



Universidade do Minho  
Escola de Engenharia

Cristiana Mendes Magina

Técnicas de Monitorização de  
Marcha em Pessoas Saudáveis





Universidade do Minho  
Escola de Engenharia

Cristiana Mendes Magina

Técnicas de Monitorização de  
Marcha em Pessoas Saudáveis

Dissertação de Mestrado  
Ciclo de Estudos Integrados Conducentes ao Grau de  
Mestre em Engenharia Eletrónica Industrial e Computadores

Trabalho efetuado sob a orientação da  
Professora Doutora Cristina Manuela Peixoto dos Santos

## AGRADECIMENTOS

Em primeiro lugar, à minha orientadora, Professora Doutora Cristina Santos, por todo o apoio, disponibilidade e conhecimentos transmitidos ao longo deste trabalho.

Um especial agradecimento ao João André por toda ajuda, disponibilidade e paciência prestada.

Ao Professor Doutor Luís Rocha pelo fornecimento do material utilizado neste trabalho e ao Pedro Macedo por toda a sua disponibilidade e ajuda em relação ao mesmo.

Ao Professor Doutor Lino Costa e à Professora Doutora Celina Leão pelo esclarecimento das minhas dúvidas.

A todos os voluntários, um grande agradecimento, por toda a compreensão e paciência na realização dos testes, não sendo possível a realização desta dissertação sem a sua colaboração.

À minha amiga, Bárbara Rodrigues, por todo o seu apoio e disponibilidade em ajudar na correção de erros ortográficos.

Aos meus amigos de curso pelo incentivo, carinho, amizade e por sempre acreditarem que eu era capaz.

Por fim, aos meus colegas de laboratório, em especial ao Pedro Gil, a Joana Figueiredo e ao César Ferreira, por sempre estarem prontos a esclarecer alguma dúvida e pela boa disposição e alegria no laboratório.



## RESUMO

As quedas são a principal causa de lesões fatais e não fatais em pessoas com 65 anos ou mais, sendo um grande fator de preocupação. A sua prevenção para se poder atuar atempadamente é importante, de modo a diminuir as lesões causadas pela mesma.

Um aspeto importante a ter em conta é a diferença entre prevenção e deteção de uma queda. Para a deteção, muitos métodos passam por identificar o impacto no solo, ocorrendo assim na mesma a queda, o que leva a poder causar lesões graves. No entanto na prevenção da queda o princípio é evitar o impacto no solo, de modo a minimizar as lesões.

Nesta dissertação estuda-se um método capaz de prever uma queda, mais especificamente, um estudo das métricas importantes na prevenção da mesma. Neste sentido, primeiro realizou-se uma pesquisa sobre as métricas que quantificam a análise da marcha, de modo a no fim se poder identificar as métricas mais relevantes para a prevenção de quedas.

O estudo dessas métricas, mais concretamente, a obtenção de dados para posterior análise passou pela realização de testes experimentais com sensores inerciais posicionados de acordo com o levantamento do estado da arte, de modo a se poder proceder ao respetivo cálculo das mesmas.

O sistema utilizado é constituído por cinco módulos cinéticos, em que cada um é composto por dois sensores inerciais (um giroscópio e um acelerómetro), e um módulo base.

Os testes experimentais consistiram em testes de marcha normal e cinco quedas diferentes (para a frente, para trás, escorregar, de joelhos e lateral).

O pós-processamento do sinal envolveu filtragem, análise estatística e *Principal Component Analysis* (PCA) que levaram à identificação das métricas que caracterizam a marcha normal, identificação das que caracterizam as quedas e as que são importantes para a prevenção das quedas. Além disso é identificado as métricas importantes para a prevenção da queda de escorregamento.

Para a análise da marcha, em que são calculadas as métricas e posterior análise das mesmas é utilizado como ambiente o Matlab.

**Palavras-Chave:** Marcha, Situações de Risco, Queda, Sensores Inerciais.



## ABSTRACT

Falling is the leading cause of fatal and non-fatal wounds on elderly people (above 65), which is a cause of worry. Fall prediction is thus important so that preventive action can be taken in order to minimize lesions.

An important aspect in this discussion is a proper distinction between fall detection and fall prevention. Many fall detection methods identify the body's impact with the ground, and fall is not avoided, which may lead to serious injuries. On the other hand, fall prevention approaches aim to completely avoid the fall, so injuries are minimized.

In this dissertation, a study of a method to reliably predict fall situations is developed, particularly through a study of gait related metrics. A preliminary study of several gait related metrics was conducted in order to identify the most relevant in a context of fall prediction.

Data acquisition for posterior analysis was based on experimental gait trials with inertial sensors placed at specific locations on the waist and legs, previously planned with the help of a literature review on gait analysis. Five fall situations (backward, forward, sideways, slipping and weak knees) were simulated, as well as normal walking. The acquisition system consisted of five wireless inertial modules equipped with gyroscope and accelerometer hardware, and a base module that received the data.

Signal post-processing involved filtering, statistical analysis and Principal Component Analysis (PCA) that lead to the identification of gait metrics that characterize normal gait, identification of those that characterize the falls, and those that are important for the prevention of falls. In addition, identification of important metrics for preventing the fall slip.

Code development was conducted in Matlab.

KEYWORDS: GAIT, SITUATION OF RISK, FALL, SENSOR INERTIAL





# Índice

Agradecimentos.....	iii
Resumo.....	v
Abstract.....	vii
Lista de Figuras.....	xi
Lista de Tabelas.....	xiii
Lista de Abreviaturas, Siglas e Acrónimos.....	xv
1 Introdução.....	1
1.1 Motivação.....	1
1.2 Enquadramento.....	2
1.3 Estrutura da Dissertação.....	3
2 Estado de Arte.....	5
2.1 Ciclo de Marcha.....	5
2.2 Métodos de deteção/prevenção de quedas.....	7
2.3 Deteção de situações de risco na marcha.....	8
2.4 Métricas potencialmente relevantes para a prevenção de quedas.....	10
2.5 Sensores e Localização.....	12
2.6 Configurações experimentais.....	18
2.7 Técnicas de pré-processamento.....	19
3 Metodologia e Métodos.....	21
3.1 Protocolo Experimental.....	21
3.2 Métricas.....	23
3.3 Sensores Inerciais.....	27
3.3.1 Características.....	27
3.3.2 Procedimento de funcionamento.....	30
3.3.3 Limitações.....	31
3.4 Processamento dos dados.....	32
3.4.1 Implementação do algoritmo de preparação dos dados.....	32
3.4.2 Implementação do algoritmo do cálculo das métricas.....	36
3.5 Principal Component Analysis.....	37

3.5.1 Análise do PCA.....	38
3.5.2 Metodologia .....	38
4 Resultados e Discussão .....	43
4.1 Teste <i>t-student</i> .....	43
4.2 Análise da marcha normal .....	45
4.3 Análise das quedas.....	50
4.4 Comparação da análise da marcha normal com as quedas .....	51
4.5 Análise do PCA da marcha normal com <i>fall slip</i> .....	51
5 Conclusões e Perspetivas Futuras .....	57
Bibliografia.....	59
Anexo I – Consentimento Informado.....	65
Anexo II – Protocolo .....	67
Anexo III – Matrizes para aplicação do PCA .....	69
Anexo IV - Representação dos biplots para a marcha normal .....	79
Anexo V – Representação dos biplots para as quedas .....	87
Anexo VI – Representação dos <i>scree plots</i> para a análise da marcha normal e das quedas ....	95
Anexo VII – Representação dos biplots para a análise da marcha normal com <i>fall slip</i> .....	101

## LISTA DE FIGURAS

Figura 1 - Ciclo de marcha com as várias subfases. Retirado de: [7].	5
Figura 2 - Base de suporte para um ciclo de marcha para heel strike (i), heel off (ii), foot flat (iii), toe off (iv) e heel strike (v). As regiões sombreadas do pé e as linhas tracejadas representam a área de contato do pé e do limite da base de suporte, respetivamente. Retirado de: [8].	6
Figura 3 - Eventos para um ciclo de marcha. Retirado de: [5].	6
Figura 4 - Comprimento da passada e do passo.	6
Figura 5 - Classificação de algoritmos de deteção de queda proposto por [10].	7
Figura 6 - Diferentes tipos de quedas. Queda horizontal: a, b, c. Queda vertical: d, e. Retirado de: [16].	9
Figura 7 - Representação do equilíbrio em posição vertical.	10
Figura 8 - Diferentes eixos/planos e posição do centro de massa. O plano frontal é referido como Antero-Posterior (AP), o plano lateral como Médio-Lateral (ML) e o vertical simplesmente como Vertical (V). Retirado de: [19].	13
Figura 9 - Ilustração de cada tipo de queda. (1) Fall frontal. (2) Fall side. (3) Fall slip. (4) Fall knee. (5) Fall back.	23
Figura 10 - Representação dos eixos x, y e z, e da aceleração da gravidade.	26
Figura 11 - Sistema de aquisição cinético.	28
Figura 12 - Módulo sensorial com respetivo eixo.	29
Figura 13 - Representação dos módulos sensoriais nas respetivas posições do corpo.	29
Figura 14 - Caixa adaptada para colocação do sensor.	30
Figura 15 - Fluxograma para a preparação dos dados.	33
Figura 16 - Trama dos dados obtidos do giroscópio. Angles corresponde ao ângulo obtido do giroscópio.	33
Figura 17 - Trama dos dados obtidos do acelerómetro. Acc corresponde a aceleração.	33
Figura 18 - Fluxograma da função sincronização.	35
Figura 19 - Fluxograma para o cálculo das métricas. Straight corresponde a marcha normal.	36
Figura 20 - Apresentação da normalização das passadas no sensor da cintura no eixo AP.	37
Figura 21 - Representação do scree plot do PCA do sensor da cintura nas quedas e de uma reta tangencial ao maior ponto de inflexão.	40
Figura 22 - Representação dos valores próprios em scree plot no sensor da cintura na marcha normal.	45

Figura 23 - Representação dos coeficientes e dos scores do 1º e 2º componente através do biplot no sensor 4 na marcha normal.....	48
Figura 24 - Representação dos coeficientes e dos scores do 1º e 3º componente através do biplot no sensor 4 na marcha normal.....	49
Figura 25 - Representação dos coeficientes e dos scores do 1º e 4º componente através do biplot no sensor 4 na marcha normal.....	49
Figura 26 - Representação dos valores próprios em scree plot para análise da marcha normal com fall slip no sensor da cintura.....	52
Figura 27 - Representação do biplot para o 1º e 2º PC na análise da marcha normal com fall slip no sensor da cintura.....	55
Figura 28 - Representação do biplot para o 1º e 3º PC na análise da marcha normal com fall slip no sensor da cintura.....	55
Figura 29 - Representação do biplot para o 1º e 4º PC na análise da marcha normal com fall slip no sensor da cintura.....	56

## LISTA DE TABELAS

Tabela 1 – Métricas potencialmente relevantes para prevenção de quedas, com respectivo sensor utilizado e sua posição.....	14
Tabela 2 - Representação de cada tipo de marcha com respectivos voluntários. ....	39
Tabela 3 - Matriz para marcha normal no sensor da cintura para aplicação do PCA. ....	41
Tabela 4 - Matriz para as quedas do sensor da cintura para aplicação do PCA.....	42
Tabela 5 - Médias para cada métrica com respectiva diferença entre as médias de cada tipo de marcha. ....	44
Tabela 6 - Resultado da aplicação do teste t-student. ....	44
Tabela 7 - Resultado do teste t-student para a marcha normal com fall slip.....	44
Tabela 8 - Variações dos componentes principais no sensor da cintura na marcha normal. ...	45
Tabela 9 - Coeficientes dos componentes principais no sensor da cintura na marcha normal.	46
Tabela 10 – Percentagem da variância total para cada métrica da combinação dos componentes principais. ....	47
Tabela 11 - Variação para cada combinação dos componentes principais no sensor da cintura na marcha normal. ....	47
Tabela 12 - Variações dos componentes principais nas quedas para o sensor da cintura. ....	50
Tabela 13 – Resumo das métricas que caracterizam cada tipo de marcha.....	51
Tabela 14 -Métricas relevantes para a prevenção das quedas.....	51
Tabela 15 - Variações dos componentes principais para análise da marcha normal com fall slip no sensor da cintura.....	52
Tabela 16 - Representação dos coeficientes dos componentes principais no sensor da cintura para a marcha normal com fall slip. ....	53
Tabela 17 - Percentagem da variância total para cada métrica da combinação dos componentes principais para a marcha normal com fall slip. ....	54
Tabela 18 - Resumo das métricas relevantes para detetar fall slip.....	56



## LISTA DE ABREVIATURAS, SIGLAS E ACRÓNIMOS

COG – Centro de gravidade;

COM – Centro de Massa;

COMv – Velocidade do Centro de Massa;

BOS – Base de Suporte;

COP – Centro de Pressão;

COPv – Velocidade Média do Centro de Pressão;

ZMP – *Zero Moment Point*;

BOS – Base de Suporte;

maxLE – Expoente Máximo de *Lyapunov*;

RMS – *Root Mean Square*;

IMUs – *Inertial Measurement Units*;

$a_{min}$  – Pico Mínimo da Aceleração;

PPv – Velocidade Angular pico-a-pico;

HR – *Harmonic Ratio*;

RI – *Ratio Index*;

SVM – *Sum Vector Magnitude*;

SMA – *Signal Magnitude Area*;

$SV_D$  – *Dynamic Sum Vector*;

AP – Ântero-Posterior;

ML – Médio-Lateral;

V – Vertical;

PCA – *Principal Component Analysis*;

HS – *Heel-Strike*;

C – Coeficientes de *wavelet*;

E – Energia dos Coeficientes do *Wavelet Decomposition*;

STD – Desvio-Padrão dos Coeficientes do *Wavelet Decomposition*;

FFT – *Fast Fourier Transformation*;

NS – Número da sequência;

PCs – Componentes Principais;

V1, V2, V3, V4, V5 – Voluntários;

FF – *Fall Frontal*;



FSI – *Fall Side*;

FS – *Fall Slip*;

FK – *Fall Knee*;

FB – *Fall Back*;

h – teste *t-student* para o sensor da cintura;

h\_R – teste *t-student* para o sensor da coxa direita;

h\_R1 – teste *t-student* para o sensor da canela direita;

h\_L – teste *t-student* para o sensor da coxa esquerda;

h\_L1 – teste *t-student* para o sensor da canela esquerda;

# CAPÍTULO 1

## 1 INTRODUÇÃO

Neste capítulo são descritas a motivação e o enquadramento deste trabalho, incluindo os objetivos do mesmo. Para além disso, são apresentadas a organização e respetiva estrutura deste documento.

