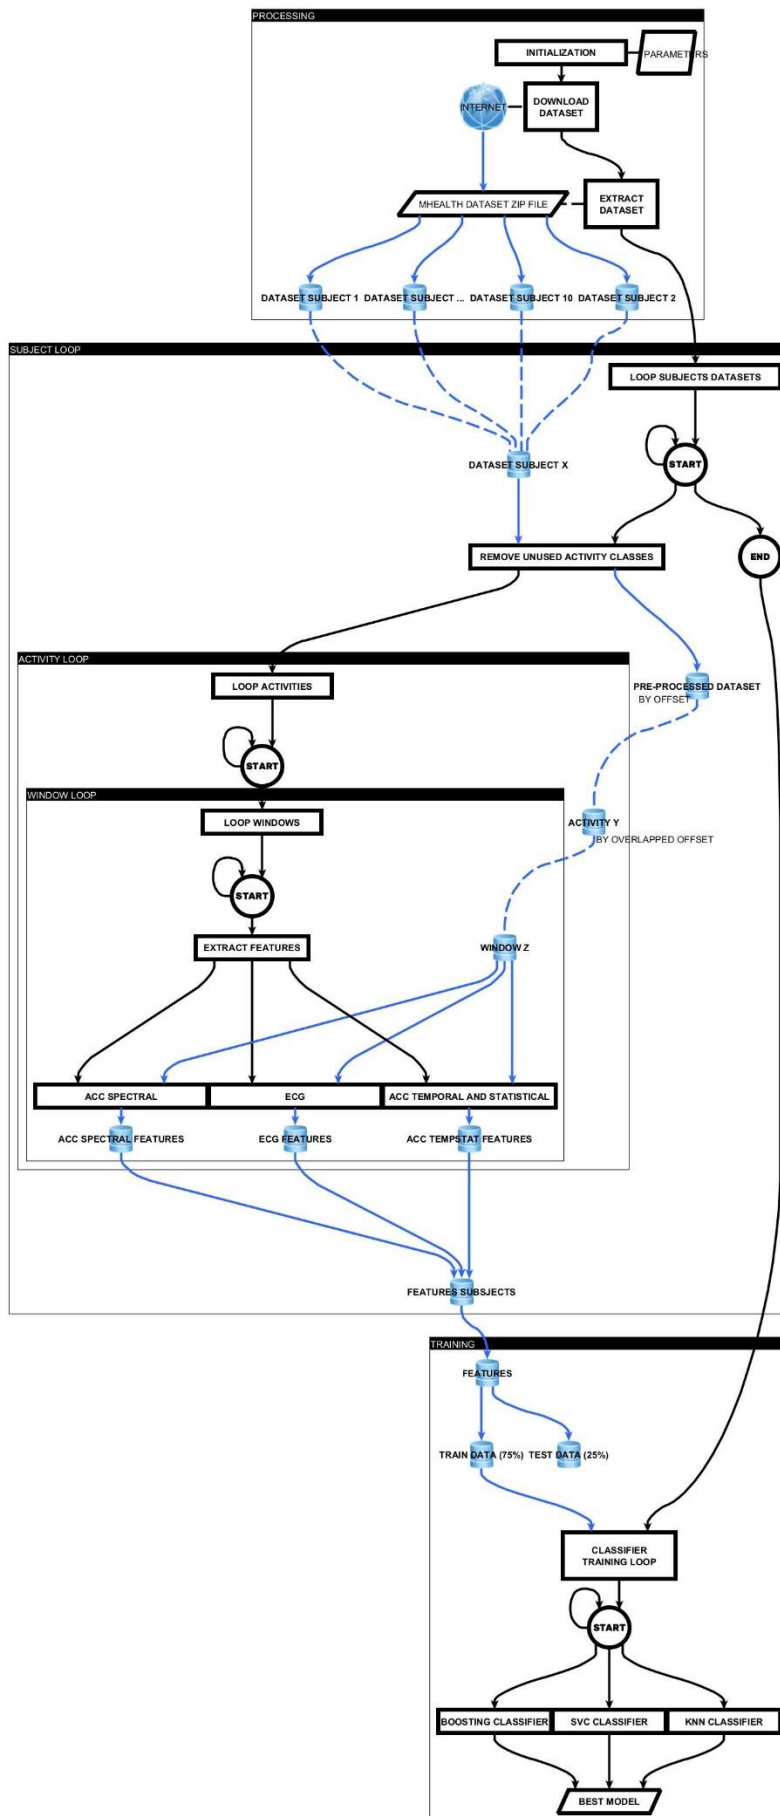


Figura 29. Fluxograma de detecção automática de atividade pelo método de fusão.

Capítulo 4: Resultados e Discussão

De seguida são apresentados os resultados e validação dos algoritmos de deteção de atividade para o estudo realizado.

4.1. Quantificação de passos – peak detection

Resultados MHEALTH DATASET

Um dos dataset usados neste algoritmo foi o MHEALTH DATASET, o qua possui um total de 10 dataset, cada um com 13 atividades. Para este teste, usou-se apenas a atividade 5 da base de dados. Tendo sido anotado num ficheiro json os vários picos e vales para posterior cálculo da precisão do algoritmo. Os resultados obtidos pelo algoritmo a este dataset estão ilustrados na Figura 31.

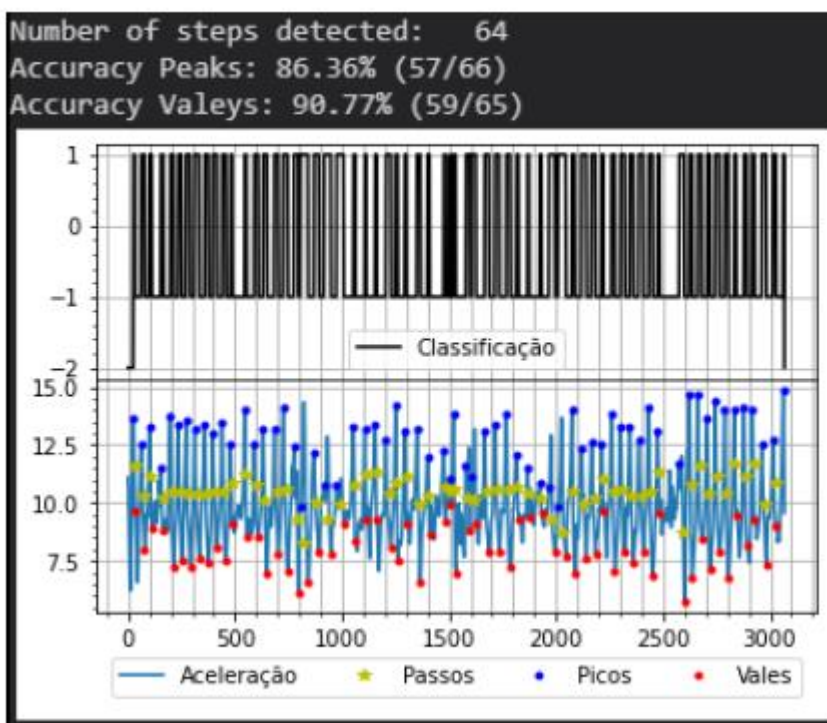


Figura 30. Resultados obtidos para a MHEALTH DATASET.

