



Deteção de Quedas em Ambiente Residencial

OSVALDO JOÃO SEIXAS RIBEIRO

novembro de 2020

INSTITUTO SUPERIOR DE ENGENHARIA DO PORTO

Deteção de Quedas em Ambiente Residencial

Oswaldo João Seixas Ribeiro



Mestrado em Engenharia Eletrotécnica e de Computadores

Área de Especialização em Telecomunicações

Departamento de Engenharia Eletrotécnica

2020

Relatório elaborado para satisfação parcial dos requisitos da Unidade Curricular de Tese/Dissertação do Mestrado em Engenharia Eletrotécnica e de Computadores.

Candidato: Osvaldo João Seixas Ribeiro, N.º 1180437, 1180437@isep.ipp.pt

Orientação científica: Professora Doutora Zita Vale, zav@isep.ipp.pt

Coorientação: Professor Doutor Luís Gomes, log@isep.ipp.pt



Mestrado em Engenharia Eletrotécnica e de Computadores

Área de Especialização em Telecomunicações

Departamento de Engenharia Eletrotécnica

Instituto Superior de Engenharia do Porto

15 de novembro de 2020

À minha neta Carolina.

Agradecimentos

Se premissa houvesse, agradeço em forma de prelúdio, à vida, por me ter dado tanto, aos meus pais, pela gênese e dádiva, pelo melhor que a vida tem para dar, amor.

Nesta senda, agradeço à minha esposa e filhos, pela luz das manhãs, pelo mar e entardecer de todos os dias, passados e porvir da minha vida.

Ainda, pelos caminhos da vida, agradeço a todos os meus camaradas, professores, alunos e ex alunos por me terem ensinado mais, do que aquilo que lhes ensinei.

Por esta dissertação, agradeço ao Grupo de Investigação em Engenharia e Computação Inteligente para a Inovação e o Desenvolvimento (GECAD) que me facilitou os meios para a sua execução e oportunidade pela causa humana, nomeadamente na pessoa da minha orientadora, Professora Doutora Zita Vale. Ao meu coorientador, Professor Doutor Luís Gomes, pela sapiência, disponibilidade, perseverança e paciência demonstrada durante a sua execução.

Não posso deixar de agradecer, ao meu colega de curso, Tiago Amaral, pela amizade, competência, responsabilidade e incentivo, para lá da nossa diferença de idades.

E como penso que na vida não existem coincidências, ter sido avô no decorrer desta dissertação, em tempos tão difíceis para mostrar o sorriso enternecido, foi o maior alento para acreditar num futuro melhor da humanidade.

Resumo

O envelhecimento demográfico trouxe novos desafios à sociedade. Associado à prevalência do risco de quedas na população idosa, são primordiais projetos de desenvolvimento que sejam uma mais valia na prevenção desta realidade e que minimizem os seus danos. Contudo, antecipar ou mesmo detetar uma queda humana é uma tarefa complexa, devido a limitações funcionais relacionadas com a condição de dependência do utilizador, a dificuldade em distinguir o evento de atividades do dia a dia, ou constringimentos que afetem a privacidade da pessoa.

Relevando o privilégio de contribuir para a manutenção da qualidade de vida dos idosos, pretende-se com esta dissertação efetuar um estudo detalhado sobre dispositivos e sensores de deteção de quedas, baseado nas vibrações e áudio do piso da divisão utilizada pela pessoa idosa. Após este estudo, será apresentada uma solução cuja arquitetura de computação envolva conceitos como *edge computing*, *fog computing* e *cloud computing*.

Neste contexto, a solução proposta integra-se no ambiente residencial do idoso, consistindo num dispositivo por divisão e um dispositivo central na habitação. Para o efeito procedeu-se ao desenvolvimento do dispositivo IoT (*internet of things*) a instalar na divisão, cuja função principal será monitorizar os sinais de vibração, som e movimento a partir da leitura dos sensores, sem requerer a manutenção ou configuração por parte do utilizador. Para além das funcionalidades de comunicação ao dispositivo no edifício, o dispositivo na divisão tomará a decisão de um alerta imediato para o cuidador residente, no caso da existência de uma queda e o envio da série temporal para classificação.

O dispositivo implementado no edifício realiza a recolha de dados que depois de pre-processados constituem uma base de conhecimento. Ao aplicar a transformada de *wavelet* e *dynamic time warping* (DTW) na análise de séries temporais correspondentes ao registo de simulações de quedas e atividades diárias, foi possível efetuar a classificação inteligente da série temporal baseada em algoritmos de aprendizagem. A solução proposta integra-se nas áreas de *smart homes* e *assisted living*, usando técnicas de *deep learning* de forma a identificar e distinguir com precisão uma queda.

Palavras-Chave: classificação de quedas, medição de vibrações, séries temporais, sistemas de aprendizagem.

Abstract

Demographic aging has brought new challenges to society. Associated with the prevalence of the risk of falls in the elderly population, development projects that are an asset in preventing this reality and that minimize their damage are essential. However, anticipating or even detecting a human fall is a complex task, due to functional limitations related to the user's condition of dependence, the difficulty in distinguishing the event from daily activities, or constraints that affect the privacy of the person.

Relevant to the privilege of contributing to the maintenance of the quality of life of the elderly, it is intended with this dissertation to carry out a detailed study on devices and sensors for fall detection, based on vibrations and audio of the floor of the division used by the elderly. After this study, a solution will be presented whose computing architecture involves concepts, such as edge computing, fog computing, and cloud computing.

In this context, the proposed solution is inserted into the residential environment of the elderly, consisting of a device per division and a central device in the building. For this purpose, the IoT (internet of things) device to be installed in the room was developed, whose main function will be to monitor the vibration, sound, and movement signals from the reading of the sensors, without requiring maintenance or configuration by the user. In addition to the communication features of the device in the building, the device in the room will decide an immediate alert for the resident caregiver, in the event of a fall and the sending of the time series for classification.

The device implemented in the building performs the collection of data, which after pre-processing, constitutes a knowledge base. By applying the wavelet transform and dynamic time warping (DTW) in the analysis of time series corresponding to the registration of simulations of falls and daily activities, it was possible to perform the intelligent classification of the time series based on learning algorithms. The proposed solution is integrated into the areas of smart homes and assisted living, using deep learning techniques to accurately identify and distinguish a fall.

Keywords: classification of falls, learning systems, times series, vibration measurement.

Conteúdo

1	Introdução	1
1.1	Contextualização	1
1.2	Motivação	5
1.3	Objetivos	6
1.4	Estrutura da Dissertação	7
2	Estado da Arte	9
2.1	Vibrações	9
2.1.1	Vibração gerada por cargas de impacto	11
2.1.2	Radiação sonora	13
2.1.3	Cargas dinâmicas de atividades humanas	14
2.1.4	Modelo de carga de queda	16
2.2	Medição de Vibrações	18
2.2.1	Modelo matemático	18
2.2.2	Vibrómetro	20
2.2.3	Acelerómetro	20
2.2.4	Análise de vibrações	22
2.3	Sistemas de deteção de quedas	23
2.3.1	Classificação das tecnologias de deteção de quedas	24
2.3.2	Sistemas que utilizam Aprendizagem Máquina	27
2.3.3	Desempenho	32
2.3.4	Sistemas no mercado	33
2.4	Comparação de Séries Temporais	35
2.4.1	Modelos	37
2.4.2	Transformada <i>wavelet</i>	40
2.4.3	Medidas de similaridade	41
2.4.4	<i>Dynamic time warping</i>	42
2.5	Sistemas de Aprendizagem	43
2.5.1	Aprendizagem automática	43
2.5.2	Redes neuronais artificiais	45
2.5.3	Aprendizagem profunda	45
2.5.4	Redes neuronais convolucionais	46
2.5.5	Redes neuronais recorrentes	47
2.5.6	<i>Frameworks</i> de aprendizagem profunda	47
2.6	Considerações finais	48
3	Solução Proposta	49
3.1	Arquitetura da Solução	49
3.2	Sensores aplicados na solução	50

3.2.1	Sensor inercial MPU-9250/6500	50
3.2.2	Sensor inercial GY-521	51
3.2.3	Sensor de som - Analog Sound V2	52
3.2.4	Sensor PIR HC-SR501	52
3.2.5	Sensor Doppler HB-100	52
3.3	Conetividades	53
3.3.1	Comunicação Série	53
3.3.2	I2C/TWI	54
3.3.3	SPI	54
3.3.4	Wi-Fi e Ethernet	54
3.3.5	MQTT	56
3.4	Protótipos Desenvolvidos	57
3.4.1	Arduino Uno R3	57
3.4.2	NodeMCU v3	59
3.5	Sistemas de aquisição de dados para treino	60
3.6	Considerações finais	65
4	Descrição e Análises de Resultados	67
4.1	Dataset	67
4.2	Método CWT de Classificação	70
4.3	Método DWT de Classificação	73
4.4	Regressão para a Identificação Local de Queda	75
4.5	Classificação inteligente usando Redes Neurais	76
4.6	Considerações finais	82
5	Conclusões	83
5.1	Limitações do Projeto	83
5.2	Conclusões e Discussão	83
5.3	Evolução Futura	84
	Referências	85

Lista de Figuras

1.1	Porcentagem de quedas por grupo etário	3
2.1	Modelo de um sistema mecânico de um grau de liberdade	10
2.2	Aceleração eixo x e y	10
2.3	Martelo de impacto	12
2.4	Espectro da força de impacto	12
2.5	Varição da pressão produzida por uma fonte sonora	14
2.6	Força desenvolvida ao saltar	15
2.7	Função de impacto de calcanhar humano	16
2.8	Força do piso durante o processo de queda	17
2.9	Modelo de um corpo humano sujeito a vibração	18
2.10	Modelo do transdutor sísmico	19
2.11	Sistema de detecção de quedas	24
2.12	Modelo de classificação de quedas	26
2.13	<i>Wavelet</i> de Morlet	40
3.1	Arquitetura geral da solução	49
3.2	Captura GY-521 da aceleração x, y e z	51
3.3	Sinal do sensor de som captado durante uma queda	52
3.4	Arquitetura MQTT	56
3.5	Notificação de queda MQTT	57
3.6	Esquema geral do dispositivo baseado no Arduino	58
3.7	Esquema geral do dispositivo baseado no NodeMCU v3	59
3.8	Esquema elétrico do dispositivo baseado no NodeMCU v3	60
3.9	Dispositivo para aquisição de dados	61
3.10	Fluxograma da detecção de queda e envio de dados aplicado no dispositivo	62
3.11	JSON minimizado	62
3.12	Pseudocódigo da gravação de dados.	63
3.13	Gráfico do vetor de soma vetorial D	63
3.14	Fases do evento de queda visualizadas através da leitura do sensor 1	64
4.1	Modelo antropomórfico	68
4.2	Correlação de todos os sensores do dispositivo	70
4.3	Contorno da série temporal D	72
4.4	Gráfico de contorno da série temporal D não queda	73
4.5	Séries temporais diferentes	74
4.6	Caminho de deformação de séries diferentes	74
4.7	Duas séries semelhantes A e B	74
4.8	Caminho de deformação de séries semelhantes	75
4.9	Curva ROC obtida para a série temporal D	79
4.10	Comparação de algoritmos	81

Lista de Tabelas

2.1	Resultados de queda	25
2.2	Sistemas baseados em ambiente	28
2.3	Sistemas baseados em acústica	29
3.1	Sensores	61
4.1	Estatísticas da componente soma vetorial da aceleração	69
4.2	Parâmetros de entrada e variável de saída da função regressão	75
4.3	Estatística da regressão	76
4.4	Sumário dos resultados da regressão	76
4.5	Precisão dos algoritmos de classificação	80
4.6	Relatório de classificação	81

Lista de Acrónimos

AAL	<i>Ambient Assisted Living</i>
ADL	Acidentes Domésticos e de Lazer
AGS	<i>American Geriatrics Society</i>
ANN	<i>Artificial Neural Networks</i>
BGS	<i>British Geriatrics Society</i>
CSMA/CD	<i>Carrier Sense Multiple Access/Collision Detection</i>
CWT	<i>Continuous Wavelet Transform</i>
DGS	Direção-Geral da Saúde
DTW	<i>Dinamyc Time Warping</i>
EQM	Escala de Quedas de Morse
IMU	<i>Inertial Measurement Unit</i>
INE	Instituto Nacional de Estatística
ISO	<i>International Organization for Standardization</i>
IoT	<i>Internet of Things</i>
JSON	<i>JavaScript Object Notation</i>
MEMS	<i>Microelectromechanical Systems</i>
MFCC	<i>Mel-frequency cepstral coefficients</i>
MQTT	<i>Message Queue Telemetry Transport</i>
NUTS	Nomenclatura das Unidades Territoriais para Fins Estatísticos
OMS	Organização Mundial da Saúde
ProFaNE	<i>Prevention of Falls Network Europe</i>
RMS	<i>Root Mean Square</i>
RNC	Rede Neural Convolutacional
RNN	Redes Neurais Recorrentes
ROC	<i>Receiver Operating Characteristic</i>
SNS	Serviço Nacional de Saúde

Capítulo 1

Introdução

Este capítulo, tem por objetivo elaborar a introdução desta dissertação, apresentando o enquadramento do tema, a descrição do problema no contexto do envelhecimento da população e a motivação para minimizar os danos das quedas em ambientes residenciais. Também são fornecidas nesta secção a enumeração dos objetivos a alcançar e a descrição da estrutura do documento.

1.1 Contextualização

“A fall is an unexpected event in which the participant comes to rest on the ground, floor or lower without know loss of consciousness.” (Archcare, 2010).

De acordo com a Organização Mundial da Saúde (OMS) e a Prevention of Falls Network Europe (ProFaNE), queda é um evento que leva uma pessoa inadvertidamente ao chão ou a outro nível inferior, excluindo situações intencionais (WHO, 2020), sendo este conceito mais simples e utilizado em trabalhos de investigação. As quedas ocorrem em todas as faixas etárias devido à perda de equilíbrio ou à incapacidade em recuperá-lo. No entanto, é na população mais idosa que a prevalência do risco de queda e os danos daí resultantes são maiores. As quedas estão na origem de uma significativa morbidade ou mortalidade, sendo uma das principais causas de internamento hospitalar. Em consequência, aumentam os custos diretos de tratamentos e custos indiretos, perda de produtividade e absentismo, com impacto económico nas famílias e na sociedade. As quedas podem também originar estados de dependência, perda de autonomia, confusão, imobilização e depressão, que conduzem a várias restrições nas atividades do dia-a-dia (DGS, 2015).

O envelhecimento da população é uma realidade a nível mundial, sendo no continente europeu que se verifica uma população mais envelhecida. As pessoas com 65 anos, ou mais, residentes na Europa, no ano 1991 representavam 13,9 % da população e em 2011 representavam 17,5 %. O Eurostat prevê que esse grupo etário, passe de uma percentagem de 19,2 % em 2016, para cerca de 30 % em 2050 (DGS, 2014).

Em Portugal, o Instituto Nacional de Estatística (INE) (INE, 2017) divulgou os resultados do mais recente exercício de Projeções de População Residente – publicado a cada três anos – desagregadas por sexo e por idade, para o continente e regiões autónomas NUTS II¹. O presente exercício de Projeções de População Residente 2018-2080 segue o método das componentes por coorte, e tem como população de base, a estimativa provisória de população residente em 31 de dezembro de 2018. Assim, em 2080, de acordo com o resumo do cenário central de projeção:

- A população em Portugal diminuirá, dos atuais 10,3 para 8,2 milhões de pessoas;
- O número de jovens diminuirá de 1,4 para cerca de 1,0 milhões;
- O número de idosos (65 e mais anos) passará de 2,2 para 3,0 milhões;
- O índice de envelhecimento em Portugal passará de 159 para 300 idosos por cada 100 jovens, em 2080. A região mais envelhecida em 2080 será a Região Autónoma da Madeira, e a região menos envelhecida será o Algarve, com um índice de 204.
- A população em idade ativa (15 a 64 anos) diminuirá de 6,6 milhões para 4,2 milhões de pessoas;
- O índice de sustentabilidade potencial passará de 259 para 138 pessoas em idade ativa, por cada 100 idosos, entre 2018 e 2080.

Estima-se que, a nível mundial, cerca de 30 % das pessoas com mais de 65 anos de idade sofram quedas, sendo que para pessoas com mais de 70 anos estes valores aumentam para 40 %, verificando-se com efeito, que a ocorrência das quedas aumenta com a idade e o nível de fragilidade da pessoa (WHO, 2008).

A OMS refere ainda, que a prevalência de quedas na população residente em lares é superior àquela que vive na comunidade. Entre 30 a 50 % da população residente em instituições de cuidados continuados de longa duração sofre uma queda por ano, e cerca de 40 % tem mais do que uma queda (DGS, 2015).

De acordo com o relatório de Epidemiologia e Vigilância dos Traumatismos e Acidentes (Evita), 21 % do total de incidentes notificados são incidentes relacionados com quedas (Contreiras & Rodrigues, 2014). Os mecanismos de lesão que mais contribuíram para o número de Acidentes Domésticos e de Lazer (ADL), são as quedas, destacando-se de forma pronunciada com 68,7 % (A. I. F. Costa, 2019).

Considerando os registos clínicos das urgências de unidades de saúde do Serviço Nacional de Saúde (SNS) (Figura 1.1), verifica-se que nos grupos etários dos 0 aos 44 anos, existe uma maior percentagem de quedas no sexo masculino, enquanto que nos grupos etários acima dos 45 anos existe uma percentagem maior no sexo feminino (A. I. F. Costa, 2019). De salientar que acima dos 65 anos, a percentagem de quedas quase que duplica.

¹NUTS II é constituído por sete unidades, cinco regiões no continente e os territórios dos Açores e Madeira.

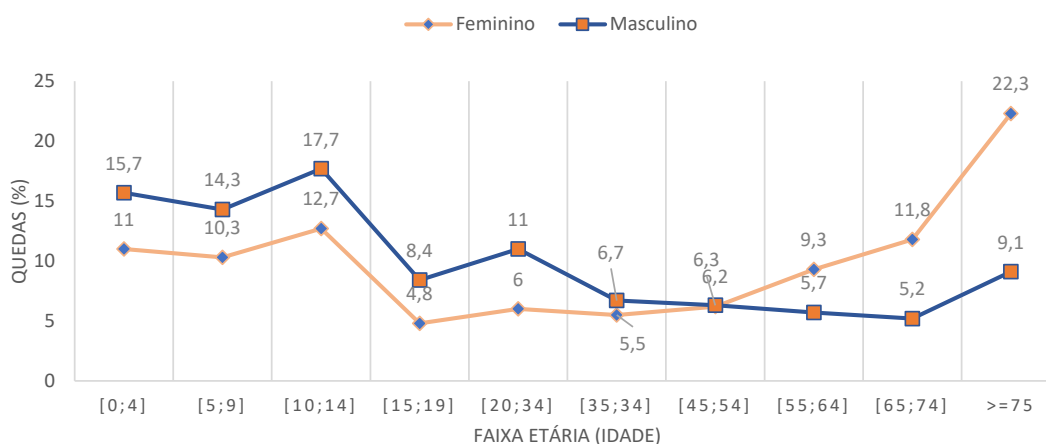


Figura 1.1: Percentagem de quedas por grupo etário (Contreiras & Rodrigues, 2014).

No final de 2017, o Serviço Nacional de Saúde (SNS) lançou um livro intitulado “Tropeções, quedas e trambolhões” (SNS, 2017), onde refere que as quedas são o acidente mais frequente em casa sendo a principal causa de morte acidental dos idosos (pessoas com mais de 65 anos). Os números apresentados no mesmo livro revelam que 3 % dos internamentos de pessoas com mais de 65 anos em Portugal tiveram origem em quedas e cada internamento teve uma duração média de 13 dias. Das pessoas internadas 6 % morrem ainda no hospital.

Extrapolando as estatísticas para o contexto atual, e segundo dados do INE (INE, 2017), se em Portugal existirem atualmente 2 244 225 idosos, durante o ano corrente 67 327 serão internadas por motivo de queda e destes, 4040 acabarão por falecer no hospital. As quedas têm diferentes causas, e segundo o manual de utilização elaborado por (Luís Carvalho & Cruz, 2015), estas podem ser classificadas em:

- Quedas acidentais – Acontecem por fatores externos em pessoas sem risco de queda, não são previsíveis. Para a sua prevenção as medidas passam por minimizar os riscos;
- Quedas fisiológicas não antecipáveis – Ocorrem também em pessoas sem risco de queda, mas acontecem pela primeira vez devido a fatores fisiológicos, como convulsões ou fraturas patológicas. Representam acerca de 8 % do total das quedas;
- Quedas fisiológicas antecipáveis – Surgem em indivíduos que apresentam potencial risco de queda, devido a existência de alterações fisiológicas. Apesar de constituírem quase 80 % do total de quedas, podem ser evitadas com a aplicação da Escala de Quedas de Morse (EQM) (Morse, 2008).

Relativamente ao tipo de quedas vivenciado pelos idosos, apenas alguns investigadores referiram que as quedas ocorreram maioritariamente da própria altura do idoso (A. I. F. Costa, 2019), ou seja, o idoso sofre uma queda no nível onde se encontra. Quanto à localização das quedas, é consensual que ocorrem maioritariamente no interior do domicílio.

A atividade no momento da queda, mencionada como mais frequente é a “andar” (A. I. F. Costa, 2019). Os acidentes representam a quinta causa de morte nos indivíduos com idade igual ou superior a 65 anos. As quedas representam dois terços destas mortes acidentais. A taxa de mortalidade aumenta exponencialmente com a idade em ambos os sexos, sendo mais elevada no grupo etário dos 85 anos ou mais. O género masculino apresenta maior taxa de mortalidade (Gomes, 2015). As pessoas frequentemente ficam involuntariamente no chão por um longo período após a queda, desenvolvendo outras complicações não diretamente relacionadas com a queda. Isso é conhecido na comunidade médica como mentira longa (Madarshahian, Caicedo, & Arocha Zambrana, 2016).

Ainda segundo a OMS, os fatores de risco associados às quedas podem ser multifatoriais e refletem a multiplicidade de determinantes da saúde que, direta ou indiretamente, afetam o bem-estar. Estes fatores podem ser biológicos, como é o caso da idade e condições de saúde agudas ou crónicas, comportamentais, socioeconómicos, como é o caso do isolamento social, fraca rede de apoio social, baixos rendimentos e, por último, ambientais, como é o caso, nomeadamente, dos perigos existentes no ambiente envolvente, na inexistência de estruturas de apoio à mobilidade ou nas barreiras à mobilidade no espaço físico. Quanto mais fatores de risco uma pessoa tiver, maior é o risco de queda (DGS, 2015).

Sobre a identificação de idosos em risco de queda, um estudo elaborado em Portugal (Gomes, 2015), concluiu que “fatores intrínsecos incluem a idade avançada, o género feminino, a raça caucasiana, a história de quedas anteriores e a presença de doenças agudas e/ou crónicas” e os “fatores extrínsecos os riscos encontrados no ambiente, a polifarmácia, a toma de fármacos psicotrópicos e o contexto socioeconómico do idoso”, para além disso “fatores comportamentais englobam a atitude sedentária, o consumo de bebidas alcoólicas e o calçado inadequado”.

De acordo com as categorias da NANDA-I (Sousa et al., 2017), identificaram-se cerca de 50 fatores de risco de queda, os quais, foram organizados:

- Pessoal – Idade maior ou igual a 65 anos, história de quedas, viver sozinho, prótese no membro inferior, uso de auxiliar de marcha, género feminino, uso de chinelos;
- Ambiental – Ambiente desorganizado, iluminação insuficiente, material antiderrapante insuficiente no WC, ausência de barras de apoio e corrimão/obstáculo da soleira da porta;
- Agente farmacológico – Fármaco, polimedicação, anti hipertensor, psicofármaco;
- Cognitivo – Alteração na função cognitiva, diminuição das funções executivas;
- Fisiológico – Glicémia, artrite, diarreia, dificuldade na marcha, compromisso do equilíbrio e da mobilidade, incontinência, hipotensão ortostática, insónia, urgência urinária, doença vascular, compromisso visual;

- Comorbilidade – Doença crónica, dor crónica, hipertensão arterial, função sensório-motor reduzida, osteoporose, insuficiência de vitamina D, obesidade, tonturas, perímetro abdominal elevado, síndrome metabólico, doença pulmonar obstrutiva crónica, baixo nível de albumina sérica.

De acordo com Classificação Internacional para a Prática de Enfermagem (CIPE), confusão, é um “pensamento distorcido: memória comprometida, com desorientação em relação à pessoa, local ou tempo” (A. Costa, Amaral, Sequeira, & et. al., 2018). No estudo (Hitcho et al., 2004), quase metade dos doentes que sofreram quedas estavam confusos. As pessoas com demência, como os pacientes com Alzheimer, correm maior risco de cair devido aos seus padrões de marcha (Shaw, 2007).

1.2 Motivação

Na operação “Censos Sénior 2019”, a GNR (Guarda Nacional Republicana) sinalizou 41 868 idosos a viverem sozinhos e/ou isolados ou em situação de vulnerabilidade devido à sua condição física, psicológica ou outra que possa colocar a sua segurança em causa (Expresso, 2019). Em quedas graves, 80 % dos idosos não conseguem levantar-se sozinhos, se a imobilização demorar até uma hora, a mortalidade é de 12 %, aumentando para 67 % se o socorro acontecer após as 72 horas. Mesmo que a queda em si não cause ferimentos, ficar deitado no chão por um longo período pode provocar úlceras de pressão, desidratação, necrose muscular, hipotermia ou em última instância pneumonia. A deteção de quedas de forma “automática” previne assim consequências graves, permitindo o socorro à vítima atempadamente (Vigilio Vigifall, 2010).

Apesar de existirem atualmente produtos que detetam quedas e as comunicam a centros de informação ou aos serviços de emergência, todos eles apresentam vulnerabilidades que os levam a serem pouco usados ou até mesmo ignorados. As opções que dependem do utilizador, como dispositivos *wereables*, sofrem de limitações tais como a pessoa atuar o dispositivo inadvertidamente com um movimento abrupto provocando a deteção de falsa queda. A deteção de quedas através de meios independentes do utilizador, na maioria das vezes, utiliza câmaras de infravermelhos para monitorizar o comportamento dos utilizadores e detetar eventos de queda com técnicas de visão computacional. No entanto, o uso de câmaras provoca constrangimentos, uma vez que os residentes têm a sensação de “ser observados”.

O progresso para novos métodos sem câmaras, foi feito através da utilização de acelerómetros, implementados no pavimento para capturar vibrações provocadas no chão, por atividades humanas. A existência de atividades diárias dificulta, a forma como lidar com falhas, pois uma falha pode significar a morte do residente. Subsequentemente é necessário a utilização de mecanismos de redundância, como por exemplo, a utilização de sensores de diferentes tipo e independentes e a sua classificação com algoritmos de aprendizagem.

Em consonância com o aumento do número de idosos, cresce de forma exponencial o número de dispositivos com poder de computação, comunicação e capacidade sensorial que estão presentes no dia a dia, principalmente os dispositivos dotados de tecnologias de comunicação sem fio. A possibilidade de adquirir uma maior quantidade de dados de diversos cenários nos quais estão presentes, criou um paradigma que se tornou bastante importante, conhecido por IoT (Internet das Coisas). De acordo com a literatura, um desafio para os sistemas de detecção de quedas está na aceitação da tecnologia pelo utilizador (Mubashir, Shao, & Seed, 2013), ou seja, caso sinta que a sua privacidade esteja comprometida, esta tecnologia ao ser utilizada, deixa de ser viável.

Por todos estes constrangimentos, cresceu a motivação para o desenvolvimento de uma solução acessível, integrada no contexto/ambiente e que permita a classificação inteligente usando redes neuronais.

1.3 Objetivos

O objetivo abrangente desta dissertação visa a conceção e implementação de uma plataforma de desenvolvimento de baixo custo, não intrusiva, que combine sensores inerciais, de som e de movimento para aquisição de dados numa divisão.

A solução de AAL (*Ambient Assisted Living*) a desenvolver irá possuir uma arquitetura baseada em *edge computing*, *fog computing* e *cloud computing*, com a finalidade de detetar e distinguir quedas de não quedas com suporte em aprendizagem automática.

Esta solução possibilitará a leitura e registo de séries temporais com o intuito de desenvolver uma base de conhecimento para classificação e treino de um sistema de aprendizagem. No sentido de alcançar o objetivo principal podem ser enumerados vários subobjetivos:

- Análise do estado da arte referente a vibrações e a sua medição;
- Análise de soluções para detecção de quedas;
- Estudo de séries temporais e sistemas de aprendizagem;
- Desenho de uma solução capaz de detetar quedas;
- Implementação de um protótipo para aquisição de dados;
- Descrição e análise do conjunto de dados;
- Teste da solução.

1.4 Estrutura da Dissertação

Esta dissertação é composta por cinco capítulos organizados em secções e subsecções. Após o presente capítulo de introdução, o capítulo 2 apresenta um levantamento do estado de arte onde são abordados diversos assuntos relacionados com sistemas de detecção e medição de vibrações; sistemas de detecção de quedas baseados em análise de séries temporais e sistemas de aprendizagem.

O capítulo 3 incorpora a solução para o problema desta dissertação, apresentando a arquitetura, e conectividades do dispositivo proposto e o processo de aquisição de dados de vibrações para classificação de queda ou não queda.

O capítulo 4 contém a descrição e análise do conjunto de dados obtidos nos ensaios de quedas. Na sequência dos atributos e recursos extraídos, com base em métodos matemáticos será feito o treino e avaliação de funções de classificação para os modelos de aprendizagem máquina.

Por fim, o capítulo 5 apresenta as restrições inevitáveis do projeto e as principais conclusões enquadradas em função dos objetivos propostos. No sentido da prossecução do trabalho realizado, será sugerida a evolução futura.

Capítulo 2

Estado da Arte

A vibração no piso gerada por cargas de impacto, é um fenómeno que depende das estruturas envolvidas, pelo que, o registo e processamento para monitorizar quedas é comprovadamente, uma tarefa difícil e recente. No estado da arte desta dissertação, a revisão de literatura e a introdução dos conceitos chave apresentam-se em cinco secções, antecedendo a solução proposta

2.1 Vibrações

“Vibration: The variation with time of the magnitude of a quantity which is descriptive of the motion or position of a mechanical system, when the magnitude is alternately greater and smaller than some average value or reference.”
(ISO, 1975).

De acordo com a definição anterior, uma vibração mecânica é o movimento oscilatório observado numa partícula ou corpo, em torno de uma posição de equilíbrio (Correia, 2007). Este fenómeno mecânico é a resposta do sistema quando deslocado do equilíbrio estático por uma ação externa, força ou momento. O sistema é deslocado da sua posição de equilíbrio, através de permutações da energia potencial e cinética do sistema cujo valor diminuirá com o atrito (Sampaio, 2018). As forças atuantes podem ser pontuais ou contínuas no tempo, e quando estas perturbações terminam, o corpo tende a restaurar a condição inicial. A vibração dos sistemas mecânicos está relacionada com a massa (ou seja, inércia), o amortecimento e a rigidez. O conceito de grau de liberdade é normalmente invocado na descrição de um sistema vibratório (Rao, 2010).

No modelo de um grau de liberdade, é necessária uma coordenada independente para determinar com exatidão as posições das partes que constituem o sistema, num determinado momento (ou seja, período de tempo). A energia é armazenada na massa e na mola, sob a forma de energia cinética e potencial, respetivamente. A energia é fornecida ao sistema pela excitação, e é dissipada no amortecedor (Figura 2.1) (Sampaio, 2018).




Figura 2.1: Modelo de um sistema mecânico de um grau de liberdade (Sampaio, 2018).

Em cada instante pode ser medido o afastamento (ou seja, amplitude) do ponto ou sistema em relação à posição de referência, calculada e visualizada a aceleração através do *ViewWave*¹ (Figura 2.2).




Figura 2.2: Aceleração eixo x (em cima) e y (em baixo) (*ViewWave*).

O movimento da partícula pode ser caracterizado pelo deslocamento (d), velocidade (v) e aceleração (a), sendo comum apresentarem-se as vibrações em decibéis, Equação 2.1:

$$L_{dB} = 20 \log \left(\frac{L_1}{L_{ref}} \right) \quad (2.1)$$

onde L_{dB} é o nível de sinal em dB, L_1 pode ser o nível de vibração em aceleração, velocidade ou deslocamento e L_{ref} o nível de referência, equivalente a 0 dB.