### 1.1 Motivação

Atualmente existe uma elevada percentagem de pessoas idosas e todos os estudos apontam no sentido de um crescimento desta percentagem. Esta variação demográfica vai impor uma elevada carga nos serviços de assistência associados com riscos recorrentes da idade. As quedas são um fator de preocupação muito grande com consequências motoras graves e irrecuperáveis. As quedas, como dito anteriormente, são a razão mais comum de acidentes domésticos entre idosos e uma importante causa de perda de mobilidade, incapacidade e utilização de cuidados de saúde.

Assim, é necessário detetar as situações de risco na marcha de forma a se poder atuar atempadamente.

Para tal é necessário proceder-se à monitorização e caracterização da marcha em pessoas visando a identificação de possíveis situações de risco durante a locomoção, que pode potencialmente levar a uma queda. De forma a se atingir este objetivo mais alargado, torna-se necessário cumprir também os seguintes objetivos. Identificar situações de risco temporárias e potenciais situações de queda durante a locomoção. Para tal, será feito um levantamento do estado da arte. Será também feito um estudo da marcha e das suas diversas fases e eventos. O segundo objetivo pretende identificar na literatura quais as métricas necessárias para identificar essas situações de risco e os sensores mais adequados para a aquisição das mesmas. Delineamento do cenário experimental para recolha dos sinais e cálculos dessas métricas. Caracterização e análise da marcha em pessoas saudáveis sujeitas às situações de risco identificadas e instrumentadas com os sensores também identificados. Aplicação de testes estatísticos para identificar quais as métricas que são mais úteis para distinguir entre uma marcha normal e uma queda.

## 1.2 Enquadramento

As quedas são uma ameaça para a saúde e bem-estar dos idosos e 70% destas ocorrem durante a locomoção [1]. Uma lesão não intencional, que na maioria das vezes é resultante de quedas, é a sexta causa de morte em pessoas com mais de 65 anos. Outras consequências das quedas incluem o medo e perda de função e independência [2]. Além disso, cerca de um terço das pessoas com mais de 65 anos caem pelo menos uma vez por ano, sendo esta a principal causa de hospitalização devido a lesões na velhice [3].

De forma a contornar este problema, a solução passa por prever a queda de modo a que se possam aplicar meios para esta não ocorrer. É de realçar que prever uma queda é diferente de detetar uma queda. Muitos métodos de deteção de queda dependem da deteção do impacto no solo [4,5]. No entanto na prevenção da queda quer evitar o impacto no solo.

Há evidências claras que quedas em pessoas mais velhas pode ser evitada com programas de intervenção devidamente concebidos. Em estudos recentes, sensores inerciais (ou seja, acelerómetros e giroscópios) têm sido usados para medir o desempenho funcional em idosos e risco de queda [3].

Como tal, especial ênfase é colocada sobre as métricas a calcular sobre os dados obtidos dos sensores inerciais, que permitem a prevenção da queda.

Resumidamente, este trabalho pretende recolher dados para diferentes tipos de marcha, com posterior implementação das métricas escolhidas para o estudo e determinar quais as métricas mais relevantes para prever as quedas.

Para a recolha de dados foi realizado 2 tipos de testes experimentais em que um consistiu em cada voluntário caminhar à sua velocidade normal e o outro, em cada voluntário caminhar até determinada zona (onde permaneciam os colchões) e efetuar a queda dita inicialmente, podendo esta ser de 5 tipos: para a frente, para trás, lateral, escorregar e de joelhos.

Na determinação das métricas mais relevantes para a prevenção das quedas é feita uma análise através da técnica *Principal Component Analysis* (PCA).

Numa fase futura, este trabalho vai levar ao desenvolvimento de um aparelho de análise de laboratório de marcha focado na gravação e cálculo das métricas, bem como o delineamento de um conjunto de ensaios de locomoção objetivas num contexto laboratorial.

### 1.3 Estrutura da Dissertação

A dissertação está organizada em 5 capítulos. No primeiro capítulo é feita uma pequena introdução, contendo a contextualização do tema e os objetivos, como toda a estrutura desta dissertação.

No capítulo 2 é apresentado o estado da arte que está dividido em 6 partes. Na 1ª parte são abordados tópicos relevantes do ciclo de marcha para este trabalho. A 2ª parte engloba os vários tipos de queda e clarifica que este trabalho é sobre a prevenção de uma queda, e não na sua deteção. A 3ª e 4ª parte contêm todas as métricas, sensores e localização dos mesmos, encontrados no final de uma revisão literária. A parte seguinte descreve as configurações experimentais que foram encontradas na literatura. São relatadas as condições que foram realizados os testes, a descrição do tipo e quantidade de participantes, o tipo de calçado, entre outros detalhes importantes a ter em consideração nos testes de marcha. Por último, são abordadas as técnicas que se utiliza para uma melhor análise e redução dos dados.

O capítulo 3 explica os testes de marcha realizados, as métricas analisadas, as características dos sensores inerciais e esclarece a técnica utilizada para redução das dimensões, especificamente o algoritmo PCA.

No capítulo 4 são apresentados os resultados obtidos, sendo apresentado as métricas significativas para a prevenção da queda, e são também discutidos os resultados.

E por fim, o último capítulo consiste nas principais conclusões relativas a este trabalho e as perspetivas para um trabalho futuro.



## CAPÍTULO 2

### 2 ESTADO DE ARTE

Neste capítulo, primeiramente é feita uma contextualização com pontos relevantes do ciclo de marcha. De seguida são abordados algoritmos que se utilizam para a deteção/prevenção de quedas, as métricas encontradas para uma análise da marcha, e respetivos sensores utilizados para a aquisição dos dados e localização dos mesmos. Por último é abordado o tipo de processamento a realizar nas métricas calculadas de forma a reduzir o número de métricas, obtendo as importantes.

#### 2.1 Ciclo de Marcha

A marcha consiste num movimento rítmico durante a locomoção [6]. Esta caracteriza-se pelo tempo entre dois contactos sucessivos no solo do mesmo pé, correspondendo esta sequência a um ciclo de marcha, estando dividida em duas fases: apoio e balanço. A primeira corresponde ao momento durante a qual o pé está em contacto com o solo, que se divide em subfases: contacto inicial, resposta à carga, apoio médio, apoio final e pré-balanço. Já a fase de balanço representa a duração de tempo em que o pé está no ar, dividindo-se em 3 subfases: balanço inicial, balanço médio e balanço final. A Figura 1 ilustra um ciclo de marcha com as várias fases constituintes [7]. Para um ciclo de marcha há dois passos.

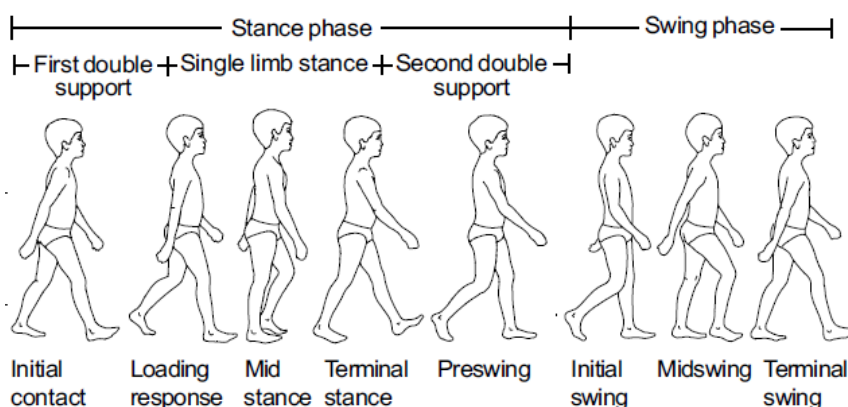


Figura 1 - Ciclo de marcha com as várias subfases. Retirado de: [7].

Tradicionalmente o ciclo de marcha está dividido em oito eventos, cinco durante a fase de apoio e três durante a fase de balanço. Os da fase de apoio são dados pelo: *heel strike*, *foot-flat*, *midstance*, *hee-off* e *toe-off*. Os eventos da fase de balanço são os seguintes: aceleração,

*midswing* e desaceleração. De modo a perceber cada um deles, na Figura 2 estão ilustrados os mesmos e na Figura 3 também mostra os diversos eventos das fases de apoio.




Figura 2 - Base de suporte para um ciclo de marcha para *heel strike* (i), *heel off* (ii), *foot flat* (iii), *toe off* (iv) e *heel strike* (v). As regiões sombreadas do pé e as linhas tracejadas representam a área de contato do pé e do limite da base de suporte, respectivamente. Retirado de: [8].




Figura 3 - Eventos para um ciclo de marcha. Retirado de: [5].




Figura 4 - Comprimento da passada e do passo.

Alguns parâmetros que permitem analisar a marcha são o tempo e o comprimento do passo ou da passada, velocidade da marcha, cadência, centro de massa e base de suporte. O comprimento do passo é definido como a distância entre um dado evento no pé (por exemplo, *heel strike*) até à ocorrência do mesmo evento no pé oposto. Caso sejam dois comprimentos de passo (à esquerda, mais à direita) é chamado de comprimento da passada, ou seja, é a distância entre um dado evento no pé até ao mesmo evento no mesmo pé. Para uma melhor compreensão,

a Figura 4 ilustra o comprimento da passada e o comprimento do passo [7]. A base de suporte pode ser observada na Figura 2.

## 2.2 Métodos de detecção/prevenção de quedas

Uma distinção bastante importante a fazer é entre métodos de prevenção e detecção de uma queda. Numa revisão literária é fácil apontar várias obras que lidam com a identificação de uma queda, e as obras que tentam evitá-la. Muitas outras obras baseiam-se na detecção do impacto [7, 8], e como tal não têm aplicação num contexto de prevenção de uma queda.

Os métodos existentes que visam detetar/prever uma queda podem ser alarmes passivos ativados por indivíduos à beira da queda, a sistemas externos de áudio/vídeo para monitorar pacientes propensos a quedas, como dispositivos com sensores *wearable* (localizados ao longo do corpo) que detetam situações de risco [10]. [11] propõe uma divisão em três métodos de detecção de quedas, podendo ser vistos na Figura 5. Os dispositivos *wearable* podem ser

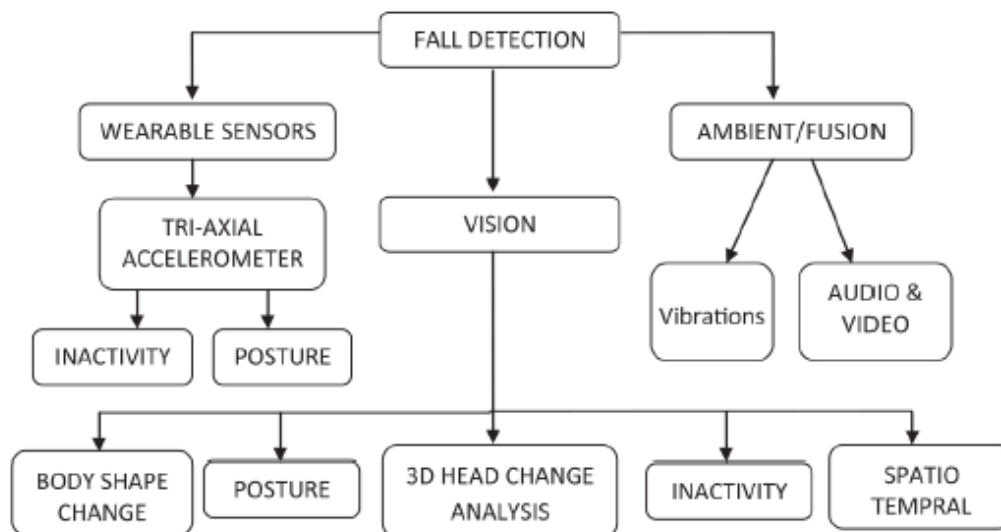


Figura 5 - Classificação de algoritmos de detecção de queda proposto por [10].

divididos em dispositivos baseados em postura e em movimento. Os dispositivos de ambiente podem ser classificados em sensores baseados na presença e na postura, e fundem dados áudio e visuais e detecção de eventos através de dados vibratórios. E os sistemas baseados em câmara (visão) podem ser ainda categorizados em três classes como alteração da forma do corpo, inatividade e movimento da cabeça 3D.