Com este dataset é possível observar o efeito dos falsos positivos, pois embora nos valores de exatidão de picos e vales tenhamos valores de 86% e 91%, respectivamente, o número de passos apresenta-se muito próximo do número de passos esperados 65. Isto deve-se a dois fatores: em primeiro, pelo facto de a anotação ser feita no ponto X e o algoritmo fazer a deteção alguns pontos à frente ou atrás, sendo que esta situação foi colmatada com a adição de um intervalo de 5 pontos em ambas as direções, em segundo, pela existência de falsos positivos, o que neste caso fazem o valor de passos ficar perto do valor anotado.

Resultados smartphone

Os próximos dados analisados provêm do acelerómetro embutido num smartphone da marca Samsung. Foram adquiridos em dois momentos diferentes e com dois protocolos diferentes:

a) A andar numa passadeira, começando a 1km/h e a cada 1:30 minutos incrementando 0,5 km/h até a um máximo de 4,0 km/h (Figura 32).

b) A andar por 2 minutos, seguidos de 1 minuto de pausa, novamente 1 minuto a andar por fim novamente 1 minuto em pausa, neste caso, existe uma anotação externa do número de passos (228 passos) (Figura 33).

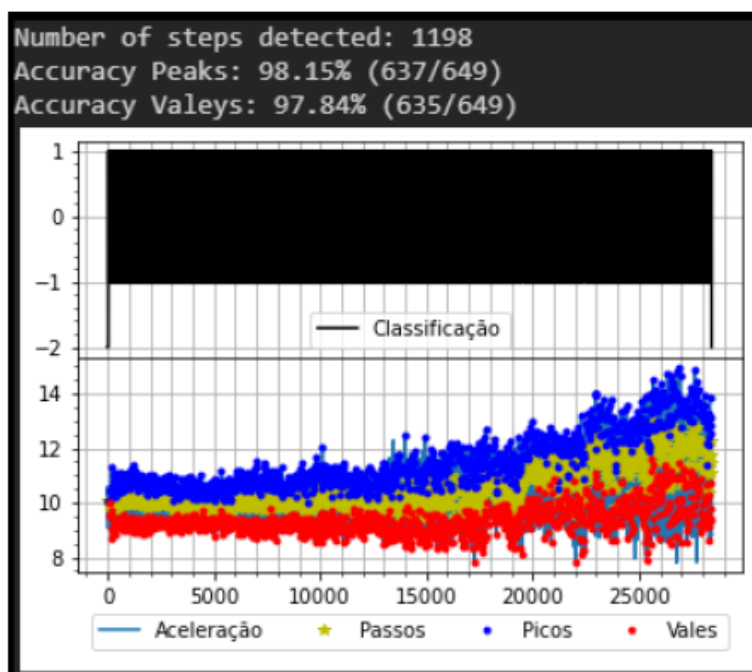


Figura 31. Resultados obtidos para os dados do smartphone segundo o protocolo (a).

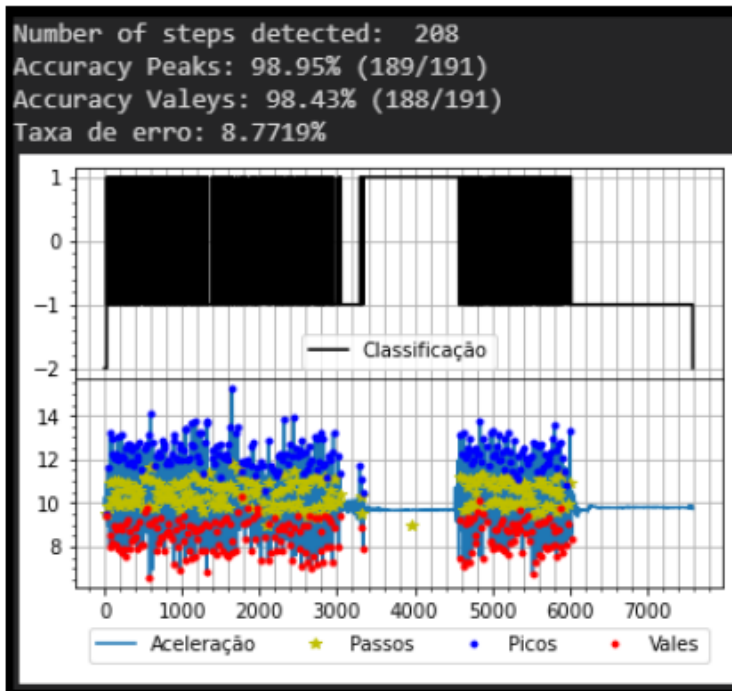


Figura 32. Resultados obtidos para os dados do smartphone segundo o protocolo (b).

Analisando os resultados obtidos pelo algoritmo, no caso do protocolo (a) visto na Figura 32 é possível observar uma elevada exatidão na classificação de picos e vales. O que também se observa na Figura 33 protocolo (b). Adicionalmente, neste último protocolo, como temos a informação do número real de passos, calculou-se o erro percentual sendo este de 8.7%.

Contudo e consultando a bibliografia sobre este assunto, pode se afirmar que a percentagem de erro apresentada neste dataset está dentro das percentagens de erro de outras soluções no mercado, entre 1,5% e 9,6%.

4.2. Detecção automática de atividade usando sinal de acelerómetro




Figura 33. Sinal Raw obtido de todo o dataset em estudo MHEALTH DATASET.




Figura 34. Módulo do sinal de todo o dataset em estudo MHEALTH DATASET.




Figura 35. Representação de sinal em 60 segundos em que o sujeito está em "Inatividade".




Figura 36. Representação de sinal em 60 segundos em que o sujeito está a "Andar".




Figura 37. Representação de sinal em 60 segundos em que o sujeito está a "Correr".

Nas figuras Figura 36, Figura 37 e Figura 38, está representado o sinal de acelerómetro nas três atividades estudadas, respetivamente quando o sujeito está parado a andar e a correr. Está representado graficamente um minuto de cada atividade nos três eixos do acelerómetro (XYZ), e consegue-se distinguir perfeitamente as três atividades, mas sendo muito perceptível a diferença quando o sujeito está em inatividade quando o sujeito está em movimento seja ele andar ou correr. Mas sendo também possível distinguir graficamente quando o sujeito está a andar e a correr.

Como referido anteriormente, foram extraídas características tanto no domínio de tempo como no domínio de frequência, de seguida representam-se dois estudos de características nomeadamente um em cada domínio. Foi feito um estudo de bandas de frequência e calculada a potencia de densidade espectral em cada banda e em cada uma das três atividades analisadas neste estudo. Foram estudadas bandas de 0,2 HZ no intervalo de frequência de 0 a 25 Hz. As figuras seguintes representam graficamente esse estudo.