A forma mais simples de vibração é a provocada por um impacto num sistema não amortecido de um grau de liberdade, denominada vibração harmónica. Todas as outras

¹ *ViewWave* é um *software* (<https://smo.kenken.go.jp/kashima/viewwave>), que permite visualizar gráficos de dados de movimento forte, como sismos.

formas de vibração podem ser resumidas à soma de vibrações harmônicas, cuja representação do deslocamento pode ser dada pela Equação 2.2:

$$x(t) = A \cos(2\pi ft + \alpha) \quad (2.2)$$

onde A é a amplitude máxima da função harmônica, f é a frequência da função, α é a fase.

$$\text{Velocidade: } \dot{x}(t) = -2\pi f A \sin(2\pi ft + \alpha) \quad (2.3)$$

$$\text{Aceleração: } \ddot{x}(t) = -(2\pi f)^2 A \cos(2\pi ft + \alpha) \quad (2.4)$$

2.1.1 Vibração gerada por cargas de impacto

As vibrações exteriores à edificação, propagam-se do solo até à estrutura, provocadas na maioria das vezes pelo tráfego rodoviário, presença de obras de construção nas imediações ou até o vento. Os equipamentos presentes nos edifícios também são fontes de vibração, que devido ao contacto com o pavimento ou paredes, as transmitem pela estrutura.

Nos edifícios, as vibrações migram através de vigas, colunas e placas. As divisórias dos compartimentos são placas na forma de paredes e pavimentos. As placas têm por isso um papel importante na propagação de vibrações estruturais e radiação sonora, no instante em que acontece uma queda. A maioria das paredes e pavimentos podem ser analisados como placas maciças. No entanto, existem outros tipos de placas a considerar, como as paredes em placa de gesso hidrofugada (vulgo, pladur) perfiladas com vazios, ou executadas em alvenaria de tijolo com furação. Considerando as placas como maciças, podem obter-se valores de referência para os restantes tipos de placas (Carl Hopkins, 2007). Uma placa tem um número infinito de modos de vibração, tendo assim um número infinito de graus de liberdade, o que complica a análise do estudo das vibrações.

Assim, o comportamento dinâmico de um sistema resulta da convicção dos vários modos de vibração. A análise modal permite a descrição matemática do comportamento e das características dinâmicas de uma estrutura (Ewins, 1984). Apesar da análise dos modos locais ser fundamental na análise da vibração e do som, é limitada porque despreza o sistema de paredes e pavimentos com as quais a placa está acoplada (Carl Hopkins, 2007).

A vibração pode ser caracterizada pelo seu comportamento ao longo do tempo, como transitória (ou seja, impulsiva), intermitente ou contínua. As vibrações transitórias são vibrações provocadas por choques ou cargas de impacto, e caracterizam-se pela rápida formação de um pico de amplitude seguida de um decréscimo, com a possibilidade de aparecimento de vários ciclos de vibração, consoante o amortecimento e a sua frequência (M. Griffin, 1996). Os materiais de que são compostos os componentes que entram em choque, influenciam as características do impacto e deste modo a resposta do sistema.

Considere-se um martelo de impacto (Figura 2.3) com uma ponta rígida, de alumínio, o que, gera uma força de curta duração e grande amplitude e um impulso mais instantâneo, quando comparado com uma ponta de borracha (Figura 2.4) (Kjær, 2005).



Figura 2.3: Martelo de impacto (Kjær, 2005).

Pela aplicação da Transformada de Fourier (Figura 2.4), verifica-se que, quanto maior for o tempo de contacto da fonte de impacto com a superfície menor será o espectro de frequência da força introduzida. Ao aumentar o tempo de contacto entre o pavimento e a fonte impulsiva, está-se a diminuir a amplitude da força introduzida e o conteúdo em frequência. Os revestimentos aplicados no pavimento, provocam assim efeitos diferentes em função da sua rigidez e da natureza do corpo que provoca o impacto.

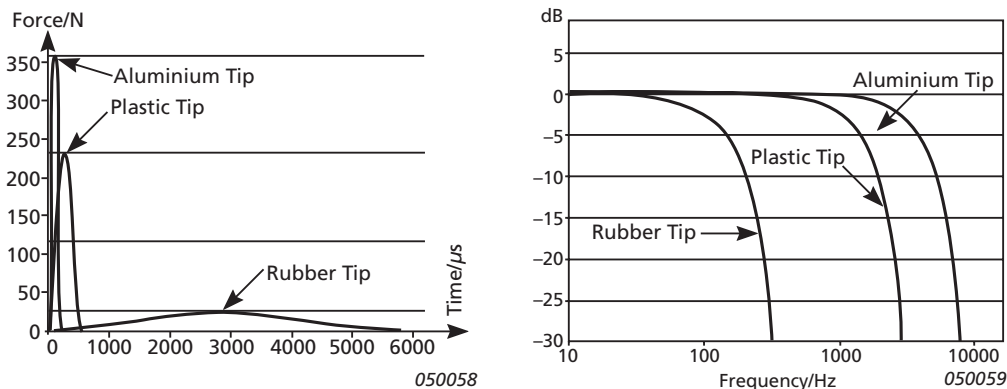


Figura 2.4: Formas de impulso para as pontas do martelo em função do tempo (à esquerda); Espectro da força de um impacto numa placa de alumínio (à direita) (Kjær, 2005).

Pode-se considerar três tipos de ondas presentes na vibração das placas: as ondas quase longitudinais, as ondas transversais e as ondas de flexão. As ondas quase longitudinais e as ondas transversais propagam-se no plano da placa, sendo mais preponderantes na transmissão de vibrações do que na radiação de som. As ondas de flexão apresentam comprimentos de onda superiores à espessura das placas provocando deslocamentos laterais superiores aos provocados pelas outras ondas, por isso, possuem um papel mais importante na radiação de ruído.

O amortecimento numa estrutura, é o mecanismo que transforma a energia da vibração em calor, provocando um decréscimo na resposta do sistema, de forma que a amplitude das vibrações desapareça.

Num pavimento o amortecimento total depende bastante dos elementos não estruturais, como o revestimento do piso e o mobiliário existente, do material do qual são feitos e das suas dimensões.

A capacidade de amortecimento pode ser calculada pelo método do decremento logarítmico, ou através do método da largura de banda de meia potência (Tadeu, 2015).

2.1.2 Radiação sonora

As vibrações de uma placa, podem gerar a radiação de som para a envolvente, relacionada com a interação entre as ondas de flexão estruturais e as ondas sonoras no meio adjacente. O som radiado pode ser diminuído se o amortecimento das placas for aumentado. Estas ondas são dispersivas e propagam-se com maior velocidade para frequências mais altas. A frequência em que a velocidade da onda de flexão iguala a velocidade de propagação do som no ar denomina-se frequência crítica (Tadeu, 2015).

No caso de placas infinitas, para comprimentos de onda da vibração da placa superiores ao comprimento de onda das ondas no meio acústico, a eficiência de radiação é superior a 1 e abaixo da frequência crítica não ocorre radiação. No caso de placas finitas, devido à reflexão das ondas de flexão nas extremidades da placa existe radiação mesmo abaixo da frequência crítica (mesmo sendo pouco eficiente). Abaixo da frequência crítica, a eficiência da radiação gerada por cada modo vai depender muito das condições fronteira do contorno da placa (Tadeu, 2015).

Se um objeto for sujeito a um impacto, este vai vibrar a uma frequência característica e a sua amplitude vai diminuindo ao longo do tempo. Se o mesmo objeto for forçado a vibrar na sua frequência natural, devido a qualquer força externa, então a amplitude de vibração irá aumentar para valores muito elevados. Este fenómeno é designado de ressonância. Normalmente as primeiras 3 ou 4 frequências naturais são as mais preocupantes, uma vez que necessitam de menor energia para surgirem.

A primeira frequência natural normalmente é definida pela Equação 2.5 expressa em rad/s, em que k é a rigidez do material em N/m, e m é a massa em kg.

$$\omega_n = 2\pi f = \sqrt{\frac{k}{m}} \quad (2.5)$$

Da equação anterior, verifica-se que aumentando a rigidez do material do objeto ou dos seus apoios aumenta-se a frequência natural, o inverso se aumentar a massa do objeto (Cabral, 2012).

O ruído produzido por uma fonte pode ser caracterizado pela potência sonora mediada em Watt ou, através do nível de potência sonora em dB. A pressão sonora num determinado ponto, depende da fonte e das características do meio envolvente como a absorção e reflexão da onda acústica (Ramos, 2019).

Assim, a pressão total resultante nesse ponto, corresponde à soma da pressão atmosférica P com a pressão devida às perturbações referidas (Figura 2.5), sendo designada por $P(t)$ (Prof. Diogo Mateus, n.d.).




Figura 2.5: Variação da pressão produzida por uma fonte sonora (som ou ruído) (Prof. Diogo Mateus, n.d.).

2.1.3 Cargas dinâmicas de atividades humanas

A maioria das fontes de vibrações dentro dos edifícios existem devido às atividades diárias dos seus ocupantes, como andar, saltar, correr, cair, arrastar uma cadeira, a queda de um objeto ou falar (Racic, Pavic, & Brownjohn, 2009).

Andar será a forma mais comum de provocar vibrações e depende do físico, da idade, frequência do passo, comprimento da passada e tempo de contacto (Bard, Davidsson, & Wernberg, 2010).

A análise do comportamento dinâmico de estruturas, quando solicitadas a ações dinâmicas induzidas por atividades humanas como exercícios aeróbicos, danças ou saltos, constituem um problema complexo nomeadamente se forem de betão armado (Mello, da Silva, Vellasco, de Andrade, & de Lima, 2008).

As cargas dinâmicas induzidas por atividades humanas, podem ser classificadas em 4 tipos: harmónicas, periódicas, transientes e impulsivas (Smith, Hicks, Devine, & Britain, 2009; Murrat, T. and Aleen, D. and Ungar, E., 1997). A dança é classificada como carga periódica e a movimentação aleatória ou esporádica de pessoas como saltar ou correr são cargas transientes (Filipa & De Oliveira, 2014). O ato de saltar é descrito na Figura 2.6. Quando o indivíduo salta e perde o contacto com o piso, a força aplicada sobre este é nula. Ao voltar ao contacto com o solo, a força aumenta até atingir o valor máximo apresentado (Murrat, T. and Aleen, D. and Ungar, E., 1997). Deste modo, conclui-se que a força é

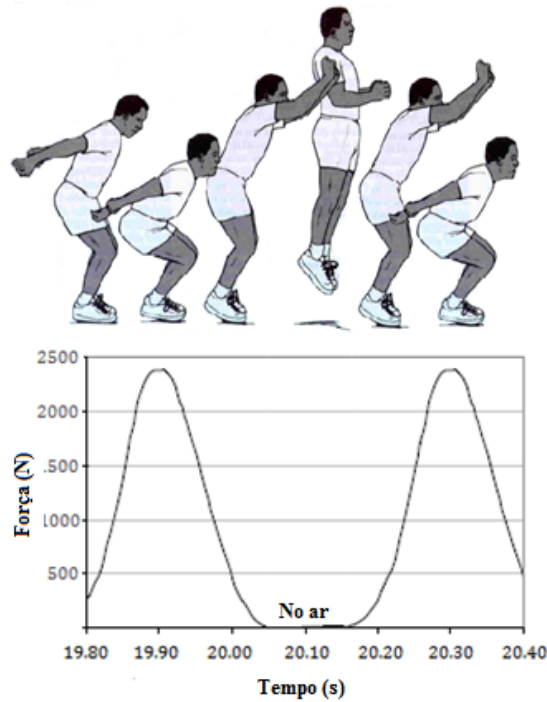


Figura 2.6: Força desenvolvida ao saltar (Filipa & De Oliveira, 2014).

inversamente proporcional ao tempo de contacto com a superfície, vide Equação 2.6.

$$F(t) = \begin{cases} K_p G \sin\left(\frac{\pi t}{t_p}\right) & 0 \leq t \leq t_p \\ 0 & t_p \leq T_p \end{cases} \quad (2.6)$$

em que,

K_p - Fator de impacto $\left(\frac{F_{\text{máx.}}}{G}\right)$; $F_{\text{máx.}}$ - Amplitude máxima de carga;

G - Peso do indivíduo; T_p - Período da atividade; t - Tempo.

Estas características foram determinadas experimentalmente a partir de ensaios do impacto do calcanhar (“heel drop”), em que se projeta o calcanhar sobre o piso após se elevar o pé até uma altura que depende do peso do indivíduo. Este ensaio serve para determinar de forma simples e rápida, as frequências naturais e acelerações de pico, (Kappos, 2001), correspondendo a frequências mais propícias à ocorrência de vibrações. O ensaio obteve excelentes resultados para frequências entre 2–15 Hz, (Blakeborough & Williams, 2003).

O teste do impacto do calcanhar, também pode ser usado para representar o modelo de carregamento das forças do movimento da caminhada. Essa carga é considerada a principal fonte de excitação durante o movimento da caminhada e produz uma resposta transiente, uma aplicação de força instantânea no sistema.

A representação gráfica, (Figura 2.7) foi ilustrada por Ohmart e Lenzen (Donahue, 1982) em medições experimentais, do impacto produzido por um calcanhar sobre o piso.




Figura 2.7: Função de impacto de calcanhar humano (Donahue, 1982).

As vibrações resultantes de carregamentos dinâmicos podem ser classificadas como movimentos determinísticos ou aleatórios. Os primeiros são as ações, cujas características são conhecidas e que se subdividem em movimentos periódicos ou não periódicos. Por outro lado, os movimentos não-periódicos, podem ser de curta duração ou impulsivos (M. Griffin, 1996). Em geral, recorrendo a um sistema de equações que regem o movimento e, diferenciando as propriedades das cargas dinâmicas e a ação do indivíduo, é possível realizar-se uma análise dinâmica da estrutura (J. D. Rodrigues, n.d.).

2.1.4 Modelo de carga de queda

Uma queda é considerada como um acontecimento com uma força igual ou inferior a $2.5 g$ (força g), pressuposto de que as pessoas sejam incapazes de executar uma ação acima desse limiar (Abbate, Avvenuti, Corsini, Light, & Vecchio, 2010). De acordo com a Equação de Torricelli (2.7), é possível calcular a velocidade de queda:

$$V = \sqrt{2gh} \quad (2.7)$$

Durante o processo de queda inconsciente, as forças externas que agem sobre o corpo humano são a gravidade e a força de suporte do solo. A força de suporte representativa de uma queda inconsciente é mostrada na (Figura 2.8). Com base na natureza das quedas humanas, o processo pode geralmente ser dividido em quatro estágios: ficar em pé, cair, impacto e repouso (Liu, Jiang, Su, Benzoni, & Maxwell, 2019).




Figura 2.8: Força do piso durante o processo de queda (ISO, 1981).

Uma queda inconsciente de dois segundos pode ser dividida da seguinte forma:

- De pé (0–0,25 s): a gravidade e a força de suporte do solo estão em estado de equilíbrio;
- Queda (0,25–0,75 s): a força do solo tem uma distribuição parabólica. No final dessa fase, o corpo está no ar (sem contato com o solo) e a força que atua no solo é zero;
- Impacto (0,75–1,75 s): o corpo humano está numa posição supina. O estado de vibração e o equilíbrio da força do corpo humano após a queda podem ser analisados através da física;
- Repouso (1,75–2 s): o corpo humano está em estado de repouso. Nesse estado, o corpo tem contacto total com o solo e sua força no solo é igual ao peso do corpo.

A norma internacional ISO 5982 (ISO, 1981) fornece um modelo de impedância de aceleração no ponto de impacto de todo o corpo. A vibração vertical, devido ao impacto, é simplificada como uma vibração livre de três graus únicos de liberdade com amortecimento sob determinadas condições iniciais. O sistema de movimento (Equação 2.8) é estabelecido conforme evidenciado na Figura 2.9, m_1 , m_2 e m_3 são a massa concentrada do quadril, costas e cabeça, respectivamente k_1 , k_2 , k_3 , c_1 , c_2 e c_3 são os coeficientes de rigidez e amortecimento correspondentes.

$$m_i \ddot{x}_i + c_i \dot{x}_i + k_i x_i = 0 \quad (2.8)$$

As condições iniciais do movimento são,

$$\ddot{x}_i(0) = g \quad \dot{x}_i(0) = \sqrt{2gh} \quad (2.9)$$

Em que, h é a distância entre o centro de gravidade do corpo e o chão, sendo $i = 1, 2$ e 3 os graus de liberdade do sistema. No equilíbrio a força F exercida pelo pavimento pode

ser obtida por,

$$F = \sum_{i=1}^3 m_i \ddot{x}_i - m_i g \quad (2.10)$$




Figura 2.9: Modelo de um corpo humano sujeito a vibração (ISO, 1981).

2.2 Medição de Vibrações

Os transdutores são equipamentos que transformam valores de variáveis físicas em sinais elétricos equivalentes, isto é, transformam uma forma de energia (mecânica) noutra forma de energia (elétrica) (J. D. Rodrigues, n.d.).

2.2.1 Modelo matemático

Os transdutores mais utilizados para medir a força dinâmica e movimento vibratório são os designados transdutores sísmicos cujo modelo matemático representa um sistema massa-mola-amortecedor com um grau de liberdade (J. D. Rodrigues, n.d.). Um transdutor de vibrações consiste numa massa m , designada por massa sísmica, num elemento elástico de rigidez k e num amortecedor de constante c no interior de uma caixa que é fixada ao sistema em vibração como ilustrado na Figura 2.10.

O movimento vibratório é medido através do deslocamento da massa do transdutor, relativamente ao sistema em vibração no qual o transdutor está montado e com o qual está solidário.

Desta forma, a caixa está sujeita ao movimento do sistema em vibração a medir, e esta vibração excita a massa suspensa do transdutor através do deslocamento imposto à caixa. Considerando um movimento harmónico $y(t) = Y \sin(\omega t)$ para o sistema em vibração, e $x(t)$ o movimento absoluto da massa, a equação de movimento da massa m escreve-se,

$$m\ddot{x} + c(\dot{x} + \dot{y}) + k(x - y) = 0 \quad (2.11)$$

Definindo o deslocamento relativo da massa em relação à caixa, $z(t)$, como sendo,

$$z(t) = x(t) - y(t) \quad (2.12)$$




Figura 2.10: Modelo do transdutor sísmico (sistema massa-mola amortecedor) (J. D. Rodrigues, n.d.).

A Equação 2.11 pode escrever-se na forma

$$m\ddot{z} + c\dot{z} + kz = -m\ddot{y} \quad (2.13)$$

Derivando em ordem ao tempo a equação $y(t)$, e substituindo em (2.13) obtém-se a seguinte Equação 2.14:

$$m\ddot{z} + c\dot{z} + kz = -m\omega^2 Y \sin(\omega t) \quad (2.14)$$

Sendo a solução estacionária da Equação 2.12 do tipo,

$$z(t) = Z(\omega) \sin(\omega t - \varphi) \quad (2.15)$$

Onde $Z(\omega)$ é a amplitude e φ o ângulo de fase.

A severidade de uma vibração, pode ser caracterizada pela sua amplitude. O movimento é transformado num sinal elétrico, caracterizado pelo seu valor RMS (*root mean square*), pico-a-pico ou pico (Kjær, 2020). Para a medição de vibrações, são indicados dois tipos de transdutores sísmicos: o vibrómetro e o acelerómetro.

O vibrómetro caracteriza-se por apresentar uma frequência natural baixa, de modo que a sua frequência natural W_n seja inferior à frequência W do movimento vibratório que se pretende medir. Ao contrário, o acelerómetro apresenta uma frequência natural elevada, de modo que a sua frequência natural W_n seja elevada comparativamente com a frequência W do movimento vibratório a medir.

Os vibrómetros são designados deste modo, como transdutores de baixa frequência enquanto que os acelerómetros são transdutores de alta frequência. Em consequência o tipo de transdutor, vibrómetro ou acelerómetro, depende da banda útil de frequências (J. D. Rodrigues, n.d.).

2.2.2 Vibrómetro

Um vibrómetro é um instrumento que mede o deslocamento de um sistema em vibração. A frequência natural do transdutor (Equação 2.5) tem de ser baixa, o que significa que a massa sísmica tem de apresentar um valor elevado, e a rigidez um valor baixo. Estes requisitos, conduzem a transdutores tipo vibrómetro de grande atravancamento, e de massa elevada, que são desadequados em determinadas aplicações (sistemas ligeiros). Para medir vibrações do solo, um transdutor deste tipo apresenta tipicamente uma frequência natural de 1 Hz. Sem qualquer tipo de mecanismo de amortecimento adicional, para além do amortecimento inerente ao próprio transdutor, a sua frequência natural não deve exceder um terço da frequência ω a medir, $\frac{\omega}{\omega_n} > 3$.

2.2.3 Acelerómetro

A aceleração é definida como a taxa de variação de velocidade, e pode ser obtida segundo uma, duas ou três direções ortogonais (x, y, z). Um acelerómetro é um instrumento que mede a aceleração de um sistema em vibração. Devido às dimensões e massa reduzidas, aliadas à sua elevada sensibilidade, os acelerómetros são os transdutores preferidos para medição de vibrações em aplicações mecânicas. A partir de registos de acelerómetros, a velocidade e o deslocamento podem ser obtidos por um processo de integração (J. D. Rodrigues, n.d.).

O método de deslocamento da massa, caracteriza de forma básica o tipo de acelerómetro, no entanto, em função do alcance, frequências naturais, amortecimentos e modos de fixação, podem ser escolhidos diversos acelerómetros: acelerómetros potenciométricos; acelerómetros de relutância variável e acelerómetros LVDT (*linear variable differential transformer*); acelerómetros capacitivos; acelerómetros piezoelétricos; acelerómetro piezoresistivo; Microacelerómetros MEMS (J. D. Rodrigues, n.d.).

- Acelerómetro potenciométrico – Este dispositivo mede o movimento utilizando um sistema de massa-mola ligado a um potenciómetro. A mudança de posição da massa traduz-se numa variação de resistência elétrica. Devido à sua frequência natural ser baixa (cerca de 30 Hz ou menos), a sua aplicação é limitada às baixas frequências, para além do alcance dinâmico também ser baixo;
- Acelerómetro LVDT – Nestes dispositivos, o núcleo da bobina é a massa sísmica e os seus deslocamentos lineares são convertidos diretamente em valores de tensão. Sendo a frequência natural inferior a 80 Hz, são aplicados em medições de vibração de baixas frequências e estacionárias;
- Acelerómetro de relutância variável – Neste caso, a massa é um íman permanente, à medida que esta massa magnética se move sob a influência da aceleração é induzida uma tensão em torno da bobina de medição. Deste modo, o acelerómetro de relutância variável produz um sinal de saída apenas quando a massa se encontra

em movimento, daí a sua aplicação em estudos de vibrações e choques refletidos em rochas subterrâneas (Braz, 2015);

- Acelerómetro capacitivo – O deslocamento de um diafragma, funcionando como massa, altera a distância entre placas ou seja, o dielétrico; a aceleração do movimento do diafragma origina a variação da capacidade, como resposta, varia o sinal à saída. Este tipo de acelerómetro, tem assim uma boa resposta em corrente contínua, tal como os acelerómetros mais potentes (Braz, 2015);
- Acelerómetros piezoelétricos – O componente fundamental é uma placa de material piezoelétrico que gera uma carga elétrica proporcional à aceleração, quando sujeito a uma tensão de compressão, de tração ou de corte. O modo como o elemento piezoelétrico é deformado, indica o tipo de configuração. Estes acelerómetros apresentam uma elevada sensibilidade, e uma elevada razão sinal-ruído. As suas reduzidas dimensões facilitam a sua utilização em pequenas áreas confinadas, e a sua reduzida massa, tipicamente de 0,2 a 20 g, permite a sua montagem em estruturas ligeiras sem afetar de modo apreciável as características dinâmicas e/ou de vibração a medir (J. D. Rodrigues, n.d.);
- Acelerómetros piezoelétricos de menores dimensões – Diferenciam-se por serem constituídos por massas sísmicas pequenas, podem apresentar frequências naturais superiores a kHz e fornecem medições precisas para componentes de frequência até 10 kHz, com distorção de fase praticamente desprezável. Os amplificadores de carga, são utilizados com os acelerómetros piezoelétricos para reduzir a perda de sensibilidade devida à capacitância no cabo de ligação do acelerómetro ao instrumento de medição, como, por exemplo, um osciloscópio ou um analisador dinâmico de sinal. A sensibilidade do acelerómetro é, geralmente, fornecida na forma de pico coulomb (pC) por unidade de aceleração (m/s^2 ou g), e o output do amplificador de carga em volt/ m/s^2 ou volt/g (J. D. Rodrigues, n.d.);
- Acelerómetro piezoresistivo – O elemento piezoelétrico é substituído por um componente piezoresistivo. A força exercida pela massa faz variar a resistência, que por sua vez é detetada por uma ponte Wheatstone, o que permite medir acelerações, para frequências até aos 0 Hz (Figueiredo, Gafaniz, Lopes, & Pereira, 2007);
- Microacelerómetros MEMS (*micro electro mechanical systems*) – Uma unidade de medição inercial, também conhecida como IMU (*inertial measurement unit*), é um dispositivo eletrónico que mede a aceleração e orientação. É composto por 3 acelerómetros, 3 giroscópios e, dependendo do título - 3 magnetómetros, um por para cada um dos três eixos: *roll*, *pitch* e *yaw* ou seja 9 DOF (*degrees Of freedom*). Existem diferentes tipos de sensores IMU: baseado em FOG (*fiber optic gyroscope*), RLG IMU (*ring laser gyroscope*) e, por último, o IMU baseado na tecnologia MEMS. Esta tecnologia garante um bom desempenho, com custos mais baixos e requisitos de baixa

energia. Os dados são enviados a 1 KHz para aplicações em tempo real (Figueiredo et al., 2007).

O sistema *Proof Mass* é suspenso por molas e move-se de forma livre, conforme o dispositivo é sujeito a aceleração. O pente fixo de elétrodos estabelece um efeito capacitivo entre ele e a massa de prova, ao movimentar, surge uma mudança na capacidade, sendo registrada e convertida por um ADC num valor digital entre 0 e 32 750. O giroscópio funciona de maneira semelhante, mas por Efeito Coriolis (SBG, n.d.). Para além da aceleração, podem ser utilizados também na medição de inclinação, rotação, vibração, colisão ou gravidade. Em aplicações médicas, os acelerómetros são muito utilizados na avaliação do movimento humano, na deteção de distúrbios de sono e na deteção de variáveis fisiológicas (Figueiredo et al., 2007).

A fixação do acelerómetro na superfície pode ser importante para obter uma boa resposta mais realista da vibração da mesma, para isso existem quatro métodos de montagem típicos (National Instruments Corp., 2020):

- Ponteiras portáteis ou de sonda;
- Magnético;
- Adesivo;
- Montagem com pino.

2.2.4 Análise de vibrações

A utilização da vibração do piso para monitorar a atividade humana é recente, os primeiros trabalhos sobre monitorização baseada em vibração VBM² para deteção de queda foram publicados em 2006 (Alwan et al., 2006) e VBM com adição de som em 2008 (Litvak, Zigel, & Gannot, 2008).

Mais recente é a integração e o uso de sensores inteligentes sem fios (Davis, Caicedo, Langevin, & Hirth, 2011; Chaudhuri, Thompson, & Demiris, 2014; Dorvash, Pakzad, Naito, Hodgson, & Yen, 2014), fornecendo uma alternativa para outros métodos já utilizados nas áreas médica e de segurança (Madarshahian et al., 2016).

Questões fundamentais como o número de sensores, a sensibilidade apropriada, e a sua distribuição espacial, ainda estão em estudo. Alguns dos desafios associados aos algoritmos para determinar as atividades humanas com base em vibrações estruturais incluem:

- A severidade do sinal depende da distância entre o sensor e a localização da atividade de interesse;
- Duas actividades diferentes podem produzir características de sinal semelhantes (ou seja, amplitude semelhante);

²VBM – *vibration-based monitoring*.

- Alterações nas condições ambientais e na utilização da estrutura podem levar a diferentes características dinâmicas do piso;
- Toda as estruturas possuem piso diferentes (tipo de revestimento ou configuração estrutural, etc.);
- Os registos podem sofrer uma relação ruído/sinal elevada.

A versão portuguesa (2007) da norma ISO 2631-1 (ISO, 1997), intitulada, Vibrações mecânicas e Choque, tem como principal objetivo, a definição de métodos de quantificação de vibração em regime de corpo inteiro relativamente à saúde, conforto, probabilidade de perceção da vibração e incidência ao enjoo ao movimento. Na análise do ponto de vista do conforto humano, são considerados dois tipos de transmissão: *Whole Body Vibration* (WBV) – vibração de corpo inteiro – transmitida através da superfície de apoio, e *Hand-Transmitted Vibration* (HTV), vibração transmitida pela mão através de um objeto (Margarido, 2013).

Uma avaliação completa da exposição à vibração, requer a medição da aceleração da vibração (m/s^2), e a combinação de vibrações em mais que uma direção. O método básico utilizado, é o da aceleração ponderada, cujo valor total nas coordenadas ortogonais, foi calculado pela Equação 2.16.

$$a_v = \sqrt{k_x^2 \cdot a_{wx}^2 + k_y^2 \cdot a_{wy}^2 + k_z^2 \cdot a_{wz}^2} \quad (2.16)$$

Sendo awx , awy e awz as acelerações ponderadas dos eixos ortogonais, x , y e z , respetivamente, e k_x , k_y e k_z são fatores multiplicadores, onde k_x e $k_y=1,4$ e $k_z=1,0$ (ISO, 1980). A direção da exposição à vibração é um parâmetro importante sendo medida em direções definidas. Pela mesma razão, as frequências de vibração e a duração da exposição também são determinadas (Margarido, 2013).

2.3 Sistemas de detecção de quedas

O sistema de resposta a emergências pessoais (PERS) ou sistema de alarme pessoal (PAS), consiste num pequeno transmissor acionado por um botão, sendo dos primeiros dispositivos de sinalização desenvolvido nos anos 80, para ajudar os pacientes a obter ajuda imediata (Madarshahian et al., 2016). Apesar de fáceis de usar e de baixo custo, nem sempre as pessoas conseguem pressionar o botão após o incidente – considerando que o impacto pode provocar inconsciência, lesões graves e pânico. Ao contrário do PERS, os sensores vestíveis com sensores inerciais, não exigem que o paciente aperte um botão. Mas ambos dependem da sua colocação no utilizador e necessitam de baterias.

Os sistemas baseados na visão, surgem assim, como os sistemas mais autónomos para detecção de quedas e monitorização da atividade humana em geral. Porém, a maioria das pessoas não se sente confortável com a sensação de serem observadas, especialmente em

lugares como quartos ou casas de banho. Deste modo, o registo e análise das vibrações do piso fornecem uma alternativa aos PERS ou aos sensores baseados em visão e *wearable*.

A monitorização VBM evita os desafios de conformidade de sensores *wearable* e PERS, e não tem as preocupações de privacidade dos sistemas de visão. Por outro lado, pode ser implementada na análise da marcha para monitorizar as condições do paciente (Madarshahian et al., 2016).

2.3.1 Classificação das tecnologias de deteção de quedas

No estudo (Vallabh & Malekian, 2018) é considerado comum, a maioria dos autores abordarem um sistema de deteção de quedas baseado na seguinte sequência de processos, Figura 2.11: i) Recolha de dados; ii) Extração de Recursos; iii) Seleção de Recursos; iv) Classificação e v) Testes e Avaliação.




Figura 2.11: Sistema de deteção de quedas (Vallabh & Malekian, 2018).

Pelo que, a deteção de quedas deverá começar pela aquisição de dados, através dos sensores. Na secção seguinte, veremos que estes sensores podem ser classificados em sensores *wearables*, sensores de contexto/ambiente e sensores baseados em visão. De seguida é feita a extração de recursos, a partir dos dados brutos adquiridos, com o intuito de detetar sinais com atributos que à partida consistem em informação sem sentido; existem atributos relacionados com ADL (*activities of daily living*), ou quedas. A extração é geralmente realizada numa janela temporal, permitindo a criação de um conjunto de valores dos quais um único recurso pode ser extraído, por exemplo, o índice máximo SMV (*signal magnitude vector*) (Equação 2.17), para cada registo de atividade (Vallabh, Malekian, Ye, & Bogatinoska, 2016).