No contexto da identificação de parâmetros de marcha durante a locomoção, neste trabalho apenas os sensores *wearable* são de interesse.



De modo a detetar as quedas, em [5] foi implementados três algoritmos, sendo no primeiro reconhecida a queda se for detetado o impacto e a postura final ser horizontal, no segundo além do método anterior é detetado o início da queda antes 1 s do impacto, e por fim, no último é detetado todos os pontos anteriores e que a velocidade antes do impacto é acima de 0.7 m/s. No entanto, em [4] deteta o pico mais alto na aceleração, que consiste no impacto no solo.

Para prever as quedas em [12] foi calculado parâmetros como a velocidade do centro de pressão (COPv), de modo a selecionar os necessários que indicam risco de queda.

### **2.3 Detecção de situações de risco na marcha**

A maioria das quedas ocorrem durante as transições posturais [13], no entanto para este estudo o importante são as quedas que ocorrem durante a locomoção.

O nível do risco de queda de um indivíduo é determinado por vários fatores intrínsecos e extrínsecos. Os fatores intrínsecos podem ser os efeitos da medicação, diminuição da força muscular dos membros inferiores e função cognitiva e diminuição no sistema de controlo de equilíbrio. Como fatores extrínsecos, relativos a riscos ambientais contribuindo para a maioria das quedas, pode incluir objetos para tropeçar, má iluminação, pisos escorregadios ou imobiliário inadequado [14].

Vários trabalhos na literatura propõe uma divisão e classificação das quedas. Em [9] são identificados seis tipos de quedas: desmaiar, tropeçar, sentado em uma cadeira, deslizando, queda lateral, rolando para fora da cama. [15], por outro lado, enumera sete diferentes situações de queda: deslizamentos, colisões, outras quedas extrínsecas, intrínsecos, de escadas, de um nível superior e não definidas dentro de casa ou ao ar livre. E [4] enumera até nove cenários de quedas (agrupadas em quedas para a frente, para trás e vertical).

As quedas apenas no contexto de locomoção dividem-se em duas categorias principais: as quedas ao longo da direção horizontal/lateral, devido a tropeços (perda de equilíbrio na marcha ou obstáculos no caminho de locomoção) e as quedas ao longo da direção vertical, provocadas pelas pernas fracas ou escorregamento do pé. A primeira pode ser repartida em quedas para a frente, para trás e laterais. A segunda pode ser fragmentada em quedas por escorregamento e de joelhos [16, 17]. Um esboço destes tipos de quedas é ilustrado na Figura 6.

Existem dois eventos principais associados a uma queda: uma mudança na orientação do tronco para uma posição horizontal deitada, e um pico negativo na aceleração/desaceleração

súbita devido ao impacto com o chão. A postura final pode estabilizar apenas 2 segundos após o impacto com o chão [5]. Esta informação é útil para identificar se uma queda ocorreu, no entanto não ajuda para evitá-la [4,17,18].

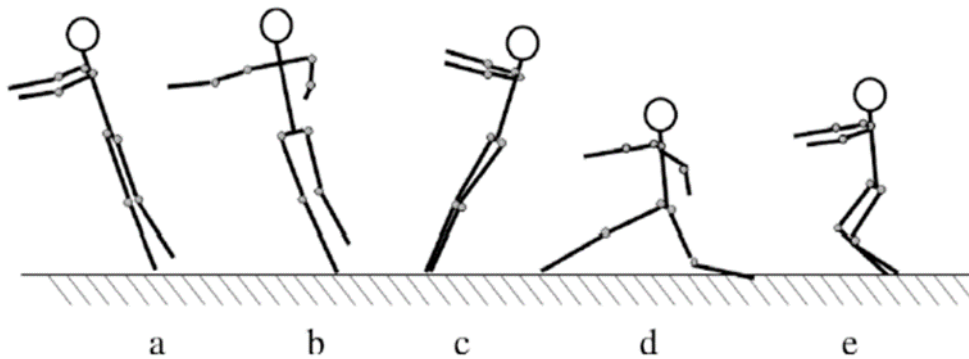


Figura 6 - Diferentes tipos de quedas. Queda horizontal: a, b, c. Queda vertical: d, e. Retirado de: [16]

Uma distinção importante a ter em consideração é entre a detecção de queda e prevenção de queda. Os algoritmos de detecção de queda poderão depender da detecção do impacto no solo [9, 4], e como tal, como neste trabalho se quer evitar o impacto com o solo, terão de se ter outras abordagens como de prevenção de queda.

Depois de uma revisão literária [5, 18, 20, 21, 22], a detecção de queda é feita a partir do cálculo de determinadas métricas, recorrendo a sensores no corpo humano. Tendo em consideração a grande quantidade e diversidade dessas métricas, torna-se necessário identificar qual delas podem ser mais proveitosas para a prevenção de quedas.

Uma maneira simples de prever uma queda horizontal, referida anteriormente como um dos tipos de queda, poderá ser recorrendo ao centro de pressão (COP) e ao *zero moment point* (ZMP). Durante a locomoção humana, a projeção do COP está perto do pé de apoio, assim, uma distância maior entre eles implicará instabilidade da marcha e uma elevada probabilidade de queda, ou seja, se a distância entre o COP e o pé de apoio aumentar de forma brusca e inesperada, poderá ocorrer uma queda. Relativamente à identificação das quedas ao longo da direção vertical, um aspeto óbvio é a altura da cintura humana, ou seja, pode-se recorrer à posição vertical do centro de gravidade (COG), também conhecido como centro de massa (COM). No caso de não haver robustez nas pernas, ocorrerá uma diminuição vertical do COG enquanto os pés mantêm a sua posição. Quanto ao deslizamento do pé, a posição vertical do COG diminui enquanto a distância entre os pés aumenta [16].

## 2.4 Métricas potencialmente relevantes para a prevenção de quedas

Neste trabalho foi feita uma pesquisa de parâmetros que potencialmente levam a prever uma queda (estes serão indicados a negrito nesta secção). Para isso foi estudado teoricamente a análise da marcha.

A análise da marcha é caracterizada por três características principais de locomoção humana: estabilidade, variabilidade e harmonia.

Na estabilidade podemos fazer uma distinção entre estabilidade postural e dinâmica. A estabilidade postural, também conhecida como equilíbrio estático ou equilíbrio postural, quantifica quão bem é que se consegue permanecer na posição vertical, sendo medida com o paciente estático, quantificando a *postural sway* (para a medição recorre-se a velocidade média do centro de pressão (COPv)) [12]. O equilíbrio em posição vertical é obtido quando a projeção do **COM** se encontra sobre a base de suporte (BOS) e é tanto maior quanto menor a distância ao **COP** - Figura 7. Uma perturbação externa ou interna altera a projeção do COM para os limites da BOS resultando num desequilíbrio postural [23]. A distância da posição do COM para a fronteira mais próxima da BOS (COM - BOS) representa controlo de equilíbrio estático [24].

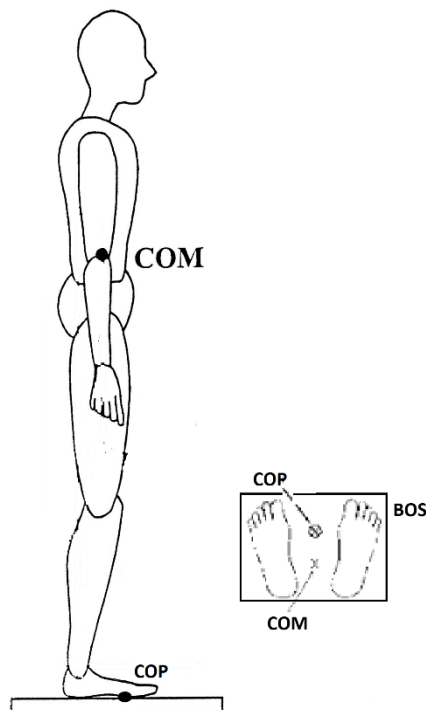


Figura 7 - Representação do equilíbrio em posição vertical.

A estabilidade dinâmica (ou equilíbrio dinâmico) está relacionada com o equilíbrio durante o movimento, sendo que a sua diminuição contribui para um maior risco de quedas. O parâmetro que tem maior importância é a estabilidade dinâmica local, caracterizado pelo **expoente máximo de Lyapunov (maxLE)**. Este em termos de locomoção, quantifica o quão bem um indivíduo pode manter padrões de caminhada estáveis sob perturbações no meio ambiente ou de ele/ela mesma, como um piso irregular ou diferentes movimentos do corpo superior [12]. O controle de equilíbrio dinâmico é representado pelo deslocamento do COM, ao longo da direção do vetor de velocidade do mesmo ao limite da BOS (COM<sub>v</sub> – BOS) [24]. [12] concluiu que uma combinação de medidas de estabilidade postural e dinâmica pode conseguir melhores resultados na identificação de quedas do que métricas individuais.

Como parâmetros relacionados com a estabilidade da marcha temos: **root mean square da aceleração ( $Acc_{RMS}$ )**, **pico mínimo da aceleração ( $a_{min}$ )** e **velocidade angular pico-a-pico (PPv)** [25, 1].

A variabilidade dos parâmetros cinemáticos e espaço-temporais da marcha tem sido avaliada com estabilidade e usada para diferenciar quedas de não-quedas [26]. Uma maior variabilidade poderá indicar uma perda de estabilidade, ou seja, aumento do risco de queda [27, 28, 26]. Caso contrário, uma menor quantidade desta significa melhor controle neuromuscular e estabilidade de caminhada. Esta aumenta, tanto para velocidades de caminhada mais rápidas como para mais lentas [29].

Uma redução da velocidade de caminhada aumenta o risco de queda se se assumir, que maior variabilidade indica perda de estabilidade. No entanto, os indivíduos jovens saudáveis também apresentam maior variabilidade durante a marcha lenta e a estabilidade não é claramente um problema, colocando esta hipótese em causa. Se o aumento da variabilidade era indicativo de perda de estabilidade, então diminuir a velocidade de caminhada como uma estratégia de controle locomotor seria completamente contraditório com o objetivo de manter a estabilidade [27]. Para solução deste paradoxo, [29] concluiu que os sistemas de controle neuromuscular que regulam a caminhada podem acomodar, pelo menos, algum aumento modesto na Variabilidade que acompanham velocidades de marcha mais lentas, em troca de uma maior Estabilidade Dinâmica Local [29].

Um aumento da variabilidade ainda pode ser um indicador válido de um aumento de risco de queda, devendo essas correlações ser interpretadas com cuidado [29].

A harmonia é uma característica essencial da marcha humana que garante movimentos eficientes e suavizados durante a caminhada, sendo definida como a capacidade de transferir a simetria do nosso corpo para movimentos alternados, simétricos, rítmicos e sincronizados por

intermédio da coordenação do corpo inferior-superior [25]. Esta pode ser calculada por meio da investigação da razão entre os harmónicos ímpares e pares do sinal de aceleração. Os parâmetros relacionados com a harmonia da marcha são: *harmonic ratio (HR)*, *ratio index do pico mínimo da aceleração ( $a_{min}$  RI)* e *ratio index da velocidade angular pico a pico (PPv RI)* [25].

Como pré-requisitos básicos para uma análise de marcha é feita uma avaliação dos parâmetros espaço - temporais da marcha, tais como o **comprimento do passo ou duração da passada** [30]. Posto isto, será importante analisar esses parâmetros, de forma a avaliar o risco de queda. A análise do comprimento do passo ou passada é importante, tendo em consideração que para recuperar o equilíbrio, por vezes é necessário dar um passo. Assim, torna-se evidente que a capacidade de dar um passo pode ser importante para evitar uma queda [31].

Outras métricas encontradas foram a **simetria da marcha**, *cadence*, *walking velocity*, *sum vector magnitude (SVM)* e **orientação postural**. A simetria da marcha refere-se à semelhança entre os movimentos do lado direito com o lado esquerdo e é comparada passo a passo [20,21]. O SVM quantifica a intensidade do movimento [34] e é utilizado para detetar o impacto no solo [5]. Quando ocorre uma queda, uma grande aceleração é produzida, mas quando se dá o impacto do corpo com o solo, a aceleração é depois reduzida instantaneamente. Neste ponto, o SVM do acelerómetro gera um pico significativo, sendo este produzido pela queda, muito maior do que o pico periódico produzido pela caminhada [10]. Quanto à orientação postural, refere-se à inclinação relativa do corpo no espaço [34].

Na Tabela 1 mostra todos os parâmetros encontrados após uma revisão literária, a que chamamos neste trabalho de métricas. Como também mostra que sensores utilizados e respetiva localização dos mesmos para o cálculo dessas métricas. A seguir é explicado mais detalhadamente os sensores e localização dos mesmos.

## 2.5 Sensores e Localização

Para o cálculo das métricas, referenciadas anteriormente, geralmente usam-se sensores fixos ao corpo [13]. Depois de uma revisão literária, como se pode ver na Tabela 1, os sensores mais comuns são *Inertial Measurement Units (IMUs)* e acelerómetros. Outros dispositivos comuns são as plataformas de força [20, 21, 33], que podem ser utilizadas para identificar eventos de marcha, pois fornecem uma grande quantidade de informações sobre o contato do pé. Os giroscópios, incluídos nos IMUs, ou utilizados individualmente como em [13] também

são comuns. Os restantes sensores incluem uma única utilização de barómetros (usado em conjunto com um acelerómetro) e electrogoniómetros (também utilizados com acelerómetros), e duas utilizações de sensores de pressão colocados nos sapatos [32, 30].