Figura 39. Representação da Potência espectral em bandas de frequência de 0,2HZ quando o sujeito está em Inatividade.




Figura 38. Representação da Potência espectral em bandas de frequência de 0,2HZ quando o sujeito está a andar.




Figura 40. Representação da Potência espectral em bandas de frequência de 0,2Hz quando o sujeito está a correr.

Na Figura 40 à

Figura 40 está representado o estudo referido acima, consegue se ver uma distribuição muito diferente entre quando o sujeito está parado e o sujeito está em movimento, mas o mais importante e de salientar aqui é o valor de potencia espectral nas três atividades, verifica-se uma grande diferença de valores, sendo que quando o sujeito está parado temos valores mínimos na casa das milésimas, ao contrário das outras atividades onde temos valores de potencia bem superiores, quando o individuo está a andar um pouco superiores a 10 e quando o indivíduo está a correr chega a atingir quase valores na casa dos 250. Como temos uma diferença bem delineada em todas as atividades apresentadas é natural que esta característica, seja uma ótima para distinguir as atividades em estudo. Outro aspeto importante neste estudo, foi descobrir quais as bandas mais significativas para o estudo destas atividades, como se pode visualizar graficamente, quando o individuo está parado a potência mantém-se igual em todas as bandas, o mesmo não acontece quando o individuo está em movimento, pois é possível verificar que as bandas mais representativas se situem entre as frequências de 1,8 Hz e 2,4 Hz. Sendo então as bandas de frequência situadas entre estas frequências as fulcrais para distinguir as atividades em estudo.




Figura 41. Representação gráfica da precisão de cada característica usada no modelo de treino (Função do SKLEARN):

Como anteriormente referido foi feito um estudo das características mais representativas no domínio de tempo, que está representado na Figura 42. Foram extraídas características nos três eixos do sinal de acelerómetro e através de uma função baseada do *scikit learn* foi possível calcular a precisão das mesmas no modelo de treino. Como se pode ver temos características mais precisas que outras, sendo que as características do eixo do x são as fulcrais para distinguir as atividades pois dão as que apresentam melhor precisão, o que faz total sentido nas atividades propostas que refletem um deslocamento maior ou menor no plano horizontal, por outro lado o eixo do y é o menos representativo. O máximo, o mínimo, o desvio absoluto da média, o desvio padrão e a variância são as características com melhor precisão.

Tabela 2. Resultados da classificação no domínio de tempo.

Algoritmos	Precisão
KNN	0,79
SVM	0,88
BOOSTING MODEL	0,75

Na Tabela 2 acima representada temos os resultados da classificação nos três classificadores utilizados apenas usando características no domínio de tempo. Como se pode verificar o classificador mais preciso é o SVM que obteve uma classificação de 0,88 e o classificador com menor precisão foi o *boosting*. Os valores de classificação são aceitáveis para todos os classificadores em estudo, segundo a bibliografia existente.

Tabela 3. Resultados da classificação no domínio da frequência.

Algoritmos	Precisão
KNN	0,92
SVM	0,90
BOOSTING MODEL	0,82

Na Tabela 3 estão representados os resultados de precisão dos classificadores usando as características no domínio da frequência, neste caso temos 2 classificadores com classificação acima dos 90% nomeadamente o KNN e o SVM. Comparando a classificação em ambos os domínios (frequência e tempo), observa-se claramente que temos uma precisão mais alta no domínio de frequência.

Tabela 4. Resultados da classificação no domínio de tempo + domínio de frequência.

Algoritmos	Precisão
KNN	0,91
SVM	0,89
BOOSTING MODEL	0,80

Na Tabela 4 está representado os resultados da classificação quando o modelo foi treinado com as características de ambos os domínios, é possível ver que os classificadores que se voltam a destacar são novamente o KNN e o SVM. O modelo perde um pouco a precisão quando comparado com o modelo só no domínio de frequência, mas é normal pois os modelos no domínio de tempo têm uma precisão mais baixa.