O SMV permite obter as mudanças de movimento em todas as direções de forma mais ampla, do que se considerarmos cada componente da aceleração em separado (Vallabh et al., 2016).

$$SMV = D = \sqrt{a_x^2 + a_y^2 + a_z^2} \quad (2.17)$$

Para além das características estatísticas comuns dos sinais de aceleração no domínio temporal, como o valor máximo, mínimo, média ou desvio padrão, pode ser relevante conhecer no domínio da frequência, a *skewness*, *kurtosis*, a energia ou a correlação sensorial.

A seleção de recursos permite encontrar características, que descrevem melhor os dados, desprezando as características redundantes, em função disso, podemos melhorar a velocidade computacional e precisão da previsão do algoritmo de aprendizagem máquina.

A classificação implica, que os dados fornecidos sejam identificados com as características ou atributos mais importantes, separados em categorias distintas, de forma a atribuir um valor a queda, e outro valor a não queda. Em função disso, o modelo de classificação pode indicar quatro possíveis resultados (Delahoz & Labrador, 2014), conforme apresentado na Tabela 2.1:

Tabela 2.1: Resultados de queda.

	A Queda Acontece	Não Acontece Queda
Queda detetada	TP	FP
Queda não detetada	FN	TN

A interpretação dos resultados da Tabela 2.1 permite avaliar o desempenho do sistema de detecção de queda:

- TP (*true positive*) – deteta corretamente uma queda, quando a queda ocorreu;
- FP (*false positive*) – uma queda é detetada quando nenhuma queda ocorreu;
- TN (*true negative*) – não é deteta queda e nenhuma queda ocorreu;
- FN (*false negative*) – não deteta queda, mas a queda ocorreu.

Os classificadores de detecção de quedas podem ser divididos em dois tipos, baseado em limiares ou baseado em regras e algoritmos de aprendizagem máquina (Vallabh & Malekian, 2018). Nos sistemas que fazem uso de acelerómetros, é considerado um parâmetro limiar da magnitude da aceleração absoluta ou da soma vetorial para detetar quedas comparando-o com o valor predefinido. O valor predefinido é calculado e determinado a partir de um sinal de queda, usando técnicas de análise de conhecimentos de domínios ou de análise de dados, como tal são necessários vários ensaios de quedas. A facilidade em implementar, o reduzido consumo de energia e baixo poder computacional são as vantagens do limiar.

O problema dos sistemas com limiares é a incapacidade em obter com rigor os valores predefinidos, o que resulta em altas taxas de falsas quedas como correr ou saltar, motivando os investigadores a enveredar mais pela aprendizagem automática com classificadores eficientes.

Os algoritmos de aprendizagem automática, apesar de complexos quando comparados com a implementação com limiar, baseiam-se habitualmente em decisões aplicadas à postura, o que resulta em taxas de detecção de quedas mais elevadas (Vallabh & Malekian, 2018). Outra vantagem destes algoritmos, é que podem reconhecer diferentes tipos de quedas; a precisão alcançada é mais alta comparando com os métodos-limiar; melhora a gestão de anomalias (como ruído e interrupções); pode detetar padrões nos sinais. A desvantagem do algoritmo de aprendizagem automática, é a necessidade de elevadas quantidades de dados para treino, e requer um tratamento pesado.

Nos modelos sem supervisão um dos métodos de classificação de quedas é a máquina vetorial de suporte de uma classe, já os modelos supervisionados incluem a *support vector machine* (SVM), *decision threshold tree*, Naive Bayes, *least squares method* (LSM), *k-nearest neighbor* (k-NN), e *artificial neural networks* (ANNs) (Vallabh et al., 2016).

O teste típico do sistema consiste em executar o método de validação cruzada *leave one-out* (Ren & Peng, 2019). Este método é um caso específico do *k-fold*, com *k* igual ao número total de dados *N*. O conjunto de dados também pode ser dividido em 70 % para a formação do classificador e 30 % para testes (Vallabh & Malekian, 2018).

Dependendo dos sensores e algoritmos utilizados, as abordagens sobre detecção de queda podem ser classificadas em três categorias, como demonstra a Figura 2.12, baseada em dispositivos *wearables*, baseado em sensores de ambiente e com base em visão, ou seja, câmaras (Nizam, Haji Mohd, & Abdul Jamil, 2016). Considerando estas categorias, os dispositivos *wearables* podem ser divididos em dispositivos baseados na postura e em movimento. Os dispositivos de ambiente podem ser classificados ainda mais, em sensores baseados na presença e na postura. E os sistemas baseados em câmaras, podem ser categorizados em classes como mudança de forma, inatividade e movimento 3D da cabeça. A aquisição de dados pode variar de um sensor para vários sensores e de uma câmara fixa para várias câmaras, incluindo câmaras móveis.

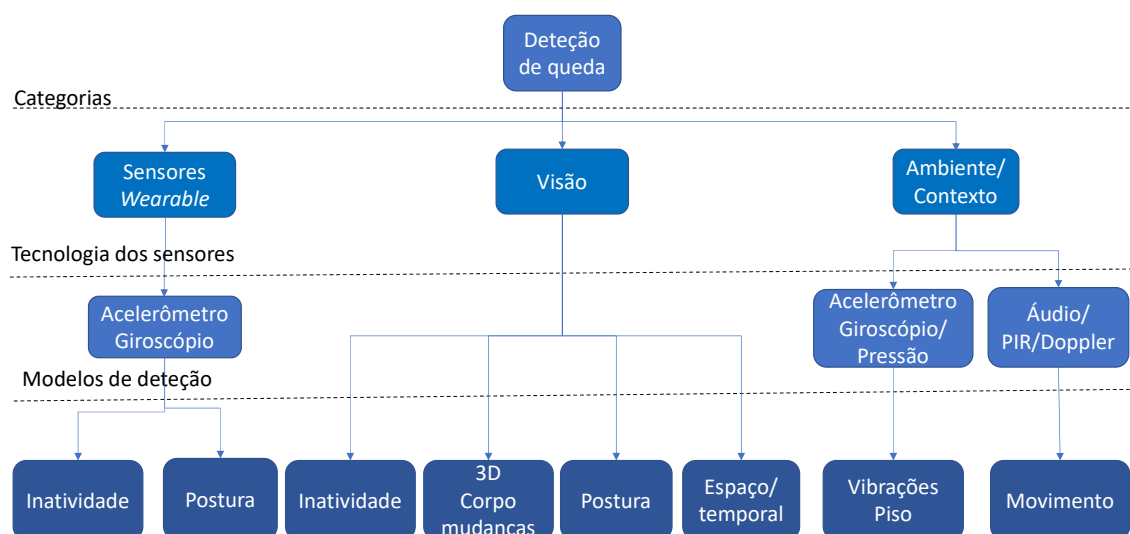


Figura 2.12: Modelo de classificação de quedas (Nizam et al., 2016).

Os dispositivos de detecção de queda vestíveis, como acelerômetros ou giroscópios são usados por baixo ou por cima das roupas da pessoa (Nizam et al., 2016). A pessoa transporta o dispositivo com ele, durante todo o tempo. Apesar de se deslocarem com o dispositivo de monitorização e geolocalização para todo o lado, na realidade existem limitações, como o desconforto com o dispositivo, esquecimento em o colocar, ou carregar a bateria.

Os sistemas de detecção de queda com reconhecimento de contexto incluem sensores que

são implantados no ambiente em redor das pessoas para detetar uma queda. Os sistemas projetados com base nessa classe de tecnologia podem incorporar sensores de pressão e sensores de vibração no piso, sensores infravermelhos e microfones. O conjunto destes sensores fazem a aquisição dos dados e enviam para um computador de forma a serem processados e analisados.

Com base em certos valores e condições de limite, o algoritmo em execução no computador, decide se uma queda ocorreu ou não. Esses sistemas dependem do ambiente, já que cada casa tem um piso diferente exigindo configurações específicas para cada instalação. Algoritmos de classificação de aprendizagem máquina estão também a ser utilizados para a classificação da atividade humana em duas classes (queda e não queda).

Os sistemas acústicos, usam vários microfones instalados no ambiente para capturar o som gerado durante uma queda. Ao comparar a magnitude e a direção do som gerado (Popescu & Mahnot, 2009), com um valor limite especificado, os sistemas detetam se uma queda ocorreu ou não. Devido ao ruído excessivo gerado pelas atividades quotidianas, a degradação da qualidade do sinal recebido pelo sensor, resulta em deteções de falsas quedas. Em alguns estudos, são aplicadas as funcionalidades do MFCC (*Mel-frequency cepstral coefficients*) na captura do som dos movimentos para detetar quedas. As características do MFCC são extraídas através da remoção do componente de alta frequência (Salman Khan, Yu, Feng, Wang, & Chambers, 2015). A aplicação da técnica *beamforming* ao sinal sonoro pode aumentar o sinal desejado e reduzir a interferência da televisão, rádio ou toque de telefone (Vallabh & Malekian, 2018). Os estudos que fazem uso de manequins como a boneca Randy Rescue para imitar quedas humanas, não conseguem replicar sons realistas devido à pele dura e à falta de ossos nos manequins (Popescu & Mahnot, 2009).

Os sistemas baseados em visão beneficiam da variação abrupta dos padrões de postura e forma do sujeito durante e após uma queda (Delahoz & Labrador, 2014). Essas mudanças repentinas são fundamentais para determinar se ocorreu uma queda. Os algoritmos baseados em câmaras processam imagens pixel por pixel usando diferentes abordagens, alguns sistemas baseiam-se na silhueta do esqueleto humano (Rougier, Meunier, St-Arnaud, & Rousseau, 2007), outros em características mais simples como o ângulo de queda, ou histograma de projeção vertical.

Para além das questões de oclusão, e várias pessoas no local, as questões de privacidade são uma das maiores preocupações dos sistemas baseados em câmaras. Para atenuar esse problema, (Ozcan, Mahabalagiri, Casares, & Velipasalar, 2013) desenvolveu um sistema de deteção de queda que utiliza uma câmara inteligente montada na cintura do indivíduo, não gravando assim as imagens da pessoa, mas o ambiente ao seu redor. Outras soluções possíveis usam câmaras infravermelhas e câmaras térmicas (Delahoz & Labrador, 2014).

2.3.2 Sistemas que utilizam Aprendizagem Máquina

Como referido, os algoritmos baseados em limites são mais simples e utilizados na maioria das vezes na deteção de queda. A Tabela 2.2 resume os sistemas baseados no

ambiente que estão a utilizar diferentes algoritmos para fins de classificação.

Tabela 2.2: Sistemas baseados em ambiente (Singh et al., 2019).

Autor	Sensores	Recursos	Classificação
Alwan et al.(2006)	Sensor piezoelétrico	Padrão de vibração do piso	Baseado no <i>Threshold</i>
Zigel et al. (2009)	Sensor de chão e microfone	Espectro de resposta ao impacto, MFCC	Classificação de Bayes
Rimminen et al. (2010)	Sensor de piso e sensor de imagem de campo próximo	Posição com base no piso de imagem de campo próximo	Filtro Bayesiano
Mastorakis and Makris (2014)	Sensor KINECT	Posição de uma pessoa (largura, altura, profundidade)	Detecção de inatividade na fase pós-queda
Tzeng et al. (2010)	Sensores de pressão e infravermelho	Desvio Padrão do Histograma de Projeção Vertical, Desvio Padrão do Histograma de Projeção Horizontal, Proporção	Sinal de pressão do piso combinado com um sinal infravermelho
Toreyin et al. (2007)	Sensor de som, piso, infravermelho	Extração de característica baseada em wavelet	<i>Hidden Markov Model</i> (HMM)
Kim and Ling (2009)	Radar Doppler	<i>Four-fold cross validation</i>	SVM, Árvore de Decisão
Jokanovic et al. (2016a)	Radar Doppler	Espectrograma de janela única para encontrar dados de movimento de tempo-frequência	Classificador de regressão Softmax em DNN (rede neural profunda)
Jokanović and Amin (2017)	Radares de alcance-Doppler	Espectrogramas, mapas de alcance para encontrar dados de movimento de frequência e tempo	Classificador de regressão logística

As atividades não-queda praticadas nos ambientes experimentais podem não abranger todas as atividades do dia a dia, portanto, o limite determinado desta forma, pode não abordar o problema de forma suficiente. Para um melhor desempenho, diferentes investigadores utilizaram uma combinação de sensores para projetar o sistema de deteção de queda em humanos (Thanh Hai Nguyen, Ty Phu Pham, Cuong Q. Ngo, 2016; Perry et al., 2009), com suporte de algoritmos de aprendizagem máquina, como a máquina de vetores de suporte, modelo oculto de Markov e as redes neurais artificiais.

No período de treino, os dados coletados durante as atividades não relacionadas com queda, são usados para a extração de características e a classificação das ADL. Contudo, os algoritmos de aprendizagem máquina podem não ser realizáveis em tempo real e levar a um tempo de deteção mais prolongado.

Os algoritmos de aprendizagem máquina, quando aplicados para classificar os dados gerados pela deteção de queda com reconhecimento de contexto, fornecem um resultado

melhor para cenários em que o ruído é menor. Um breve resumo do trabalho realizado neste campo é mostrado na Tabela 2.3.

Tabela 2.3: Sistemas baseados em acústica (Singh et al., 2019).

Autor	Sensores	Recursos	Classificação
Popescu et al. (2008)	Matriz Linear de 3 Microfones	Intensidade e altura do som	Definiu o seu próprio classificador
Li et al. (2012)	Matriz de Microfone	MFCC, localização da fonte	Classificador <i>K-Nearest Neighbor</i>
Zhuang et al. (2009)	Microfone de campo distante único	Diferença de pares entre segmentos de som usando distância euclidiana	Modelo de mistura gaussiana com máquina de vetores de suporte
Li et al. (2010)	Matriz de Microfone Circular	MFCC, localização do som	Classificador <i>K-Nearest Neighbor</i>
Li et al. (2011)	Matriz Circular de 8 Microfones	Estimativa 3D do som, a altura do som, <i>Adaptive Signal Windowing</i>	Classificador <i>K-Nearest Neighbor</i>

Das tabelas anteriores, salientamos as experiências mais relevantes para este estudo:

- Alwan em 2006, desenhou um detetor de quedas que usa as vibrações do chão. O princípio por trás deste modelo baseava-se no padrão de vibração gerado por um piso. Verificou-se que o padrão de vibração do chão durante uma queda difere com o padrão de vibração gerado durante as atividades normais, como caminhar (Singh et al., 2019; Alwan et al., 2006);
- Zigel em 2009, simulou o conceito de padrão de vibração do chão com dados sonoros para detetar a localização e frequência atuais da queda. As características de saída como o espectro de resposta dos impactos e os coeficientes MFCC, foram calculados e encaminhados para um classificador Bayes de maneira a diferenciar entre uma queda e um ADL (Singh et al., 2019; Zigel, Litvak, & Gannot, 2009);
- Rimmine em 2010, usou um sensor de chão com *near-field imaging* para encontrar a forma, tamanho e magnitude do padrão de vibração e um filtro bayesiano para fins de classificação (Singh et al., 2019; Rimminen, Lindstrom, Linnavuo, & Sepponen, 2010);
- Mastorakis em 2014, usou uma câmara de infravermelhos para observar a atividade humana. Primeiro, o humano é detetado no cenário e uma caixa de delimitação 3D é desenhada à sua volta. Em seguida, a velocidade do movimento humano é calculada com base na contração ou expansão da caixa de delimitação 3D, medindo a sua

largura, altura e profundidade. O seu sistema de deteção funciona com a ideia de que a queda termina num estado inativo, ou seja, após a queda, não há movimento. Assim, o valor da velocidade calculada é comparado com um valor limiar específico para detetar uma queda (Singh et al., 2019; Mastorakis & Makris, 2014);

- Tzeng em 2010, usou uma câmara de infravermelhos para observar a área sempre que o sensor de pressão do chão instalado deteta qualquer pressão. O sensor de pressão usou um transformador diferencial variável linear para detetar a atividade humana e sinalizar a câmara para tirar registos fotográficos. Em seguida, foram aplicados alisamentos e filtragem nas imagens capturadas para clarificar o recurso. As características extraídas são combinadas com o valor do limiar de pressão, quer exista queda tenha ou não (Huan-Wen Tzeng, Mei-Yung Chen, & Chen, 2010);
- Toreyin em 2007, implementou diferentes tipos de sensores no contexto sendo usados em conjunto (piso, infravermelhos, som) para recolher dados. Estes dados são então transmitidos a um sistema de extração de recursos baseado em *Wavelet* para obter funcionalidades. No final, estas características extraídas são passadas através de HMM para classificação (Singh et al., 2019; Toreyin, Soyer, Onaran, & Cetin, 2007);
- Kim e Ling em 2009, usaram Doppler Radar e Doppler Spectrogram para extrair características de sete atividades diferentes, ou seja, caminhar, correr, rastejar, ficar quieto, boxe, andar com uma vara (Youngwook Kim & Hao Ling, 2009). As características extraídas são então examinadas com a transformada de Fourier de curta duração (STFT³) para encontrar assinaturas Doppler. Em seguida, uma validação de quatro classes dobráveis é aplicada para otimização de funcionalidades. No final, as funcionalidades otimizadas são passadas para SVM e *Decision-Tree* para classificação de STFT;
- Jokanovic em 2016, usou o Espectrograma de Janela Única (SWS) para recolher dados. Posteriormente, aplicaram a análise da tempo-frequência (TF) em dados recolhidos, para reconhecer os componentes de velocidade das partes do corpo humano. As funcionalidades extraídas são então passadas para DNN (*deep neural network*) formada a partir de *stack auto-encoder* e *softmax regression classifier* (Jokanovic, Amin, & Ahmad, 2016);
- Popescu em 2008, desenhou um sistema acústico de deteção de quedas (acústico-FADE). Este sistema utiliza uma matriz linear de 3 microfones para recolher dados sonoros gerados quando uma pessoa cai. Este sistema deteta uma queda comparando e analisando a altura do sensor de som do solo com o tamanho do som gerado. Se o som estiver localizado a uma altura superior a 60 cm, então é considerado como um alarme falso. Na sua experiência, mostraram que o seu sistema gera uma taxa

³STFT - *short-time Fourier transform*.

de erro de 0 quando a taxa de detecção de quedas é de 70 % e gera 5 detecções falsas de quedas por hora quando a taxa de detecção de quedas é de 100 % (Popescu & Mahnot, 2009);

- Li em 2012, usou a matriz de microfone circular. Com a ajuda da técnica de transformação de fase, é gerada uma estimativa 3D da localização da fonte sonora. Posteriormente, o sinal é melhorado e as características MFCC são extraídas deles. No final, o classificador *nearest-neighbor* é usado para classificar o som em duas classes, ou seja, queda e não queda (Yun Li, Ho, & Popescu, 2012).

Como se depreende, existem na literatura, muitos relatos sobre sistemas de detecção de quedas, mas poucos conjuntos de dados estão disponíveis ao público. Apresentaremos uma visão geral de alguns desses conjuntos de dados, com relevo para este estudo:

- UMAFall – é um conjunto de dados que inclui três tipos de quedas e oito ADL obtidos a partir de um smartphone usado no bolso direito da coxa e quatro sensores *wearables* usados no tornozelo, cintura, pulso direito e peito. Os sujeitos executaram pelo menos três ensaios de cada atividade num ambiente doméstico. Aplicaram uma abordagem baseada em limiares para a detecção de quedas (Casilari, Santoyo-Ramón, & Cano-García, 2017);
- SisFall – é um conjunto de dados de quedas e ADL obtido a partir de um protótipo desenvolvido com dois acelerómetros e um giroscópio (Sucerquia, López, & Vargas-Bonilla, 2017). O dispositivo estava posicionado na cintura. O conjunto de dados foi gerado com a colaboração de 38 participantes com 15 idosos e 23 jovens adultos, dos 19 aos 75 anos. Os autores selecionaram 19 atividades ADL e 15 tipos de queda com mais interesse. É importante salientar que este conjunto de dados é o único que inclui idosos nos seus testes (SISTEMIC, 2019);
- DLR (*Deutsches Zentrum für Luft- und Raumfahrt*) – conjunto de dados efetuado no Centro Aeroespacial Alemão, consiste na recolha de dados de um IMU usado no cinto de 16 pessoas, cujas idades variam entre os 23 e os 50 anos. Foram consideradas atividades como caminhar, correr, ficar de pé, sentar-se, deitar, cair e saltar. Os tipos de queda não foram distinguidos (Frank, Vera Nadales, Robertson, & Pfeifer, 2010);
- MobiFall – Foram adquiridos dados gerados a partir de sensores de inércia de um Smartphone (acelerómetro 3D e giroscópio) posicionados no bolso das calças. Os 24 indivíduos, 17 homens e sete mulheres com idades compreendidas entre os 22 e os 47 anos realizaram entre 3 a 6 ensaios por cada atividade. Os autores consideraram quatro tipos de quedas e nove atividades diferentes de vida diária (ADL) (Chatzaki, Padiaditis, Vavoulas, & Tsiknakis, 2017);

- UP-Fall – Neste *dataset* os indivíduos participantes realizaram seis atividades diárias e cinco tipos de quedas, sendo executados três ensaios por cada evento. Estes dados foram recolhidos em mais de 17 jovens, adultos saudáveis sem deficiência, utilizando sensores *wearables*, sensores ambiente e dispositivos de visão (Martínez-Villaseñor et al., 2019).

2.3.3 Desempenho

Com base nas quatro situações possíveis: TP; FP; TN e FN, descritas na Tabela 2.1, o desempenho de um sistema de detecção de queda é obtido normalmente por três índices, especificidade (SP), sensibilidade (SE) e precisão (CA) (Madarshahian et al., 2016). A especificidade de um modelo é definida como a capacidade de detetar e classificar corretamente uma ADL. A sensibilidade é definida como a capacidade de detetar e classificar uma queda, exactamente como queda, também é denominada como *recall*. A precisão de um modelo é a sua capacidade de detetar corretamente uma queda e uma ADL. A precisão é calculada como o número total de quedas detetadas corretamente dividido pelo número total de quedas detetadas (Madarshahian et al., 2016).

Para comparar os diferentes modelos de detecção de queda, é essencial unificar o padrão do número de quedas e outras atividades envolvidas, bem como a seleção dos tipos de queda na avaliação do modelo.

Assim, o cálculo da especificidade, SP, é dado pela Equação 2.18, indicando a capacidade de evitar falsos positivos, ou seja, a capacidade de detetar uma queda se esta ocorrer realmente.

$$SP = \frac{TN}{TN + FP} \quad (2.18)$$

A sensibilidade, SE, (Equação 2.19) é dada pela razão entre o número de quedas detetadas e as quedas totais que ocorreram.

$$SE = \frac{TP}{TP + FN} \quad (2.19)$$

A capacidade de distinguir e detetar tanto o evento queda (TP) como de não-queda (TN) é dada pela, precisão, CA (Equação 2.20), onde P e N são, respetivamente, o número de quedas realizadas e o número de não-quedas realizadas.

$$CA = \frac{TP + TN}{P + N} \quad (2.20)$$

A análise ROC (*receiver operating characteristic*) teve origem na teoria de decisão estatística e foi desenvolvida entre 1950 e 1960 para avaliar a detecção de sinais em radar e na psicologia sensorial (Braga, 2001).

Nos sistemas de detecção de quedas as curvas ROC são normalmente usadas na classificação binária para avaliar a qualidade de saída do classificador, servindo para obter valores

limiares baseados em restrições na sensibilidade do sistema e na especificidade (Delahoz & Labrador, 2014).

Ao ajustar o valor limiar é gerada a curva ROC, representando a sensibilidade, como a taxa de verdadeiro positivo no eixo das ordenadas Y , e a especificidade, como a taxa de falso positivo no eixo X .

A partir da curva, o ponto limiar é selecionado tendo como base a média geométrica (M_G) máxima da sensibilidade (SE) e especificidade (SP) (Equação 2.21):

$$M_G = \sqrt{SE \times SP} \quad (2.21)$$

Isso significa que o canto superior esquerdo do gráfico é o ponto “ideal” – uma taxa de falso positivo de zero e uma taxa de verdadeiro positivo de um. Isso não é muito realista, mas significa que uma área maior sob a curva (AUC⁴) geralmente é melhor, ao indicar o grau de separabilidade.

O tempo de espera e/ou o tempo de detecção são normalmente usados para avaliar a eficiência da detecção de queda em sistemas de pré impacto. O tempo de espera é definido pelo intervalo de tempo entre o momento em que a queda foi detetada e o impacto da queda, e é responsável pelo tempo para as medidas de proteção serem ativadas para proteger as vítimas da queda dos impactos da queda.

O tempo de detecção é a diferença de tempo entre o início da queda e a detecção da queda. Este parâmetro também é usado para indicar a rapidez com que o sistema de detecção de queda responde a uma queda. Um melhor desempenho de detecção de queda está associado a um menor tempo de detecção, sendo o intervalo de tempo entre o golpe do calcanhar e o impacto da queda estimado em cerca de 900 ms (X. Hu & Qu, 2016).

2.3.4 Sistemas no mercado

No mercado estão disponíveis diversos dispositivos de detecção de quedas, alguns direcionados para ambientes domésticos outros com um raio de ação mais alargado como é o caso dos smartwatches ou smartphones que fazem uso de sistemas GPS. No caso de ambientes residenciais ou ambulatório, os sistemas de detecção de queda abrangem comumente (OMG, n.d.; Vigilio Vigifall, 2010).

- Almofadas de pressão com sensor de peso para alarmes de saída de cama ou cadeira;
- Tapetes de chão com sensor de peso;
- Sensores de movimento;
- Pingentes, pulseiras e cintos;
- Botões de pânico.

⁴AUC-area under the curve

Menos comum é o uso de sistemas intrusivos de processamento de vídeo em tempo real ou pisos dotados de sensores de vibração.

Os pingentes ou botões de pânico desencadeiam o alarme durante algum tempo, sendo transmitido por GSM (*Global System for Mobile*) ou por uma rede sem fios até uma central que posteriormente e, caso não haja desativação do alarme, a queda é confirmada e as entidades de emergência alertadas (OMG, n.d.). Estes sistemas implicam o custo do dispositivo e uma fidelização mensal (Alert 1 Medical Alerts, 2020). Alguns dos dispositivos atuais comercializados:

- GOsafe 2 – o primeiro sistema “tudo-em-um” da Philips Lifeline, oferece um larga cobertura e suporte quer seja em sua casa ou no exterior (Philips Lifeline, n.d.);
- Angel4 – o detetor de queda Angel4 é um dispositivo pessoal com um acelerómetro triaxial e um algoritmo específico, pode ser colocado na cintura. Este sensor, é conectado a um sistema de atendimento à distância, posto de saúde ou telemóvel via *bluetooth*, opera numa aplicação *Android* (Sense4Care, n.d.);
- Nock Senior – pingente detetor de quedas para idosos, pessoas com Alzheimer ou outras degenerações cognitivas, permite localização GPS e comunicação através da aplicação Nock *Android/iPhone/Web* (Neki, 2020);
- Globalhelp I – o sistema permite ter até 3 botões de pânico, 1 incorporado diretamente no painel de controlo e 2 botões de pânico *wireless* nos dispositivos de pulseira e fio (A48 - Sistemas de Segurança, 2020);
- Shimmer3 IMU – é um sensor sem fios de deteção leve, que contém um acelerómetro, um giroscópio triaxial e um magnetómetro. É colocado na cintura do utilizador (Nadeem, Mehmood, & Rizwan, 2019; Shimmer, n.d.);
- Giver Code Blue – Os tapetes desta marca são concebidos também para pacientes não ambulatorios. Quando o paciente sai da cama (ou se cair no tapete) o monitor de alarme no quarto pode soar a 120 dB para chamar a assistência de emergência de um cuidador próximo. Este alarme inclui ainda um cabo de rutura que pode ser ligado à roupa de cama ou ser puxado de qualquer direção, funcionando em conjunto com uma cadeira de rodas ou outro ajuste (AwareGiver, 2020).

A Patente WO 2009/113056 (Litvak, Gannot, & Zigel, 2009) refere-se a um dos primeiros dispositivos patenteados nos EUA (2009) para deteção automática de queda para pessoas idosas. Trata-se de uma solução baseada na combinação de deteção de vibrações no piso e som durante uma queda, não requer que o sujeito use nada, no entanto inclui um detetor de aceleração, para detetar vibração, um microfone, para colocar em associação com o detetor de aceleração para deteção de eventos de som, uma unidade de segmentação para segmentar a vibração e ruído, uma unidade de classificação configurada para classificar eventos simultâneos do microfone e do detetor de aceleração, para assim determinar se

uma queda humana é válida, e uma unidade de alarme, associada à unidade de classificação para fornecer uma saída de alarme quando a queda humana é indicada (Litvak, Gannot, & Zigel, 2008).

Em Portugal existem alguns projetos financiados:

- FRADE, é uma plataforma para detecção de queda, avaliação de risco de queda e prevenção. A solução proposta pela FRADE é composta por um *bundle* de componentes (sensor vestível, aplicação de computador, aplicação *Android* e servidor *backend* com interface *Web*) para realizar FD (detecção de queda), FRA (avaliação de risco de queda) e FP (prevenção de queda). O idoso usará o sensor vestível para monitorar quedas e fornecer uma estimativa contínua do risco de queda, com base na análise do movimento. Envia um alarme para o servidor *backend* e um SMS para um cuidador sempre que uma queda é detetada (se estiver fora, a localização também será enviada). O dispositivo vestível também será usado para monitorar os movimentos do idoso e comunicar com o computador e com a aplicação *Android* enquanto ele realiza testes FRA e *exergames* FP. Todos os dados são armazenados no servidor *backend* e podem ser acedidos através da sua interface *Web*, por um cuidador (Portugal, 2020);
- CAALYX (*Complete Ambient Assisted Living Experiment*), visa aumentar a autonomia e autoconfiança dos idosos, desenvolvendo um dispositivo portátil leve capaz de medir sinais vitais específicos de idosos, detetar quedas e comunicar-se automaticamente em tempo real com o seu prestador de cuidados em caso de emergência, onde quer que pessoa idosa se encontre, em casa ou fora (Boulos et al., 2007; Martins, Ângelo, 2012);
- ASCane (*Assistive Smart Cane*), é baseado numa bengala com capacidade de detecção de quedas, está equipado com um sensor inercial cujos dados serão testados com três diferentes algoritmos de detecção de queda multi-limiar fixos, um multi limiar dinâmico e métodos de aprendizagem de máquina (Mouta, Ribeiro, Santos, & Moreira, 2020).

2.4 Comparação de Séries Temporais

“A time series is a sequence of observations which are ordered in time (or space)” (Valerie J.Easton, 2004).

Num universo não estacionário como o nosso, encontramos séries temporais em diversos domínios, Medicina, Economia, Meteorologia, neste tipo de dados existe uma dependência das observações vizinhas, sendo importante analisar esta dependência. Em função do registo das observações podemos considerar dois tipos de séries temporais: contínuas, onde temos observações em todos os instantes do tempo e discretas, onde existe uma observação

em espaços de tempo normalmente regulares. Assim, uma série temporal X corresponde ao conjunto de valores medidos em relação ao tempo t :

$$X = \{X_{t-1}, X_{t-2}, X_{t-3}, \dots\} \quad (2.22)$$

Uma série temporal exhibe padrões ao longo do tempo como tendência, sazonalidade e ciclo. Qualquer padrão previsível que se repita durante um dado período é considerado sazonal (Investopedia, 2019). A tendência é uma componente linear ou não linear sistemática, que muda ao longo do tempo e não se repete. Uma série poderá apresentar uma tendência crescente ou decrescente (Jae Duk Seo, 2018). Os métodos de decomposição identificam esses padrões individualmente e podem ser extraídos da série para uma melhor compreensão ou apenas para melhorar as previsões.

Assim ao analisar as séries temporais é possível extrair informação quanto à inércia da sucessão, a sua variação “em média” ao longo do tempo, descrever variações em relação a tendência que ocorrem geralmente em períodos de um ano, ou as variações cíclicas a que se referem movimentos oscilatórios. Será importante também detetar irregularidades para construir um modelo que permita prever a evolução futura da série temporal ou encontrar relações entre os dados a analisar outras variáveis e que possam influenciar diretamente os mesmos (Moisés Alves Pinto & Lage Campelo Calheiros, 2009).