Os dados da aceleração e velocidades angulares correspondem à aceleração ao longo do eixo do corpo vertical (V), médio-lateral (ML) e ântero-posterior (AP), e velocidade angular em torno dos mesmos eixos. Esses eixos estão representados na Figura 8 com a localização do centro de massa.

A posição na qual o sensor é colocado sobre o corpo é importante para o cálculo das métricas. No caso do acelerómetro, é normalmente fixado à parte do corpo cujo movimento está a ser estudado. Por exemplo, os acelerómetros ligados à coxa ou ao tornozelo são utilizados para estudar o movimento das pernas durante o caminhar. Para analisar os movimentos com o




Figura 8 -Diferentes eixos/planos e posição do centro de massa. O plano frontal é referido como Antero-Posterior (AP), o plano lateral como Médio-Lateral (ML) e o vertical simplesmente como Vertical (V). Retirado de: [19]

corpo todo (como locomoção) são exigidos vários sensores em todo o corpo/membro ou um único sensor colocado próximo do COM [19]. Em [16] para detetar uma queda utilizaram-se sensores em cinco segmentos corporais, nas coxas, nas canelas e na cintura, e foram utilizados um magnetómetro, um acelerómetro e um giroscópio, todos tri-axiais. No entanto, uma grande quantidade de dispositivos implica maior complexidade e custo, portanto, muitas vezes opta-se por uma abordagem de um único elemento, sendo anexado à parte do corpo relevante. A quantidade de dados registados, com um único sensor colocado próximo do COM, diminui significativamente, contudo, podem ser fornecidas informações úteis ao estudar os movimentos do corpo inteiro [19], como em [34] que utilizaram um único acelerómetro tri-axial na cintura.

Os acelerómetros uniaxiais registam acelerações apenas numa única direção. No entanto, um acelerómetro tri-axial atua em três eixos ortogonais e assim pode fornecer um quadro de aceleração em três dimensões.

Os dados obtidos de um acelerómetro junto ao corpo dependem da posição em que é colocado, a orientação em relação à pessoa, a postura e a atividade a ser realizada pela mesma.

O uso de IMUs para avaliar o movimento oferecem um baixo custo; o teste não é restrito a um ambiente de laboratório; permite às pessoas andar relativamente sem restrições devido ao seu pequeno tamanho e baixo peso [31, 33].

O sítio de colocação mais comum dos sensores é na parte inferior das costas (como se pode ver na Tabela 1), que reflete acelerações do tronco inferior reais durante a caminhada. Isto deve-se ao facto de que esta região do corpo tem uma baixa rotação transversal em relação ao plano de rotação axial da pelve e tórax [36]. As restantes localizações comuns incluem a cintura [6, 25, 40, 41, 42], coxas, canelas [4, 6, 29, 33] e tornozelo [9, 15, 30].

Tabela 1 – Métricas potencialmente relevantes para prevenção de quedas, com respetivo sensor utilizado e sua posição.

Métrica	Descrição	Sensores	Posição	Referências
<b>Centro de Pressão (CoP)</b>	Se a distância entre o CoP e o pé de suporte aumentar de repente pode ocorrer uma queda.	IMU	Cintura, coxas e canelas	[16]
	Testes em pessoas obesas e saudáveis.	2 Plataformas de força		[37]
	Descalços na primeira plataforma em uma postura relaxada.			
	COPv quantifica a intensidade da oscilação postural	IMU	Parte inferior das costas	[12]
		2 Plataformas de força		[38]
<b>Centro de Massa (CoM)/ Centro de Gravidade (COG)</b>	Estático. Deslocamento do CoM.	Acelerómetro tri-axial	Parte inferior das costas	[39]
				[8]
	Dinâmico. Descrição de 3 métodos para a estimativa do CoM	3 IMU	Parte inferior das costas e na canela	[40]
		IMU	Cintura, coxas e canelas	[16]
<i>The mean squared modulus ratio for postural sway derived from lower back angular velocity</i>		IMU	Parte inferior das costas	[5][41]

<i>Sit-to-stand fractal dimension derived from sternum acceleration and angular velocity</i>		IMU	Cintura	[42]
<i>Sit-to-stand transition duration determined from sternum acceleration and angular velocity</i>		IMU	Cintura	[42]
<i>Sit-to-stand lower back jerk (derivative of acceleration)</i>		Acelerómetro tri-axial	Parte inferior das costas	[43]
		IMU	Parte inferior das costas	[5][41]
<b>Desvio nos padrões de marcha</b>	Algoritmo projetado para aprender automaticamente nos primeiros dias e depois é capaz de detetar se ocorre padrões inéditos.	Acelerómetro tri-axial	Parte inferior das costas	[6] [44]
<i>Previous faller</i>				
<i>Walking bout duration variability</i>		IMU	Peito	[2] [45]
<i>Longest walking bout duration</i>				
<i>Walking bouts average duration</i>	Pessoas com AVC e utilizaram dados de pessoas saudáveis	3 Acelerómetros	1 no peito e 2 nas coxas	[46]
<b>Parâmetros da marcha (Contacto inicial, contacto terminal, toe-off, heel-strike)</b>	Dinâmico	2 Acelerómetros e 4 <i>footswitch</i> dentro dos sapatos	Tornozelos e 2 <i>footswitch</i> dentro de cada sapato	[47]
	Dinâmico	Acelerómetro Numa fase de testes: plataforma equipada com sensores de força	Lado dorsal do tronco	[30]
	Dinâmico (utilizaram uma escada rolante)	IMU	Peito do pé (no direito)	[35]
	Dinâmico	2 Acelerómetros piezoresistivos 2 Sensores de pressão dentro dos sapatos	Coxas	[21]
		IMU e 4 giroscópios	Peito (IMU) Canelas e coxas (4 giroscópios)	[13]
	Dinâmico	IMU Plataforma de força	Coxa e canela	[36]



<b>Comprimento do passo/ Comprimento da passada</b>	Dinâmico		Cabeça e Parte inferior das costas	[1]
	Dinâmico	Acelerómetro tri-axial	Parte inferior das costas	[48]
				[31]
		2 Acelerómetros	Parte inferior das costas	[22]
		IMU e 4 giroscópios	Peito (IMU) Canelas e coxas (4 giroscópios)	[13]
	Dinâmico	Acelerómetro Numa fase de testes: plataforma equipada com sensores de força	Lado dorsal do tronco	[30]
	Dinâmico	IMU	Peito do pé (no direito)	[35]
<b>Cadence</b>	Dinâmico		Cabeça e parte inferior das costas	[1]
	Dinâmico	Acelerómetro tri-axial	Parte inferior das costas	[48]
		IMU e 4 giroscópios	Peito (IMU) Canelas e coxas (4 giroscópios)	[13]
	Dinâmico	IMU Plataforma de força	Coxa e canela	[36]
<b>Walking Velocity</b>	Dinâmico		Cabeça e Parte inferior das costas	[1]
	Dinâmico	Acelerómetro Numa fase de testes: plataforma equipada com sensores de força	Lado dorsal do tronco	[30]
	Dinâmico.	IMU	Peito do pé (no direito)	[35]
		IMU e 4 giroscópios	Peito (IMU) Canelas e coxas (4 giroscópios)	[13]
				[49]
<b>Aumento do Movimento Médio- Lateral do CoM</b>				[49]
				[49]
<b>Simetria da Marcha</b>	Dinâmico	Acelerómetro tri-axial	Centro frontal da cintura	[33]
	Dinâmico	3 IMU	Parte da frente da cintura e em cada perna perto do tornozelo.	[32]

	Dinâmico	IMU	Peito do pé (no direito)	[35]
	Dinâmico	2 Acelerómetros	Parte inferior das costas	[22]
<b>Harmonic Ratio (HR)</b>	Dinâmico	IMU	Parte inferior das costas	[25]
	Dinâmico		Cabeça e Parte inferior das costas	[1]
	Dinâmico	IMU	Coxa e canela	[36]
<b>Root mean square da aceleração (<math>Acc_{RMS}</math>)</b>	Dinâmico	IMU	Parte inferior do tronco	[25]
	Dinâmico		Cabeça e Parte inferior das costas	[1]
<b>Expoente máximo de lyapunov (maxLE)</b>	Medidas locais de estabilidade dinâmica. Valores mais altos implicam uma maior instabilidade.	1 Acelerómetro tri-axial 3 Electrogoniómetros	Peito (esterno). Quadril, joelho e tornozelo da perna direita.	[27]
			Parte Inferior das costas	[50]
		IMU	Tornozelo direito	[12]
<b>SVM (Sum Vector Magnitude)</b>	Queda ocorre se, pelo menos, dois picos consecutivos no SVM acima de um limite definido são registados.	1 Acelerómetro tri-axial	Cintura	[34]
	Dinâmico. Após a queda a aceleração é parada instantaneamente. SVM do sensor de aceleração produz um pico significativo.	6 Acelerómetros tri-axiais	Mãos, pés, pescoço e cintura (parte da frente)	[10]
		1 Acelerómetro tri-axial 1 Barómetro	Cintura	[20]
	Dinâmico	2 Acelerómetros e 4 footswitch dentro dos sapatos	Tornozelos e 2 footswitch dentro de cada sapato	[47]
	Dinâmico	Acelerómetros tri-axiais	Cintura, punho e cabeça	[9]
<b>SMA (Signal Magnitude Area)</b>		1 Acelerómetro tri-axial 1 Barómetro	Cintura	[20]
	Dinâmico	Acelerómetros tri-axiais	Cintura, punho e cabeça	[9]
<b><math>SV_D</math> (Dynamic Sum Vector)</b>	Dinâmico	Acelerómetros tri-axiais	Cintura, punho e cabeça	[9]
	Dinâmico	Acelerómetro tri-axial	Cintura	[5]

$\frac{d(SVM)}{dt}$			6 Acelerómetros tri-axiais	Mãos, pés, pescoço e cintura (parte da frente)	[10]
<b>Orientação Postural</b>	Valores de referência para várias atividades diárias.		1 Acelerómetro tri-axial	Cintura	[34]
			6 Acelerómetros tri-axiais	Mãos, pés, pescoço e cintura (parte da frente)	[10]
<b>Wavelet decomposition</b>			Acelerómetro tri-axial	Cintura	[51]
			IMU e 4 giroscópios	Peito (IMU) Canelas e coxas (4 giroscópios)	[13]
<b>Pico mínimo/máximo da aceleração (<math>a_{max}, a_{min}</math>)</b>	Dinâmico		IMU	Coxa e canela	[36]
	Dinâmico		IMU	Parte inferior das costas	[25]
<b>Velocidade angular pico-a-pico (<math>PP_V</math>)</b>	Dinâmico		IMU	Parte inferior das costas	[25]
<b>Ratio Index do pico mínimo da aceleração (<math>a_{min} RI</math>)</b>	Dinâmico		IMU	Parte inferior das costas	[25]
<b>Ratio Index da velocidade angular pico a pico (<math>PP_V RI</math>)</b>	Dinâmico		IMU	Parte inferior das costas	[25]
<b>Variabilidade do tempo de passo</b>	Dinâmico			Cabeça e Parte inferior das costas	[1]
$\rho, \phi$ e $\theta$	Dinâmico. Inclinações dos eixos 3D.		6 Acelerómetros tri-axiais	Mãos, pés, pescoço e cintura (parte da frente)	[10]

## 2.6 Configurações experimentais

Após saber todas as métricas, tipos de sensores e posição a colocar os mesmos, é importante compreender em que condição cada métrica, revista na secção anterior, foi considerada relevante, e particularmente, como são projetadas as experiências a realizar, considerando: o número de indivíduos, o tipo de tarefas a efetuar e as etapas de processamento realizados sobre os dados brutos.

Nas experiências para a análise de marcha, o número de indivíduos altera muito consoante o estudo, sendo com um ou dois indivíduos [9], até dez indivíduos [42, 22, 46, 25, 8], com algumas dezenas de pacientes [47, 9, 14, 23, 48, 41, 13, 43, 49], ou grandes grupos de indivíduos (mais de cinquenta) [44, 50]. Para testes académicos, envolve-se um grupo mais

pequenos de indivíduos [7, 43], enquanto para os ensaios clínicos exige-se um grande número de pacientes, apresentando distintos estados de saúde entre eles (sendo alguns saudáveis e outros sofrendo de certas patologias) [49, 37, 13].

Os testes de caminhada são realizados numa passadeira rolante [41, 46, 15, 47, 9, 14] e em solo normal [44, 13]. No entanto, caminhar numa passadeira rolante não é idêntico ao caminhar num solo. A primeira estabiliza um pouco a marcha e reduz a variabilidade de passada para passada na locomoção, em comparação com o caminhar num solo [27]. As distâncias percorridas nos testes em solo são de 10 m a 200 m (sendo a distância de 10 m mais referenciada) [38, 12, 13, 39, 15]. Na passadeira rolante apenas são consideradas distâncias de 30 passos [50]. A duração da gravação dos dados é representada por estas distâncias ou pela duração dos testes. Na passadeira rolante, a duração varia entre 1 a 5 minutos contínuos [14, 9, 46]. O número de repetições de cada teste pode ser nenhuma, feito o ensaio apenas uma vez [14, 15], 10 [51], e mais comumente, de 2 a 5 repetições [46, 41, 25, 13, 8].