4.3. Detecção automática de atividade usando sinal de ECG

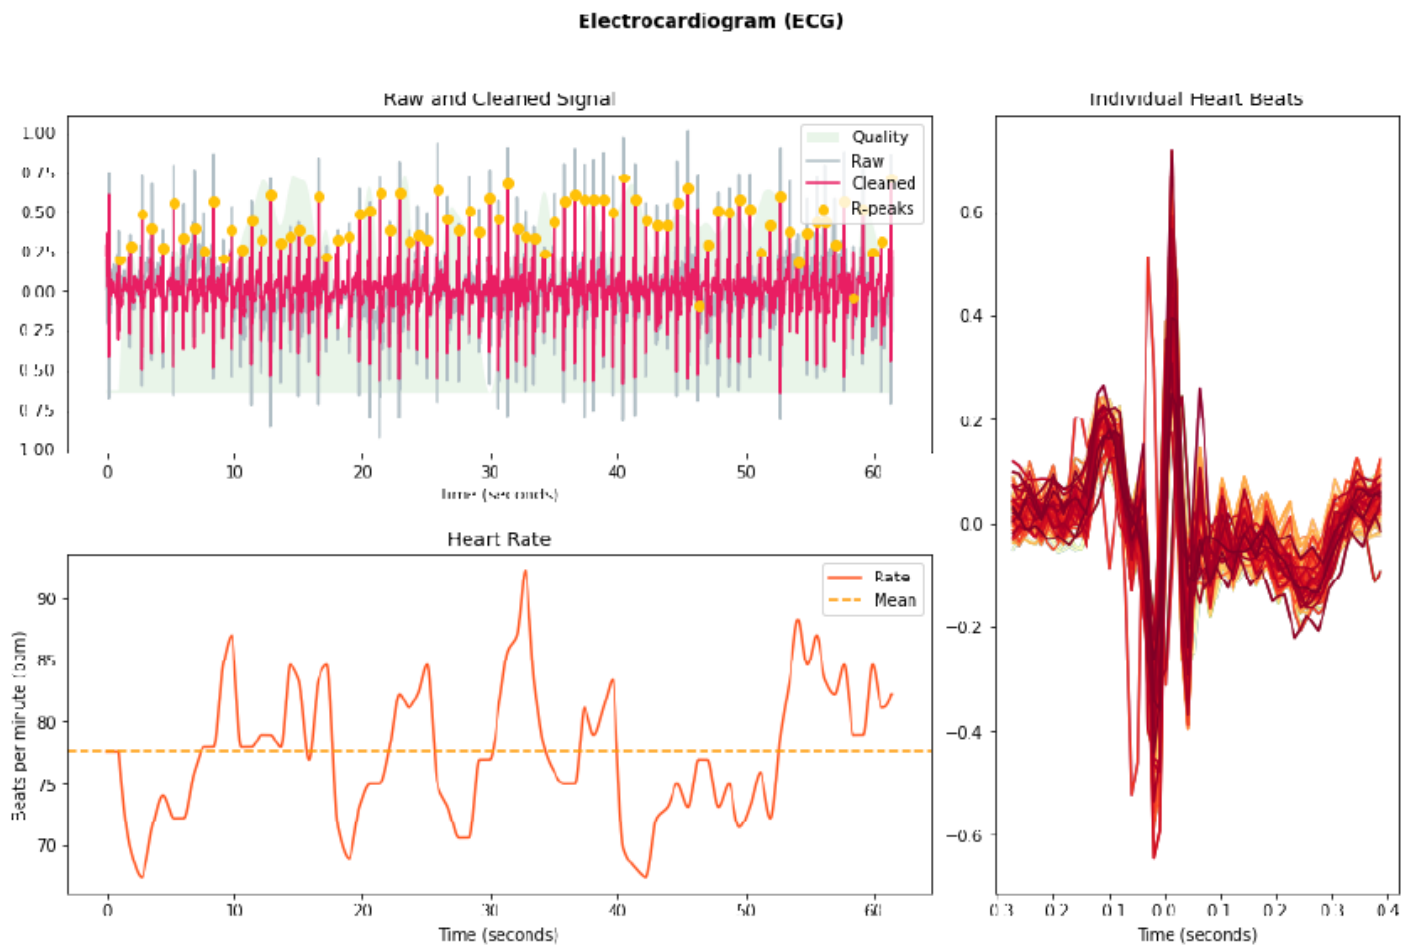


Figura 42. Processamento do sinal de ECG usando a biblioteca neurokit, enquanto o indivíduo está em “inatividade”.

Electrocardiogram (ECG)




Figura 43. Processamento do sinal de ECG usando a biblioteca neurokit, enquanto o individuo está a "andar".




Figura 44. Processamento do sinal de ECG usando a biblioteca neurokit, enquanto o individuo está a "correr".

Da Figura 443 à Figura 45 está representado o processamento de sinal usando a biblioteca neurokit, foram determinados os picos R do sinal de ECG, como se pode verificar em todas as imagens, existem alguns erros, isto deve-se a uma frequência de amostragem muito baixa, pois a frequência de amostragem da base de dados MHEALTH é de 50 Hz, sendo que a frequência de amostragem mínima para se utilizar esta biblioteca é na casa dos 90Hz, foi feito um *resample* para o dobro de modo a se conseguir processar o sinal, foi bem sucedido quando o individuo está em inatividade mas perde a precisão com o individuo está em movimento, seja ele correr ou andar.

Comparando o a média do ritmo cardíaco nas três atividades propostas verificasse um aumento bem vincado com o aumento da atividade física. Quando o individuo esta parado temos um ritmo cardíaco entre os 75 e os 80 batimentos por minuto. E verifica-se um aumento quando o individuo está a correr e andar na casa dos 90 a 100 batimentos por minuto, logo conseguimos concluir que o ritmo cardíaco se altera com o aumento da atividade física.




Figura 45. Distribuição dos intervalos R-R, enquanto o individuo está em inatividade.

Distribution of R-R intervals




Figura 46. Distribuição dos intervalos R-R, enquanto o indivíduo está a andar.

Distribution of R-R intervals




Figura 47. Distribuição dos intervalos R-R, enquanto o indivíduo está a correr.

Foi feito um estudo dos intervalos R-R como está representado nas figuras acima, foi bem claro que a distribuição dos IBIS (*interbeat interval*) é bastante diferente nas 3 atividades, verifica-se um estreitamento dos intervalos quando a intensidade física aumenta, consegue-se perceber que quando o indivíduo está a correr temos uma predominância maior dos intervalos R-R entre os 250 ms e 500 ms, que é bem mais baixo de quando o indivíduo está parado e mesmo a andar. Logo é possível determinar que quando a intensidade física aumenta os intervalos entre batimentos têm tendência a diminuir que está em concordância com os sinais processados anteriormente e por sua vez com a média de ritmo cardíaco, sendo possível então distinguir estas atividades pelo sinal cardíaco do sujeito.




Figura 48. Representação gráfica da precisão de cada característica usada no modelo de treino (Função do SKLEARN).

Mais uma vez foi feito um estudo das características mais precisas no modelo de treino, que está representado na Figura 49. Representação gráfica da precisão de cada característica usada no modelo de treino (Função do SKLEARN).

Figura 49. Representação gráfica da precisão de cada característica usada no modelo de treino (Função do SKLEARN).

. Foram extraídas características estatísticas tanto no HR (*heart rate*) como no HRV (*heart rate variability*) e através de uma função baseada do *scikit learn* foi possível calcular a precisão das

mesmas no modelo de treino. Como se pode ver temos características mais precisas que outras, sendo que a moda e média do HRV e a média do HR as que tiveram melhor cotação, e as medianas e o desvio padrão a pior cotação.

Tabela 5. Resultados da classificação do sinal de ECG.

Algoritmos	Precisão
KNN	0,69
SVM	0,73
BOOSTING MODEL	0,64

Na Tabela 5 temos os resultados de classificação para os 3 classificadores, realmente verificamos que todos os classificadores têm uma precisão relativamente baixa sendo que o melhor e mais se salienta novamente é o SVM com uma precisão de 73% sendo que o KNN e o *Boosting model* têm precisões mais baixas. Teriam de ser testadas mais características de modo a se conseguir fornecer mais informação ao modelo de treino e por sua vez melhorar a precisão do mesmo. Volto a salientar que apenas foi usada uma base de dados e que esta tinha uma frequência de amostragem muito baixa, logo é um fator de erro bastante vincado neste estudo.

4.4. Deteção automática de atividade usando acelerómetro e ECG (fusão)

Tabela 6. Resultados da classificação o sinal do acelerómetro + o sinal de ECG.

Algoritmos	Precisão
KNN	0,92
SVM	0,94
BOOSTING MODEL	0,86

Foi feita uma fusão dos algoritmos desenvolvidos e utilizadas todas as características estudadas, em ambos os sinais, nomeadamente de ECG e acelerómetro, foi possível obter uma excelente precisão de quase todos os modelos, sendo que o KNN e o SVM tiveram cotações acima dos 90% sendo os mais precisos. Com estes resultados de classificação é possível dizer que as combinações de características de diferentes bio-sinais melhora a precisão da classificação e por sua vez torna o

modelo de classificação mais completo e capaz de detetar e monitorizar a atividade física de uma forma muito mais acertada.

Capítulo 5: Conclusões e Trabalho Futuro

Neste estudo foram realizadas várias abordagens para classificar atividades humanas e contar número de passos. Foi usada uma base dados previamente estudada, e também dados recolhidos de um acelerómetro de um smartphone.

No algoritmo de deteção e contabilização de passos, foram feitos 2 estudos um usando a MHEALTH dataset e outro experimental como forma de validação dos resultados, os resultados foram bons e conseguiu-se obter um algoritmo de contagem de passos com uma taxa de erro dentro do aceitável, como foi observado na bibliografia.