No estudo de séries temporais (Murteira, A, & Turkman, 2000) e (Chatfield, 2001) mencionam quatro objetivos:

- Descrição – Numa primeira fase, da análise gráfica da série temporal podemos extrair valores como: máximos, mínimos, ou pontos discrepantes. Numa segunda fase pode-se fazer o cálculo de indicadores como: média aritmética, variância de todos os termos ou dos termos correspondentes a troços sucessivos, distância média entre máximos ou mínimos locais;
- Explicação – Consiste na construção de modelos que permitam tentar explicar a evolução de uma série temporal a partir da variação de uma outra série, sendo um caso importante o das funções de transferência, que permitem explicar uma “série de saída” como função de uma ou mais “séries de entrada”;
- Previsão – Como o termo sugere, consiste em prever valores futuros a partir de valores passados. Podem-se destacar duas famílias de métodos de previsão. Os primeiros são os métodos multivariáveis que procuram relacionar a série com outras séries a partir de modelos. Os segundos são os métodos uni variáveis, onde a previsão tem unicamente como base os valores atuais e passados da própria série;
- Controlo – Se vemos uma série como o resultado, ou seja, *output*, de um processo qualquer, a série pode dar informações úteis sobre o próprio processo com vista a poder manter o controlo sobre ele. Pode-se considerar a modo de exemplo, uma linha de produção onde são definidos valores limites para algumas características dos

artigos produzidos. Caso os valores se mantenham nos limites estabelecidos, admite-se uma situação de controlo. Caso contrário o processo é parado para deteção e correção dos fatores que originaram o comportamento anómalo.

A série temporal é dita determinística se as observações podem ser escritas através de uma equação do tipo $y = f(t)$. Uma série temporal gerada por um processo determinístico é aquela onde é possível prever exatamente valores futuros a partir de valores passados (Carvalho De Oliveira, 2006). Contudo, muitos fenómenos dinâmicos correspondem ao conjunto dos chamados processos estocásticos ou aleatórios onde valores futuros são apenas parcialmente determinados a partir de valores passados.

Quando a função f inclui um termo aleatório, ou seja, estocástico, nos argumentos, consideramos que as observações são realizações de uma variável aleatória, indexadas no tempo. Sendo possível definir uma série temporal $\{y_t, t = 1, 2, \dots, T\}$ como uma realização de um processo estocástico, em que $\{y(t), t \in I\}$ é uma família de variáveis aleatórias para cada $t \in I$, definida num espaço de probabilidades (Ω, F, P) (G. F. Costa, 2015).

Uma classe importante de processos estocásticos é os chamados processos estacionários. Num processo estacionário, o sistema apresenta um estado de equilíbrio estatístico, em torno de um nível médio fixo, ou seja, não apresenta tendência. Isto significa, que o sistema tem propriedades probabilísticas invariantes ao longo do tempo (Holmes, 1990).

2.4.1 Modelos

Os modelos de séries temporais podem ser classificados em lineares e não-lineares. Os modelos de regressão simples, são processos matemáticos que relacionam o comportamento de uma variável Y com outra X , sendo múltiplo no caso de X conter outras variáveis.

Os modelos lineares também designados por modelos estatísticos (De Gooijer & Hyndman, 2006), são basicamente os auto regressivos (AR - *auto regressive*), de médias móveis (MA - *moving average*), auto regressivos de médias móveis (ARMA - *auto regressive moving average*) e auto regressivos de médias móveis integrados (ARIMA - *auto regressive integrated moving average*) (A. I. F. Costa, 2019). Estes modelos têm como finalidade modelar comportamentos de sistemas estacionários lineares (Murteira et al., 2000), são baseados na ideia da existência de dependência entre variáveis aleatórias referentes a sucessivos pontos do tempo, pode conceber-se que o processo estocástico é gerado por consecutivos choques aleatórios (também designados inovações) causados por um processo de ruído branco (Moisés Alves Pinto & Lage Campelo Calheiros, 2009). Uma série $\{x(n)\}$, corresponde a um processo AR(p) de ordem p quando se verifica que,

$$x(n) = \varphi_1 x(n-1) + \varphi_2 x(n-2) + \dots + \varphi_p x(n-p) + \varepsilon(n) \quad (2.23)$$

onde $\varepsilon(t)$ constitui ruído branco, ou seja, o valor da série temporal X no momento t é baseado numa combinação linear de valores anteriores (*backward prediction*), futuros (*forward prediction*) ou ambos (*backward forward prediction*). A esse valor é adicionado

um fator de erro $\varepsilon(t)$, normalmente uma distribuição normal, e uma constante c inferior a 1.

$$X_t = c + \sum_{i=0}^p \varphi_i X_{t-i} + \epsilon_t \quad (2.24)$$

Uma série $\{x(n)\}$, corresponde a um processo MA(q) de ordem q quando se verifica que,

$$x(n) = \varepsilon(n) - \theta_1 \varepsilon(n-1) - \theta_2 \varepsilon(n-2) - \dots - \theta_q \varepsilon(n-q) \quad (2.25)$$

Nos modelos MA(q) pretende-se exprimir o processo $x(n)$ em termos de um processo mais simples e puramente aleatório como é o ruído branco, sendo aplicados para detectarem tendências em valores e volumes transacionais. Existem 3 submodelos distintos:

- SMA (*simple moving verage*) – Corresponde a uma simples média pesada dos valores da Série Temporal. Apesar de simplista, funciona muito bem em dados pouco complexos e periódicos;

$$SMA = \frac{p_1 + p_2 + \dots + p_n}{n} \quad (2.26)$$

- WBA (*weighted moving average*) – Cada valor p da Série Temporal é multiplicado por uma função decrescente, tendo assim cada momento $t - x$ um peso diferente no cálculo do valor da Série no momento t . Desta maneira é dada maior importância aos valores mais próximos no tempo;
- EMA (*exponential moving average*) – Idêntico ao WMA, mas aplicando uma função exponencial decrescente. Desta maneira é dada ainda mais relevância aos valores próximos de t .

Em termos de estacionaridade, os processos MA(q) são sempre estacionários desde que os coeficientes $\{\theta_i\} = \{\theta_1, \theta_2, \dots\}$, sejam números reais finitos. Por último, um processo MA(q) será invertível, se o polinómio $\theta_q(z)$ não tiver raízes no círculo de raio unitário (Murteira et al., 2000).

Os modelos mistos auto regressivos e médias moveis [ARMA(p, q)], não são aplicados na sua forma base, sendo usualmente formados por combinações e versões dos mesmos, como são exemplo, os modelos *auto regressive moving mverage*, ARMA, *auto regressive integrated moving average*, ARIMA, *auto regressive conditional heteroskedasticity*, ARCH e *auto regression trees*, ART (Moisés Alves Pinto & Lage Campelo Calheiros, 2009).

O coeficiente de correlação amostral mede o grau de correlação entre os valores de duas séries temporais. Dadas duas séries temporais $\{x(n)\}$ e $\{y(n)\}$, o coeficiente de correlação amostral r entre $\{x(n)\}$ e $\{y(n)\}$ vem dado pela Equação 2.27 (Valerie J.Easton, 2004).

$$r = \frac{\sum_i^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (2.27)$$

Na situação de queda, para além do interesse em medir o grau de correlação entre duas séries diferentes, pode também ser útil medir entre uma série e a mesma série desfasada no tempo. Neste caso, não falamos de um coeficiente de correlação amostral, mas sim de vários coeficientes de auto-correlação, cada um correspondente a um desfasamento temporal específico (Hyndman, 2013).

O conceito básico é que prevemos a série temporal de interesse assumindo que ela tem uma relação linear com outras séries temporais. No caso mais simples, o modelo de regressão permite uma relação linear entre a variável de previsão e uma única variável preditora (Stojiljković, 2020).

$$y_t = \beta_0 + \beta_1 x_t + \varepsilon_t \quad (2.28)$$

Quando há duas ou mais variáveis predictoras, o modelo é chamado de modelo de regressão múltipla. A forma geral de um modelo de regressão múltipla,

$$y_t = \beta_0 + \beta_1 x_{1,t} + \beta_2 x_{2,t} + \dots + \beta_k x_{k,t} + \varepsilon_t \quad (2.29)$$

onde y_t é a variável a ser prevista e $x_{k,t}$ são as variáveis predictoras. Cada uma das variáveis predictoras deve ser numérica. Os coeficientes β_k medem o efeito de cada preditor após levar em consideração os efeitos de todos os outros preditores no modelo (Stojiljković, 2020; Bremer, 2012).

A análise no domínio das frequências, embora relacionada com a análise no domínio do tempo, tem uma perspectiva diferente, procura as diferentes frequências ou componentes periódicas que contribuem para a variabilidade da série temporal.

A Transformada de Fourier permite obter as frequências e amplitudes presentes num sinal de variável real, pelo que pode ser denominada como a representação no domínio frequência da função original. Esta transformada decompõe um sinal como um somatório (série) de sinusoides, cada uma com a sua amplitude e frequência. Porém, a maioria das séries na natureza, apresentam comportamentos aperiódicos, não facilitando a representação em série de Fourier na relação de dependência entre valores correspondentes a diferentes instantes no tempo. Nestes casos, pode-se expressar uma série aperiódica $\{x(n)\}$ em função de sinais exponenciais complexos, a transformada de Fourier discreta e a sua função inversa (Alan V Oppenheim, Alan S. Willsky, 1998).

$$X(e^{j\omega}) = \sum_{n=-\infty}^{+\infty} x(n) e^{-j\omega n} \quad (2.30)$$

$$x(n) = \frac{1}{2\pi} \int_0^{2\pi} X(e^{j\omega}) e^{j\omega n} d\omega \quad (2.31)$$

2.4.2 Transformada *wavelet*

“The wavelet transform can be used to analyze time series that contain nonstationary power at many different frequencies.” (Daubechies, 2009; Torrence & Compo, 1998).

Como vimos, a transformada de Fourier decompõe um sinal na frequência, a incapacidade de fornecer informação no domínio do tempo, levou inicialmente os investigadores a desenvolverem a STFT (*Short Time Fourier Transformation*) que, basicamente, aplica a transformada de Fourier a janelas temporais. O desenvolvimento desta ferramenta levou à criação das *wavelet*, que são adequadas para a análise de sinais não estacionários (Hubbard, 1996; Pong Chan & Chee Fu, 1999).

A transformada *wavelet* (WT) decompõe um sinal em componentes de escalas diferentes, comparando o sinal, com a *wavelet* de tamanhos diferentes, isso é feito por integração (Equação 2.32): multiplicando o sinal pela função *wavelet* de análise e integrando o produto (Hubbard, 1996). São conhecidas várias famílias de *wavelet*, cada uma adequada para diferentes aplicações, como a *wavelet* de Morlet, Figura 2.13.




Figura 2.13: *Wavelet* de Morlet (Hubbard, 1996).

Figura 2.13 (a) *wavelet* de Morlet de largura e amplitude arbitrárias, com o tempo ao longo do eixo x ; Figura 2.13 (b) construção da *wavelet* de Morlet (tracejada em azul) como uma curva seno (verde) modulada por um gaussiano (vermelho) (PAOS, 1998).

Na transformada *wavelet* contínua (CWT⁵), uma função ψ , semelhante a uma pequena onda, é usada para criar uma família de ondas $\psi(at + b)$ em que a e b são números reais, a corresponde a uma dilatação (comprimindo ou alongando) da função ψ e b ao deslocamento. A transformação contínua de ondas transforma um sinal $f(t)$ numa função com duas variáveis (escala e tempo), a que se pode chamar $c(a, b)$ (Hubbard, 1996).

$$c(a, b) = \int f(t) \psi(at + b) dt \quad (2.32)$$

Esta transformação de redundância extrema, permite extrair a informação essencial de uma série temporal. Em (Yuwono, Moulton, Su, Celler, & Nguyen, 2012) foi usado como um método de extração de características de dados de aceleração, no entanto, a aplicação

⁵CWT-continuous wavelet transform

de WT em estudos de detecção de queda com base em sensores inerciais, tem sido limitada (Yazar, Keskin, Töreyn, & Çetin, 2013; Palmerini et al., 2015).

2.4.3 Medidas de similaridade

A previsão de valores implica uma pesquisa no passado por padrões de informações semelhantes aos disponíveis na atualidade. A partir de técnicas de regressão numérica aplicadas às séries temporais é possível obter a predição de valores, ao gerar parâmetros que caracterizam curvas definidas pelos dados que pertencem à série em análise (Monteiro Barragan, Hora de Oliveira Fontes, Pereira, Torres Sá Barreto, & Almeida Pacheco, 2012).

Assim como a correlação mede a extensão de uma relação linear entre duas variáveis, a função autocorrelação mede a relação linear entre os valores defasados de uma série temporal. Na estatística, esta medida, pode indicar a influência de uma variável aleatória sobre as observações vizinhas. Por exemplo, r_1 mede a relação entre y_t e $y_{(t-1)}$; e r_2 mede a relação entre y_t e $y_{(t-2)}$. O valor da autocorrelação de $lag - k$ é calculado partir da igualdade da Equação 2.33:

$$r_k = \frac{\sum_{t=k+1}^T (y_t - \bar{y}) (y_{t-1} - \bar{y})}{\sqrt{\sum_1^T (y_t - \bar{y})^2}} \quad (2.33)$$

onde T é a dimensão da série temporal (Hyndman, 2013).

Pode-se avaliar o valor desta diferenciação a partir da utilização de funções distância. O erro numérico em problemas de regressão pode ser considerado uma distância.

Por exemplo, o erro entre o valor esperado e o valor previsto, é uma medida de distância unidimensional, que pode ser somada, ou a média calculada de todos os exemplos num conjunto de testes, fornecendo deste modo, uma distância total, entre os resultados esperados e previstos no conjunto de dados. O cálculo do erro, como o erro médio quadrático ou o erro absoluto médio, será interpretado, como uma medida de distância padrão.

Usualmente o agrupamento de séries temporais é realizado através de métodos como o algoritmo K-médias ou o agrupamento hierárquico (Oliveira, David Carvalho de, 2019). Estes métodos permitem agrupar os dados de acordo com uma medida de proximidade, para tal é calculada uma matriz de distâncias, frequentemente baseada na distância Euclidiana.

Dependendo do tipo de dados, as medidas de distância desempenham um papel importante na aprendizagem máquina. As medidas de distância mais usadas na aprendizagem de máquina são as seguintes (Monteiro Barragan et al., 2012): distância Hamming; distância Euclidiana; distância Manhatta e distância Minkowski.

A distância Euclidiana é a mais aplicada nos processos de agrupamentos de variáveis. Dada duas séries temporais, a distância entre a série X e série Y é obtida através da

Equação 2.34.

$$d_{euc(x,y)} = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (2.34)$$

Em que n é a dimensão das séries temporais e x_i e y_i elementos das séries temporais. Como os dados a tratar no âmbito deste trabalho podem ser séries temporais de tamanhos diferentes, para além da distância euclidiana, vamos considerar o método *dinamyc ime warping* (DTW) (Oliveira, David Carvalho de, 2019).

2.4.4 *Dynamic time warping*

O DTW é um método que permite medir a semelhança entre duas séries temporais normalmente desalinhadas, calculando a distância entre elas. Com essa distância, podemos encontrar todas as sequências mais próximas de uma sequência em particular. Uma função custo menor, significa um melhor alinhamento e semelhança entre as séries (*Dynamic Time Warping for Sequence Classification*, n.d.).

A distância Euclidiana é calculada para séries cuja dimensão é igual, enquanto a DTW pode ser calculada para duas séries com diferentes dimensões (*Dynamic Time Warping for Sequence Classification*, n.d.; Akl & Valaee, 2010).

Consideremos duas séries N e M com dimensão L_n e L_m respetivamente. De seguida é criada uma matriz P de dimensão $L_n \cdot L_m$ onde o elemento genérico (i, j) corresponde à distância euclidiana entre N_i e M_j . O algoritmo DTW é aplicado sobre a matriz P de modo a encontrar o caminho mínimo entre as duas séries temporais (Oliveira, David Carvalho de, 2019).

$$D_{i,j} = \min(D_{i-1,j}, D_{i,j-1}, D_{i-1,j-1}) + S_{i,j} \quad (2.35)$$

Este processo irá dar origem a uma matriz de distâncias cumulativa D , cuja construção é dada pela Equação 2.35 sendo esta responsável por definir o custo total do alinhamento entre (n_1, m_1) e (n, L_n, m, L_m) (Oliveira, David Carvalho de, 2019).

Devido à sua estrutura adaptativa, o DTW é amplamente utilizado em muitos problemas de reconhecimento de padrões, como reconhecimento de fala, reconhecimento de assinatura e marcha, localização de rosto em imagens coloridas e classificação de sinal de ECG (*Dynamic Time Warping for Sequence Classification*, n.d.). Também são aplicados para gerar um modelo representativo para quedas humanas típicas. Em seguida, o evento de queda é detetado na fase *online*, avaliando a semelhança entre os padrões de velocidade/aceleração em tempo real e o modelo representativo (Y. Hu, Zhang, Wu, Wang, & Ray Liu, 2020).

2.5 Sistemas de Aprendizagem

O conceito de inteligência artificial (IA) surge como campo de investigação em 1956 na Conferência de Dartmouth e teve como objetivo alcançar a inteligência geral artificial, uma máquina capaz de raciocinar e executar qualquer tarefa intelectual como um ser humano. Mas, desde a sua criação, que o desafio à inteligência artificial foi a resolução de tarefas intuitivas, que são fáceis de realizar para as pessoas, mas difíceis de formalizar e descrever, como reconhecimento de voz ou rostos (Goodfellow, 2016; DeepMind, n.d.; Openai, n.d.). Recentemente a IA denominada “Inteligência Artificial Estreita” incide na construção de sistemas inteligentes – que percebem e agem num determinado ambiente, capazes de aprender a executar uma tarefa específica, quando treinados com exemplos suficientes (Russell, Dewey, & Tegmark, 2015). Devido à sua complexidade, a IA é constituída por vários ramos distintos de desenvolvimento (Ferreira, 2020):

- Redes neuronais – têm como principal objetivo imitar a forma física de trabalho de um cérebro, ou seja, através da aprendizagem, em contraste com a programação clássica dos computadores;
- Sistemas especialistas – dizem respeito à implantação de um sistema de computação, com uma base de conhecimento especializada numa determinada área, de modo a que a máquina consiga oferecer conselhos inteligentes ou que seja capaz de tomar uma decisão inteligente sobre a função de um determinado processo.

2.5.1 Aprendizagem automática

As dificuldades enfrentadas pelos sistemas que dependem de conhecimentos codificados, sugerem que os sistemas de IA precisam de capacidade para adquirir os seus próprios conhecimentos, extraindo padrões de dados brutos. O conjunto de dados têm aumentado em tamanho e complexidade, esta capacidade é conhecida como aprendizagem automática, as técnicas e modelos avançados, usados para analisar diferentes conjuntos de dados, são conhecidos hoje como ML⁶ (Barry & Rachel, 2019).

A aprendizagem automática utiliza técnicas responsáveis por descobrir padrões e relações ocultas nos dados, através do desenvolvimento de métodos computacionais que permitem aos computadores “aprender” com a experiência. Algumas das tarefas mais comuns desempenhadas por aprendizagem automática incluem a tradução automática, a transcrição, deteção de anomalias, contudo no âmbito da deteção de quedas, são consideradas relevantes a classificação e regressão:

- Classificação: neste tipo de tarefa, o *programa de computador* é solicitado para especificar qual das categorias k pertencem algumas entradas;

⁶ML – *machine learning*

- Regressão: neste tipo de tarefa, pede-se ao *programa de computador* que preveja/-prediga um valor numérico dada uma entrada. Para resolver esta tarefa, o algoritmo de aprendizagem é solicitado para obter uma função $f : R_n \rightarrow R$. Este tipo de tarefa é semelhante à classificação, excepto no formato de saída.

O estudo de aprendizagem automática divide-se basicamente em dois grupos, supervisionada e não supervisionada, pelo tipo de experiência que lhes é permitido ter durante o processo de aprendizagem. A aprendizagem supervisionada, induz conceitos a partir de exemplos que estão pré-classificados, ou seja, estão rotulados com uma classe conhecida, útil em problemas de classificação (a classe possui valores discretos) e regressão (para classe de valores contínuos). Na aprendizagem não supervisionada, os padrões de entrada são conhecidos, e existe uma incerteza sobre a saída esperada, desta forma, é necessário utilizar métodos probabilísticos, para simular uma experiência não vivida.

Os algoritmos de aprendizagem supervisionados, experimentam um conjunto de dados contendo funcionalidades, mas cada exemplo também está associado a um rótulo ou alvo.

Os algoritmos de aprendizagem não supervisionados, experimentam um conjunto de dados contendo muitas características, em seguida, aprendem propriedades úteis da estrutura deste conjunto de dados, outros desempenham funções, como *clustering*, que consiste em dividir o conjunto de dados em aglomerados de exemplos semelhantes.

O desafio central no ML, é obter um bom desempenho para entradas novas, e desconhecidas, e não apenas naquelas, em que o modelo foi treinado. A capacidade de obter um bom desempenho em entradas que não foram observadas anteriormente chama-se generalização. Normalmente, quando um modelo ML é treinado, tem acesso a um conjunto de treino, o que possibilita o cálculo e redução do erro no conjunto de treino, sendo isto um problema de otimização. O que separa a aprendizagem automática da otimização é que queremos que o erro de generalização, também chamado de erro de teste, seja baixo. O erro de generalização é definido como o valor esperado do erro numa nova entrada. Neste caso, a expectativa pode ser feita através de diferentes inputs possíveis, extraídos da distribuição de inputs que esperamos que o sistema encontre na prática.

Underfitting e *overfitting* são dois desafios centrais da aprendizagem automática-quando um modelo perde a capacidade de generalizar, ocorre um fenómeno denominado de sobre ajuste (*overfitting*), onde a complexidade da função f obtida é superior à necessidade do problema, na prática a distância entre o erro de treino e o erro de teste é demasiado grande. Por outro lado, se a complexidade da função obtida é inferior a necessidade do problema (Gama, Carvalho, Faceli, Lorena, & Oliveira, 2017), temos o chamado de sub ajuste (*underfitting*) e ocorre quando o modelo não é capaz de obter um valor de erro suficientemente baixo no conjunto de treino (A. I. F. Costa, 2019).

O processo de aprendizagem em ML, envolve numerosos exemplos de formação sobre uma determinada tarefa, em que a máquina NN tenta executar, como a classificação, e dependendo da distância das suas previsões, irá ajustar os seus parâmetros internos de forma a melhorar a sua precisão. Uma vez treinada a máquina, é capaz de classificar

novos dados, fazer previsões e até gerar novas amostras, sem a necessidade de escrever um código extenso. Neste campo, são aplicados vários métodos, algoritmos genéticos, árvores de decisão, máquinas vetoriais de apoio, K-means, redes bayesianas e recentemente com interesse acrescido, as abordagens *deep learning* e redes neuronais (Dionísio, Nuno Rafael Marques, 2018; Schmidhuber, 2015).

2.5.2 Redes neuronais artificiais

Um dos algoritmos mais comuns em aprendizagem automática são as redes neuronais artificiais (RNA). As RNA, baseiam-se em modelos inspirados em redes neuronais biológicas, estes sistemas conexionistas foram utilizados com entusiasmo crescente a partir de 1986, quando foi proposto o algoritmo de treino de retro propagação (Rumelhart, Hinton, & Williams, 1986; Hirose, Yamashita, & Hijiya, 1991). Uma RNA é constituída por unidades de processamento, denominadas neurónios, com capacidade para o processamento paralelo de informação e armazenamento de conhecimento empírico (Cortez & Neves, 2000). A organização destes algoritmos é estruturada em camadas, cada camada inclui várias unidades de processamento que são interligadas com outros neurónios das camadas vizinhas por links direcionados com um determinado peso. Quando um sinal é enviado adquire o peso respetivo da ligação por onde passa, todos os sinais são adicionados, havendo uma função de ativação que verifica se o sinal adicionado, é maior do que algum valor limiar (D. J. L. F. d. V. Rodrigues, 2019).

A rede do tipo *multilayer perceptron* (MLP), também conhecida por rede neuronal (RN) é um dos algoritmos mais estudados que permite modelar relações não-lineares complexas entre um conjunto de variáveis de entrada e uma variável de saída (Rob J. Hyndman and George Athanasopoulos, 2014). Uma rede neuronal representa uma rede de nós organizados em camadas, com: uma camada de entrada, uma ou mais camadas intermediárias (que contêm nós escondidos) e uma camada de saída (A. I. F. Costa, 2019). O processo global em que uma rede recebe uma entrada e produz uma previsão é chamado de *feed-forward*. Os dados são alimentados através da camada de entrada, depois encaminhados para as camadas ocultas onde cada neurónio processa a informação e, finalmente, na camada de saída através de uma função (por exemplo, um combinador linear ou uma função Softmax) (Dionísio, Nuno Rafael Marques, 2018).

2.5.3 Aprendizagem profunda

Os algoritmos simples de aprendizagem automática descritos, funcionam muito bem, em uma grande variedade de problemas importantes. No entanto, não conseguiram resolver os problemas centrais da IA, como reconhecimento de voz ou objetos. O desenvolvimento da aprendizagem profunda foi motivado em parte, pelo fracasso de algoritmos tradicionais difíceis de realizar tarefas de IA, quando o número de dimensões nos dados é alta. O

desenvolvimento da aprendizagem profunda pode ser dividido em três momentos: a aprendizagem profunda conhecida como cibernética nos anos 40–60, a aprendizagem profunda conhecida como conexionismo nos anos 80–90, e o atual ressurgimento sob o nome de aprendizagem profunda, a partir de 2006 (Goodfellow, 2016).

Os modelos inspirados no cérebro biológico, como as redes neuronais artificiais (ANN), são uma das principais sustentações da aprendizagem profunda. Um dos conceitos chave do conexionismo, é que um grande número de unidades computacionais simples, podem alcançar um comportamento inteligente quando ligados em rede. Este modelo, aplica-se aos neurónios nos sistemas nervosos biológicos, e com a mesma percepção, às unidades ocultas em modelos computacionais, sendo fulcrais para a aprendizagem profunda (Nielsen, 2015).

A crescente pesquisa em redes neuronais, popularizou o uso do termo “deep learning” (Bengio, 2013). Neste momento, as redes neuronais profundas superaram os sistemas de IA concorrentes, com fundamento noutras tecnologias de aprendizagem automática, nomeadamente, em novas técnicas de aprendizagem não supervisionadas e na capacidade de modelos profundos para generalizar, a partir de pequenos conjuntos de dados (Cruz & Cortez, 2019; Srinivas et al., 2016).

O aumento constante do poder computacional da unidade central de processamento e o emprego das unidades de processamento gráfico em tarefas ML, tem permitido o uso de muitas camadas escondidas e a formação de grandes NN. Além desta maior profundidade proporcionada pelo incremento no número de camadas, em DL as funcionalidades e métodos de processamento de dados também podem diferir entre as camadas. Tal desenvolvimento abriu as portas para arquiteturas neuronais mais complexas, com a possibilidade de treinar milhões de parâmetros em múltiplas camadas. Esta arquitetura é muitas vezes designada como uma rede neural totalmente ligada. No entanto, em dL existem outras arquiteturas que têm atraído uma grande atenção devido à sua melhoria em tarefas reais, como a rede neuronal convolucional (RNC) e as redes neuronais recorrentes (RNN⁷) (Schmidhuber, 2015).

2.5.4 Redes neuronais convolucionais

O modelo RNC tem as suas origens nos anos 70, inspirado no funcionamento do sistema de visão dos mamíferos, mas foi com o modelo convolucional LeNet-5 aplicado no reconhecimento de dígitos manuscritos (Silva, 2019) que ganhou visibilidade.

Este modelo de rede emprega uma operação matemática chamada convolução, no lugar da matriz geral multiplicação, em pelo menos uma das suas camadas, sendo conhecida pelas suas aplicações na visão computacional. Deste modo, em vez de cada neurónio de uma camada anterior estar ligado a todos os neurónios a partir da camada seguinte, a camada convolucional aplica ligações locais a diferentes grupos de neurónios, partilhando o peso e os valores de preconceito.

⁷RNN – *recurrent neural network*

Normalmente, uma arquitetura RNC para tarefas de classificação, começa com uma camada de entrada, uma camada convolucional, uma camada de agrupamento e uma camada de saída que contém uma função Softmax para obter uma previsão (Dionísio, Nuno Rafael Marques, 2018).

2.5.5 Redes neuronais recorrentes

A RNN promove a retenção de conhecimentos para orientar decisões futuras. Adicionando loops numa rede, permite que a informação persista. A célula contém um estado oculto, um vetor de neurónios, que recebe uma entrada x_t , em cada passo executa a multiplicação tradicional de peso, adição de preconceitos e ativação não linear (Dionísio, Nuno Rafael Marques, 2018).

Em RNN é comum usar a função de ativação *tanh* (tangente hiperbólica) mas ao contrário das redes tradicionais não recorrentes totalmente ligadas, o resultado é mantido para o próximo passo, introduzindo assim a memória. As redes de Memória de Longo Prazo (LSTM), conseguem reter informações que podem não ter surgido tão recentemente (Schmidhuber, 2015).

2.5.6 Frameworks de aprendizagem profunda

O interesse crescente por aprendizagem profunda, levou várias organizações a desenvolverem *frameworks* para facilitar a sua implementação, exemplos bem-sucedidos como o TensorFlow da Google, o PyTorch do Facebook ou o CNTK da Microsoft.

A escolha do TensorFlow para o caso de estudo desta dissertação está relacionada com a existência de bastante documentação, ser de baixo nível, permitindo realizar qualquer ação entre as camadas do modelo. O TensorFlow é uma biblioteca de software de código aberto para computação numérica utilizando gráficos de fluxo de dados, criados e mantidos pela Google, capazes de operar em larga escala e em ambientes heterogêneos. A biblioteca está escrita em Python, C++ e CUDA, oferecendo mais flexibilidade através da sua API Python. O TensorFlow utiliza um gráfico de fluxo de dados para representar a computação em termos de dependências entre operações representadas como nós.

Estes contêm tensores que são uma generalização de uma estrutura de dados multidimensional: desde vetores e matrizes até qualquer dimensão. Com isto é mais fácil aceder às capacidades de processamento da GPU⁸ (Dionísio, Nuno Rafael Marques, 2018).

⁸GPU – *graphics processing unit*

2.6 Considerações finais

Este capítulo começou por descrever na secção um, o conceito físico e matemático de vibração mecânica e os modos de vibração gerada por cargas de impacto, em especial, a radiação sonora e as vibrações devido a cargas dinâmicas de atividades humanas.

O modelo de carga de queda de uma pessoa, permite adquirir a noção das grandezas e valores a considerar, como a velocidade e aceleração do corpo. A necessidade de medir as vibrações, foi desenvolvida na secção subsequente, nomeadamente no que concerne à utilização de acelerómetros.

O levantamento do estado da arte dos sistemas de deteção de quedas, é fundamental para antecipar resultados, assim, foi sugerido a sua classificação, em função da tecnologia dos sensores utilizados e do desempenho dos algoritmos implementados.

Tendo em consideração o interesse em sistemas que utilizam aprendizagem máquina, a secção quatro incidiu sobre a análise de séries temporais, de forma a determinar similaridades entre os registos temporais dos sinais de vibração obtidos para indicar a possibilidade de queda ou ADL.

A regressão linear é o método mais simples para prever o comportamento de uma série temporal, contudo o sinal proveniente de uma queda pode ser considerado um fenómeno não estacionário, pelo que foram aprofundados outros métodos matemáticos como a Transformada de *wavelet*, e o método DTW. Por fim, foi realizada uma revisão dos sistemas de aprendizagem e *frameworks* de aprendizagem profunda.

Capítulo 3

Solução Proposta

Nas aplicações *internet of things* (IoT), os dados extraídos dos sensores são processados e centralizados nas *cloud* públicas ou privadas, levando a constrangimentos de latência e largura de banda. No sentido de responder aos requisitos de localidade e resposta em tempo real, a solução proposta neste capítulo baseia-se numa arquitetura de computação envolvendo conceitos como *edge computing*, *fog computing* e *cloud computing*.

3.1 Arquitetura da Solução

A arquitetura do espaço onde o idoso está inserido, como a habitação, o lar ou a unidade de saúde, será determinante para o escopo do modelo a desenvolver para a deteção de quedas em ambientes residenciais.

Neste contexto, a solução apresentada na Figura 3.1, tem como base a implementação dos sensores e dispositivo numa divisão, a ligação no edifício, a decisão de um alerta imediato para o cuidador residente e por fim a integração na *cloud*, em termos de rastreio final e sistemas de comunicação.