Muitos destes estudos são orientados para a deteção e prevenção das quedas na população idosa. No entanto, conseguir voluntários idosos dispostos a este tipo de experiências é muito difícil. Existe uma maior preocupação, sendo essencial outro tipo de atenção para estes voluntários, tanto a nível psicológico como a nível físico, de modo a que não ocorra nenhum tipo de lesão, sendo mais complicada de ser tratada nesta idade.

As experiências para a simulação de uma queda consistem no voluntário cair intencionalmente para um colchão [42, 43, 7, 48, 22], de modo a evitar ferimentos. O tipo de calçado dos voluntários não é muito mencionado, tendo em [25] utilizado os sapatos do dia-a-dia. Já em [56], colocaram chinelos de espuma antiderrapante de tamanho apropriado, enquanto outros realizaram as experiências descalços [38, 41] ou com sapatos de atleta [9, 14].

Por último, quanto ao processamento de dados (obtidos dos sensores), a maioria dos estudos de avaliação de locomoção implementaram um filtro *Butterworth* passa-baixo de 2ª a 6ª ordem com uma frequência de corte de 0.1 a 10 Hz [7, 22, 14, 41, 42, 25, 47], sendo que em [22] subtraem os seus valores médios.

## 2.7 Técnicas de pré-processamento

A revisão literária permitiu encontrar uma variedade de métricas, como se pode ver na secção 2.3. Analisar quais serão importantes para prever uma queda será uma tarefa difícil e poderá não ser tão claro perceber quais contribuem melhor para a prevenção de uma queda.

Para uma melhor análise recorre-se a técnicas de pré-processamento. Em [57] propõem aplicar duas técnicas: *Principal Component Analysis* (PCA) linear e *Kernel-PCA* (KPCA).

O PCA linear produz um conjunto de bases ortogonais que captura as direções de variância máxima nos dados. Além disso, o PCA tem sido aplicada com êxito no campo da análise de marcha com a finalidade de reduzir a redundância de informações. Como também, aplicado a parâmetros de marcha (parâmetros espaço-temporais, cinemáticos e cinéticos) para o mesmo efeito. No entanto, os parâmetros de marcha normalmente interagem de forma complexa e não-linear, e o PCA linear baseia-se na correlação de segunda ordem entre os dados. O que motiva o uso de uma técnica de análise não-linear que pode capturar a estrutura não-linear de padrões de marcha. Isso pode ser conseguido por meio de uma função de *Kernel*. Assim, os dados são mapeados para um espaço de características de dimensão mais elevada através de uma função de *Kernel* para em seguida, aplicar o método PCA linear, de modo a extrair características de marcha no espaço transformado correspondente à extração de características não-lineares no espaço de entrada [57].

## CAPÍTULO 3

### 3 METODOLOGIA E MÉTODOS

Este capítulo apresenta todo o procedimento selecionado para a realização dos testes experimentais, o tipo de marcha a executar, quantas repetições para cada tipo de marcha, o número de voluntários, entre outros pontos. Além disso aborda cada métrica escolhida para análise e uma breve explicação dos sensores utilizados na aquisição dos dados.

#### 3.1 Protocolo Experimental

Para a realização dos testes experimentais foi necessário decidir todos os pontos referidos anteriormente na secção 2.5.

Relativamente aos participantes, foram constituídos por um grupo de 6 pessoas (3 mulheres e 3 homens) com idades entre os 22 e 26 anos, todos eles saudáveis. Antes da realização dos testes experimentais foi entregue um consentimento informado, apresentado no Anexo I, que todos os participantes leram e assinaram.

Todos os participantes efetuaram os testes experimentais com o seu calçado do dia-a-dia.

Os sensores escolhidos foram os inerciais, pois após uma revisão literária concluiu-se que são os mais utilizados. Os sensores utilizados nos testes são constituídos por cinco nós de sensores e uma base, estando sincronizados. Estes sensores são tri-axiais, obtendo dados para os eixos Ântero-Posterior, Médio-Lateral e Vertical. Na secção 3.3 será explicado mais detalhadamente as suas características e o seu funcionamento.


Quanto a posição a escolher para os sensores, com a Tabela 1 podemos ver que a posição mais utilizada claramente é a parte inferior das costas/cintura. Para as outras posições já não é tão claro, mas com uma análise mais aprofundada concluiu-se que são as coxas e canelas. Assim, as posições escolhidas foram a parte inferior das costas (na zona da cintura), e em ambas coxas e canelas, como se pode ver na Figura 13.

Os testes foram realizados no Complexo Desportivo Universitário de Azurém, numa sala com acesso a colchões para amparar as quedas pelos mesmos, de modo aos participantes

não sofrerem lesões nas quedas. O objetivo destes testes é obter os dados do acelerómetro e giroscópio para posterior análise de marcha, conseguindo prever a queda.

Inicialmente, cada participante teve de caminhar 10 m em linha reta à sua velocidade normal com os sensores devidamente colocados nas posições ditas anteriormente, repetindo este processo 3 vezes.

Os testes seguintes consistiram em cada participante caminhar à sua velocidade normal (de conforto) em linha reta e em determinada zona (onde permaneciam os colchões) os participantes realizavam a queda comunicada inicialmente. Os colchões dependendo do tipo de queda alteravam de posição. Sendo que as quedas poderiam ser de 5 tipo: para a frente (*fall frontal*), para trás (*fall back*), lateral (*fall side*), escorregar (*fall slip*) e de joelhos (*fall knee*), baseadas no artigo [16]. De modo a se compreender melhor é ilustrado cada tipo de queda na Figura 9.



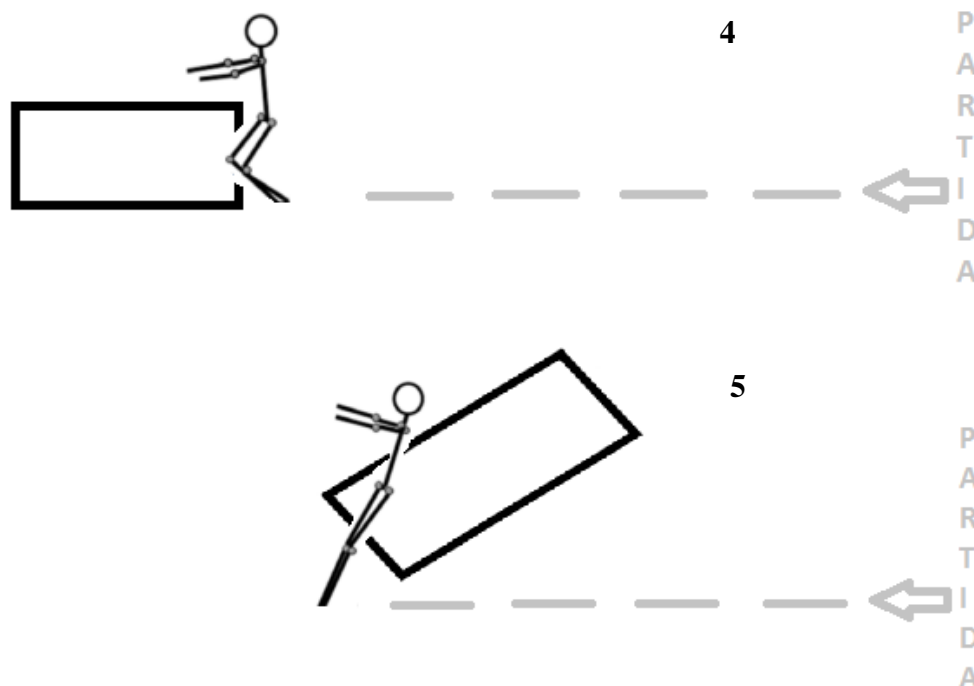


Figura 9 - Ilustração de cada tipo de queda. (1) *Fall frontal*. (2) *Fall side*. (3) *Fall slip*. (4) *Fall knee*. (5) *Fall back*.

Cada participante apenas efetuava uma vez cada tipo de queda. Os módulos dos sensores eram bastante sensíveis, não sendo possível fazer mais repetições para não os danificar. Na realização dos testes foi seguido um protocolo elaborado para o devido efeito – Anexo II.

Todos os testes efetuados foram devidamente gravados com uma câmara de vídeo, para uma posterior análise.

### 3.2 Métricas

Numa revisão literária foi encontrado uma grande variedade de métricas que podem ser vistas na Tabela 1 na secção 2.3. Um dos critérios aplicados na escolha foi as que não exigiam o uso de FSRs para o cálculo das mesmas. Não se usou este sensor pela razão de não possuir esse equipamento, no entanto na posse do mesmo era uma boa escolha utilizar juntamente com os sensores inerciais. Sendo os FSRs excelentes para detetar os parâmetros espaço-temporais da marcha (por exemplo, contacto inicial, contacto terminal, *toe-off* e *heel-strike*). Também se excluíram algumas métricas que na revisão literária foram menos encontradas. Tendo sido implementadas as mais abordadas. A seguir é explicado mais pormenorizadamente as métricas escolhidas para posterior implementação em Matlab.



Iniciando pela **cadência, velocidade da caminhada e comprimento do passo ou da passada**. A **cadência** é o número de passos dados num determinado tempo, sendo as unidades usuais passos por minuto [58]. A cadência pode ser vista pela seguinte equação:

$$Cadência [passos/min] = \frac{n^{\circ} \text{ de passos}}{\text{tempo [min]}} \quad (1)$$

A **velocidade da caminhada** ( $v$ ) é dada pela Equação 2, sendo a distância total ( $d$ ) percorrida nos testes a dividir pelo tempo total ( $t$ ) que demorou a percorrer essa distância.

$$v [m/s] = \frac{d [m]}{t [s]} \quad (2)$$

O **comprimento da passada** é a distância entre duas colocações sucessivas do mesmo pé, ou seja, consiste em dois comprimentos do passo, esquerda e direita, em que cada um é a distância pela qual determinado pé se move para a frente [58]. Optou-se por calcular o comprimento da passada, sendo o cálculo mais direto. Para a identificação da passada recorre-se a aceleração no eixo AP, onde é detetado o momento HS. Mais a frente será explicado melhor como são identificadas as passadas.

A análise da marcha classifica a estabilidade da marcha e a harmonia da marcha, ou seja, os seus parâmetros vão ser métricas relevantes. Na estabilidade da marcha, a aceleração RMS, como o nome indica é o valor eficaz da aceleração, sendo calculada para cada eixo. A equação 3 mostra como se calcula **aceleração RMS do eixo AP** ( $Acc_{AP_{RMS}}$ ) e T corresponde ao período.

$$Acc_{AP_{RMS}} = \sqrt{\frac{1}{T} \cdot \int_0^T Acc_{AP}^2(t) \cdot dt} \quad (3)$$

No **pico mínimo da aceleração** ( $a_{min}$ ) é utilizado a função  $min()$  do Matlab para encontrar este pico e o **valor pico a pico da velocidade angular** ( $PP_v$ ) é calculado pela diferença do pico máximo e mínimo da velocidade angular. Além do pico mínimo da aceleração é calculado o **pico máximo da aceleração** ( $a_{max}$ ), tendo em conta que iria ser necessário no cálculo da métrica **RI**  $a_{min}$ .

Quanto aos parâmetros da harmonia da marcha, para o cálculo do **harmonic ratio** recorre-se às amplitudes dos harmónicos obtidos através da FFT da aceleração. Para os eixos V e AP é a soma das amplitudes dos primeiros 10 harmónicos pares divididos pela soma das

amplitudes dos 10 harmónicos ímpares. Para o eixo ML é a soma das amplitudes dos harmónicos ímpares divididos pela soma das amplitudes das harmónicas pares [12, 13]. O **RI do  $a_{min}$**  corresponde à relação percentual entre os valores absolutos menor/maior registados para os dois membros inferiores, que, quando inferior a 100 % é um indicador de assimetrias em desacelerações. Para finalizar, temos o **RI do  $PP_v$** , que é calculado de forma similar ao parâmetro anterior, e é um indicador de assimetrias em rotações durante dois passos incluídos na passada [25].

**Signal magnitude area (SMA)** é a soma da área inferior das curvas de aceleração para cada eixo [24,44].

O **sum vector magnitude (SVM)**, como foi dito no capítulo 2.3, proporciona uma medida do grau de intensidade do movimento através do sinal da aceleração, sendo dado pela Equação 4 [24,25]. A **derivada de SVM** é dada pela Equação 5 [10].

$$SVM = \sqrt{Acc_x^2 + Acc_y^2 + Acc_z^2} \quad (4)$$

$$\frac{d(SVM)}{dt} = \frac{d(\sqrt{Acc_x^2 + Acc_y^2 + Acc_z^2})}{dt} \quad (5)$$

$\rho$ ,  $\phi$  e  $\theta$  representam inclinações dos eixos.  $\rho$  é a inclinação da  $Acc_x$  (aceleração no eixo do x) em relação ao plano do solo;  $\phi$  é a inclinação da  $Acc_y$  (aceleração no eixo do y) em relação ao plano do solo; e por último,  $\theta$  é a inclinação  $Acc_z$  (aceleração no eixo do z) em relação à aceleração da gravidade. Na Figura 10 estão representados os respetivos eixos. Quanto ao modo de cálculo destas métricas é dado pelas Equações 6, 7 e 8 [10].

$$\rho = \arctan\left(\frac{Acc_x}{\sqrt{Acc_y^2 + Acc_z^2}}\right) \quad (6)$$

$$\phi = \arctan\left(\frac{Acc_y}{\sqrt{Acc_x^2 + Acc_z^2}}\right) \quad (7)$$

$$\theta = \text{acrtan}\left(\frac{\sqrt{\text{Acc}_x^2 + \text{Acc}_y^2}}{\text{Acc}_z}\right) \quad (8)$$




Figura 10 - Representação dos eixos x, y e z, e da aceleração da gravidade.