No algoritmo de deteção de atividades (inatividade, andar e correr), usando o acelerómetro, foi possível estudar várias características tanto no domínio de tempo como no domínio de frequência, e também vários classificadores. Conclui-se que as características no domínio da frequência são as mais capazes de distinguir as atividades propostas. As características do domínio de tempo que foram estudadas, muitas delas não são representativas e têm pouca importância no treino eficaz do modelo. É de notar que o eixo mais representativo é o eixo dos X pois as características extraídas usando este eixo são as que têm maior importância no treino do modelo de classificação. Em relação aos modelos de classificação os que apresentaram melhor precisão foram o KNN e SVM. Em relação ao boosting model, não parece ter grande precisão para esta abordagem de classificação supervisionada.

Conclui-se que tanto as características no domínio de tempo como a combinação das características do domínio do tempo com as características do domínio da frequência fazem o algoritmo perder precisão. Dá-se então mais ênfase ao uso de características no domínio de frequência, tornando uma classificação mais certa e equilibrada.

No algoritmo desenvolvido usando o sinal de ECG, verificou-se que é possível distinguir as atividades propostas usando o sinal de cardíaco, apesar de os resultados não serem do mesmo nível que os do acelerómetro dá para perceber que tanto o ritmo cardíaco como a variabilidade do ritmo cardíaco são afetadas com o aumento da intensidade da atividade física. Foi possível fazer um estudo dos intervalos RR e conclui-se que entre as atividades propostas se verificam grandes diferenças de distribuição.

Em relação a característica verifica-se que a média do HR e a média e a moda do HRV são as que têm maior importância no modelo de classificação, e o modelo de classificação com a melhor precisão continua a ser o SVM como aconteceu no estudo anterior do sinal de acelerómetro.

Em relação á fusão da classificação usando dos dois sinais, foi possível obter uma excelente precisão de quase todos os modelos. Com estes resultados de classificação é possível concluir que as combinações de características de diferentes sinais melhoram a precisão da classificação e por sua vez torna o modelo de classificação mais completo e robusto.

Como trabalho futuro, seria pertinente o estudo de mais atividades de modo a tornar o algoritmo mais completo e adaptado a várias situações. Seria muito pertinente validar com dados reais tanto o algoritmo do sinal de acelerómetro como o de sinal cardíaco. Pois com dados reais apenas foi validado o algoritmo da deteção de passos.

Seria pertinente também aprofundar o estudo do sinal cardíaco, estudar mais características e utilizar uma base de dados com uma frequência de amostragem maior, pois a usada era relativamente baixa levando a erros por parte das bibliotecas usadas para processar este sinal.

Por último, fazer um algoritmo que fundisse os 3 algoritmos desenvolvidos, usando o número de passos como uma característica na classificação das atividades, e assim cada vez tornar um algoritmo mais certo e consistente.

Referências Bibliográficas

- [1] A. Perez, M. Labrador, and S. Barbeau, “G-Sense: a scalable architecture for global sensing and monitoring,” *IEEE Netw.*, vol. 24, no. 4, pp. 57–64, 2010, doi: 10.1109/MNET.2010.5510920.
- [2] O. D. Lara and M. A. Labrador, “A Survey on Human Activity Recognition using Wearable Sensors,” *IEEE Commun. Surv. Tutorials*, vol. 15, no. 3, pp. 1192–1209, 2013, doi: 10.1109/SURV.2012.110112.00192.
- [3] Y. Jia, “Dietetic and Exercise Therapy against Diabetes Mellitus,” in *2009 Second International Conference on Intelligent Networks and Intelligent Systems*, Nov. 2009, pp. 693–696, doi: 10.1109/ICINIS.2009.177.
- [4] O. Banos, J.-M. Galvez, M. Damas, H. Pomares, and I. Rojas, “Window Size Impact in Human Activity Recognition,” *Sensors*, vol. 14, no. 4, pp. 6474–6499, Apr. 2014, doi: 10.3390/s140406474.
- [5] Sungmee Park and S. Jayaraman, “Enhancing the quality of life through wearable technology,” *IEEE Eng. Med. Biol. Mag.*, vol. 22, no. 3, pp. 41–48, May 2003, doi: 10.1109/MEMB.2003.1213625.
- [6] S. C. Mukhopadhyay, “Wearable Sensors for Human Activity Monitoring: A Review,” *IEEE Sens. J.*, vol. 15, no. 3, pp. 1321–1330, Mar. 2015, doi: 10.1109/JSEN.2014.2370945.
- [7] Y. Chuo *et al.*, “Mechanically Flexible Wireless Multisensor Platform for Human Physical Activity and Vitals Monitoring,” *IEEE Trans. Biomed. Circuits Syst.*, vol. 4, no. 5, pp. 281–294, Oct. 2010, doi: 10.1109/TBCAS.2010.2052616.
- [8] S. Brage, N. Brage, P. W. Franks, U. Ekelund, and N. J. Wareham, “Reliability and validity of the combined heart rate and movement sensor Actiheart,” *Eur. J. Clin. Nutr.*, vol. 59, no. 4, pp. 561–570, Apr. 2005, doi: 10.1038/sj.ejcn.1602118.
- [9] T. Shany, S. J. Redmond, M. R. Narayanan, and N. H. Lovell, “Sensors-Based Wearable Systems for Monitoring of Human Movement and Falls,” *IEEE Sens. J.*, vol. 12, no. 3, pp. 658–670, Mar. 2012, doi: 10.1109/JSEN.2011.2146246.
- [10] J. R. Kwapisz, G. M. Weiss, and S. A. Moore, “Activity recognition using cell phone accelerometers,” *ACM SIGKDD Explor. Newsl.*, vol. 12, no. 2, pp. 74–82, Mar. 2011, doi: 10.1145/1964897.1964918.
- [11] M. J. Mathie, B. G. Celler, N. H. Lovell, and A. C. F. Coster, “Classification of basic daily movements using a triaxial accelerometer,” *Med. Biol. Eng. Comput.*, vol. 42, no. 5, pp. 679–687, Sep. 2004, doi: 10.1007/BF02347551.
- [12] A. Sung, M., Marci, C. & Pentland, “Wearable feedback systems for rehabilitation,” *J NeuroEngineering Rehabil*, vol. 2, no. 17, 2005.