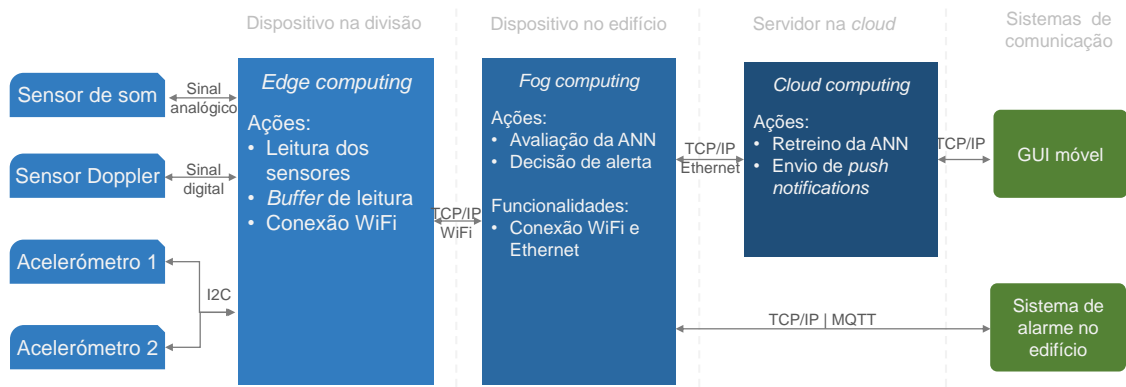


Figura 3.1: Arquitetura geral da solução.

O dispositivo na divisão terá como função principal monitorar os sinais de vibração, som e movimento a partir dos sensores estrategicamente distribuídos no contexto. A leitura dos mesmos será efetuada por um microcontrolador, cujo registo num Buffer servirá para detetar alterações no padrão dos sinais com suspeita de queda.

O dispositivo no edifício recebe os dados de uma suposta queda, primordialmente por Wi-Fi. De forma a partilhar os recursos de comunicação e descentralizar o processamento e armazenamento de dados, no edifício será feita a seleção de recursos para a rede neuronal e a atuação do sistema de alarme. A decisão de alerta surge de imediato devido à computação na proximidade do local de queda, utilizando os recursos de métodos estatísticos como a regressão ou métodos matemáticos mais elaborados como CWT ou DTW para analisar as séries temporais de Quedas ou ADL. Funcionalidades de conexão como Wi-Fi ou Ethernet vão permitir o uso de protocolos seguros para ligação ao servidor na Cloud.

No servidor na *cloud* será executado o retreino da rede neuronal e envio de notificações. A rede neuronal a indicar queda pode ser treinada, num servidor (asusgid), e a sua execução/avaliação no Jetson Nano¹. O NVIDIA Jetson Nano é uma plataforma de desenvolvimento suportada pelo SDK JetPack, compatível com a plataforma de inteligência artificial da NVIDIA. Com isto, é possível executar redes neuronais para aplicações como classificação de imagens, deteção de objetos, segmentação e processamento de fala.

3.2 Sensores aplicados na solução

A existência no mercado de vários sensores de tecnologia MEMS, fáceis de calibrar e de conectar ao Arduino, permitiu que fossem testados um vasto leque de soluções. A combinação de sensores de vibração, áudio e movimento dispostos no ambiente, promove à fusão de informação.

3.2.1 Sensor inercial MPU-9250/6500

O módulo MPU-9250 da InvenSense, é um sensor inercial de 9 eixos (9 DoF) combinando no mesmo invólucro (SiP) dois chip: um MPU-6500 responsável pelos 3 eixos do acelerómetro e pelos 3 eixos do giroscópio; e um AK8963 que contém um magnetómetro de 3 eixos. Além da informação inercial, o MPU-9250 possui um termómetro interno, um conversor analógico-digital de 16 bits e portas de comunicação SPI (*Serial Peripheral Interface*) e I2C (*Inter-Integrated Circuit*).

No caso de estudo não são usadas todas as funcionalidades do IMU, apenas o acelerómetro, de forma a reduzir o consumo de energia (da ordem 450 pA). O MPU-6500 é um dispositivo *motionTracking* de 6 eixos que combina um giroscópio, um acelerómetro e um processador de movimento digital (DMP²).

¹Jetson Nano-developer kit

²DMP-digital motion processor

Também possui um FIFO (*first in first out*) de 512 bytes que permite reduzir o tráfego da interface serial e o consumo de energia. Com I2C dedicado, o MPU-6500 possibilita entradas diretas de dispositivos I2C externos. Com a integração de 6 eixos, a DMP SoC e o *firmware* de calibração, permite um ótimo desempenho de detecção de movimento.

O MPU-6500 também foi projetado para interagir com múltiplos sensores digitais não inerciais, tais como sensores de pressão. O giroscópio tem uma gama programável de ± 250 , ± 500 , ± 1000 e ± 2000 graus/s e uma taxa de ruído de $0,01 \text{ dps}/\sqrt{\text{Hz}}$. O acelerómetro é programável na escala $\pm 2 \text{ g}$, $\pm 4 \text{ g}$, $\pm 8 \text{ g}$ e $\pm 16 \text{ g}$. A sensibilidade inicial calibrada de fábrica em ambos o sensor reduz os requisitos de calibração (TDK InvenSense, n.d.).

3.2.2 Sensor inercial GY-521

GY-521 é um módulo baseado no sensor MPU-6050, contém um acelerómetro e um giroscópio de tecnologia MEM. Um conversor analógico digital de 16 bits para cada canal analógico, permite a captura dos eixos x , y e z em simultâneo. O módulo utiliza o protocolo I2C para comunicar com o microcontrolador (Robots, 2016).

Para a sua configuração e calibração, foi selecionada a sensibilidade de $\pm 2 \text{ g}$ para o acelerómetro e a faixa de 250 graus/s para o giroscópio. Os dados de cada eixo são armazenados em dois bytes ou registos (Dejan, 2019), função *requestFrom* (MPU, 6, *true*), solicita a leitura de todos os 6 registos para os eixos X , Y e Z .

Em seguida, são lidos os dados de cada registo e convertidos de complemento para dois, para os valores legíveis da Figura 3.2, correspondentes ao registo da aceleração durante uma simulação de queda.




Figura 3.2: Captura GY-521 da aceleração x , y e z .

Foi testado ainda o sensor ADXL-345, este é um acelerômetro de 3 eixos, com resolução de 13 bits, tendo a saída digital acessível por SPI (3-4-wire) ou I2C. O dispositivo é adequado para medição estática da aceleração da gravidade em aplicações que seja necessário medir a inclinação, bem como medição da aceleração dinâmica resultante do movimento ou choque (Adafruit, 2020).

3.2.3 Sensor de som - Analog Sound V2

Os sensores de som analógicos são normalmente utilizados na detecção do ruído ambiente. Possui um microfone *electret* de condensador cujo limite de detecção pode ser ajustado através do potenciômetro presente no sensor que regulará a saída digital D0.

Contudo, de forma a obter uma resolução melhor, foi utilizada a entrada analógica A0, para aquisição do sinal de som da divisão, como observável na Figura 3.3.

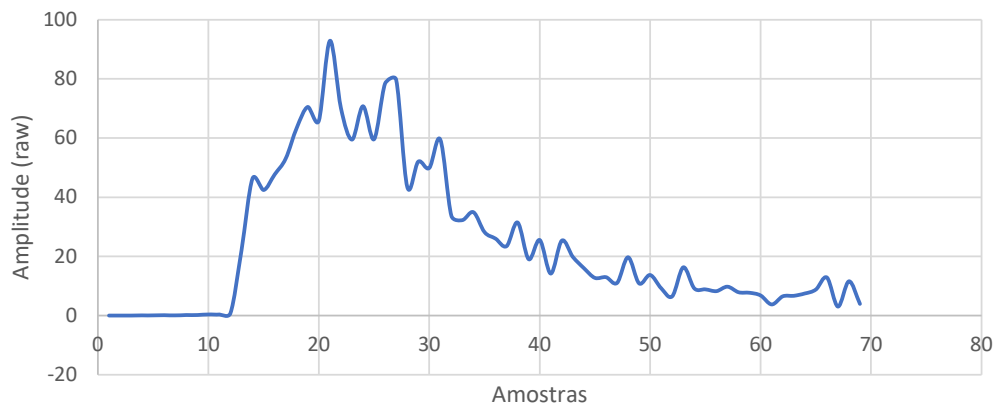


Figura 3.3: Sinal do sensor de som captado durante uma queda (*Analog Sound Sensor SKU DFR0034*, n.d.).

3.2.4 Sensor PIR HC-SR501

O sensor PIR (*Passive Infrared Sensor*) HC-SR501 é usado para detetar radiações infravermelhas com comprimento de onda em torno de $10\ \mu\text{m}$, que corresponde à temperatura corporal de seres vivos de sangue quente.

O caso de estudo, envolve a detecção de movimento antes, e depois da queda. A saída (em termos de tensão) do sensor PIR é alta quando deteta movimento, baixando na ausência de movimento (Ptrobotics, n.d.).

3.2.5 Sensor Doppler HB-100

O sensor de movimento de micro-ondas, é um detetor de objetos, baseado no princípio do efeito de Doppler.

Ao contrário dos detetores de infravermelhos comuns, detetam o movimento de um objeto detetando micro-ondas refletidos a partir do objeto, assim, não é afetado pela temperatura ambiente, tem um longo alcance de deteção e alta sensibilidade (Spark Fruit, n.d.). Em combinação com o sensor PIR, pode efetivamente determinar se alguém passou, não sendo afetado por outras fontes de calor, cor da roupa ou outros objetos.

O Módulo HB-100 testado, é formado por um emissor, que transmite impulsos na frequência de 10,525 GHz, e receptor, que capta os impulsos refletidos pelo objeto em movimento (Spark Fruit, n.d.). A queda é um evento de pouca duração, caracterizado pelo aumento da velocidade do corpo humano, que se traduz em alta frequência Doppler no domínio Tempo/Frequência.

3.3 Conetividades

O dispositivo implementado em cada divisão e os sensores conectados tem recursos limitados, as funcionalidades de comunicação previstas na ligação ao dispositivo central, dependem da eficiência do protocolo escolhido. Nesta secção serão descritos os meios de comunicação utilizados e o protocolo MQTT.

3.3.1 Comunicação Série

A comunicação série permite a troca de dados enviando bit após bit ao longo do tempo. Exemplos de aplicação de comunicação série são a RS-232C (porta série dos computadores pessoais), I2C, SPI ou USB (*Universal Serial Bus*).

Todas as placas Arduino possuem pelo menos uma porta serial (UART ou USART), usada para comunicação entre a placa, e um computador ou outros dispositivos. No protocolo UART (*Universal Asynchronous Receiver/Transmitter*) a comunicação é assíncrona, i. e., sem qualquer sinal de relógio. Os bits são enviados/recebidos a uma dada cadência acordada entre emissor e recetor a que se chama baudrate (medida em bits por segundo).

Na placa do Arduino Uno, os pinos da interface necessários à implementação do protocolo UART, são os pinos 0 (RX) e 1 (TX), sendo que estes já se encontram conetados ao circuito integrado FT232 da FTDI, que os liga ao porto USB da placa, permitindo assim a comunicação da placa com o computador a que ela está ligada via USB (Mendonça, n.d.).

A interface USB, permite a ligação de periféricos a computadores, de forma que os dispositivos interagem diretamente com o sistema de operação do computador, sem intervenção do utilizador (interação *plug and play*). Esta interface facilita a ligação e a retirada de qualquer periférico a qualquer momento, sem desligar o sistema (tecnologia *hot-swap*). Do mesmo modo, pode-se fornecer energia aos periféricos, através do mesmo cabo utilizado para comunicação de dados.

3.3.2 I2C/TWI

A biblioteca WIRE do Arduino, permite a comunicação com dispositivos I2C/TWI. Nas placas Arduino com layout R3 (pinagem 1.0), a linha de *Serial Data* (SDA) e linha de *Serial Clock* (SCL), são os pinos próximos de AREF (analogReference), e os pinos adicionais, A4 e A5.

Conforme descrito, tanto o módulo MPU 9250, como o GY-521, possuem um pino de endereço, que é responsável pelo endereçamento do CI no barramento I2C. Quando esse pino está desconectado, define que o endereço I2C do sensor é o 0x68. Quando conectado a 3,3 V, define o endereço 0x69. Dessa forma, foram utilizados os dois módulos, na captação da vibração do piso (*Arduino - Wire*, 2020).

Por exemplo, o acelerômetro ADX-345 tem um endereço de dispositivo único 0x53 e endereços de registos internos para o eixo X, Y e Z (Dejan, n.d.) .

No protocolo I2C, o sinal de dados é transferido em sequências de 8 bits, após a condição START, ocorre a primeira sequência de 8 bits, que indica o endereço do dispositivo *slave*. Depois das sequências de endereçamento, são enviadas todas as sequências de dados, até serem completamente enviados, terminando com uma condição especial de STOP.

3.3.3 SPI

O Arduino comunica com o módulo Ethernet e o cartão SD, utilizando o bus SPI, cujas conexões no header ICSP, são os pinos digitais 10, 11, 12 e 13.

A Interface Periférica Serial (SPI), é um protocolo de dados série, síncrono, usado por microcontroladores, para comunicar com um ou mais dispositivos periféricos rapidamente e em curtas distâncias. Com uma conexão SPI, há sempre um dispositivo mestre, usualmente um microcontrolador, que controla os dispositivos periféricos. Para estabelecer a ligação, estão disponíveis quatro linhas:

- MISO (*master in slave out*) – A linha *slave*, para enviar dados ao mestre;
- MOSI (*master out slave in*) – A linha *master*, para o envio de dados aos periféricos;
- SCK (*serial clock*) – Os pulsos de clock, que sincronizam a transmissão de dados gerados pelo mestre, e uma linha específica para cada dispositivo;
- SS (*slave select*) – O pino em cada dispositivo, que o mestre pode usar para habilitar e desabilitar dispositivos específicos.

3.3.4 Wi-Fi e Ethernet

No contexto das redes para monitorização de quedas, podem ser utilizadas tecnologias com fios ou wireless. Na solução proposta, é possível estabelecer a conectividade pelos dois meios de comunicação, através do ESP-12E ou *ethernet shield* do Arduino.

O grupo de trabalho responsável pelos *standards* IEEE 802.11, considera a existência de quatro grandes tipos de redes de comunicação sem fios, WPAN, WLAN, WAAN e WMAN, para efeitos de conetividade do dispositivo desenvolvido, consideremos apenas os dois primeiros:

- WPAN – *wireless personal area network*, onde se enquadram tecnologias sem fios de curto alcance, por norma até 10 metros, podendo alcançar os 100 metros, mediante do tipo de rede. Sendo esta uma tecnologia especificada pela norma 802.15. Esta área, compreende redes sem fios que utilizam dispositivos como o assistente pessoal digital (PDA), o computador pessoal (PC), ou periféricos, sendo o campo de tecnologias, o Bluetooth ou o adaptador de infravermelhos (IrDA). Este tipo de redes opera normalmente nas bandas de espectro *Industrial Scientific and Medical* (ISM) (Jorge L. Olenewa, 2016);
- WLAN – *wireless local area network*, consiste num nó central conhecido como *Access Point* (AP), que controla os canais de comunicação para um determinado número de nós, normalmente computadores, *smartphones*, entre outros. Estas são redes com alcances entre os 100 e os 300 metros, frequentemente como extensão, ou alternativa a redes de cabeamento convencional (par de cobre, cabo coaxial ou fibra ótica) (Gun, Maan, & Rana, 2015).

As redes locais sem fios (WLAN), apresentam a vantagem de já serem utilizadas em habitações, lares e hospitais, garantindo a conexão de dispositivos eletrónicos à internet, desde que ligados a um AP³. No entanto, devido a restrições no consumo energético de alguns dispositivos, esta tecnologia não é eficiente em aplicações de *wireless body area network* (WBAN).

Atualmente, existem já dispositivos de muito baixo consumo, que oferecem suporte para a tecnologia Wi-Fi, como o NodeMCU baseado no microcontrolador ESP8266. Oferecendo suporte nativo para redes Wi-fi (2,4 Ghz), com suporte para as normas 802.11 b/g/n, WPA/WPA, Wi-Fi Direct (P2P), *soft access point*, e antena integrada. O *firmware* utiliza o paradigma *event-driven* (Gonçalves, 2019), para facilitar o desenvolvimento de aplicações que necessitem de acesso à internet.

Apesar das restrições temporais, para garantir um alarme de queda, em tempo real, a tecnologia IEEE 802.3 tem condições, para ser implementada no dispositivo, garantindo boas taxas de transferência, e um mecanismo que permita determinar os tempos de entrega da mensagem. Quando existe um meio que é partilhado, é utilizada a técnica CSMA/CD, permitindo que a rede possa funcionar a débitos elevados (100 Mbps a 1 Gbps).

O Arduino *ethernet shield 2*, permite a conexão à internet usando a biblioteca *ethernet*. Esta plataforma depende do controlador W5500, que incorpora TCP/IP, 10/100, *ethernet* MAC e PHY. O módulo é ligado ao computador, *hub* ou *router* de rede usando um cabo *ethernet* padrão, CAT5 ou CAT6, com conectores RJ45.

³AP-*access point*

3.3.5 MQTT

O MQTT (*message queue telemetry transport*), consiste num protocolo de mensagens direcionado para a comunicação M2M (*machine-to-machine*).

Tendo em conta às características exigidas, é um dos protocolos apto para dispositivos embutidos. Para que a troca de mensagens se realize, o MQTT utiliza o paradigma *publish/subscribe* (Al-Fuqaha, Guizani, Mohammadi, Aledhari, & Ayyash, 2015). O paradigma implementa um *middleware*, que é chamado de *broker*, o qual é responsável por encaminhar as mensagens recebidas do *publisher*, para os *subscribers*, conforme ilustrado na Figura 3.4.




Figura 3.4: Arquitetura MQTT (Al-Fuqaha et al., 2015).

As mensagens do MQTT são organizadas por tópicos, o desenvolvedor de aplicativos, tem a flexibilidade de especificar que determinado cliente, pode interagir com determinadas mensagens. É possível também, gerir esses tópicos com um único *broker* (Mesquita, 2018; Shan Desai, 2019).

Cada uma das mensagens, pode ser enviada com diferentes níveis de *quality of service* (QoS). O nível de QoS, define o nível de garantia de entrega de uma mensagem, controlando a forma como as mensagens são transmitidas, entre o *broker* e determinado cliente, estando definidos três níveis distintos, QoS 0, QoS 1, QoS 2 (Mesquita, 2018).

O *Eclipse Mosquitto*, é um *broker* de mensagem *open-source*, que implementa o protocolo MQTT (Mosquitto, 2020). O *Mosquitto* realiza troca de mensagens com *hardware* de baixo custo, ou dispositivos *mobile*, e pode ser instalado em computadores e microcontroladores (*MQTT Version 3.1.1*, 2015).

Uma das formas de envio da notificação de queda, será utilizando o protocolo MQTT. Quando o nó dispositivo deteta a queda, é enviado um sinal pelo protocolo *publish*, com o IP do *broker*, o tópico “Queda” do MQTT, e a mensagem JSON (*JavaScript object notation*) para o *router*. Ao receber o sinal, o *router* verifica se tem alguma configuração de porta, e

envia a mensagem e o tópico para o *broker*. Por fim, o *broker* verifica o tópico, e envia a mensagem usando o protocolo *subscribe*, para todos os aplicativos que estiverem à espera da resposta do mesmo tópico (Pplware, 2019).




Figura 3.5: Notificação de queda MQTT.

3.4 Protótipos Desenvolvidos

A solução tecnológica deverá ser de baixo custo, nesse sentido, optou-se pelo Arduino Uno, e posteriormente, pelo Nodemcu, para a plataforma de desenvolvimento.

O Arduino Uno foi usado numa primeira fase, para adquirir os dados de aceleração e velocidade angular. Em regime estacionário, os valores A_x , A_y e A_z do acelerômetro triaxial são praticamente constantes, e a velocidade angular é 0 grau/s. Quando algo cai, origina vibração, e uma variedade de sinais ao longo da direção da queda, refletidas na mudança brusca dos valores da amplitude da aceleração, e da velocidade angular. O sinal de queda, requer uma frequência de amostragem alta, próxima dos 100 Hz, devido à mudança rápida da aceleração. Os valores dessa alteração, são aferidos e comparados, com os desempenhos do sistema, em experiências anteriores, nas mesmas posições e condições de velocidade (Malheiros, 2017).

Pela sua compatibilidade e desempenho foram selecionados os acelerômetros baseados no MPU 6050 e 6500, apesar do ADXL345 possuir algumas funções definidas, como o Free-fall, o que facilita a programação do sensor a sua sensibilidade é inferior, ambos mantêm um custo e consumo baixo. Conforme descrito acima, tanto o módulo MPU-9250 como o GY-521 possuem um pino de endereço, que é responsável pelo endereçamento do CI no barramento I2C. Quando esse pino está desconectado define que o endereço I2C do sensor é 0x68. Quando conectado a 3,3 V, define o endereço 0x69. Dessa forma foi possível utilizar os dois módulos na captação da vibração do piso.

3.4.1 Arduino Uno R3

A placa de desenvolvimento Arduino, tem por base um microcontrolador da ATMEL AVR de 8 bits (ATmega 328), de 16 Mhz, com 32 kB de memória interna dos quais 0,5 kB são utilizados no *bootloader*. Uma das características essenciais à interação entre o Arduino e os sensores e componentes eletrônicos, são os pinos de entrada e saída, que permitem ler

e escrever dados. A placa tem 14 pinos digitais, 6 dos quais podem realizar PWM (*pulse width modulation*) e 6 pinos analógicos capazes de medir sinais de 0 a 5 V ligados a um conversor analógico/digital (ADC) de 10 bits. O Arduino comunica, com computadores, microcontroladores ou sensores, através de I2C, SPI e UART (Atmel, 2015).

Assim como a generalidade de todos os microcontroladores, o ATmega328 apresenta como funcionalidades, temporizadores (*timers*) e interrupções (*interrupts*). O uso de interrupções, permite que um programa possa ser interrompido por um dado evento, sendo chamada uma rotina de serviço à interrupção, ISR⁴, no sentido de dar resposta a esse evento. Os pinos digitais 2 e 3, podem ser utilizados como interrupções no Arduino Uno.

Para minimizar o consumo de energia, e o envio permanente de dados, a saída do sensor de movimento HB 100 do dispositivo, foi ligada ao pino 2, e configurado como interrupção, ao detetar a presença de alguém na divisão.

Para além da leitura da vibração do piso foram combinados outros sensores, para captação de som e movimento de acordo com o esquema geral na Figura 3.6.

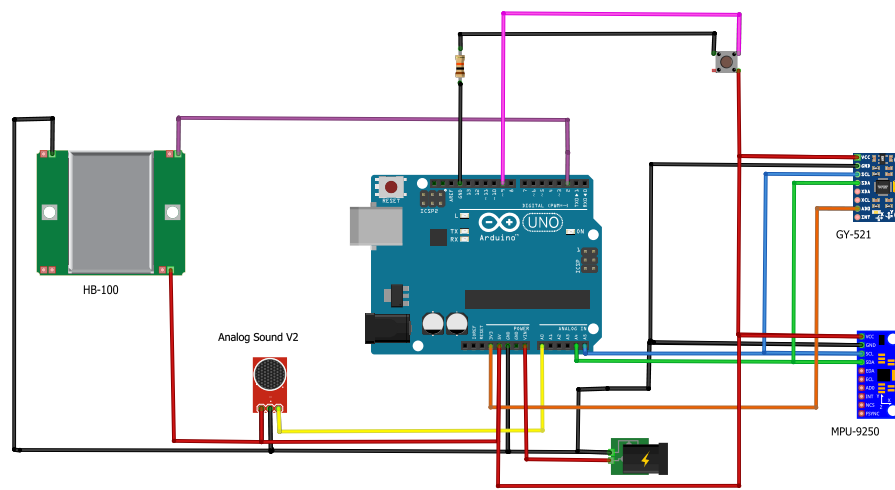


Figura 3.6: Esquema geral do dispositivo baseado no Arduino.

O Arduino Uno pode ser programado com recurso a software de código aberto, conhecido como Arduino IDE⁵. Esta plataforma de programação, permite escrever programas baseados na linguagem *wiring*. Ambos os ambientes de desenvolvimento são escritos em Java, contudo, incluem uma biblioteca C/C++ também denominada *wiring*, que simplifica as operações de entrada e saída no Arduino, abstraindo o utilizador da linguagem C/C++ de baixo nível (Santos, Duarte Sérgio Rodrigues Granado, 2014).

⁴ISR-*interrupt service routine*

⁵IDE-*integrated development environment*

3.4.2 NodeMCU v3

NodeMCU é um *firmware* baseado em Lua (Ierusalimschy, de Figueiredo, & Celes, 2020), de código aberto para o ESP8266 Wi-Fi SoC (*system on chip*) da Espressif, usa um sistema de arquivos SPIFFS (SPI *Flash File System*) baseado em Flash, e permite a conexão a uma rede Wi-Fi sem o auxílio de outro dispositivo.

Possui uma antena *wireless* embutida (padrão 802.11 b/g/n), um conector micro USB para conexão ao computador, pinos de entrada e saída (I/O), uma porta ADC de 10 bits e um regulador de tensão 3.3 V. NodeMCU é implementado em C e está em camadas no Espressif NON-OS SDK (*Overview - NodeMCU Documentation*, n.d.-a).

As características do NodeMCU apresentado em 2014, para ser utilizado no desenvolvimento de projetos IoT, surge como solução alternativa ao Arduino, Figura 3.7.

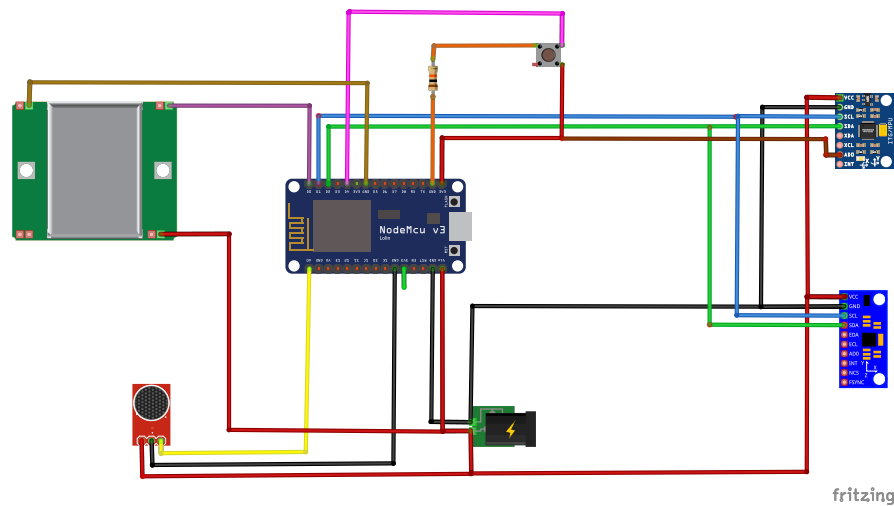


Figura 3.7: Esquema geral do dispositivo baseado no NodeMCU v3.

O NodeMCU é menos dispendioso do que o Arduino, para além disso, tem Wi-Fi incorporado, o que permite o envio dos dados em tempo real, sendo opção, para implementar no dispositivo final.

O módulo utilizado no protótipo, foi o NodeMCU v3, fabricado pela Lolin, inserido numa base de conexão, facilitando assim as ligações aos pinos, Figura 3.8.

A programação do NodeMCU, pode ser feita usando Lua, ou o IDE (*integrated development environment*) do Arduino, através da porta micro USB. Lua é implementada como uma biblioteca, escrita em clean C (isto é, no subconjunto comum de (*American national standards institute*) ANSI C e C++).

Como linguagem de extensão de aplicativos, Lua não tem o conceito de um programa “principal”, pois, funciona embutido num cliente anfitrião. Este programa anfitrião, invoca funções para executar um trecho de código Lua, pode escrever e ler variáveis Lua, e pode registar funções C chamadas pelo código Lua. Através da utilização de funções C, Lua pode

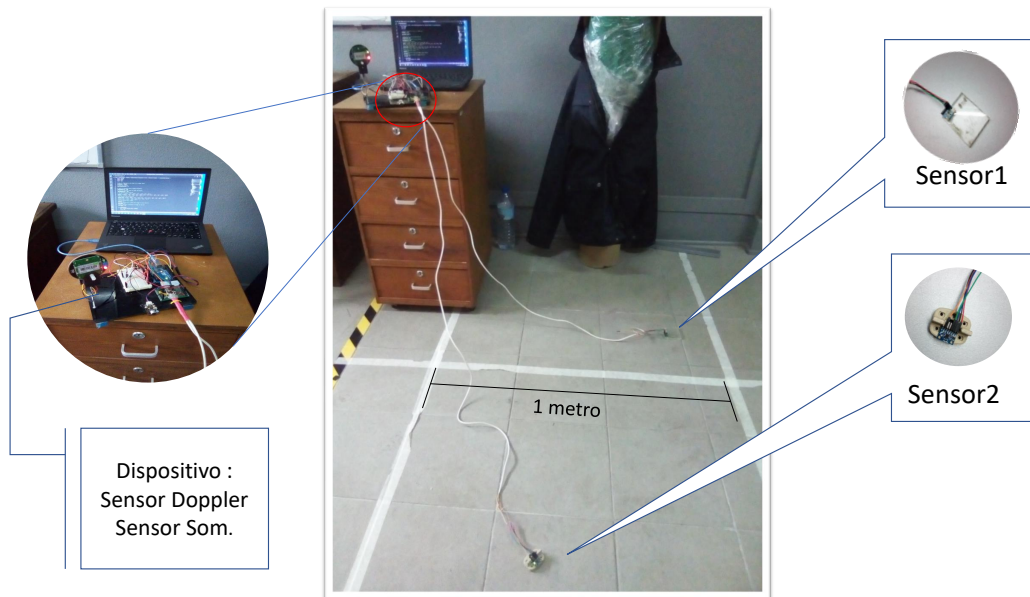


Figura 3.9: Dispositivo para aquisição de dados.

O Sensor 1, permite a captura da vibração no piso, através dos valores brutos da aceleração (acx , acy , acz) e velocidade angular (gyx , gyy , gyz). O Sensor 2, está colocado a 1,5 m do Sensor 1, efetua apenas a leitura da aceleração (acx_1 , acy_1 , acz_1). O sensor de som, e o sensor de presença, estão inseridos na base do dispositivo.

Na Tabela 3.1, estão descritos os parâmetros dos sensores utilizados no protótipo, e as variáveis atribuídas, para o registo da leitura da vibração no pavimento, som gerado pelo impacto da queda e deteção de movimento.

Tabela 3.1: Sensores.

Sensor	Referência	Variável	Função	Atributos
Sensor 1	MPU 9250/6500	acx ; acy ; acz ; gyx ; gyy ; gyz	Vibração no piso (<i>trigger</i>)	<i>raw</i>
Sensor 2	GY-521	acx_1 ; acy_1 ; acz_1	Vibração no piso (> 1,5 m)	<i>raw</i>
Sensor de Som	Analog V2.2	som	Som do impacto	0 – 255
Sensor Doppler	HB-100	<i>dop</i>	Movimento	0 – 10

De acordo com o fluxograma implementado (Figura 3.10), o dispositivo efetua a leitura de todos os sensores num primeiro *buffer*, se o valor D, ultrapassar os valores limiares

estabelecidos por análise de treino, ou regressão, significa a possibilidade de uma queda, registrando os valores imediatos, num segundo *buffer*.

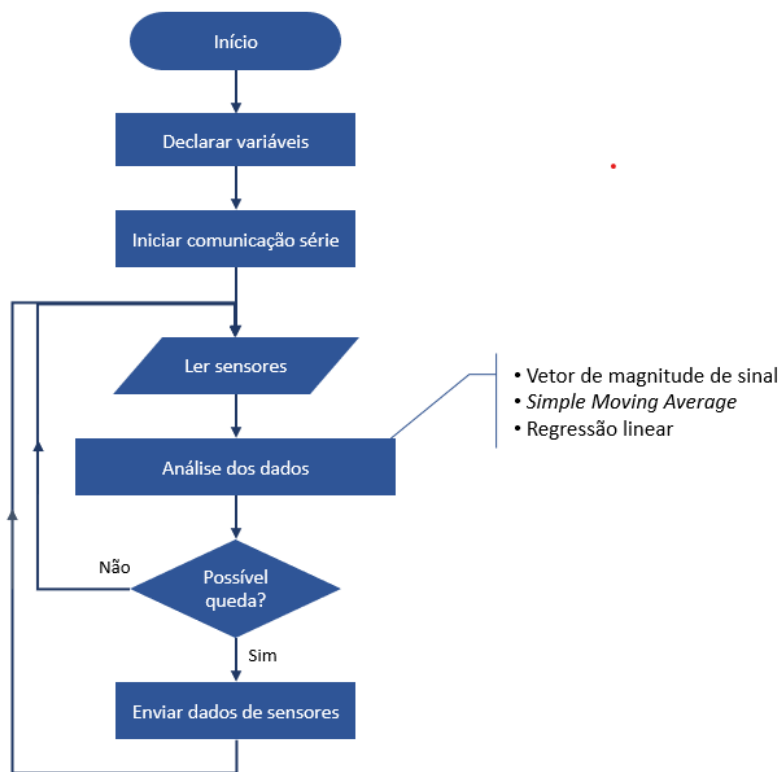


Figura 3.10: Fluxograma da detecção de queda e envio de dados aplicado no dispositivo.