**Dynamic sum vector (SV<sub>D</sub>)** é similar à métrica **SVM** mas os dados são filtrados por um passa-alto.

A **variabilidade do tempo de passo** é o desvio padrão do tempo entre HS sucessivos.

Para dados de marcha que a duração é finita, não estacionária ou não-linear, a análise de Fourier é de uso limitado, sendo a análise de *wavelet* uma alternativa melhor nestas situações. Como tal, procedeu-se a implementação da *wavelet decomposition*, tendo como métricas a **energia** dos coeficientes *wavelet* (C) do sinal de aceleração do AP, ML e V (AP/ML/V<sub>E</sub>); **desvio-padrão** do mesmo sinal (AP/ML/V<sub>STD</sub>); e **valor RMS** do sinal de aceleração AP e V (AP/V<sub>RMS</sub>) [51].

As informações úteis relacionadas com a aceleração do impacto é contida abaixo da banda dos 17 Hz. Além disso, as frequências superiores a 0.25 Hz permite-nos efetivamente separar a aceleração do corpo e os componentes da aceleração da gravidade. Tendo em consideração o referido anteriormente, e para facilitar a modulação fractal, a banda de frequência do sinal de 0.39 – 18.75 Hz é o mais adequado. Para a aplicação de *wavelet decomposition* é aplicado ao sinal de aceleração uma decomposição de seis níveis e um de quinta ordem *daubechies wavelet*, tendo assim todos os parâmetros para aplicação da função *wavedec* do Matlab [51].

Para seis níveis, a **energia**, o **desvio padrão** e o **valor RMS** são dados pelas seguintes equações, respetivamente:

$$AP/ML/V_E = \sum_{j=2}^6 \|C_j\|^2 \quad (9)$$

$$AP/ML/V_{STD} = std(C_j)_{j=2,3,4,5} \quad (10)$$

$$AP/V_{RMS} = \sqrt{\frac{C_j^2_{j=2,3,4,5}}{length(C_j)_{j=2,3,4,5}}} \quad (11)$$

Para a **análise de frequência/ potência do espectro** foi utilizada a função *Fast Fourier Transformation* (FFT) e posterior integração. Para obter uma **potência do espectro por tempo**, é calculado a FFT com uma determinada janela, procedendo à integração.

Por último, temos como métricas a **aceleração AP, ML e V**, obtidas diretamente dos sensores inerciais, mais precisamente, do acelerómetro, não sendo preciso qualquer cálculo.

### 3.3 Sensores Inerciais

#### 3.3.1 Características

O sistema de medição inercial utilizado na aquisição de dados é composto por uma estação base conectada a um computador e cinco módulos sensoriais que coletam informações sensoriais do usuário, tendo sido desenvolvido pelo grupo de microtecnologias da Universidade do Minho [59] – Figura 11. As leituras dos sensores inerciais e magnéticos são continuamente coletadas e enviadas sem fios para a estação base, usando para a comunicação o CC2530 da Texas Instruments. Essa leitura é feita a 33 ms e enviada para a base ao fim de 100 ms, ou seja, ao fim de ter 3 frames juntas.

A transmissão da estação base ao computador é feita através de uma conexão serial.

Na placa do sensor estão presentes três sensores. O MPU-6000 da *Invensense*, que contém um giroscópio MEMS (não utilizado neste trabalho) e um acelerómetro MEMS, ambos de 3 eixos, e um magnetómetro ligado ao MPU via i2c. Para o cálculo dos ângulos estão a ser utilizados o magnetómetro e o acelerómetro.

A representação dos eixos nos módulos sensoriais é dada pela Figura 12. O eixo x, eixo y e eixo z correspondem a acelerações medio-lateral (ML), vertical (V) e ântero-posterior (AP), respetivamente.

Cada módulo é colocado em cada parte definida do corpo (cintura, coxas e canelas). Na Figura 13 é possível ver os sensores nas respectivas posições do corpo. Devido às quedas realizadas nos testes experimentais, os sensores são colocados na parte de trás do corpo da pessoa, de modo a não danificar os módulos. Exceto na queda para trás, que os sensores são trocados para a parte da frente do corpo (tendo depois atenção na análise dos dados devido ao eixo x e y estarem em sentidos diferentes). Contudo, estes módulos estão protegidos numa caixa improvisada de maneira a estar bem fixos ao corpo – Figura 14. Estes módulos são fixados no corpo da pessoa através de bandas de velcro.

Com estes sensores obtenho a aceleração e os ângulos dos três eixos, sendo necessário posterior filtração dos dados para retirar o ruído.




Figura 11 - Sistema de aquisição cinético




Figura 12 - Módulo sensorial com respetivo eixo.




Figura 13 - Representação dos módulos sensoriais nas respetivas posições do corpo.



*Figura 14 - Caixa adaptada para colocação do sensor.*

### 3.3.2 Procedimento de funcionamento

Primeiro é feita a ligação da base ao computador, são colocadas as antenas e as baterias.

No fim da montagem do sistema, há dois componentes a ter em conta: a configuração da rede (configuração da estação base e nós sensores) e a calibração dos nós sensores. Dentro da pasta do programa Matlab estão os ficheiros de configuração e calibração. No ficheiro de configuração poderá ser alterado pelo utilizador o número da porta COM que está associada à estação base e o número de sensores a serem utilizados. O ficheiro de calibração corresponde aos valores máximos e mínimos das leituras do acelerómetro e magnetómetro. Este ficheiro é alterado pelo utilizador, sendo encontrados os valores por uma aplicação diferente, destinada só à calibração dos sensores. Esta calibração será feita apenas uma vez no local de funcionamento.

No programa Matlab, para calibrar cada sensor, é ligada a estação base e apenas um único sensor a ser calibrado. Depois de encontrar os valores máximos e mínimos do acelerómetro e do magnetómetro, o utilizador altera os valores no ficheiro de calibração, referido anteriormente, procedendo à calibração de outro sensor.

Depois das respetivas alterações necessárias nestes ficheiros, colocam-se os sensores nas respetivas posições do corpo do voluntário, podendo-se seguir para a realização dos testes experimentais.

Para cada teste é necessário o seguinte processo: desligar base; desligar todos os sensores; ligar base; ligar todos os sensores.

### 3.3.3 Limitações

Ao longo do trabalho foi encontrado algumas limitações no sistema de medição inercial, tendo de se ajustar os objetivos inicialmente pré-definidos. A seguir é nomeado essas limitações com respetiva solução para o problema encontrado.

Na realização dos testes experimentais das quedas, as antenas dos sensores tendiam a partir, impossibilitando a continuação dos mesmos. Como eram frágeis teve-se de improvisar uma proteção para os mesmos. Para tal, foi utilizada uma caixinha, como se viu na secção 3.3.1. No entanto foi necessário criar duas aberturas, na parte superior e na inferior, a primeira para a antena e segunda para ter acesso ao botão on/off.

O botão on/off era muito utilizado, tendo em conta que para cada teste era necessário fazer *reset* ao sistema todo. A realização do *reset* provocava muitos atrasos nos testes e incómodo aos voluntários que tinham de estar periodicamente a ligar/desligar cada sensor.

Ocorriam também muitas falhas de transmissão de dados, o que levava à repetição contínua do mesmo teste. Tendo em conta que os voluntários teriam de realizar várias vezes a mesma queda e os sensores poderiam se danificar, não foi uma boa solução. As falhas na receção dos dados poderiam ser de uma até todas as tramas, não conseguindo prever o número de tramas que se perdia.

Os testes experimentais inicialmente iriam consistir na repetição de 5 vezes cada queda e marcha normal, tendo sido ajustado para a repetição de 3 vezes a marcha normal e apenas uma vez cada queda devido aos dois pontos ditos anteriormente.

Contudo, os testes experimentais ainda demoravam em média uma tarde para um máximo de duas pessoas. No entanto, depois na análise dos dados, alguns dados não se conseguiam aproveitar devido a falha de dados no momento da queda.

Com a realização de muitos testes por pessoa, devido a perda de dados, as baterias não tinham autonomia suficiente, sendo estas de pouca duração. Para minimizar a situação, houve a necessidade da aquisição de várias baterias para troca.

Além das limitações dos sensores inerciais referidas anteriormente, nos objetivos inicialmente previstos, as quedas iriam se realizar numa sala acolchoada de modo aos participantes só saberem o tipo de queda que iriam realizar no momento da queda. Esses testes,



mais pormenorizadamente, consistiam no voluntário em linha reta caminhar a sua velocidade de conforto, em determinada altura era dito o tipo de queda e realizavam-na nesse momento. No entanto, como o piso era de colchões, a sua marcha não iria ser tão estável como no piso normal (regular) e havia muito ruído, influenciando assim nos resultados. Desse modo, procedeu-se a realização dos testes como dito na secção 3.1.

### 3.4 Processamento dos dados

Depois da aquisição dos dados do acelerómetro e do giroscópio procede-se ao processamento dos mesmos. Os dados são processados em Matlab e consiste em três algoritmos diferentes. O primeiro é utilizado para preparar os dados, ou seja, serve para retirar a parte inicial dos dados, em que a pessoa ainda está parada, e o primeiro e último passo, que são diferentes dos restantes. Como houve problemas na aquisição dos dados, neste algoritmo procedeu-se a implementação de uma função de sincronização dos dados, em que consistia acrescentar valores nos instantes em que dado sensor falhou, de maneira a cada instante ter dados de cada sensor. No segundo algoritmo são feitos todos os processos necessários para obtenção de cada métrica. Por fim, o terceiro corresponde à redução das dimensões das métricas, em que foi utilizado o *Principal Component Analysis* (PCA). Este algoritmo é explicado na secção 3.5.

#### 3.4.1 Implementação do algoritmo de preparação dos dados

No algoritmo de preparação dos dados é feito o carregamento dos dados, a sincronização e a escolha dos dados importantes. Sendo este o primeiro algoritmo a processar na primeira fase. Na Figura 15 podemos ver em forma de fluxograma em que consiste este algoritmo. Como se pode ver, a primeira etapa é o carregamento dos dados, e este é feito através da função *load()* do Matlab.

A sincronização consiste na verificação de todos os dados de cada sensor ter o mesmo número de sequência (NS) do pacote. Caso não tenha, são acrescentados ou eliminados dados, consoante a falta ou duplicação do número de sequência, respetivamente. Este número é dado pelos dados obtidos do giroscópio na primeira coluna - Figura 16. Os dados obtidos do acelerómetro não contém o NS, no entanto se o tamanho do ficheiro do acelerómetro e



Figura 15 - Fluxograma para a preparação dos dados.

giroscópio tiver o mesmo tamanho, o NS para cada trama dos dados do acelerómetro é igual a trama do giroscópio. O formato da trama dos dados obtidos do acelerómetro pode ser vista na Figura 17.




Figura 16 - Trama dos dados obtidos do giroscópio. *Angles* corresponde ao ângulo obtido do giroscópio.




Figura 17 - Trama dos dados obtidos do acelerómetro. *Acc* corresponde a aceleração.

Na Figura 18 pode ser visto o fluxograma correspondente à função de sincronização. E como se pode ver é comparado o valor de NS com  $j$  (variável com valor que supostamente

deveria ser do NS). Quando faltam dados, para o primeiro é inserido o valor do declive dos dados anteriores, o segundo fica igual a este declive também e o último dado em falta fica com o valor do declive dos próximos dados. Isto acontece porque são recebidas 3 tramas com o mesmo número de sequência, ou seja, cada pacote contém 3 tramas. Quando falta mais que um pacote, as tramas do meio vão ficar com igual valor ao primeiro, sendo este e o último calculado de forma igual a quando se perde um pacote. Esta normalização foi uma solução que se encontrou de forma a conseguir utilizar os dados adquiridos pelos sensores.