- [13] T. Brezmes, J. L. Gorricho, and J. Cotrina, "Activity recognition from accelerometer data on a mobile phone," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 5518 LNCS, no. PART 2, pp. 796–799, 2009, doi: 10.1007/978-3-642-02481-8_120.
- [14] M. J. Mathie, A. C. F. Coster, N. H. Lovell, and B. G. Celler, "Accelerometry: providing an integrated, practical method for long-term, ambulatory monitoring of human movement," *Physiol. Meas.*, vol. 25, no. 2, pp. R1–R20, Apr. 2004, doi: 10.1088/0967-3334/25/2/R01.
- [15] A. M. Khan, "Human Activity Recognition Using A Single Tri-axial Accelerometer," *Comput. Eng.*, vol. 93, pp. 1379–1383, 2011, [Online]. Available: http://uclab.khu.ac.kr/resources/thesis/PhD_Thesis_Adil.pdfhttp://uclab.khu.ac.kr/resources/thesis/PhD_Thesis_Adil.pdf.
- [16] A. Sucerquia, J. López, and J. Vargas-Bonilla, "Real-Life/Real-Time Elderly Fall Detection with a Triaxial Accelerometer," *Sensors*, vol. 18, no. 4, p. 1101, Apr. 2018, doi: 10.3390/s18041101.
- [17] B. Carlson, B. M., Biebz, J., Chaffin, B., Childers, L., & Hickman, *The Circulatory System. The Human Body*. 2019.
- [18] W. World Health Organization, "Cardiovascular diseases," 2021. [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)).
- [19] A. F. M. Botelho *et al.*, "Non-invasive ECG recording and QT interval correction assessment in anesthetized rats and mice," *Pesqui. Veterinária Bras.*, vol. 39, no. 6, pp. 409–415, Jun. 2019, doi: 10.1590/1678-6160-pvb-6029.
- [20] S. Meek, "ABC of clinical electrocardiography: Introduction. I---Leads, rate, rhythm, and cardiac axis," *BMJ*, vol. 324, no. 7334, pp. 415–418, Feb. 2002, doi: 10.1136/bmj.324.7334.415.
- [21] G. Kaur, D. Singh, and Simranjeet, "Electrocardiogram (ECG) as a Biometric Characteristic: A Review," 2015.
- [22] M. Boyett, "The sinoatrial node, a heterogeneous pacemaker structure," *Cardiovasc. Res.*, vol. 47, no. 4, pp. 658–687, Sep. 2000, doi: 10.1016/S0008-6363(00)00135-8.
- [23] Z. D. G. and A. S. Ary L. Goldberger, *Goldberger's clinical electrocardiography. ECG basics: waves, intervals, and segments*. 2013.
- [24] P. Sörnmo, L., & Laguna, *Bioelectrical Signal Processing in Cardiac and Neurological Applications*. Academic Press, 2005.
- [25] M. Zheng, G., Chen, Y. H., & Dai, *HRVBased Stress Recognizing by Random Forest*, In Fuzzy S. IOS Press, 2016.
- [26] M. A. Jimenez-Limas, C. A. Ramirez-Fuentes, B. Tovar-Corona, and L. I. Garay-Jimenez, "Feature selection for stress level classification into a physiological signals set," in *2018 15th International Conference on Electrical Engineering, Computing Science and Automatic*

- Control (CCE)*, Sep. 2018, pp. 1–5, doi: 10.1109/ICEEE.2018.8533968.
- [27] M. Gjoreski, M. Luštrek, M. Gams, and H. Gjoreski, “Monitoring stress with a wrist device using context,” *J. Biomed. Inform.*, vol. 73, pp. 159–170, Sep. 2017, doi: 10.1016/j.jbi.2017.08.006.
- [28] W. Sousa Lima, E. Souto, K. El-Khatib, R. Jalali, and J. Gama, “Human Activity Recognition Using Inertial Sensors in a Smartphone: An Overview,” *Sensors*, vol. 19, no. 14, p. 3213, Jul. 2019, doi: 10.3390/s19143213.
- [29] J. W. Lockhart and G. M. Weiss, “Limitations with activity recognition methodology & data sets,” in *Proceedings of the 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing: Adjunct Publication*, Sep. 2014, pp. 747–756, doi: 10.1145/2638728.2641306.
- [30] E. Pietka, “Expert systems in parameter extraction of the ECG signal,” in *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 1988, pp. 165–166 vol.1, doi: 10.1109/IEMBS.1988.94460.
- [31] E. Keogh, S. Chu, D. Hart, and M. Pazzani, “An online algorithm for segmenting time series,” in *Proceedings 2001 IEEE International Conference on Data Mining*, pp. 289–296, doi: 10.1109/ICDM.2001.989531.
- [32] S. D. Bersch, D. Azzi, R. Khusainov, I. Achumba, and J. Ries, “Sensor Data Acquisition and Processing Parameters for Human Activity Classification,” *Sensors (Basel)*, vol. 14, pp. 4239–4270, 2014.
- [33] N. C. Cook, D. J., & Krishnan, *Activity Learning: Discovering, Recognizing, and Predicting Human Behavior from Sensor Data*. 2015.
- [34] D. Chu *et al.*, “Balancing energy, latency and accuracy for mobile sensor data classification,” in *Proceedings of the 9th ACM Conference on Embedded Networked Sensor Systems - SenSys '11*, 2011, p. 54, doi: 10.1145/2070942.2070949.
- [35] D. Figo, P. C. Diniz, D. R. Ferreira, and J. M. P. Cardoso, “Preprocessing techniques for context recognition from accelerometer data,” *Pers. Ubiquitous Comput.*, vol. 14, no. 7, pp. 645–662, Oct. 2010, doi: 10.1007/s00779-010-0293-9.
- [36] N. Widanti, B. Sumanto, P. Rosa, and M. Fathur Miftahudin, “Stress level detection using heart rate, blood pressure, and GSR and stress therapy by utilizing infrared,” in *2015 International Conference on Industrial Instrumentation and Control (ICIC)*, May 2015, pp. 275–279, doi: 10.1109/IIC.2015.7150752.
- [37] Y. Deng, Z. Wu, C.-H. Chu, Q. Zhang, and D. F. Hsu, “Sensor Feature Selection and Combination for Stress Identification Using Combinatorial Fusion,” *Int. J. Adv. Robot. Syst.*, vol. 10, no. 8, p. 306, Aug. 2013, doi: 10.5772/56344.
- [38] J. Vicente *et al.*, “Listen to Your Heart: Stress Prediction Using Consumer Heart Rate Sensors,” *Sensors (Switzerland)*, vol. 12, no. 7, pp. 16937–16953, 2014, [Online]. Available:

- <http://cs229.stanford.edu/proj2013/LiuUlrich-ListenToYourHeart-StressPredictionUsingConsumerHeartRateSensors.pdf><http://dx.doi.org/10.1016/j.eswa.2010.12.028>.
- [39] Y. Nakashima, J. Kim, S. Flutura, A. Seiderer, and E. André, “Stress Recognition in Daily Work,” 2016, pp. 23–33.
- [40] P. Zimmermann, S. Guttormsen, B. Danuser, and P. Gomez, “Affective Computing—A Rationale for Measuring Mood With Mouse and Keyboard,” *Int. J. Occup. Saf. Ergon.*, vol. 9, no. 4, pp. 539–551, Jan. 2003, doi: 10.1080/10803548.2003.11076589.
- [41] R. Picard, *Affective Computing*. Massachusetts Institute of Technology, 1997.
- [42] E. Hudlicka, “To feel or not to feel: The role of affect in human–computer interaction,” *Int. J. Hum. Comput. Stud.*, vol. 59, no. 1–2, pp. 1–32, Jul. 2003, doi: 10.1016/S1071-5819(03)00047-8.
- [43] J. Zhai and A. Barreto, *Stress Recognition Using Non-invasive Technology*. 2006.
- [44] A. Barreto, J. Zhai, and M. Adjouadi, “Non-Intrusive Physiological Monitoring for Automated Stress Detection in Human-Computer Interaction,” in *Proceedings of the 2007 IEEE International Conference on Human-Computer Interaction*, 2007, pp. 29–38.
- [45] Wenhui Liao, Weihong Zhang, Zhiwei Zhu, and Qiang Ji, “A Real-Time Human Stress Monitoring System Using Dynamic Bayesian Network,” in *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05) - Workshops*, vol. 3, pp. 70–70, doi: 10.1109/CVPR.2005.394.
- [46] J. Han, M. Kamber, and J. Pei, “Chapter 9: Graph Mining, Social Network Analysis, and Multirelational Data Mining,” *Data Min. concepts Tech.*, pp. 535–589, 2006, [Online]. Available: http://books.google.com/books?hl=en&lr=&id=AfL0t-YzOrEC&oi=fnd&pg=PP2&dq=Data+Mining:+Concepts+and+Techniques&ots=Uv-WrRflz9&sig=E_20H417umQmqnf_jM9m9DyNRf0.
- [47] Z. Dharmawan, “Analysis of Computer Games Player Stress Level Using EEG Data,” 2007.
- [48] S. Scherer *et al.*, *Emotion Recognition from Speech: Stress Experiment*. 2008.
- [49] Y. Fukuoka and A. Ishida, “Chronic stress evaluation using neural networks,” *IEEE Eng. Med. Biol. Mag.*, vol. 19, no. 1, pp. 34–38, 2000, doi: 10.1109/51.816242.
- [50] M. M. Bunde and R. Banerjee, “Detection of fatigue of vehicular driver using skin conductance and oximetry pulse,” in *Proceedings of the 11th International Conference on Information Integration and Web-based Applications & Services - iiWAS '09*, 2009, p. 739, doi: 10.1145/1806338.1806478.
- [51] G. E. Sakr, I. H. Elhajj, and U. C. Wejinya, “Multi level SVM for subject independent agitation detection,” in *2009 IEEE/ASME International Conference on Advanced Intelligent Mechatronics*, Jul. 2009, pp. 538–543, doi: 10.1109/AIM.2009.5229958.
- [52] N. El Haouij *et al.*, “Random Forest-Based Approach for Physiological Functional Variable

- Selection : Towards Driver ' s Stress Level Classification,” *Proc. Conf. Ital. Stat. Soc.*, pp. 393–398, 2017.
- [53] A. Alberdi, A. Aztiria, and A. Basarab, “Towards an automatic early stress recognition system for office environments based on multimodal measurements: A review,” *J. Biomed. Inform.*, vol. 59, pp. 49–75, Feb. 2016, doi: 10.1016/j.jbi.2015.11.007.
- [54] E. Smets *et al.*, “Comparison of Machine Learning Techniques for Psychophysiological Stress Detection,” 2016, pp. 13–22.
- [55] C. D. Katsis, N. Katertsidis, G. Ganiatsas, and D. I. Fotiadis, “Toward Emotion Recognition in Car-Racing Drivers: A Biosignal Processing Approach,” *IEEE Trans. Syst. Man, Cybern. - Part A Syst. Humans*, vol. 38, no. 3, pp. 502–512, May 2008, doi: 10.1109/TSMCA.2008.918624.
- [56] M. Kumar, M. Weippert, R. Vilbrandt, S. Kreuzfeld, and R. Stoll, “Fuzzy Evaluation of Heart Rate Signals for Mental Stress Assessment,” *IEEE Trans. Fuzzy Syst.*, vol. 15, no. 5, pp. 791–808, Oct. 2007, doi: 10.1109/TFUZZ.2006.889825.
- [57] O. Fukuda, Y. Nagata, K. Homma, and T. Tsuji, “Evaluation of heart rate variability by using wavelet transform and a recurrent neural network,” in *2001 Conference Proceedings of the 23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 1769–1772, doi: 10.1109/IEMBS.2001.1020562.
- [58] N. Carter, D. Young, and J. Ferryman, “A combined Bayesian Markovian approach for behaviour recognition,” *Proc. - Int. Conf. Pattern Recognit.*, vol. 1, pp. 761–764, 2006, doi: 10.1109/ICPR.2006.47.
- [59] R. C. Deo, “Machine Learning in Medicine,” *Circulation*, vol. 132, no. 20, pp. 1920–1930, Nov. 2015, doi: 10.1161/CIRCULATIONAHA.115.001593.
- [60] D. Chicco, “Ten quick tips for machine learning in computational biology,” *BioData Min.*, vol. 10, no. 1, p. 35, Dec. 2017, doi: 10.1186/s13040-017-0155-3.
- [61] I. El Naqa *et al.*, “Machine learning and modeling: Data, validation, communication challenges,” *Med. Phys.*, vol. 45, no. 10, pp. e834–e840, Oct. 2018, doi: 10.1002/mp.12811.
- [62] M. A. Little *et al.*, “Using and understanding cross-validation strategies. Perspectives on Saeb *et al.*,” *Gigascience*, vol. 6, no. 5, May 2017, doi: 10.1093/gigascience/gix020.
- [63] M. W. Browne, “Cross-Validation Methods,” *J. Math. Psychol.*, vol. 44, no. 1, pp. 108–132, Mar. 2000, doi: 10.1006/jmps.1999.1279.
- [64] Z. Shao, M. J. Er, and N. Wang, “An Efficient Leave-One-Out Cross-Validation-Based Extreme Learning Machine (ELOO-ELM) With Minimal User Intervention,” *IEEE Trans. Cybern.*, vol. 46, no. 8, pp. 1939–1951, Aug. 2016, doi: 10.1109/TCYB.2015.2458177.
- [65] A. H.-R. Ko, P. R. Cavalin, R. Sabourin, and A. de Souza Britto, “Leave-One-Out-Training and Leave-One-Out-Testing Hidden Markov Models for a Handwritten Numeral Recognizer: The Implications of a Single Classifier and Multiple Classifications,” *IEEE Trans. Pattern*