Este *trigger* (valor limiar D) é usado para a obtenção do *dataset*, com o envio dos dados gravados nos dois *buffer*. No caso de estudo, foram testados diferentes valores de limiar brutos, como demonstrado, $D > 15\,700$ ou $D < 15\,400$, estas condições permitem reduzir o custo computacional, e podem ser o *trigger* do dispositivo.

Para estabelecer a comunicação entre o Arduino e um PC, o dispositivo foi configurado com a chamada do método `ser.serial` (porta-série, *baud rate*) após instalação da biblioteca *python-serial* (*pyserial*) e importado o módulo `serial`. Os dados são enviados no formato JSON, sendo fundamental para manipular a *String* enviada pelo dispositivo. Exemplo de JSON minimizado, e transmitido para a porta-série do Arduino Figura 3.11.

```

{"Estado": "espera"}
{"queda?": "GY_521", "acc": [-1272, -208, -15588], "gyy": [-43, 12, -22], "som": [758]}
  
```

Figura 3.11: JSON minimizado

Os parâmetros de queda adquiridos pelo dispositivo, são enviados para um computador. O *script* para a gravação de dados no formato CSV (*comma-separated-values*), foi elaborado em Python, de acordo com o pseudocódigo descrito na Figura 3.12:

```

estado = "passivo"
Leitura de dados {
  Ciclo infinito {
    Se estado == "passivo" && trigger > limite, então {
      estado = "ativo"
      tempo_trigger = tempo()
    }
    Se estado == "passivo", Então {
      dados_sensores → buffer_antes
    } Senão {
      dados_sensores → buffer_depois
      Se tempo() - tempo_trigger > periodo_leitura, Então {
        dataset = buffer_antes ∪ buffer_depois
        retorno dataset
      }
    }
  }
}

```

Figura 3.12: Pseudocódigo da gravação de dados.

Analisemos os parâmetros de amplitude adquiridos na série temporal, correspondente a uma queda efetiva. Durante as fases específicas da queda, foi usado o vetor de soma vetorial total (Equação 2.17) para estabelecer o início da mesma, apresentando um valor absoluto máximo, na fase de impacto, (Figura 3.13).

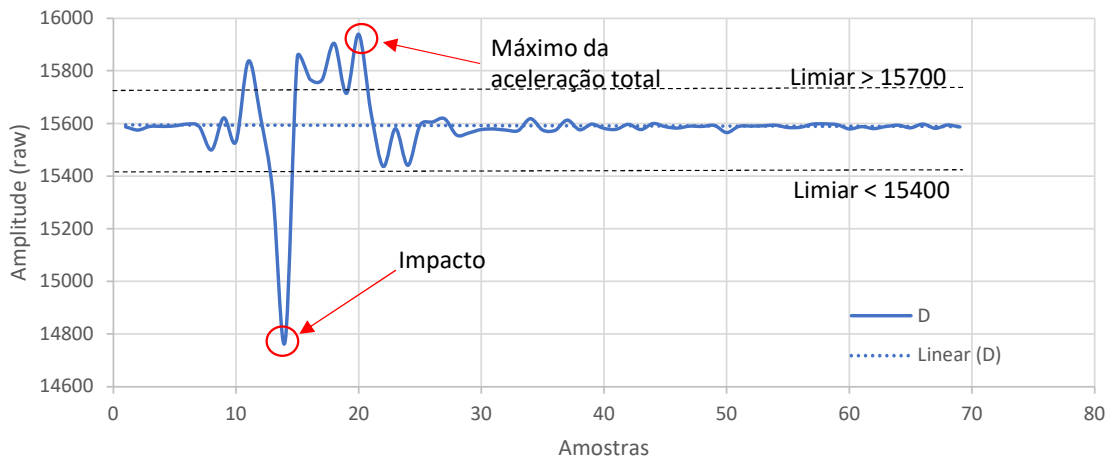


Figura 3.13: Gráfico do vetor de soma vetorial D.

Os registos gravados durante os testes de queda (Figura 3.14), evidenciam as diferentes fases da experiência.

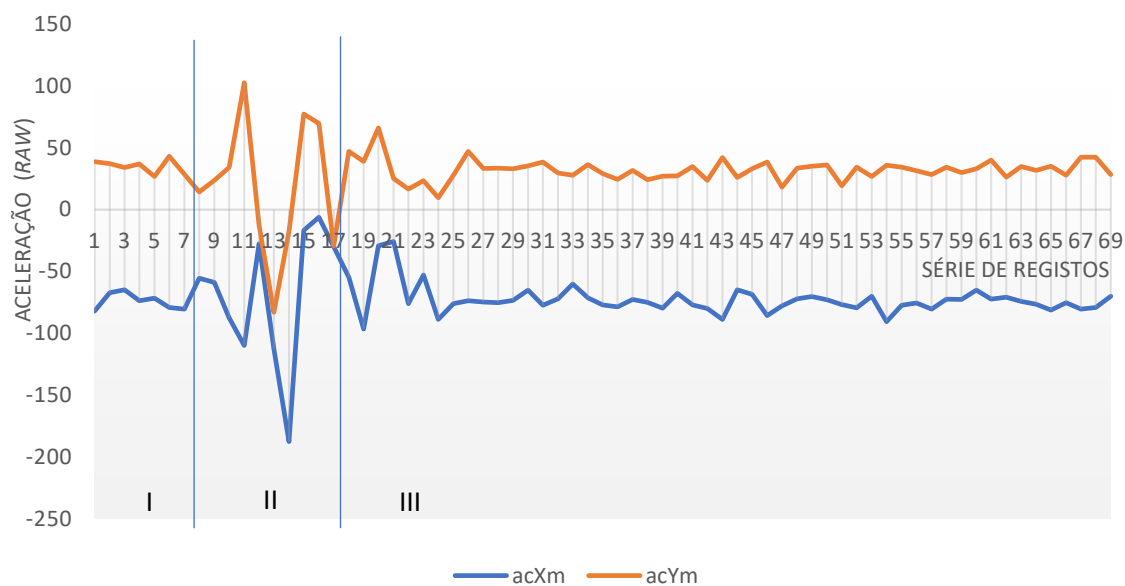


Figura 3.14: Fases do evento de queda visualizadas através da leitura do sinal do acelerómetro do sensor1: I – atividade quotidiana anterior à queda, II - a queda, III - após a queda.

Para cada queda, com a duração aproximada de 700 ms, foram registados valores dos sensores de 10 ms, em 10 ms, num total de 70 registos por série.

Observa se que, ao detetar um evento através do *trigger* estabelecido, de imediato são recuperados os valores dos sensores antes da queda (Fase I), é gravado o registo durante o impacto (Fase II) e os valores após a queda (Fase III), até estabilizarem.

3.6 Considerações finais

No início deste capítulo, foi apresentada a arquitetura da solução baseada no contexto em que o idoso se encontra.

Para monitorizar a queda na divisão, semelhante a um quarto, foi planeado o desenvolvimento de um dispositivo de baixo custo, com sensores de inércia instalados no piso, sensores de som e movimento, para aferir os indícios da atividade da pessoa.

A tarefa de medir as vibrações não é fácil, sendo mais complicada em função dos sensores frugais disponíveis, como tal, foram testadas várias configurações de acelerómetros e sensores de som. Na concepção do dispositivo, foram ainda testados, duas plataformas de desenvolvimento, uma com base no Arduino uno, outra baseada no NodeMcu.

O protótipo desenvolvido, foi implementado numa sala de 4x3 m, servindo para adquirir um conjunto de dados para treino, a partir da simulação de queda de um modelo antropomórfico, ou da queda de objetos, de forma a simular as atividades do dia a dia.

A leitura dos sensores é enviada num *buffer* para um computador, sempre que exista a suspeita de uma queda, passível de originar o *trigger*. O dispositivo no edifício, executa o pre processamento e o teste da solução, ao classificar os dados.

Capítulo 4

Descrição e Análises de Resultados

As quedas reais acontecem de forma inesperada, para além disso, existe uma diversidade de quedas, o que torna difícil a recolha de dados. Daí que, a maioria dos conjuntos de dados para deteção de quedas sejam simulados em ambientes laboratoriais.

Como referido no Estado da Arte, existem alguns *datasets* disponíveis para o público, no entanto estes conjuntos de dados na maioria das vezes incluem apenas sensores *wearables*, alguns usam apenas sensores de imagem, sensores de pressão e infravermelhos, ou apenas sensores infravermelhos.

Neste capítulo, será feita a abordagem multimodal de vários sensores, a descrição e análise de um conjunto de dados obtidos por simulação, no contexto de uma sala. A criação de modelos de aprendizagem automática para classificação, virá na sequência dos recursos extraídos por métodos matemáticos como CWT e DTW.

4.1 Dataset

Neste trabalho foram simuladas 40 quedas e 40 ADL (*activities of daily living*). O *dataset* criado consiste em 2800 registos, ou seja, linhas, gravados no formato.csv contendo o registo das acelerações brutas, valores analógicos do microfone e detetor de movimento medidas durante a simulação de uma ação queda de objeto (ADL) ou queda de manequim. Os dados do microfone e do sensor de movimento, podem não ser tidos em conta nos processos de extração e classificação de recursos (ruído em redor como sirenes, movimentos indesejados), o que pode não refletir um ambiente real.

Durante a fase inicial, foi criado o *dataset#1* tendo em conta a queda de três objetos (cadeira, telemóvel e garrafa de água 25 cl). Neste banco de dados estão gravados 90 ficheiros numerados de 0 a 90 (*data_xx.csv*): 0–30 representa a queda de uma cadeira; 31–61 representa a queda de uma garrafa de plástico de 25 cl cheia de água; 62–92 representa a queda de um telemóvel Alcatel. O *dataset#1* tem como objetivo a utilização em rede neuronal com três componentes: treino, teste, e validação de atividades ADL.

O modelo observado na Figura 4.1, foi construído com um tubo de cartão grosso, com 20 cm de diâmetro e 120 cm de altura, preenchido com 10 garrafas de plástico, cheias com 1,5 litros de água (densidade próxima da carne). No topo, tem um bloco de ferro com 3 kg (simula a cabeça e o centro de massa), cuja velocidade máxima alcançada em queda livre, pode atingir 4,1 m/s (Equação de Torriceli 2.7).



Figura 4.1: Modelo antropomórfico.

O *dataset#2*, foi gerado a partir da simulação da queda, do modelo de corpo humano (Figura 4.1) em pavimento de tijoleira, e da não queda, sendo registados os valores brutos de quatro sensores (Tabela 3.1). Este conjunto de dados, será considerado como a série temporal de referência, da análise de queda e não queda de uma pessoa.

O pré-processamento permitiu criar um conjunto de dados mais alargado, usado para o treino e testes. Cada coluna de dados registada no local, indica a aceleração, a velocidade angular (giroscópio) nos eixos xx , yy e zz , o som e a contagem Doppler. As linhas envolvem a amostragem, envio e registo dos sensores à frequência de 100 Hz ($T = 10$ ms).

Os primeiros recursos estatísticos extraídos do banco de dados, foram a média de conjunto, os valores mínimo e máximo. Na fase de pré-processamento, obtiveram-se os vetores d e g , a partir dos valores das componentes de aceleração e velocidade angular média dos sensores inerciais.

O vetor D, (Equação 2.17), seleccionado como a série temporal de estudo, envolveu na sua caracterização, para além dos recursos estatísticos referidos anteriormente, o cálculo da variância, Kurtosis e Skewness (Özdemir, 2016).

$$\text{Média (d): } \mu = \frac{1}{N} \sum_{i=1}^N d_i \quad (4.1)$$

$$\text{Variância (d): } \sigma^2 = \frac{1}{N} \sum_{i=1}^N (d_i - \mu)^2 \quad (4.2)$$

$$\text{Skewness (d): } \frac{1}{N\sigma^3} \sum_{i=1}^N (d_i - \mu)^3 \quad (4.3)$$

$$\text{Kurtosis (d): } \frac{1}{N\sigma^4} \sum_{i=1}^N (d_i - \mu)^4 \quad (4.4)$$

Como recurso extra, de modo a melhorar os resultados da classificação e a precisão dos algoritmos de aprendizagem máquina, foram ainda obtidos os coeficientes da transformada de *wavelet* de várias séries temporais. Esta análise será feita na próxima subsecção.

Com base nos dados recolhidos no conjunto de dados do *dataset#2*, foram calculados os recursos estatísticos da soma vetorial da aceleração, para diferentes atividades, sendo estes descritos na Tabela 4.1:

Tabela 4.1: Estatísticas da componente soma vetorial da Aceleração.

Atividade	Mínimo	Máximo	Média	Desvio P.	Curtose	Distorção
ADL	15526,51	15631,78	15589,12	14,1994	5,26297	-0,99728
QUEDA	14771,18	15939,67	15591,75	133,778	20,8996	-2,78021

Da análise dos valores anteriores, podemos aferir que a o desvio padrão da série temporal adquirida na queda, é bastante superior ao ADL, assim como o achatamento da distribuição de probabilidade (curtose), o que significa uma maior dispersão dos valores.

A análise de correlação, tem como objetivo a avaliação do grau de associação entre as variáveis, da aceleração, giroscópio e som, indicando a relação linear entre elas. Os componentes de cada sensor encontram-se identificadas por siglas. A Figura 4.2 mostra em linhas cinzentas os *clusters* (grupos), que mais se relacionam, possibilitando a criação de um *clustermap*.

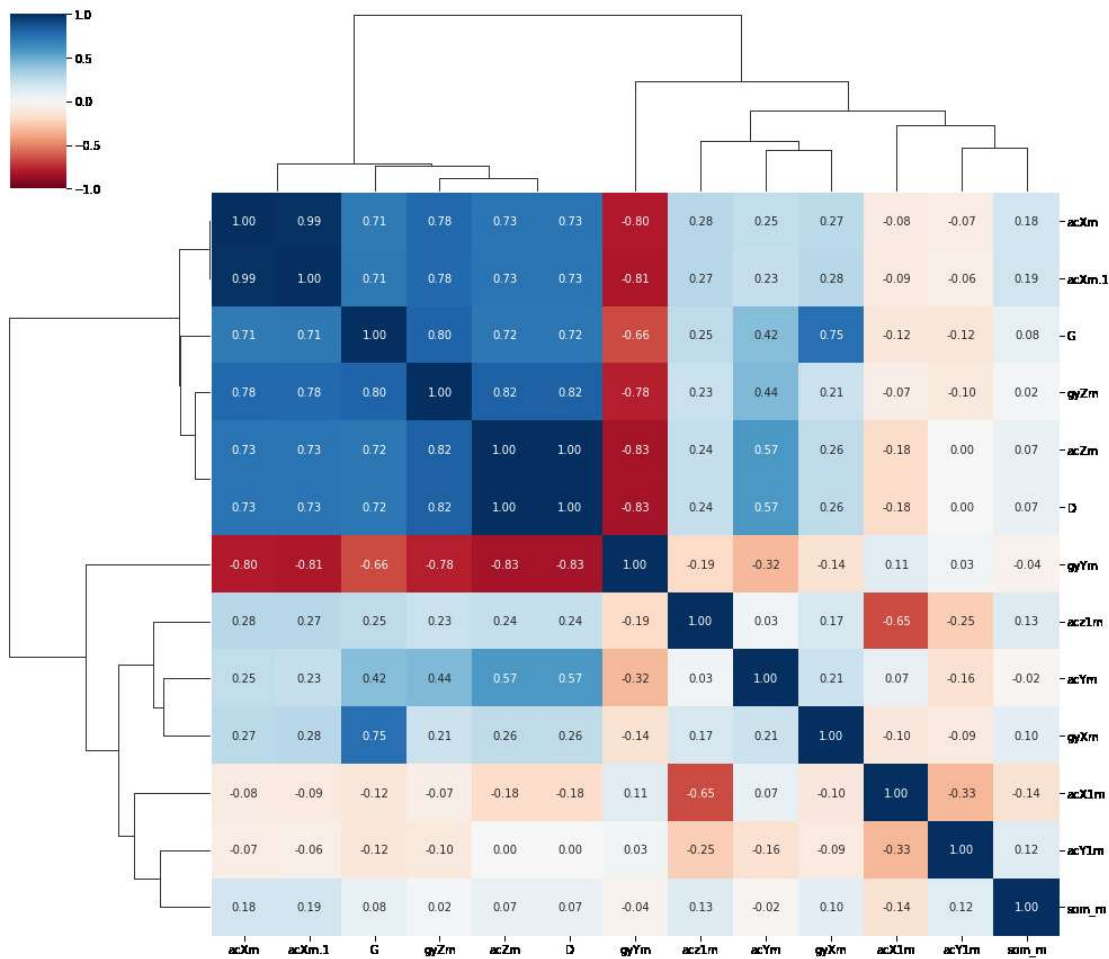


Figura 4.2: Correlação de todos os sensores do dispositivo.

As correlações positivas variam da cor branca (sem correlação), à cor azul (correlação total), enquanto as correlações negativas, variam da cor branca (sem correlação) à cor vermelha (correlação total). A diagonal da matriz, correlaciona a variável y com ela própria, como tal, possui uma relação positiva a 100 %.

Os resultados da correlação, permitem verificar que a componente D, depende fortemente de $acZm$, este valor é muito maior do que os valores de aceleração nos eixos x e y , respetivamente $acXm$ e $acYm$, o que acaba por influenciar o valor da aceleração total.

4.2 Método CWT de Classificação

Os padrões de queda registados resultam num sinal não estacionário. O cálculo estatístico da média e variância para diferentes períodos, como medida de potência afeta ao sinal e a verificação de diferenças significativas, seria um método possível e simples para analisar a não estacionaridade de uma série temporal. A análise de *wavelet* ao decompor

simultaneamente uma série temporal em espaço de tempo/frequência, permite obter informações sobre a amplitude de quaisquer “periódicos” dentro da série e como essa amplitude varia com o tempo. Por conseguinte, a WT é adequada para analisar sinais que se caracterizam por comportamentos transitórios ou descontinuidades, tais como eventos transitórios típicos do movimento humano (Caramia, De Marchis, & Schmid, 2019).

Consideremos o padrão médio de queda do mundo real, como a “queda do modelo humano” gerando a série temporal de referência “onda-mãe” para detetar quedas, cada sinal de aceleração registrado pode então ser comparado a esta série, através da análise das ondas. A semelhança do sinal gravado com a queda do “modelo”, é a característica que pode ser usada para discriminar entre quedas, e outras atividades.

Os valores médios dos sinais de aceleração, serviram para obter o sinal padrão médio de queda, que será convertido numa *wavelet* mãe adaptada, definida no intervalo $[0,1]$, e satisfazendo a definição da *wavelet* (Equação 2.33). Após a criação da onda mãe, é testado o grau de similaridade entre a mesma e os sinais a testar. Em seguida, comparamos o sinal na janela atual com a *wavelet*-mãe calculando os coeficientes de transformada *wavelet* contínua (CWT) (Equação 4.5) (Torrence & Compo, 1998).

$$CWT_{coeff(a,b)} = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} SV_{candidata}(t) \psi_{fall} \left(\frac{t-b}{a} \right) dt \quad (4.5)$$

Na Equação 4.5, a e b são a escala e os parâmetros de translação, respetivamente $CWT_{(coeff(a,b))}$ descreve a similaridade (quanto maior o coeficiente, maior a similaridade) entre o candidato e a *wavelet* mãe, em diferentes escalas, a e translações, b . Em seguida, é o escolhido valor máximo de $CWT_{(coeff(a,b))}$ (PAOS, 1998).

Para calcular a transformada *wavelet* da série temporal D , escolhemos a *wavelet* Morlet, por ser simples, comum e parecida com a onda de impacto, cuja *wavelet* mãe é,

$$\psi_0(\eta) = \pi^{-\frac{1}{4}} e^{i\omega_0\eta} e^{-\eta^2/2} \quad (4.6)$$

A escolha do número de onda w_0 , fornece o número de oscilações dentro da própria *wavelet*. Os erros devido à média, diferente de zero, serão menores. Serão ainda executadas as seguintes etapas:

- Determinar a Transformada de Fourier da *wavelet* mãe;
- Determinar a transformada de Fourier da série temporal;
- Seleção da escala mínima S_0 e todas as outras escalas.

Por fim, foi realizada a análise espectral da série temporal de queda e ADL, usando o módulo pycwt (PyCWT, 2017). Na Figura 4.3, está representado o gráfico de contorno, obtido a partir da análise da aceleração acX de uma experiência de queda do modelo.

Na Figura 4.3.a, encontra-se representada a série temporal da soma vetorial da aceleração de uma queda. Na Figura 4.3.b, encontra-se representado o espectro de potência

da *wavelet*, usando a *wavelet* de Morlet. O eixo xx é a localização da *wavelet* no tempo, para uma série temporal de 120 valores. O eixo y é o período da *wavelet* em ms. Os contornos pretos são as regiões de significância de 10 %, usando um espectro de fundo de ruído amarelo. As áreas laranjas indicam que a queda ocorreu entre a amostra 40 e 50, enquanto entre 0–20 e 60–120 não aconteceu nenhum evento.

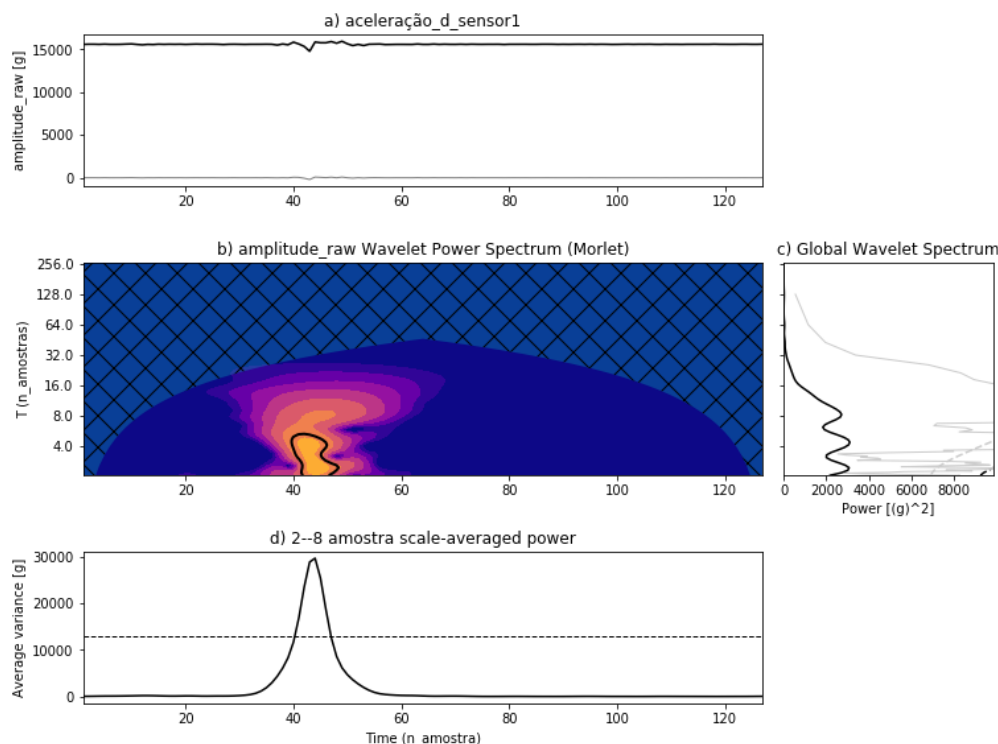


Figura 4.3: Contorno da série temporal D: (a) série temporal da soma vetorial da aceleração de uma queda; (b) o espectro de potência da *wavelet*, usando a *wavelet* de Morlet.

A aplicação da CWT aos padrões da aceleração, permite a localização do estado transitório do sinal durante o impacto. Assim, uma incidência de queda, pode ser detetada, se uma superfície máxima (zona laranja) for observada. Pelo contrário, um ADL não gerará um máximo significativo, uma vez que estas atividades resultam em padrões repetitivos. A zona laranja, corresponde à maior potência do espectro *wavelet*, ou seja, o momento do impacto. A variância média nesta zona é bastante elevada, comparada como os valores da série seguinte (Figura 4.3) correspondente a ADL.

O método de Monte Carlo foi aplicado para verificar se o espectro de potência da *wavelet* é distribuído por qui-quadrado, e determinar as fórmulas empíricas da média do tempo e da média da escala. Os espectros teóricos de energia das ondas, são derivados e comparados com os resultados de Monte Carlo (PAOS, 1998).

Os valores de confiança/variância (*SCALE_AVG_SIGNIFIC*) em caso de queda, foram comparados com o espectro e valores de ADL, Figura 4.4, deste modo este método

permite extrair atributos de uma queda ou ADL, com maior rigor e precisão do que o valor de limiar.

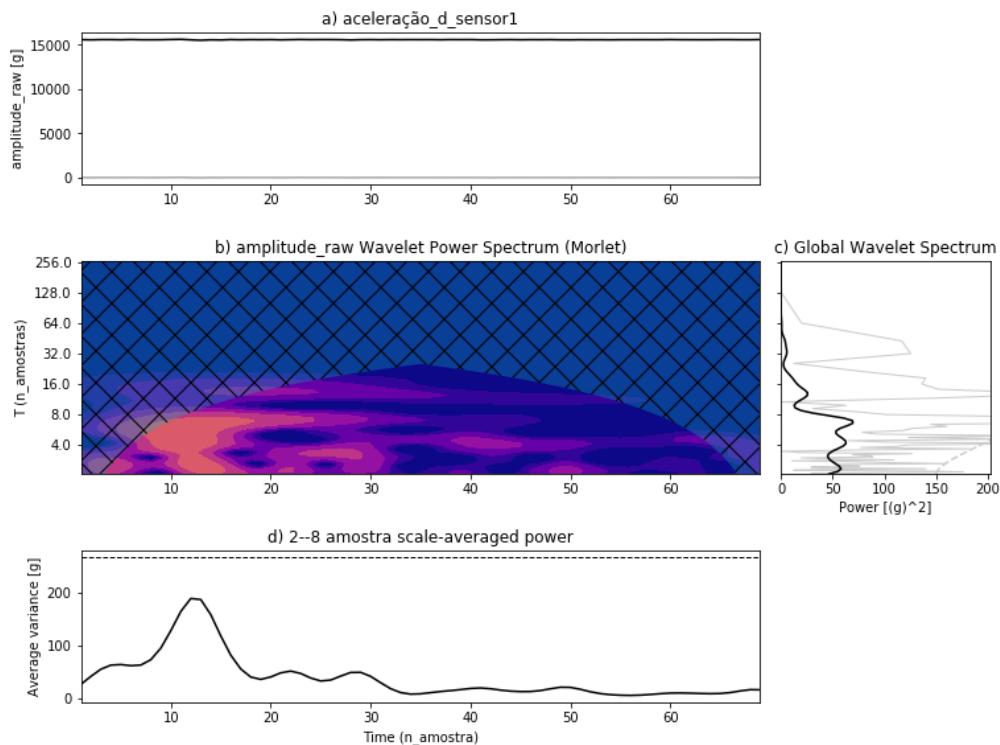


Figura 4.4: Gráfico de contorno da série temporal D não queda (ADL).

A representação do gráfico de contorno ou escalograma, permite que a classificação seja mais robusta face à mudança de dados no tempo, alterações na amplitude do sinal e na taxa de amostragem. De qualquer das formas, não é possível a sua implementação no dispositivo com o Arduino Uno. Para classificar a atividade em queda ou não queda utilizando CWT, a matriz dos valores de confiança “scale_avg_signif” pode ser submetida a uma função degrau (Gibson, Amira, Ramzan, Casaseca-De-La-Higuera, & Pervez, 2016).

4.3 Método DWT de Classificação

Ao determinar similaridades entre séries temporais de várias quedas e ADL, com tempos e velocidades diferentes ou desfasados, o DTW é um algoritmo que devido à deformação da dimensão temporal pode encontrar o melhor alinhamento na sequência de observações, e com isto ser um bom classificador das atividades simuladas (Muller, 2007).

O objetivo da DTW é alinhar temporariamente duas sequências, mantendo o sentido, mas em determinadas condições (Oliveira, 2015). Dadas as séries temporais do *dataset#1*, referentes à queda de cadeira (A) e queda de telemóvel (B), Figura 4.5, é determinado o valor absoluto das diferenças (distância euclidiana unidimensional), como medida de custo.

Em seguida, usando programação dinâmica, calculamos a matriz de custo acumulado D , para obter a distância DTW (A, B), Figura 4.6.




Figura 4.5: Séries Temporais: A - telemóvel ; B - cadeira, DTW *distance* $DTW(A, B) = 1020$ (*Total cost of optimal warping path: 1020*).

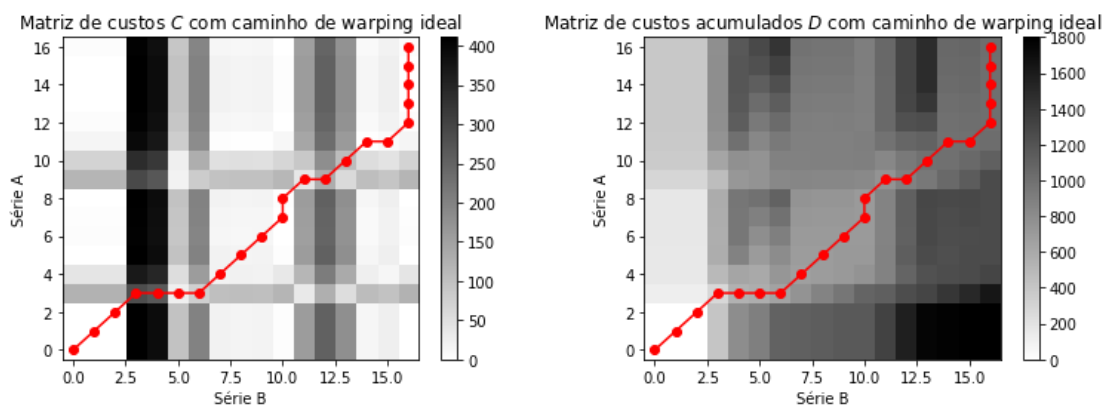


Figura 4.6: Caminho de deformação de séries diferentes.

Na demonstração seguinte, comparamos duas séries similares referentes ao mesmo evento, ou seja, a queda de cadeira em momentos diferentes, Figura 4.7.




Figura 4.7: Duas séries semelhantes A-cadeira (tentativa 1); B-cadeira (tentativa 2).

A distância obtida é inferior à experiência anterior $DTW(A, B) = 436$ (*Total Cost of Optimal Warping Path: 436*), como se observa pelo caminho de deformação (caminho na matriz distância d que determina o menor custo total) Figura 4.8.




Figura 4.8: Caminho de deformação de séries semelhantes.

Quanto maior a distância DTW (A, B), menos aproximadas são as sequências, como se pode observar, existe um custo acumulado ótimo, entre as sequências que correspondem à queda de duas cadeiras, menor do que entre a queda da cadeira, e a queda de telemóvel. No caso de estudo, o DTW pode servir para classificar quedas, comparando com uma série temporal de referência.

4.4 Regressão para a Identificação Local de Queda

O DTW e a transformada de *wavelet*, não são fáceis de implementar na plataforma de desenvolvimento. As variáveis globais usam mais de 100 % da memória dinâmica do Arduino, não restando memória dos 8192 bytes, para as variáveis locais. Em alternativa, foi testada na identificação local da ocorrência de queda, a função de regressão linear múltipla com variável resultado, obtida no Microsoft Excel, de acordo com a Tabela 4.2.

Tabela 4.2: Parâmetros de entrada e variável de saída da função regressão.

Variáveis de entrada (X)	Variável RL [0-20]	Classificação
acX _m ; acX1 _m ; acY _m ; acY1 _m ; som _m ; acZ _m ; acz1 _m ; gyX _m ; gyY _m ; gyZ _m ; D; G	Resultado ≤ 5	Inatividade
	$5 < \text{Resultado} \leq 15$	Possibilidade de queda/ADL
	Resultado > 15	A queda ocorreu

Depois de ajustar o modelo linear usando a análise de regressão, ANOVA (*analysis of variance*), foi determinado o seu ajuste aos dados, Tabela 4.3.