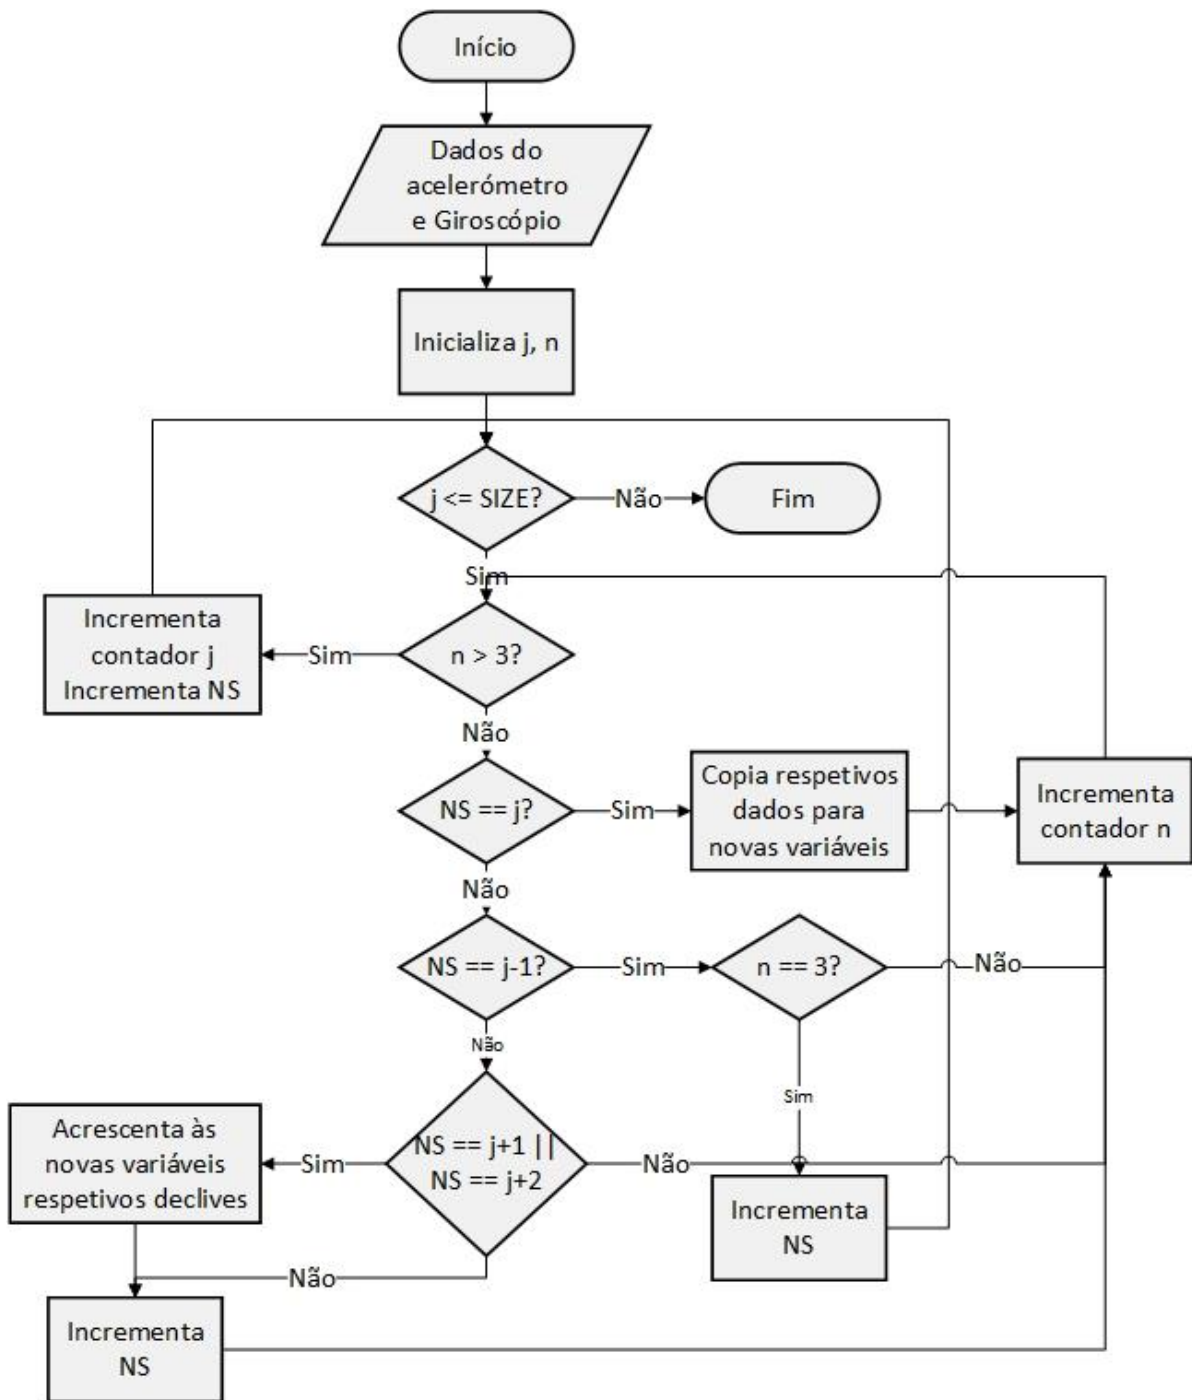


Figura 18 - Fluxograma da função sincronização.

### 3.4.2 Implementação do algoritmo do cálculo das métricas

Para a obtenção de cada métrica foi desenvolvido o algoritmo que está representado no fluxograma da Figura 19.

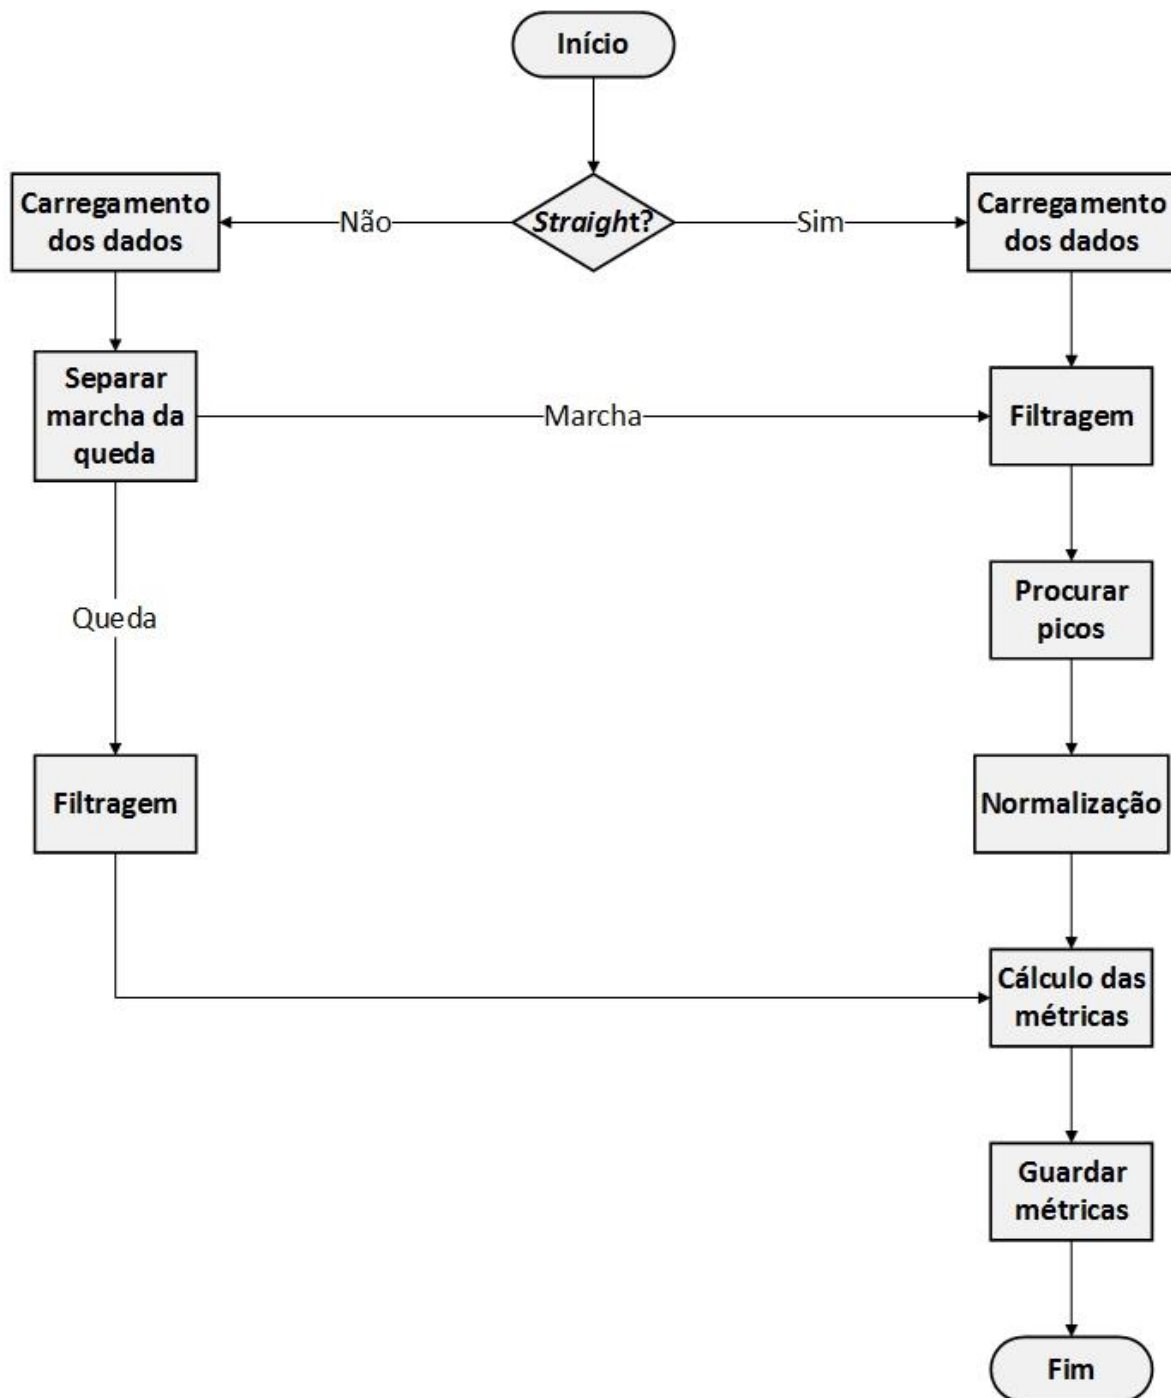


Figura 19 - Fluxograma para o cálculo das métricas. *Straight* corresponde a marcha normal.

A primeira fase de processamento abrange a filtragem dos sinais de aceleração e do giroscópio através da subtração do valor médio do sinal e dum passa-baixo *Butterworth*, 5ª

ordem, com uma frequência de corte de 10 Hz. Esta frequência foi escolhida segundo a que foi encontrado na literatura (0.1 a 10 Hz [7, 22, 14, 41, 42, 25, 47]) e de modo a não eliminar muita informação que poderia ser relevante no cálculo das métricas. Para obtenção de cada passada são encontrados todos os picos da aceleração no eixo AP no sensor da coxa direita (sensor que foi utilizado para selecionar os dados importantes do algoritmo da Figura 15), correspondentes ao HS, através da função *FindPeaks()* do Matlab. Como parâmetros para esta função foi utilizado o *MinPeakheight*, *Threshold* e *MinPeakDistance*, com diferentes valores para cada voluntário. Todos os sinais da aceleração e velocidade angular é dividido em passadas de acordo com os picos encontrados. A normalização reside em todas as passadas terem o mesmo tamanho fazendo uma reamostragem de cada passada para o mesmo número de amostras. Esta normalização serviu para se obter uma única passada com a média de todas elas, de modo a realizar o cálculo das métricas neste sinal. A Figura 20 exhibe as diferentes passadas normalizadas no sinal da aceleração AP no sensor da cintura, com a respetiva média.

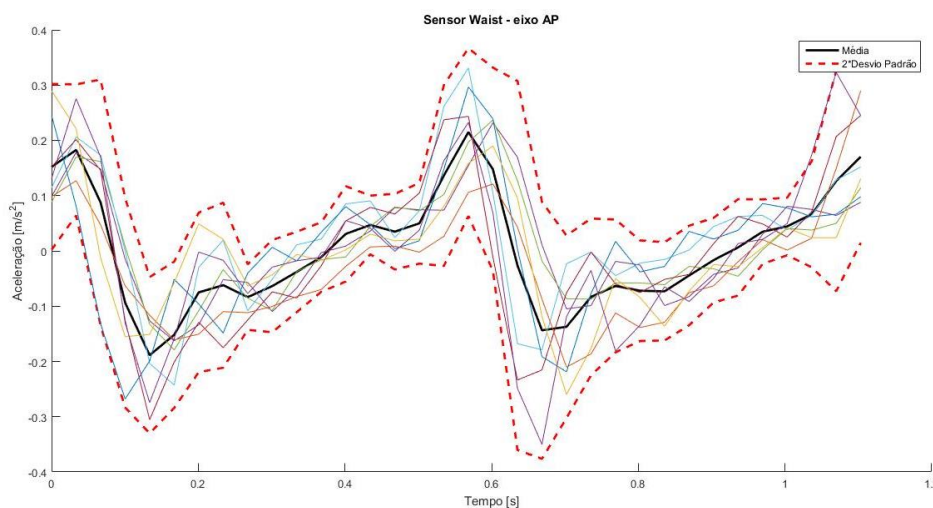


Figura 20 - Apresentação da normalização das passadas no sensor da cintura no eixo AP.

### 3.5 Principal Component Analysis

Após a implementação das métricas é necessário saber quais as que realmente são importantes para a prevenção de uma queda. De modo a reduzir as mesmas, é utilizada uma técnica que consegue distinguir características importantes e, revelar relações que não eram de fácil observação, permitindo interpretações que não se obtinham normalmente. Essa técnica chama-se *Principal Component Analysis (PCA)*.

### 3.5.1 Análise do PCA

A técnica PCA fornece uma transformação característica das características originais dos dados. Tendo como vantagem, depois do PCA ter encontrado padrões nos dados e ter compactado os dados, reduzir o número de dimensões, sem grande perda de informação [57].

O PCA transforma o espaço dos dados originais num conjunto ortogonal de componentes principais (PCs), não estando correlacionados. A direção dos PCs é a mesma da variância máxima nos dados, e os que apresentam valores próprios maiores representam os vetores com variância máxima nos dados [57].