- Anal. Mach. Intell.*, vol. 31, no. 12, pp. 2168–2178, Dec. 2009, doi: 10.1109/TPAMI.2008.254.
- [66] A. R. Syed, “A Review of Cross Validation and Adaptive Model Selection,” *Statistics (Ber)*, 2011.
- [67] H. Þórarinsdóttir, L. V. Kessing, and M. Faurholt-Jepsen, “Smartphone-Based Self-Assessment of Stress in Healthy Adult Individuals: A Systematic Review,” *J. Med. Internet Res.*, vol. 19, no. 2, p. e41, Feb. 2017, doi: 10.2196/jmir.6397.
- [68] Y. S. Can, B. Arnrich, and C. Ersoy, “Stress detection in daily life scenarios using smart phones and wearable sensors: A survey,” *J. Biomed. Inform.*, vol. 92, p. 103139, Apr. 2019, doi: 10.1016/j.jbi.2019.103139.
- [69] V. P. Cornet and R. J. Holden, “Systematic review of smartphone-based passive sensing for health and wellbeing,” *J. Biomed. Inform.*, vol. 77, pp. 120–132, Jan. 2018, doi: 10.1016/j.jbi.2017.12.008.
- [70] R.-A. Voicu, C. Dobre, L. Bajenaru, and R.-I. Ciobanu, “Human Physical Activity Recognition Using Smartphone Sensors,” *Sensors*, vol. 19, no. 3, p. 458, Jan. 2019, doi: 10.3390/s19030458.
- [71] A. Muaremi, B. Arnrich, and G. Tröster, “Towards Measuring Stress with Smartphones and Wearable Devices During Workday and Sleep,” *Bionanoscience*, vol. 3, no. 2, pp. 172–183, Jun. 2013, doi: 10.1007/s12668-013-0089-2.
- [72] I. Mohino-Herranz, R. Gil-Pita, J. Ferreira, M. Rosa-Zurera, and F. Seoane, “Assessment of Mental, Emotional and Physical Stress through Analysis of Physiological Signals Using Smartphones,” *Sensors*, vol. 15, no. 10, pp. 25607–25627, Oct. 2015, doi: 10.3390/s151025607.
- [73] S. Berrouiguet *et al.*, “Combining Continuous Smartphone Native Sensors Data Capture and Unsupervised Data Mining Techniques for Behavioral Changes Detection: A Case Series of the Evidence-Based Behavior (eB2) Study,” *JMIR mHealth uHealth*, vol. 6, no. 12, p. e197, Dec. 2018, doi: 10.2196/mhealth.9472.
- [74] Z. Vahedi and A. Saiphoo, “The association between smartphone use, stress, and anxiety: A meta-analytic review,” *Stress Heal.*, vol. 34, no. 3, pp. 347–358, Aug. 2018, doi: 10.1002/smi.2805.
- [75] É. Duke and C. Montag, “Smartphone addiction, daily interruptions and self-reported productivity,” *Addict. Behav. Reports*, vol. 6, pp. 90–95, Dec. 2017, doi: 10.1016/j.abrep.2017.07.002.
- [76] S. Thomée, A. Härenstam, and M. Hagberg, “Mobile phone use and stress, sleep disturbances, and symptoms of depression among young adults - a prospective cohort study,” *BMC Public Health*, vol. 11, no. 1, p. 66, Dec. 2011, doi: 10.1186/1471-2458-11-66.
- [77] Y.-J. Kim, H. Jang, Y. Lee, D. Lee, and D.-J. Kim, “Effects of Internet and Smartphone

- Addictions on Depression and Anxiety Based on Propensity Score Matching Analysis,” *Int. J. Environ. Res. Public Health*, vol. 15, no. 5, p. 859, Apr. 2018, doi: 10.3390/ijerph15050859.
- [78] J. Matar Boumosleh and D. Jaalouk, “Depression, anxiety, and smartphone addiction in university students- A cross sectional study,” *PLoS One*, vol. 12, no. 8, p. e0182239, Aug. 2017, doi: 10.1371/journal.pone.0182239.
- [79] Oracle, “What is a database?,” 2021. <https://www.oracle.com/database/what-is-database/>.
- [80] J. Ullman, Jeffrey; Widom, *A First Course in Database Systems*. Prentice-Hall, 1997.
- [81] G. C. Hermes, R. E., Geselowitz, D. B., & Oliver, “Development, distribution, and use of the American Heart Association database for ventricular arrhythmia detector evaluation,” *Comput. Cardiol.*, pp. 263–266, 1980.
- [82] R. G. Moody, G. B., & Mark, “The MIT-BIH arrhythmia database on CD-ROM and software for use with it,” in *Computers in Cardiology*, 1990.
- [83] A. L. Goldberger *et al.*, “PhysioBank, PhysioToolkit, and PhysioNet,” *Circulation*, vol. 101, no. 23, Jun. 2000, doi: 10.1161/01.CIR.101.23.e215.
- [84] H. P. da Silva, A. Lourenço, A. Fred, N. Raposo, and M. Aires-de-Sousa, “Check Your Biosignals Here: A new dataset for off-the-person ECG biometrics,” *Comput. Methods Programs Biomed.*, vol. 113, no. 2, pp. 503–514, Feb. 2014, doi: 10.1016/j.cmpb.2013.11.017.
- [85] S. Pouryayevali, S. Wahabi, S. Hari, and D. Hatzinakos, “On establishing evaluation standards for ECG biometrics,” in *2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, May 2014, pp. 3774–3778, doi: 10.1109/ICASSP.2014.6854307.
- [86] R. Chavarriaga *et al.*, “The Opportunity challenge: A benchmark database for on-body sensor-based activity recognition,” *Pattern Recognit. Lett.*, vol. 34, no. 15, pp. 2033–2042, Nov. 2013, doi: 10.1016/j.patrec.2012.12.014.
- [87] Y. Vaizman, K. Ellis, and G. Lanckriet, “Recognizing detailed human context in the wild from smartphones and smartwatches,” *IEEE Pervasive Comput.*, vol. 16, no. 4, pp. 62–74, 2017, doi: 10.1109/MPRV.2017.3971131.
- [88] D. Anguita, A. Ghio, L. Oneto, X. Parra, and J. L. Reyes-Ortiz, “A Public Domain Dataset for Human Activity Recognition using Smartphones,” in *ESANN*, 2013.
- [89] A. Reiss, M. Weber, and D. Stricker, “Exploring and extending the boundaries of physical activity recognition,” *2011 IEEE Int. Conf. Syst. Man, Cybern.*, pp. 46–50, 2011.
- [90] M. Zhang and A. A. Sawchuk, “USC-HAD: a daily activity dataset for ubiquitous activity recognition using wearable sensors,” in *Proceedings of the 2012 ACM Conference on Ubiquitous Computing - UbiComp '12*, 2012, p. 1036, doi: 10.1145/2370216.2370438.
- [91] O. Banos *et al.*, “mHealthDroid: A Novel Framework for Agile Development of Mobile Health Applications,” 2014, pp. 91–98.

- [92] M. Shoaib, S. Bosch, O. Incel, H. Scholten, and P. Havinga, “Fusion of Smartphone Motion Sensors for Physical Activity Recognition,” *Sensors*, vol. 14, no. 6, pp. 10146–10176, Jun. 2014, doi: 10.3390/s140610146.
- [93] D. Micucci, M. Mobilio, and P. Napolitano, “UniMiB SHAR: A dataset for human activity recognition using acceleration data from smartphones,” *Appl. Sci.*, vol. 7, no. 10, 2017, doi: 10.3390/app7101101.
- [94] M. Barandas *et al.*, “TSFEL: Time Series Feature Extraction Library,” *SoftwareX*, vol. 11, p. 100456, Jan. 2020, doi: 10.1016/j.softx.2020.100456.
- [95] Scikit-learn, “Machine Learning,” 2021. .