Tabela 4.3: Estatística da regressão.

Estatística de regressão	Valores obtidos
R múltiplo	0,927
Quadrado de R	0,859
Quadrado de R ajustado	0,845
Erro-padrão	1,522
Observações	138

Neste sentido, para 138 observações foi obtido um R-quadrado de 85 %, o que pode significar que os dados estão próximos da linha de regressão ajustada. Na regressão linear múltipla, são úteis para verificar a “adequabilidade” do modelo, certos testes de hipóteses sobre os parâmetros do modelo (Faria, 2011). O teste para significância da regressão, é um teste para determinar, se há uma relação linear entre a variável resposta Y , e algumas das variáveis de entrada (Tabela 4.4).

Tabela 4.4: Sumário dos resultados da regressão - ANOVA.

	gl	SQ	MQ	F	F _{significância}
Regressão	12	1757,91	146,4925	63,19938	3,96E-47
Residual	125	289,7427	2,317941	–	–
Total	137	2047,652	–	–	–

Considerando os coeficientes estimados pelo modelo de regressão, a função RL é dada pela Equação 4.7:

$$\begin{aligned}
 RL = & \beta_0 + \beta_1 acXm + \beta_2 acX1m + \beta_3 acYm + \beta_4 acY1m \\
 & + \beta_5 som_m + \beta_6 acZm + \beta_7 acZ1m + \beta_8 gyX \\
 & + \beta_9 gyYm + \beta_{10} gyZm + \beta_{11} G + \beta_{12} \varepsilon_t
 \end{aligned} \tag{4.7}$$

Na implementação desta função, para prever o tipo de atividade, devem ser substituídos os coeficientes pelo valor obtido, sendo desprezado o erro ε_t .

4.5 Classificação inteligente usando Redes Neurais

O algoritmo de detecção por *thresholds* nem sempre é viável, pois os limiares são diferentes para cada uma das atividades, dependendo de fatores, como o peso da pessoa e o amortecimento do pavimento.

ANN é definida como um conjunto de unidades de processamento independentes, que recebem as entradas por meio de conexões ponderadas (Özdemir, 2016), sendo um dos modelos preferidos em problemas de classificação e reconhecimento de padrões, ajustando-se desta forma, para diferenciar as atividades do dia a dia, de uma queda.

Neste estudo, foi implementada uma RNA multicamadas, que consiste numa camada de entrada, duas camadas ocultas e uma camada de saída. A camada de entrada tem 12 neurónios e a camada de saída tem um neurónio.

Nas camadas ocultas, é usada a função de ativação ReLu, no neurónio de saída, a função de ativação é uma sigmoide.

ANN é criada no ambiente Keras, tendo o TensorFlow como *backend*, e treinada com um algoritmo de retro propagação. A decisão da classe é feita normalizando os dados entre 0 e 1. Keras é uma *framework* de aprendizagem profunda, de código aberto para Python, é executada como *front-end* em TensorFlow ou Theano.

No modelo Keras, cada camada representa a camada Keras correspondente (camada de entrada, camada oculta e camada de saída), no modelo de rede neural proposto. Keras fornece muitas camadas pré-construídas, para que qualquer rede neural complexa, possa ser criada facilmente. Algumas das camadas Keras importantes, são especificadas abaixo:

- Camadas principais;
- Camadas de Convolução;
- Camadas de *pooling*;
- Camadas Recorrentes.

Os modelos Keras são de dois tipos, a *Sequential* API e a *Functional* API,

- *Sequential* API – o modelo sequencial é basicamente uma composição linear de camadas *Keras*. Este modelo é fácil de implementar, podendo representar quase todas as redes neurais disponíveis. O modelo sequencial utiliza a classe *Model* para criar modelos customizados;
- *Functional* API – a API funcional é normalmente aplicada para criar um modelo complexo.

Na sua implantação foi usada uma estrutura de rede totalmente conectada com três camadas, usando a classe *dense*. Podemos especificar o número de neurónios ou nós na camada como o primeiro argumento e especificar a função de ativação usando o argumento de ativação. Usaremos a função de ativação da unidade linear retificada referida como ReLU nas primeiras duas camadas e a função *Sigmoide* na camada de saída. *Sigmoide* é uma função (Equação 4.8) que converte um valor de entrada em número real entre 0 e 1.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (4.8)$$

$$f = f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (4.9)$$

Usamos um *Sigmoide* na camada de saída, para garantir que esteja entre 0 e 1 e seja fácil de mapear, para uma probabilidade de classe 1, ou ajustar para uma classificação rígida de qualquer classe com um limite padrão de 0,5.

Resumindo, cada camada foi acrescida:

- O modelo espera linhas de dados com 8 variáveis de entrada (o argumento $input_{dim}=8$);
- A primeira camada oculta tem 12 nós e usa a função de ativação ReLU;
- A segunda camada oculta tem 8 nós e usa a função de ativação ReLU;
- A camada de saída tem um nó e usa a função de ativação *Sigmoide*.

Todas as variáveis de entrada, aceleração triaxial, velocidade angular e som são numéricas, o que facilita a utilização diretamente em redes neurais que esperam valores de entrada e saída numéricos, como a rede neural em Keras. Existem oito variáveis de entrada e uma variável de saída (a última coluna). Iremos treinar um modelo para mapear linhas de variáveis de entrada (x) para uma variável de saída (y), que geralmente resumimos como $y = f(x)$. O ficheiro queda.csv (*dataset#2*) é carregado e dividido em variáveis de entrada (X) e de saída (y):

- As variáveis de entrada (X) são: *acx; acy; acz; gyx; gyy; gyz; som; d*;
- A variável de saída (y): Variável de classe (0-ADL ou 1-queda).

Depois o modelo é treinado, a criação de um conjunto de dados de validação, é feita dividindo o conjunto de dados em dois, 80 % dos quais usaremos para treinar, avaliar e selecionar os melhores modelos, e 20 % iremos reter, como um conjunto de dados de validação.

A seleção de um classificador para deteção de queda, foi feita com base na precisão e exatidão, uma vez que os sistemas de deteção de queda exigem um número mínimo de falsos positivos. Neste trabalho, testamos o desempenho de vários algoritmos lineares simples (LR e LDA), e não lineares (KNN, CART, NB e SVM), para classificar as atividades humanas.

- K-nearest neighbors (KNN);
- Classification and regression trees (CART);
- Gaussian Naive Bayes (NB);
- Support vector machines (SVM);
- Logistic regression (LR);
- Linear discriminant analysis (LDA).

Para avaliar a qualidade de saída do classificador usando validação cruzada, utilizamos a métrica ROC. As curvas ROC, normalmente apresentam taxa de verdadeiro positivo no eixo Y, e taxa de falso positivo no eixo X. Isso significa, que o canto superior esquerdo do gráfico, é o ponto “ideal” - uma taxa de falso positivo de zero e uma taxa de verdadeiro positivo de um. Isso não é muito realista, mas uma área maior sob a curva AUC (*Area under the ROC Curve*), geralmente é melhor. A “inclinação” das curvas ROC também é importante, pois é ideal para maximizar a taxa de verdadeiros positivos, enquanto minimiza a taxa de falsos positivos.

Este exemplo, mostra a resposta ROC de diferentes conjuntos de dados, criados a partir da validação cruzada K-fold. Tomando todas essas curvas, é possível calcular a área média sob a curva, e ver a variância da curva, quando o conjunto de treino é dividido num subconjunto diferente, Figura 4.9. Isso mostra aproximadamente, como a saída do classificador é afetada pelas mudanças nos dados de treino, e como as divisões geradas pela validação cruzada K-fold são umas das outras.




Figura 4.9: Curva ROC obtida para a série temporal D.

A possibilidade de usar métodos de otimização, baseado em algoritmos genéticos com ANN, pode reduzir o número de resultados falso-positivos (falso alarme), e melhorar a precisão do sistema de detecção de queda.

As RNN são redes de aprendizagem profunda, projetadas especificamente para processar sequências, nomeadamente como unidades de memória de longo prazo (LSTM¹), e unidades recorrentes com portas (GRU). Alguns estudos, realçam o potencial das RNN, para classificações de sinais dinâmicos, e mais precisamente para dados de acelerómetros. A execução desses modelos em microcontroladores de baixa potência, com recursos limitados, adequados para dispositivos vestíveis, pode levar a longos tempos de resposta, e alto

¹LSTM – *long short-term memory*

consumo de energia, mesmo para as tarefas mais simples. Esse fato, dificulta a criação de detetores de queda em tempo real, baseados no RNN.

Se o *Trigger* obtido por regressão linear do vetor d da aceleração (Equação 4.7) ou o SMV, “detetar alterações”, então encaminha para o Jetson Nano, para identificar o tipo de queda. O sinal adquirido de comprimento N , é aplicado na camada de entrada de neurónios N .

Na aprendizagem máquina, o *Metrics* é usado para avaliar o desempenho de um modelo, Keras fornece um módulo com algumas métricas, tendo sido utilizada a *accuracy*.

$$\text{Accuracy} = \frac{\text{Número de predições corretas}}{\text{Número total de predições geradas}} \quad (4.10)$$

Os modelos são treinados por matrizes NumPy usando *fit()*. Esta função de ajuste, é usada para avaliar o modelo no treino, podendo representar graficamente o seu desempenho. Possui a seguinte sintaxe - *model.fit (X, y, epochs =, batch_size =)*:

- X, y - dupla para avaliar os dados;
- *Epochs* - número de vezes, que o modelo é avaliado, durante a fase de treino;
- *Batch_size* - instâncias de treino.

Usaremos a validação cruzada estratificada k-fold, para estimar a precisão do modelo (Brownlee, 2019). Para tal, o conjunto de dados é dividido em 10 partes, treino em 9, e teste em 1, repetindo para todas as combinações de divisões de teste do conjunto.

A Tabela 4.5 mostra o desempenho dos algoritmos utilizados para classificar a queda ou não queda.

Tabela 4.5: Precisão dos algoritmos de classificação.

Algoritmo	LR	LDA	KNN	CART	NB	SVM
Precisão	0,750	0,874	0,860	0,905	0,921	0,702

A comparação das funções de classificação para treino, pode ser resumida no gráfico de quartis, apresentado na Figura 4.10.




Figura 4.10: Comparação de algoritmos (Gráfico de Quartis).

Verificamos que o algoritmo Naive Bayes obteve a maior precisão (92,1 %), quando comparadas com os restantes classificadores. Os métodos Naive Bayes, são um conjunto de algoritmos de aprendizagem supervisionada, baseados na aplicação do teorema de Bayes com independência condicional entre cada par de características, dado o valor da variável de classe (Learn, 2020).

A matriz confusão (*confusion_matrix* ($Y_validation$, $predictions$)) da biblioteca Scikit-learn² fornece uma indicação dos erros cometidos.

O relatório de classificação (Tabela 4.6) fornece uma análise de cada classe por precisão, sensibilidade, pontuação f_1 e suporte, mostrando resultados excelentes, tendo em conta, que o conjunto de dados de validação era pequeno.

Tabela 4.6: Relatório de classificação.

	Precision	Recall	F1-score	Support
0	0,94	1,00	0,97	15
1	1,00	0,50	0,67	2
Accuracy	–	–	0,94	17
Macro avg	0.97	0.75	0.82	17
Weighted avg	0,94	0,94	0,93	17

²<https://scikit-learn.org>

4.6 Considerações finais

Este capítulo descreveu a forma de aquisição e registo dos dados para treino. O *dataset* obtido, incidiu principalmente na queda inconsciente para a frente ou trás, causada por tropeço, falta de apoio dos músculos da perna ou escorregadela.

Para além da amplitude do impacto, a queda inconsciente foi facilmente simulada por um modelo antropomórfico.

Sem perda de consciência, os humanos podem usar por instinto a proteção do braço ou joelho para atingir o chão, e assim reduzir os ferimentos. De forma a dispor de um conjunto de dados abrangente, incluindo ADL mais parecidas com quedas, como correr, arrastar uma cadeira, deixar cair o telemóvel ou uma garrafa de água foram obtidos também registos destas atividades.

Da análise da série temporal da aceleração total, foram determinados recursos estatísticos como mínimos e máximos, média, ou desvio padrão.

A aplicação da regressão linear múltipla, permitiu de forma simples encontrar um método para prever valores, com base nas series anteriores.

Outros recursos mais complexos matematicamente, como CWT e DTW foram selecionados para caracterizar as séries temporais correspondentes a queda e não queda. Deste modo foi possível fazer a classificação inteligente usando redes neuronais. A seleção do classificador foi feita com base em parâmetros como precisão e exatidão.

Capítulo 5

Conclusões

As principais conclusões e o seu enquadramento, face aos objetivos propostos no âmbito desta dissertação, serão apresentados nesta secção final. Devido às restrições vividas atualmente em todo mundo, provocadas pela pandemia com origem no vírus SARS-CoV-2, seria inevitável não referir as limitações do projeto. No sentido de permitir a continuidade do trabalho realizado, serão identificadas e propostas sugestões, para evolução futura.

5.1 Limitações do Projeto

A construção de um *dataset* realista, deveria ser realizada com vários tipos de pessoas, tendo sido sugerido a experiência, em abril de 2020, a um conjunto de 17 alunos voluntários do Curso Técnico Profissional de Mecatrónica, da Escola Secundária Infante D. Henrique. Para o referido estudo experimental de uma queda consciente envolvendo humanos, seriam usados colchões no chão do pavilhão de educação física, para reduzir possíveis lesões nos voluntários. Apesar da introdução de modos e limiares de vibração diferentes, devido às condições do piso, amortecimento e dimensões do espaço, permitiria um conjunto de dados, com níveis de sinais, próximos de uma queda real. Infelizmente, a experiência não foi concretizada, devido ao encerramento da escola, de acordo com o Despacho n.º 3427-B/2020, de 18 de março - Suspensão das atividades letivas e não letivas e formativas presenciais, no âmbito da COVID-19.

5.2 Conclusões e Discussão

O trabalho inicial realizado nesta dissertação, permitiu aprofundar o conhecimento referente ao complexo conceito das vibrações, numa estrutura, resultantes da atividade humana, tal como a queda no pavimento de uma divisão. As soluções de mercado e as soluções propostas no estado da arte efetuam medições rigorosas com suporte de sistemas industriais de elevado custo que dificultam a sua utilização em massa nas habitações das pessoas idosas. Neste sentido foi feito o levantamento do estado da arte, tendo como

objetivo principal o desenvolvimento de um sistema de baixo custo para detecção de queda baseada em sensores de vibração e áudio. Tal estudo veio permitir a proposta de uma solução baseada microacelerómetros MEM de baixo custo, facilitando assim a instalação em massa nas habitações de pessoas idosas. A solução não pretende evitar quedas mas sim detetar e agir o mais rapidamente possível para que a assistência necessária seja ativa sem demoras.

Apesar dos sistemas mais vulgares serem baseados em sensores *wearables* comerciais, nomeadamente incorporados em *smartphones*, estes têm vulnerabilidades, pelo que a arquitetura da solução foi elaborada para um ambiente residencial, mantendo os critérios de privacidade e a condição de dependência e comorbilidades dos utilizadores. Esta arquitetura insere-se no conceito abrangente, de *smart homes* e *assisted living*. O desenho da solução, privilegiou de forma hierárquica, as ações e funcionalidades do dispositivo na divisão, no edifício, e servidor na *Cloud*, sendo aplicado desta forma o novo paradigma de computação, *Fog Computing* e *Edge Computing*.

O monitoramento dos sinais na divisão, foi implementado com sucesso num dispositivo, que faz a leitura dos sensores, e aquisição de um conjunto de dados de queda e ADL. O protótipo tem como plataforma de desenvolvimento um NodeMCU, que envia o registo de uma série temporal, formada pelos valores amostrados dos sensores inerciais e som, no instante antes e depois da queda. O conjunto de dados coletado num ficheiro CSV, fornece uma ampla gama de recursos estatísticos, para reconhecimento de atividade humana e detecção de queda. A base de conhecimento criada, permitiu aplicar o método DTW para a distinção de tipos de atividades humanas e o método CWT para classificação de queda ou não queda. Os resultados demonstraram a importância de usar um domínio consistente e adequado, como o escalograma, para treino de uma rede neuronal.

5.3 Evolução Futura

O Grupo de Investigação em Engenharia e Computação Inteligente para a Inovação e o Desenvolvimento, foi a entidade de acolhimento desta dissertação, contudo, as restrições no acesso às suas instalações, não permitiram que a rede neuronal a indicar queda fosse executada no Jetson Nano. No decorrer desta dissertação, no final de 2019, foi lançado o Arduino NANO 33 *Sense Board Bluetooth Low Energy* com cabeçalhos, baseado no processador ARM de 32 bits *Cortex-M4 CPU* a 64 MHz. Esta plataforma tem características de conectividade acrescidas como *Bluetooth Low Energy* (BLE 5.0) de emparelhamento via NFC, e I2S (*Inter-IC Sound*), para além da paleta de sensores incorporados. Mas a sua principal característica, desperta um interesse acrescido como trabalho futuro, com a possibilidade de executar aplicações *edge computing* e IA sobre ele usando *tinyML*, o que permite criar modelos de *machine learning*, utilizando o TensorFlow Lite e carregá-los utilizando o Arduino IDE. Ainda no âmbito desta dissertação, será elaborado um artigo científico internacional e serão disponibilizados o conjunto de dados obtido.

Referências

- A48 - Sistemas de Segurança. (2020). *Sistema de Apoio ao Cliente - GlobalHelp 2*. Retrieved 2020-11-02, from <http://www.a48.pt/sistemaapoioclienteglobalhelp2>
- Abbate, S., Avvenuti, M., Corsini, P., Light, J., & Vecchio, A. (2010, Dec.). Monitoring of Human Movements for Fall Detection and Activities Recognition in Elderly Care Using Wireless Sensor Network: a Survey. In *Wireless sensor networks: Application-centric design*. InTech. Retrieved from <https://doi.org/fgqb> doi: 10.5772/13802
- Adafruit. (2020). *ADXL345 Digital Accelerometer*. Retrieved 2020-11-02, from <https://learn.adafruit.com/adxl345-digital-accelerometer>
- Akl, A., & Valace, S. (2010, Mar.). Accelerometer-based gesture recognition via dynamic-time warping, affinity propagation, & compressive sensing. In *2010 IEEE International Conference on Acoustics, Speech and Signal Processing* (pp. 2270–2273). IEEE. Retrieved from <https://doi.org/bd9rz8> doi: 10.1109/ICASSP.2010.5495895
- Alan V Oppenheim, Alan S. Willsky, S. H. N. (1998). *Señales y Sistemas*. Retrieved 2020-11-02, from http://www2.fisica.unlp.edu.ar/~jarne/Clases-EET-N2/Sistemas_de_comunicaciones/OppenheimSeñalesySistemas.pdf
- Alert 1 Medical Alerts. (2020). *In-the-Home plus Fall Detection Medical Alert*. Retrieved 2020-11-02, from <https://www.alert-1.com/content/fall-detection-technology/1390>
- Al-Fuqaha, A., Guizani, M., Mohammadi, M., Aledhari, M., & Ayyash, M. (2015, Oct.). Internet of Things: A Survey on Enabling Technologies, Protocols, and Applications. *IEEE Communications Surveys and Tutorials*, 17(4), 2347–2376. Retrieved from <https://doi.org/cmzx> doi: 10.1109/COMST.2015.2444095
- Alwan, M., Rajendran, P., Kell, S., Mack, D., Dalal, S., Wolfe, M., & Felder, R. (2006, Oct.). A Smart and Passive Floor-Vibration Based Fall Detector for Elderly. In *2006 2nd International Conference on Information - Communication Technologies* (Vol. 1, pp. 1003–1007). Institute of Electrical and Electronics Engineers (IEEE). Retrieved from <https://doi.org/dhgm3n> doi: 10.1109/ictta.2006.1684511
- Analog Sound Sensor SKU DFR0034. (n.d.). Retrieved 2020-11-02, from https://wiki.dfrobot.com/Analog_Sound_Sensor_SKU__DFR0034
- Archcare. (2010). *Prevention of Falls in Older Persons: AGS/BGS Clinical Practice Guideline* (Tech. Rep.). AGS. Retrieved 2020-11-02, from <https://www.archcare.org/sites/default/files/pdf/2010-prevention-of-falls-in-older-persons-ags-and-bgs-clinical-practice-guideline.pdf>
- Arduino - Wire. (2020). Retrieved 2020-11-02, from <https://www.arduino.cc/en/Reference/Wire>
- Atmel. (2015). *ATmega328P Datasheet 8-bit AVR Microcontroller with 32K Bytes In-System Programmable Flash* (Tech. Rep.). 1600 Technology Drive, San Jose, CA

- 95110 USA: Atmel Corporation.
- AwareGiver. (2020). *Giver Advanced Technology - Folding Bedside Fall Safety Floor M*. Retrieved 2020-11-02, from <https://www.awaregiver.com/products/36x68floor>
- Bard, D., Davidsson, P., & Wernberg, P.-A. (2010). *Sound and Vibrations investigations in a multi-family wooden frame building* (Tech. Rep.). Australian Acoustical Society. Retrieved 2020-11-02, from https://www.acoustics.asn.au/conference_proceedings/ICA2010/cdrom-ICA2010/papers/p420.pdf
- Barry, & Rachel. (2019). *Artificial intelligence and machine learning in asset management Background* (Tech. Rep.). Blackrock. Retrieved 2020-11-02, from <https://www.blackrock.com/corporate/literature/whitepaper/viewpoint-artificial-intelligence-machine-learning-asset-management-october-2019.pdf>
- Bengio, Y. (2013). Deep learning of representations: Looking forward. In *Lecture notes in computer science (including subseries lecture notes in artificial intelligence and lecture notes in bioinformatics)* (Vol. 7978 LNAI, pp. 1–37). Springer, Berlin, Heidelberg. Retrieved from <https://doi.org/ggvjqd> doi: 10.1007/978-3-642-39593-2_1
- Blakeborough, A., & Williams, M. S. (2003, Nov.). Measurement of floor vibrations using a heel drop test. *Proceedings of the Institution of Civil Engineers - Structures and Buildings*, 156(4), 367–371. Retrieved from <https://doi.org/dwgbgw> doi: 10.1680/stbu.2003.156.4.367
- Boulos, M. N., Rocha, A., Martins, A., Vicente, M. E., Bolz, A., Feld, R., ... Kinirons, M. (2007, Mar.). CAALYX: A new generation of location-based services in healthcare. *International Journal of Health Geographics*, 6(1), 9. Retrieved 2020-11-02, from <https://doi.org/cmm84s> doi: 10.1186/1476-072X-6-9
- Braga, A. C. (2001). *Curvas ROC: aspectos funcionais e aplicações* (Doctoral dissertation, Universidade do Minho). Retrieved 2020-11-02, from https://repositorium.sdum.uminho.pt/bitstream/1822/195/1/tese_doutACB.pdf
- Braz, J. F. F. (2015). *Conceção e validação de uma mesa de vibração para a calibração de acelerómetros* (Doctoral dissertation, Universidade Nova de Lisboa (UNL)). Retrieved 2020-11-02, from <https://run.unl.pt/handle/10362/15702>
- Bremer, M. (2012, Feb.). *Multiple Linear Regression*. Spring. Retrieved 2020-11-02, from <http://mezeylab.cb.bscb.cornell.edu/labmembers/documents/supplement%205%20-%20multiple%20regression.pdf>
- Brownlee, J. (2019, Feb.). *Your First Machine Learning Project in Python Step-By-Step*. Python Machine Learning. Retrieved 2020-11-02, from <https://machinelearningmastery.com/machine-learning-in-python-step-by-step/>
- Cabral, C. M. (2012). *Acústica Industrial: aplicação da análise de vibrações e ruído à identificação de fontes de ruído em ambiente industrial* (Master's thesis, Universidade de Coimbra). Retrieved 2020-11-02, from <http://hdl.handle.net/10316/20582>
- Caramia, C., De Marchis, C., & Schmid, M. (2019, Apr.). Optimizing the Scale of a Wavelet-Based Method for the Detection of Gait Events from a Waist-Mounted Accelerometer under Different Walking Speeds. *Sensors*, 19(8), 1869. Retrieved from <https://doi.org/gfz4w9> doi: 10.3390/s19081869
- Carl Hopkins. (2007). *Sound Insulation* (8th ed.). Taylor & Francis Ltd.
- Carvalho De Oliveira, P. (2006). *Séries Temporais: Analisar o Passado, Predizer o Futuro*

- (Tech. Rep.). Universidade Nova. Retrieved 2020-11-02, from https://student.dei.uc.pt/~pcoliv/reports/ct_timeseries.pdf
- Casilari, E., Santoyo-Ramón, J. A., & Cano-García, J. M. (2017, Jan.). UMAFall: A Multisensor Dataset for the Research on Automatic Fall Detection. In *Procedia computer science* (Vol. 110, pp. 32–39). Elsevier B.V. Retrieved from <https://doi.org/ggw5fd> doi: 10.1016/j.procs.2017.06.110
- Chatfield, C. (2001). Time-series forecasting. *International Journal of Forecasting*, 280. Retrieved from <https://doi.org/b4txzs>
- Chatzaki, C., Pediaditis, M., Vavoulas, G., & Tsiknakis, M. (2017). Human daily activity and fall recognition using a smartphone’s acceleration sensor. In *Communications in computer and information science* (Vol. 736, pp. 100–118). Springer Verlag. Retrieved from <https://doi.org/fgtx> doi: 10.1007/978-3-319-62704-5_7
- Chaudhuri, S., Thompson, H., & Demiris, G. (2014, Oct.). Fall Detection Devices and Their Use With Older Adults. *Journal of Geriatric Physical Therapy*, 37(4), 178–196. Retrieved from <https://doi.org/f6j2bp> doi: 10.1519/JPT.0b013e3182abe779
- Contreiras, T., & Rodrigues, E. (2014, Sep.). *EVITA – Epidemiologia e Vigilância dos Traumatismos e Acidentes: relatório 2009-2012* (Tech. Rep.). Instituto Nacional de Saúde Doutor Ricardo Jorge, IP. Retrieved 2020-11-02, from <http://hdl.handle.net/10400.18/2449>
- Correia, A. A. (2007, Jan.). *Dinâmica-vibrações de sistemas com 1 grau de liberdade* (Tech. Rep.). Instituto Superior Técnico. Retrieved 2020-11-02, from <https://fdocumentos.tips/document/dinamica-de-maquinas-apostila-vibracoes-de-sistemas-com-1-.html>
- Cortez, P., & Neves, J. (2000). *Redes Neurais Artificiais* (Tech. Rep.). Universidade do Minho. Retrieved 2020-11-02, from <http://hdl.handle.net/1822/158> (Apostamentos de apoio à disciplina de Sistemas Inteligentes)
- Costa, A., Amaral, A., Sequeira, C., & et. al. (2018, Oct.). *Padrão de Documentação em Enfermagem de Saúde Mental e Psiquiátrica* (Tech. Rep.). Ordem dos Enfermeiros. Retrieved 2020-11-02, from https://www.ordemenfermeiros.pt/media/9938/ppadr%C3%A3o-documenta%C3%A7%C3%A3o_enfermagem-sa%C3%BAde-mental-e-psiqui%C3%A1trica_ausculata%C3%A7%C3%A3o_vf.pdf
- Costa, A. I. F. (2019). *Risco de queda no idoso em contexto comunitário* (Master’s thesis, Instituto Politécnico de Viana do Castelo). Retrieved 2020-11-02, from <http://hdl.handle.net/20.500.11960/2204>
- Costa, G. F. (2015). *Previsão Multi-Passos em Séries Temporais: Estratégias Clássicas e de Aprendizagem Automática* (Master’s thesis, Faculdade de Arquitetura da Universidade do Porto (FAUP)). Retrieved from https://sigarra.up.pt/faup/pt/pub_geral.show_file?pi_doc_id=33157
- Cruz, A., & Cortez, P. (2019). *Data mining via redes neuronais artificiais e máquinas de vectores de suporte* (Master’s thesis, Universidade do Minho). Retrieved 2020-11-02, from <http://hdl.handle.net/1822/10825>
- Daubechies, I. (2009, Jan.). The wavelet transform, time-frequency localization and signal analysis. *Fundamental Papers in Wavelet Theory*, 36, 442-486. Retrieved from https://www.researchgate.net/publication/287383164_The_wavelet_transform_time-frequency_localization_and_signal_analysis
- Davis, B. T., Caicedo, J. M., Langevin, S., & Hirth, V. (2011). Use of Wireless Smart Sensors for Detecting Human Falls through Structural Vibrations. In *Civil engineering topics* (Vol. 4, pp. 383–389). Springer. Retrieved from <https://doi.org/b8fp5t>

- doi: 10.1007/978-1-4419-9316-8_37
- De Gooijer, J. G., & Hyndman, R. J. (2006, Jan.). 25 years of time series forecasting. *International Journal of Forecasting*, 22(3), 443–473. Retrieved from <https://doi.org/dzt9g4> doi: 10.1016/j.ijforecast.2006.01.001
- DeepMind. (n.d.). *About*. Retrieved 2020-11-02, from <https://deepmind.com/about>
- Dejan. (n.d.). *How I2C Communication Works & How To Use It with Arduino*. Retrieved 2020-11-02, from <https://howtomechatronics.com/tutorials/arduino/how-i2c-communication-works-and-how-to-use-it-with-arduino/>
- Dejan. (2019). *Arduino and MPU6050 Accelerometer and Gyroscope Tutorial*. Retrieved 2020-11-02, from <https://howtomechatronics.com/tutorials/arduino/arduino-and-mpu6050-accelerometer-and-gyroscope-tutorial/>
- Delahoz, Y., & Labrador, M. (2014, Oct.). Survey on Fall Detection and Fall Prevention Using Wearable and External Sensors. *Sensors*, 14(10), 19806–19842. Retrieved from <https://doi.org/gcfmzv> doi: 10.3390/s141019806
- DGS. (2014). *Portugal Idade Maior em Números - 2014: A Saúde da População Portuguesa com 65 ou mais anos de idade* (Tech. Rep.). Direção-Geral da Saúde. Retrieved 2020-11-02, from <https://www.dgs.pt/estatisticas-de-saude/estatisticas-de-saude/publicacoes/portugal-idade-maior-em-numeros-2014-pdf.aspx>
- DGS. (2015). *Plano Nacional para a Segurança dos Doentes 2015-2020*. Retrieved 2020-11-02, from <https://www.dgs.pt/qualidade-e-seguranca/seguranca-dos-doentes.aspx>
- Dionísio, Nuno Rafael Marques. (2018). *Improving cyberthreat discovery in open source intelligence using deep learning techniques* (Master's thesis, Universidade de Lisboa). Retrieved 2020-11-02, from <http://hdl.handle.net/10451/36434>
- Donahue, M. E. (1982, Jan.). A Computer Method to Evaluate the Vibration Response of Stiffened Floor Systems to Impact Load. *Retrospective Theses and Dissertations*. Retrieved 2020-11-02, from <https://stars.library.ucf.edu/rtd/620>
- Dorvash, S., Pakzad, S., Naito, C., Hodgson, I., & Yen, B. (2014, May). Application of state-of-the-art in measurement and data analysis techniques for vibration evaluation of a tall building. *Structure and Infrastructure Engineering*, 10(5), 654–669. Retrieved from <https://doi.org/fgwt> doi: 10.1080/15732479.2012.757795
- Dynamic Time Warping for Sequence Classification*. (n.d.). Retrieved from <https://effectiveml.com/dynamic-time-warping-for-sequence-classification.html>
- ESP8266*. (2020). Retrieved 2020-11-02, from <https://esp8266.ru/esplorer/>
- Ewins, D. J. (1984). *Modal testing: Theory and practice (mechanical engineering research studies)*. Research Studies Pr Ltd.
- Expresso. (2019). *Há mais de 41 mil idosos a viver sozinhos ou isolados em Portugal*. Retrieved 2020-11-02, from <https://expresso.pt/sociedade/2019-11-18-Ha-mais-de-41-mil-idosos-a-viver-sozinhos-ou-isolados-em-Portugal>
- Faria, B. F. P. (2011). *Teste F na regressão linear múltipla para dados temporais em correlação serial* (Master's thesis, Universidade Aberta). Retrieved 2020-11-02, from <http://hdl.handle.net/10400.2/2071>
- Ferreira, J. M. C. (2020). *Inteligência artificial na qualidade de dados - Referencial de tecnologias de IA para a melhoria da qualidade dos dados* (Master's thesis, Universidade Nova). Retrieved 2020-11-02, from <http://hdl.handle.net/10362/94991>

- Figueiredo, L. J., Gafaniz, A. R., Lopes, G. S., & Pereira, R. (2007). *Aplicações de acelerómetros* (Master's thesis, Instituto Superior Técnico). Retrieved 2020-11-02, from <http://hdl.handle.net/10362/94991> (Monografia)
- Filipa, I., & De Oliveira, D. (2014). *Identificação das propriedades dinâmicas de um piso de ginásio* (Master's thesis, Universidade Nova). Retrieved from <http://hdl.handle.net/10362/13046>
- Frank, K., Vera Nadales, M. J., Robertson, P., & Pfeifer, T. (2010). Bayesian recognition of motion related activities with inertial sensors. In *UbiComp'10 - proceedings of the 2010 acm conference on ubiquitous computing* (pp. 445–446). New York, New York, USA: ACM Press. Retrieved from <https://doi.org/cqg266> doi: 10.1145/1864431.1864480
- Gama, J., Carvalho, A. P. d. L., Faceli, K., Lorena, A. C., & Oliveira, M. (2017). *Extração de Conhecimento de Dados: Data Mining* (3rd ed.). Silabo.
- Gibson, R. M., Amira, A., Ramzan, N., Casaseca-De-La-Higuera, P., & Pervez, Z. (2016, Feb.). Multiple comparator classifier framework for accelerometer-based fall detection and diagnostic. *Applied Soft Computing Journal*, *39*, 94–103. Retrieved from <https://doi.org/f767tj> doi: 10.1016/j.asoc.2015.10.062
- Gomes, R. S. L. (2015). *Avaliação do risco de queda no idoso e estratégias preventivas* (Master's thesis, Universidade de Coimbra). Retrieved 2020-11-02, from <http://hdl.handle.net/10316/30543>
- Gonçalves, M. M. (2019). *Event-driven Architecture (EDA) em uma Arquitetura de Microserviços*. Retrieved 2020-11-02, from <https://medium.com/@marcelomg21/event-driven-architecture-eda-em-uma-arquitetura-de-micro-servi%C3%A7os-1981614cdd45>
- Goodfellow, I. (2016). *Deep learning (adaptive computation and machine learning series)*. The MIT Press.
- Gun, S., Maan, S., & Rana, D. S. B. (2015, Jan.). Wireless Personal Area Networks architecture and protocols for multimedia applications. *International Journal of Advanced Research in Computer and Communication Engineering*, *4*. Retrieved from <https://doi.org/fgt6> doi: 10.17148/ijarce.2015.4182
- Hirose, Y., Yamashita, K., & Hijjya, S. (1991, Jan.). Back-propagation algorithm which varies the number of hidden units. *Neural Networks*, *4*(1), 61–66. Retrieved from <https://doi.org/bsqwpz> doi: 10.1016/0893-6080(91)90032-Z
- Hitcho, E. B., Krauss, M. J., Birge, S., Dunagan, W. C., Fischer, I., Johnson, S., ... Fraser, V. J. (2004, Jul.). Characteristics and circumstances of falls in a hospital setting. *Journal of General Internal Medicine*, *19*(7), 732–739. Retrieved from <https://doi.org/b8k9f6> doi: 10.1111/j.1525-1497.2004.30387.x
- Holmes, W. M. (1990, Mar.). Time Series : Sir Maurice Kendall and J. Keith Ord. *International Journal of Forecasting*, *7*, 532–533.
- Hu, X., & Qu, X. (2016, Dec.). Pre-impact fall detection. *BioMedical Engineering OnLine*, *15*(1), 61. Retrieved from <https://doi.org/ggzntg> doi: 10.1186/s12938-016-0194-x
- Hu, Y., Zhang, F., Wu, C., Wang, B., & Ray Liu, K. J. (2020, May). A WiFi-Based Passive Fall Detection System. In *Icassp 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 1723–1727). IEEE. Retrieved from <https://doi.org/fgx7> doi: 10.1109/ICASSP40776.2020.9054753
- Huan-Wen Tzeng, Mei-Yung Chen, & Chen, J.-Y. (2010, Jul.). Design of fall detection system with floor pressure and infrared image. In *2010 international conference on*

- system science and engineering* (pp. 131–135). IEEE. Retrieved from <https://doi.org/bg6g9t> doi: 10.1109/ICSSE.2010.5551751
- Hubbard, B. (1996). *The world according to wavelets the story of a mathematical technique in the making*. Universities Press (India) Pvt. Limited.
- Hyndman, R. J. (2013). *Forecasting: principles and practice*. OTexts.
- Ierusalimschy, R., de Figueiredo, L. H., & Celes, W. (2015). *Lua – an extensible extension language*. Retrieved from <https://www.lua.org/spe.html>
- Ierusalimschy, R., de Figueiredo, L. H., & Celes, W. (2019). *Lua 5.1 Reference Manual*. Retrieved 2020-11-02, from <http://www.lua.org/manual/5.1/manual.html>
- Ierusalimschy, R., de Figueiredo, L. H., & Celes, W. (2020). *Lua – About*. Retrieved 2020-11-02, from <https://www.lua.org/about.html>
- INE. (2017). *Mantém-se o agravamento do envelhecimento demográfico, em Portugal, que só tenderá a estabilizar daqui a cerca de 40 anos* (Tech. Rep.). Instituto Nacional de Estatística. Retrieved 2020-11-02, from https://www.ine.pt/xportal/xmain?xpid=INE&xpgid=ine_destaques&DESTAQUESdest_boui=277695619&DESTAQUESmodo=2&xlang=pt
- Investopedia. (2019). *Seasonality Definition*. Retrieved 2020-11-02, from <https://www.investopedia.com/terms/s/seasonality.asp>
- ISO. (1975). *ISO 2041:1975 Vibration and shock*. Retrieved 2020-11-02, from <https://www.iso.org/standard/6817.html>
- ISO. (1980). *ISO/TC 108/SC 4 Human exposure to mechanical vibration and shock*. Retrieved 2020-11-02, from <https://www.iso.org/committee/51514.html>
- ISO. (1981). *ISO 5982:1981 Vibration and shock — Mechanical driving point impedance of the human body*. Retrieved 2020-11-02, from <https://www.iso.org/standard/12174.html>
- ISO. (1997). *ISO 2631-1:1997 Mechanical vibration and shock — Evaluation of human exposure to whole-body vibration — Part 1: General requirements*. Retrieved from <https://www.iso.org/standard/7612.html>
- Jae Duk Seo. (2018). *Trend, Seasonality, Moving Average, Auto Regressive Model: My Journey to Time Series Data with Interactive Code*. Retrieved 2020-11-02, from <https://towardsdatascience.com/trend-seasonality-moving-average-auto-regressive-model-my-journey-to-time-series-data-with-edc4c0c8284b>
- Jokanovic, B., Amin, M., & Ahmad, F. (2016, May). Radar fall motion detection using deep learning. In *2016 IEEE Radar Conference (RadarConf)* (pp. 1–6). IEEE. Retrieved from <https://doi.org/fg3g> doi: 10.1109/RADAR.2016.7485147
- Jorge L. Olenewa. (2016). *Guide to wireless communication* (4th edition ed.). New York, NY: Cengage.
- Kappos, A. J. (2001). Dynamic loading and design of structures. *Earthquake Engineering & Structural Dynamics*, 31(5), 1213-1213. Retrieved from <https://doi.org/cqg5z7> doi: 10.1002/eqe.165
- Kjær, B. &. (2005). *Impact Hammers - Datasheet* (Tech. Rep.). Universitat Politècnica de Catalunya (UPC). Retrieved 2020-11-02, from https://www.upc.edu/sct/documents/equipament/d_283_id-684.pdf
- Kjær, B. &. (2020). *Measuring Vibration Introduction to Vibration | Brüel & Kjær*. Retrieved 2020-11-02, from <https://www.bksv.com/en/Knowledge-center/blog/articles/vibration/measuring-vibration>

- Learn, S. (2020). *1.9. Naive Bayes - scikit-learn 0.23.2 documentation*. Retrieved 2020-11-02, from https://scikit-learn.org/stable/modules/naive_bayes.html
- Litvak, D., Gannot, I., & Zigel, Y. (2008, Mar.). Detection of falls at home using floor vibrations and sound. In *2008 IEEE 25th convention of electrical and electronics engineers in israel* (pp. 514–518). IEEE. Retrieved from <https://doi.org/fq4pz6> doi: 10.1109/EEEI.2008.4736581
- Litvak, D., Gannot, I., & Zigel, Y. (2009, Sep.). *System for automatic fall detection for elderly people*. Retrieved 2020-11-02, from <https://patentimages.storage.googleapis.com/2a/4d/e4/9050483ba5fdc2/WO2009113056A1.pdf>
- Litvak, D., Zigel, Y., & Gannot, I. (2008, Aug.). Fall detection of elderly through floor vibrations and sound. In *2008 30th annual international conference of the IEEE engineering in medicine and biology society* (pp. 4632–4635). IEEE. Retrieved from <https://doi.org/b49tsj> doi: 10.1109/IEMBS.2008.4650245
- Liu, C., Jiang, Z., Su, X., Benzoni, S., & Maxwell, A. (2019, Aug.). Detection of Human Fall Using Floor Vibration and Multi-Features Semi-Supervised SVM. *Sensors*, *19*(17), 3720. Retrieved from <https://doi.org/ggznt8> doi: 10.3390/s19173720
- Luís Carvalho, P. B., & Cruz, S. (2015). *Escala de Quedas de Morse-Manual de utilização*. Retrieved 2020-11-02, from https://www.esenf.pt/fotos/editor2/i_d/publicacoes/978-989-98443-8-4.pdf
- M. Griffin. (1996). *Handbook of Human Vibration* (1st ed.; Academic Press, Ed.). Academic Press.
- Madarshahian, R., Caicedo, J. M., & Arocha Zambrana, D. (2016, Nov.). Benchmark problem for human activity identification using floor vibrations. *Expert Systems with Applications*, *62*, 263–272. Retrieved from <https://doi.org/fgxz> doi: 10.1016/j.eswa.2016.06.027
- Malheiros, L. (2017). *Deteção de posição e quedas corporais baseado em K-means clustering e threshold* (Master's thesis, Faculdade de Tecnologia Universidade de Brasília). Retrieved 2020-11-02, from <https://repositorio.unb.br/handle/10482/31978>
- Margarido, D. d. R. (2013). *Metodologias para a avaliação dos níveis de vibração em estruturas do ponto de vista do conforto humano* (Master's thesis, Universidade do Porto). Retrieved 2020-11-02, from <https://hdl.handle.net/10216/68892>
- Martins, Ângelo. (2012). *Complete Ambient Assisted Living Experiment - Market Validation (caalyx-mv)*. Retrieved 2020-11-02, from <https://www.inesctec.pt/pt/projetos/caalyx-mv>
- Martínez-Villaseñor, L., Ponce, H., Brieva, J., Moya-Albor, E., Núñez-Martínez, J., & Peñafort-Asturiano, C. (2019, Apr.). UP-Fall Detection Dataset: A Multimodal Approach. *Sensors*, *19*(9), 1988. Retrieved from <https://doi.org/fgx2> doi: 10.3390/s19091988
- Mastorakis, G., & Makris, D. (2014, Dec.). Fall detection system using kinect's infrared sensor. *J. Real-Time Image Process.*, *9*(4), 635–646. Retrieved from <https://doi.org/f6pscd> doi: 10.1007/s11554-012-0246-9
- Mello, A., da Silva, J., Vellasco, P. d. S., de Andrade, S., & de Lima, L. (2008, Oct.). Dynamic analysis of composite systems made of concrete slabs and steel beams. *Journal of Constructional Steel Research*, *64*(10), 1142–1151. Retrieved from <https://doi.org/dvs3sv> doi: 10.1016/j.jcsr.2007.09.011
- Mendonça, H. d. S. (n.d.). *UART | Hélio Sousa Mendonça*. Retrieved 2020-11-02, from <https://paginas.fe.up.pt/~hsm/docencia/comp/uart/>

- Mesquita, J. T. T. (2018). *Comunicação WiFi para monitorização móvel de sinais fisiológicos* (Master's thesis, Universidade do Porto). Retrieved 2020-11-02, from <https://hdl.handle.net/10216/113805>
- Moisés Alves Pinto, R., & Lage Campelo Calheiros, J. (2009). *Análise de séries temporais através de representações do espaço de fases* (Tech. Rep.). Universidade do Porto. Retrieved 2020-11-02, from <https://hdl.handle.net/10216/60394>
- Monteiro Barragan, J. F., Hora de Oliveira Fontes, C., Pereira, O. J., Torres Sá Barreto, S., & Almeida Pacheco, L. (2012, Dec.). Análises de métricas de similaridades em séries temporais para reconhecimento de padrões. *Cadernos do IME - Série Estatística*, 33(0), 35. Retrieved from <https://doi.org/fgqf> doi: 10.12957/cadest.2012.15775
- Morse, J. M. (2008). *Preventing Patient Falls*. Springer Pub.
- Mosquitto. (2020). *Download*. Retrieved 2020-11-02, from <https://mosquitto.org/download/>
- Mouta, P., Ribeiro, N. F., Santos, C. P., & Moreira, R. (2020, Sep.). Assistive Smart Cane (ASCane) for Fall Detection: First Advances. In *Ifmbe proceedings* (Vol. 76, pp. 1669–1684). Springer. Retrieved from <https://doi.org/fgqd> doi: 10.1007/978-3-030-31635-8_204
- MQTT Version 3.1.1*. (2015). Retrieved 2020-11-02, from <http://docs.oasis-open.org/mqtt/mqtt/v3.1.1/mqtt-v3.1.1.html>
- Mubashir, M., Shao, L., & Seed, L. (2013, Jan.). A survey on fall detection: Principles and approaches. *Neurocomputing*, 100, 144–152. Retrieved from <https://doi.org/f4gtxn> doi: 10.1016/j.neucom.2011.09.037
- Muller, M. (2007). *Information retrieval for music and motion*. New York: Springer.
- Murrat, T. and Aleen, D. and Ungar, E. (1997). *Floor vibrations due to human activity*. Retrieved from <https://pt.scribd.com/document/343204139/AISC-Design-Guide-11-Errata-Floor-Vibrations-Due-To-Human-Activity-pdf>
- Murteira, B. J. F., A, M. D., & Turkman, K. F. (2000). *Análise de sucessões cronológicas*. Lisboa: McGraw-Hill.
- Nadeem, A., Mehmood, A., & Rizwan, K. (2019, Dec.). A dataset build using wearable inertial measurement and ECG sensors for activity recognition, fall detection and basic heart anomaly detection system. *Data in Brief*, 27, 104717. Retrieved from <https://doi.org/ggznav> doi: 10.1016/j.dib.2019.104717
- National Instruments Corp. (2020, Jul.). Measuring vibration with accelerometers. *Online*. Retrieved 2020-11-02, from <https://www.ni.com/pt-pt/innovations/white-papers/06/measuring-vibration-with-accelerometers.html>
- Neki. (2020). *Pingente detetor de quedas gps para pessoas idosas*. Retrieved 2020-11-02, from <https://neki.pt/pingente-detetor-quedas-localizador-gps-anciaos.html>
- Nielsen, M. A. (2015). *Neural networks and deep learning*. Retrieved 2020-11-02, from <http://neuralnetworksanddeeplearning.com/chap1.html>
- Nizam, Y., Haji Mohd, M. N., & Abdul Jamil, M. M. (2016, Apr.). A study on human fall detection systems: Daily activity classification and sensing techniques. *International Journal of Integrated Engineering*, 8(1). Retrieved 2020-11-02, from <https://publisher.uthm.edu.my/ojs/index.php/ijie/article/view/1332>
- Oliveira, D. (2015). *Projeto 2 - scc-5900 - projeto de algoritmos*. GitHub. Retrieved 2020-11-02, from https://github.com/DaniloOliveira28/Dynamic_Time_Warping

- Oliveira, David Carvalho de. (2019, Jul.). *Análise de agrupamento e previsão de indicadores de performance em redes de comunicação móveis 4G* (Tech. Rep.). Instituto Politécnico de Lisboa. Retrieved from <http://hdl.handle.net/10400.21/10454>
- OMG. (n.d.). *Prevenção de quedas | Soluções OMG - Parte 6*. Retrieved 2020-11-02, from <https://omg-solutions.com/pt/search/fallprevention/page/6/>
- Openai. (n.d.). *Projects*. Retrieved 2020-11-02, from <https://openai.com/projects/Overview-NodeMCU-Documentation>. (n.d.-a). Retrieved 2020-11-02, from <https://nodemcu.readthedocs.io/en/release/>
- Overview - NodeMCU Documentation. (n.d.-b). Retrieved 2020-11-02, from <https://nodemcu.readthedocs.io/en/release/>
- Ozcan, K., Mahabalagiri, A. K., Casares, M., & Velipasalar, S. (2013, Jun.). Automatic Fall Detection and Activity Classification by a Wearable Embedded Smart Camera. *IEEE Journal on Emerging and Selected Topics in Circuits and Systems*, 3(2), 125–136. Retrieved from <https://doi.org/fgxt> doi: 10.1109/JETCAS.2013.2256832
- Özdemir, A. (2016). An Analysis on Sensor Locations of the Human Body for Wearable Fall Detection Devices: Principles and Practice. *Sensors*, 16. Retrieved from <https://doi.org/fgtc> doi: 10.3390/s16081161
- Palmerini, L., Bagalà, F., Zanetti, A., Klenk, J., Becker, C., & Cappello, A. (2015, May). A Wavelet-Based Approach to Fall Detection. *Sensors*, 15(5), 11575–11586. Retrieved from <https://doi.org/f7phfs> doi: 10.3390/s150511575
- PAOS. (1998). *Wave:Wavelets 2*. Retrieved 2020-11-02, from <https://paos.colorado.edu/research/wavelets/wavelet2.html>
- Perry, J. T., Kellog, S., Vaidya, S. M., Youn, J. H., Ali, H., & Sharif, H. (2009). Survey and evaluation of real-time fall detection approaches. In *6th international symposium on high capacity optical networks and enabling technologies, honet '09*. Retrieved from <https://doi.org/b7s9h9> doi: 10.1109/HONET.2009.5423081
- Philips Lifeline. (n.d.). *GoSafe 2*. Retrieved 2020-11-02, from <https://www.lifeline.philips.com/medical-alert-systems/gosafe-2.html>
- Pong Chan, K., & Chee Fu, A. W. (1999). Efficient time series matching by wavelets. *Proceedings - International Conference on Data Engineering*, 126–133. Retrieved from <https://doi.org/dbrqm7> doi: 10.1109/icde.1999.754915
- Popescu, M., & Mahnot, A. (2009, Sep.). Acoustic fall detection using one-class classifiers. In *2009 annual international conference of the iee engineering in medicine and biology society* (pp. 3505–3508). IEEE. Retrieved from <https://doi.org/bqk4g6> doi: 10.1109/IEMBS.2009.5334521
- Portugal, F. (2020). *FRADE - Technological pervasive platform for fall detection, fall risk assessment and prevention*. Retrieved 2020-11-02, from https://www.aicos.fraunhofer.pt/en/our_work/projects/frade.html
- Pplware. (2019). *Tutorial: Ligar um LED via MQTT com um ESP8266*. Retrieved 2020-11-02, from <https://pplware.sapo.pt/tutoriais/tutorial-ligar-um-led-via-mqtt-com-um-esp8266/>
- Prof. Diogo Mateus. (n.d.). *FEUP - Acústica de Edifícios e Controlo de Ruído*. Retrieved 2020-11-02, from https://sigarra.up.pt/feup/pt/ucurr_geral.ficha_uc_view?pv_ocorrenca_id=275663
- Ptrobotics. (n.d.). *Sensor de Detecção de Movimento PIR HC-SR501*. Retrieved 2020-11-02, from <https://www.ptrobotics.com/pir/6326-hc-sr501-pir-motion-detection-sensor.html>
- PyCWT. (2017). *PyCWT: spectral analysis using wavelets in Python — PyCWT 0.3.0a22*

- documentation. Retrieved 2020-11-02, from <https://pycwt.readthedocs.io/en/latest/>
- Racic, V., Pavic, A., & Brownjohn, J. M. (2009). *Experimental identification and analytical modelling of human walking forces: Literature review* (Vol. 326). Retrieved from <https://doi.org/fn9t3n> doi: 10.1016/j.jsv.2009.04.020
- Ramos, F. B. P. (2019). *Sistema low cost para análise de vibrações a bordo de navios de guerra* (Master's thesis, Escola Naval). Retrieved 2020-11-02, from <http://hdl.handle.net/10400.26/30274>
- Rao, S. S. (2010). *Mechanical Vibrations*. Retrieved 2020-11-02, from <https://www.pearson.com/us/higher-education/product/Rao-Mechanical-Vibrations-5th-Edition/9780132128193.html>
- Ren, L., & Peng, Y. (2019). *Research of fall detection and fall prevention technologies: A systematic review*. Institute of Electrical and Electronics Engineers Inc. Retrieved from <https://doi.org/fgxh> doi: 10.1109/ACCESS.2019.2922708
- Rimminen, H., Lindstrom, J., Linnavuo, M., & Sepponen, R. (2010, Nov.). Detection of falls among the elderly by a floor sensor using the electric near field. *IEEE Transactions on Information Technology in Biomedicine*, 14(6), 1475–1476. Retrieved from <https://doi.org/cz7zhq> doi: 10.1109/TITB.2010.2051956
- Rob J. Hyndman and George Athanasopoulos. (2014). Optimally Reconciling Forecasts in a Hierarchy. *Foresight: The International Journal of Applied Forecasting*, 42–48. Retrieved 2020-11-02, from www.forecasters.org/foresight
- Robots, P. (2016). *The MPU6050 Explained | Programming Robots*. Retrieved 2020-11-02, from <https://mjwhite8119.github.io/Robots/mpu6050>
- Rodrigues, D. J. L. F. d. V. (2019). *Risk Assessment for Alzheimer Patients, using GPS and Accelerometers with a Machine Learning Approach* (Master's thesis, Universidade Nova). Retrieved 2020-11-02, from <http://hdl.handle.net/10362/79920>
- Rodrigues, J. D. (n.d.). *FEUP - Vibrações e Ruído*. Retrieved 2020-11-02, from https://sigarra.up.pt/feup/pt/ucurr_geral.ficha_uc_view?pv_ocorrencia_id=275663
- Rougier, C., Meunier, J., St-Arnaud, A., & Rousseau, J. (2007). Fall detection from human shape and motion history using video surveillance. In *Proceedings - 21st international conference on advanced information networking and applications workshops/symposia, ainaw'07* (Vol. 1, pp. 875–880). Retrieved from <https://doi.org/c3t23s> doi: 10.1109/AINAW.2007.181
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986, Oct.). Learning representations by back-propagating errors. *Nature*, 323(6088), 533–536. Retrieved from <https://doi.org/cvjdpk> doi: 10.1038/323533a0
- Russell, S., Dewey, D., & Tegmark, M. (2015, Dec.). Research Priorities for Robust and Beneficial Artificial Intelligence. *AI Magazine*, 36(4), 105. Retrieved from <https://doi.org/gdds7c> doi: 10.1609/aimag.v36i4.2577
- Salman Khan, M., Yu, M., Feng, P., Wang, L., & Chambers, J. (2015, May). An unsupervised acoustic fall detection system using source separation for sound interference suppression. *Signal Processing*, 110, 199–210. Retrieved from <https://doi.org/f63nv5> doi: 10.1016/j.sigpro.2014.08.021
- Sampaio, R. P. C. (2018). *Vibrações Mecânicas*. Retrieved 2020-11-02, from <http://www.chedassampaio.net/home/vibracoes-mecanicas>
- Santos, Duarte Sérgio Rodrigues Granado. (2014). *Desenvolvimento de um sistema de monitorização do consumo e qualidade de energia elétrica em sistemas trifásicos*

- (Master's thesis, Universidade de Lisboa). Retrieved 2020-11-02, from <http://hdl.handle.net/10451/12378>
- SBG. (n.d.). *Ellipse Series - Miniature Inertial Navigation Sensors*. Retrieved 2020-11-02, from <https://www.sbg-systems.com/products/ellipse-series/>
- Schmidhuber, J. (2015). *Deep Learning in neural networks: An overview*. Retrieved from <https://doi.org/f6v78n> doi: 10.1016/j.neunet.2014.09.003
- Sense4Care. (n.d.). *ANGEL4 FALL DETECTION - Sense4Care*. Retrieved 2020-11-02, from <https://www.sense4care.com/tienda/angel4-fall-detection/>
- Shan Desai. (2019). *Live IoT Data Subscription with Apollo GraphQL and MQTT*. Retrieved 2020-11-02, from <https://medium.com/@shantanoodesai/live-iot-data-subscription-with-apollo-graphql-and-mqtt-60b7c5a86cde>
- Shaw, F. E. (2007, Oct.). Prevention of falls in older people with dementia. In *Journal of neural transmission* (Vol. 114, pp. 1259–1264). Springer. Retrieved from <https://doi.org/dcdcv4> doi: 10.1007/s00702-007-0741-5
- Shimmer. (n.d.). *Wearable IMU sensor | Motion sensor | 9DOF*. Retrieved 2020-11-02, from <http://www.shimmersensing.com/products/shimmer3-imu-sensor>
- Silva, C. Q. (2019). *Redes neurais aplicadas no reconhecimento de símbolos matemáticos manuscritos online*. Retrieved 2020-11-02, from <https://www.ime.usp.br/~map/tcc/2019/CaiqueQuaresmaV2.pdf>
- Singh, K., Rajput, A., & Sharma, S. (2019, Nov.). Human Fall Detection Using Machine Learning Methods: A Survey. *International Journal of Mathematical, Engineering and Management Sciences*, 5(1), 161–180. Retrieved from <https://doi.org/fgt3> doi: 10.33889/IJMEMS.2020.5.1.014
- SISTEMIC. (2019). *SisFall*. Retrieved 2020-11-02, from <http://sistemic.udea.edu.co/en/investigacion/proyectos/english-falls/>
- Smith, A., Hicks, S., Devine, P., & Britain, S. (2009). *Design of Floors for Vibration: A New Approach*. Steel Construction Institute. Retrieved from <https://doi.org/fgth> doi: 10.13140/RG.2.2.29342.95048
- SNS. (2017). *Tropeções, quedas e trambolhões*. Retrieved 2020-11-02, from <https://www.sns.gov.pt/noticias/2017/12/19/tropecoes-quedas-e-trambolhoes/>
- Sousa, L. M. M., Marques-Vieira, C. M. A., de Caldevilla, M. N. G. N., Henriques, C. M. A. D., Severino, S. S. P., & Caldeira, S. M. A. (2017, Feb.). Risk for falls among community-dwelling older people: systematic literature review. *Revista gaucha de enfermagem*, 37(4), e55030. Retrieved from <https://doi.org/fgtg> doi: 10.1590/1983-1447.2016.04.55030
- Spark Fruit. (n.d.). *HB100 X 10.525GHz Microwave Sensor 2-16M Doppler Radar Human Body Induction Switch Module for Arduino*. Retrieved 2020-11-02, from <https://sparkfruit.ph/product/mh-et-live-hb100-x-10-525ghz-microwave-sensor/>
- Srinivas, S., Sarvadevabhatla, R. K., Mopuri, K. R., Prabhu, N., Kruthiventi, S. S. S., & Babu, R. V. (2016, Jan.). A Taxonomy of Deep Convolutional Neural Nets for Computer Vision. *Frontiers in Robotics and AI*, 2(JAN), 36. Retrieved from <https://doi.org/gccx94> doi: 10.3389/frobt.2015.00036
- Stojiljković, M. (2020). *Linear Regression in Python*. Retrieved 2020-11-02, from https://realpython.com/linear-regression-in-python/#advanced-linear-regression-with-statsmodels/IBM_SPSS_Advanced_Statistics.pdf
- Sucerquia, A., López, J. D., & Vargas-Bonilla, J. F. (2017). *SisFall: A fall and movement*

- dataset. *Multidisciplinary Digital Publishing Institute (MDPI)*, 17. Retrieved from <https://doi.org/fgtd> doi: 10.3390/s17010198
- Tadeu, D. M. F. (2015). *Atenuação de vibrações em pavimentos - Estudo experimental* (Master's thesis, Universidade de Coimbra). Retrieved 2020-11-02, from <http://hdl.handle.net/10316/38693>
- TDK InvenSense. (n.d.). *MPU-6500*. Retrieved 2020-11-02, from <https://invensense.tdk.com/products/motion-tracking/6-axis/mpu-6500/>
- Thanh Hai Nguyen, Ty Phu Pham, Cuong Q. Ngo, T. T. N. (2016). *A SVM Algorithm for Investigation of Tri Accelerometer Based Falling Data*. Retrieved 2020-11-02, from <http://article.sapub.org/10.5923.j.ajsp.20160602.03.html>
- Toreyin, B. U., Soyer, A. B., Onaran, I., & Cetin, E. E. (2007, Dec.). Falling Person Detection Using Multi-Sensor Signal Processing. *EURASIP Journal on Advances in Signal Processing*, 2008(1), 149304. Retrieved from <https://doi.org/ck8xwr> doi: 10.1155/2008/149304
- Torrence, C., & Compo, G. P. (1998). A Practical Guide to Wavelet Analysis. *Bulletin of the American Meteorological Society*, 79(1), 61–78. doi: 10.1175/1520-0477(1998)079<0061:APGTWA>2.0.CO;2
- Valerie J.Easton, J. H. M. (2004). *Statistics Glossary - time series data*. Retrieved 2020-11-02, from http://www.stats.gla.ac.uk/steps/glossary/time_series.html
- Vallabh, P., & Malekian, R. (2018, Nov.). Fall detection monitoring systems: a comprehensive review. *Journal of Ambient Intelligence and Humanized Computing*, 9(6), 1809–1833. Retrieved from <https://doi.org/gfgf2g> doi: 10.1007/s12652-017-0592-3
- Vallabh, P., Malekian, R., Ye, N., & Bogatinoska, D. C. (2016). Fall detection using machine learning algorithms. In *24th international conference on software, telecommunications and computer networks, softcom*. Retrieved from <https://doi.org/fgtb> doi: 10.1109/SOFTCOM.2016.7772142
- Vigilio Vigifall. (2010). *Vigilio Telemedical - Folheto*. Retrieved 2020-11-02, from <https://pdf.medicalexpo.com/pt/pdf-en/vigilio-telemedical/vigilio-vigifall/75024-74250.html>
- WHO (Ed.). (2008). *WHO global report on falls prevention in older age*. Geneva, Switzerland: World Health Organization.
- WHO. (2020). *Falls*. Retrieved 2020-11-02, from <https://www.who.int/news-room/fact-sheets/detail/falls>
- Yazar, A., Keskin, F., Töreyn, B. U., & Çetin, A. E. (2013, Nov.). Fall detection using single-tree complex wavelet transform. *Pattern Recognition Letters*, 34(15), 1945–1952. Retrieved from <https://doi.org/f496jn> doi: 10.1016/j.patrec.2012.12.010
- Youngwook Kim, & Hao Ling. (2009, May). Human Activity Classification Based on Micro-Doppler Signatures Using a Support Vector Machine. *IEEE Transactions on Geoscience and Remote Sensing*, 47(5), 1328–1337. Retrieved from <https://doi.org/cd47d8> doi: 10.1109/TGRS.2009.2012849
- Yun Li, Ho, K. C., & Popescu, M. (2012, May). A Microphone Array System for Automatic Fall Detection. *IEEE Transactions on Biomedical Engineering*, 59(5), 1291–1301. Retrieved from <https://doi.org/fzk8st> doi: 10.1109/TBME.2012.2186449
- Yuwono, M., Moulton, B. D., Su, S. W., Celler, B. G., & Nguyen, H. T. (2012, Feb.). Unsupervised machine-learning method for improving the performance of ambulatory fall-detection systems. *BioMedical Engineering Online*, 11(1), 9. Retrieved from

- <https://doi.org/gb9jck> doi: 10.1186/1475-925X-11-9
- Zigel, Y., Litvak, D., & Gannot, I. (2009, Dec.). A Method for Automatic Fall Detection of Elderly People Using Floor Vibrations and Sound—Proof of Concept on Human Mimicking Doll Falls. *IEEE Transactions on Biomedical Engineering*, 56(12), 2858–2867. Retrieved from <https://doi.org/bk7vsz> doi: 10.1109/TBME.2009.2030171