O número de PCs selecionados é calculado mantendo os primeiros PCs que retêm a maior parte da variação de dados, de acordo com dois critérios a seguir indicados. Para selecioná-los foi utilizado o critério de Kaiser que seleciona PCs com valores próprios superiores a um [57].

Após uma análise detalhada do PCA consegue-se reduzir o número de métricas, ficando apenas as mais importantes.

O PCA é uma técnica não supervisionada, por isso, não é garantida que a projeção que maximiza a variação dos dados também o faça para as representações afetadas no espaço das características transformadas. Além disso é uma técnica linear e não considera não-linearidade subjacente.

### 3.5.2 Metodologia

Neste trabalho é estudado a marcha normal e as quedas separadamente, ou seja, um PCA para a marcha normal e outro para as quedas, de modo a saber que métricas caracterizam cada tipo de marcha. A realização de um PCA para cada tipo de queda é interessante para se obter as métricas que caracterizam cada tipo, sendo um objetivo inicialmente. No entanto não foi possível aplicar a todos os tipos de queda devido aos poucos dados que se tem para cada tipo de queda, mas é aplicado a um tipo de queda que tem maior número de dados (*fall slip* - Tabela 2), de modo a se perceber a análise feita para estes casos. Assim com um PCA para todas as quedas consegue-se as métricas que em geral caracterizam todas as quedas neste trabalho.

O primeiro passo para a implementação do PCA é a criação da matriz, observações por parâmetros. As observações são os testes experimentais realizados com 6 pessoas, em que cada uma tem 6 diferentes testes (marcha normal, queda para a frente, para trás, de joelhos, lateral e escorregar). No entanto alguns testes não poderão ser aproveitados, pois ocorreram erros na

aquisição de dados, obtendo-se no total 24 testes experimentais, ou seja, 6 testes de marcha normal (uma por pessoa) e 18 testes de quedas. De forma a tornar claro, na Tabela 2 está representado os 24 testes experimentais, onde mostra para cada tipo de marcha os voluntários que se conseguiu aproveitar os dados, ou seja, a queda para a frente (*Fall frontal*) está representada pelo voluntário 3, 4 e 6.

Tabela 2 - Representação de cada tipo de marcha com respectivos voluntários.

<i>Tipo de Marcha</i>	<i>Voluntário</i>
Straight	1, 2, 3, 4, 5 e 6
Fall frontal	3, 4 e 6
Fall side	2, 3, 5 e 6
Fall slip	1, 2, 3, 4 e 6
Fall knee	2, 4 e 5
Fall back	2, 5 e 6

Quanto aos parâmetros da matriz devido ao grande número de métricas e poucas observações é aplicado primeiro o teste *t-student* Para aplicação deste teste é utilizado a função *ttest2()* do Matlab, tendo como parâmetros a matriz da marcha normal e das quedas. O teste *t-student* compara as duas matrizes, nomeadamente vetor a vetor de cada matriz e devolve 1 se as médias não são iguais no nível de significância de 5% e 0 caso contrário. Assim as métricas com resultado 1 no teste *t-student* significa que tem valores muito diferentes para a marcha normal e quedas.

Neste trabalho foram aplicados PCAs a diferentes situações, tendo como separações métricas não-temporais e temporais. As métricas temporais são as que variam ao longo do tempo, correspondendo a um vetor de dados. Já as não-temporais correspondem a um único valor, correspondendo às métricas calculadas sobre o sinal médio obtido no fim da normalização correspondente a uma passada - Figura 20.

Dentro dessa separação, cada uma possui cinco posições diferentes de sensores, e testes de marcha normal e quedas, ou seja, para os temporais temos 10 PCAs (marcha normal para as cinco posições e quedas para as mesmas posições) e os não-temporais temos os mesmos, no total obtém-se 20 PCAs. Os não-temporais vão ter uma matriz de 6 observações por 18 variáveis (depois da aplicação do teste *t-student*).

Para os PCAs das métricas temporais é de difícil análise devido a cada métrica ser constituída por um vetor de dados que correspondem a cada instante de tempo. Assim se



considerarmos cada instante de tempo como fosse uma métrica nova, conseguia-se saber quais os instantes mais importantes para a prevenção de uma queda, no entanto iria ter um grande número de parâmetros na matriz da aplicação do PCA. Por outro lado, poderia ser considerado cada instante de tempo uma nova observação e assim conseguia-se um grande número de observações. No entanto as observações vão variar muito entre si.

Antes da aplicação dos PCAs é necessário proceder à normalização dos dados porque os dados têm magnitudes muito diferentes (médias e desvios-padrões diferentes). Portanto para a normalização é utilizada a função *zscore()* do Matlab, em que cada coluna da matriz de saída dessa função tem média 0 e desvio padrão 1.

Todas as matrizes para aplicação do PCA estão apresentadas no Anexo III. No entanto de modo a se perceber melhor a análise feita para as métricas não-temporais é mostrado na Tabela 3 e Tabela 4 as matrizes a serem aplicadas no PCA para o sensor da cintura (matrizes normalizadas).

Para selecionar o número de componentes principais é utilizado o critério de teste de *Cattell's Scree*, que avalia os pontos de inflexão do *scree plot* para saber os componentes principais que conseguem uma maior variação [60]. De modo a se perceber melhor este método, na Figura 21 está representado um *scree plot*, sendo neste caso escolhido o PC4 por apresentar um maior ponto de inflexão e pode-se ver que ao passar uma reta tangencial no PC4, os seguintes PCs não variam muito daquela reta [60].

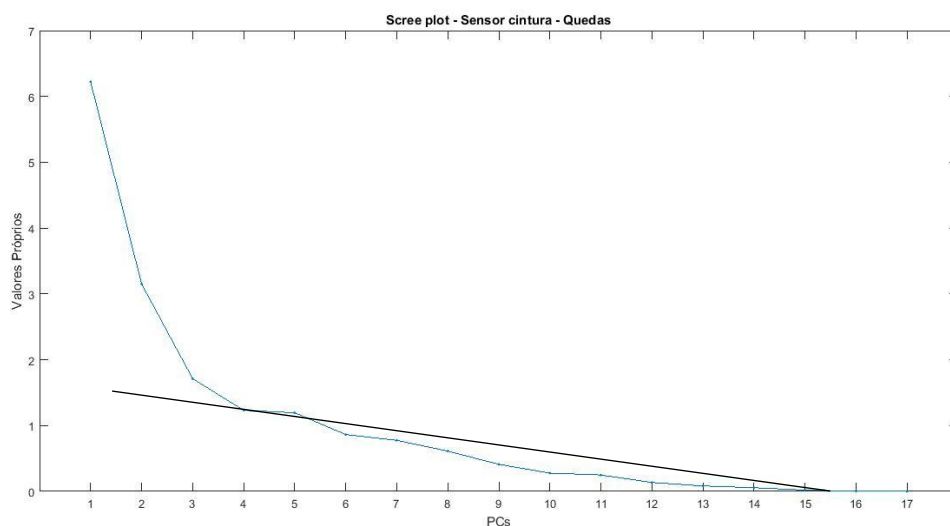


Figura 21 - Representação do *scree plot* do PCA do sensor da cintura nas quedas e de uma reta tangencial ao maior ponto de inflexão.

Tabela 3 - Matriz para marcha normal no sensor da cintura para aplicação do PCA.

	<i>HRV</i>	<i>SMA</i>	<i>EAP</i>	<i>EML</i>	<i>EV</i>	<i>aMaxAP</i>	<i>aMaxML</i>	<i>aMaxV</i>	<i>aMinAP</i>	<i>aMinML</i>	<i>aMinV</i>	<i>aMinRIAP</i>	<i>aMinRIML</i>	<i>aMinRIV</i>	<i>PPvRIAP</i>	<i>PPvRIML</i>	<i>PPvRIV</i>
<b>V1</b>	-0,320	-0,109	-0,670	-0,667	-0,625	-0,679	-1,296	-0,564	1,284	0,404	0,635	-0,323	1,429	0,319	0,335	-0,431	-0,359
<b>V2</b>	-0,398	1,299	1,992	1,953	1,145	1,360	1,255	1,464	-0,851	0,017	-0,963	-0,160	-0,751	-0,588	0,641	-0,338	1,855
<b>V3</b>	2,011	-1,296	-0,293	0,127	-0,659	-0,907	0,059	-0,758	-0,310	-1,968	0,597	-0,691	0,672	-0,279	-0,063	-0,401	-0,022
<b>V4</b>	-0,701	1,031	-0,042	-0,275	1,427	1,164	0,983	1,094	-0,257	0,236	-1,566	0,013	0,024	1,857	-0,337	-0,466	-0,712
<b>V5</b>	-0,181	-0,715	-0,433	-0,613	-0,631	-0,282	-0,130	-0,603	-1,041	0,496	0,557	-0,784	-1,393	-0,361	-1,736	2,039	-0,943
<b>V6</b>	-0,411	-0,210	-0,555	-0,524	-0,658	-0,656	-0,872	-0,635	1,175	0,815	0,740	1,944	0,020	-0,948	1,160	-0,403	0,181

Tabela 4 - Matriz para as quedas do sensor da cintura para aplicação do PCA.

	<i>HRV</i>	<i>SMA</i>	<i>EAP</i>	<i>EML</i>	<i>EV</i>	<i>aMaxAP</i>	<i>aMaxML</i>	<i>aMaxV</i>	<i>aMinAP</i>	<i>aMinML</i>	<i>aMinV</i>	<i>aMinRIAP</i>	<i>aMinRIML</i>	<i>aMinRIV</i>	<i>PPvRIAP</i>	<i>PPvRIML</i>	<i>PPvRIV</i>
<b>V1 FS</b>	2,398	-0,964	-0,862	1,409	-0,146	-1,343	0,077	0,886	-0,145	0,396	0,009	2,708	-0,811	-0,856	0,189	-0,788	-1,350
<b>V2 FSI</b>	0,321	1,920	2,784	2,367	0,945	1,009	3,021	1,945	-2,006	-1,175	-1,779	-0,126	-0,657	-0,483	1,279	0,320	0,994
<b>V2 FS</b>	1,724	1,991	0,055	0,678	1,222	0,404	0,718	0,270	-1,517	-2,514	-0,327	-0,307	-1,132	0,147	2,572	-0,042	2,685
<b>V2 FK</b>	0,529	0,572	-0,590	-1,242	-0,720	-0,132	0,218	0,455	-0,778	-0,485	-1,085	-0,080	0,801	-0,540	0,664	-0,596	0,585
<b>V2 FB</b>	-0,446	1,482	2,280	-0,285	0,707	1,694	1,439	0,216	-1,642	-1,578	-0,544	-1,116	0,510	1,647	0,598	1,308	-1,146
<b>V3 FF</b>	-1,114	-0,324	-0,540	-0,817	0,510	-0,875	0,413	0,749	0,568	-0,757	0,197	-0,495	-0,334	-0,172	-0,393	0,014	0,377
<b>V3 FSI</b>	-0,205	-1,005	0,048	-0,847	-1,366	-1,039	-0,906	-0,843	0,057	-0,135	1,348	-0,305	0,565	-0,854	-1,337	-0,968	-0,484
<b>V3 FS</b>	0,392	0,044	-0,664	0,144	-0,002	-0,599	-0,758	0,199	-0,261	-0,441	0,529	-0,659	-0,127	-0,958	-0,915	-1,321	-0,883
<b>V4 FF</b>	-1,325	0,406	-0,505	-0,041	-0,933	1,959	0,046	0,003	0,731	0,239	-0,979	-0,782	-0,826	-0,450	0,351	0,096	0,751
<b>V4 FS</b>	-0,748	-1,410	-0,465	-1,435	-1,163	-1,413	-0,761	-1,577	0,749	1,408	0,867	1,626	0,761	0,718	-0,600	-0,976	-0,866
<b>V4 FK</b>	-0,194	-0,120	0,010	0,824	-0,749	-0,633	-0,709	-0,851	-0,530	1,090	0,018	1,600	1,764	-1,107	1,191	-1,119	0,720
<b>V5 FSI</b>	-0,348	-0,148	-0,699	-1,129	1,387	0,066	-1,022	-0,024	-0,341	0,767	-0,287	-0,428	-1,052	-0,595	-0,612	-0,159	-0,226
<b>V5 FK</b>	-0,247	-0,167	-0,691	-0,277	1,571	0,015	-0,674	0,119	-0,041	0,508	0,097	-0,629	-0,743	0,871	-1,141	0,855	-0,718
<b>V5 FB</b>	-1,089	0,061	0,231	-0,514	-0,853	0,198	0,119	-1,380	0,820	0,271	-1,802	-0,522	-0,737	1,327	-0,939	1,798	-0,707
<b>V6 FF</b>	1,183	-0,886	-0,137	0,308	-1,166	0,073	-0,940	-0,293	1,124	0,735	1,106	0,320	-0,517	-1,172	-0,086	-1,135	-0,736
<b>V6 FSI</b>	0,501	-1,310	-0,651	-0,147	0,889	-0,944	-0,071	-0,427	0,825	0,472	1,502	0,101	-0,208	0,582	0,268	1,722	0,314
<b>V6 FS</b>	-0,677	0,089	0,525	-0,188	0,765	0,266	0,178	1,895	1,156	0,634	-0,122	-0,037	0,224	-0,280	-0,484	-0,043	-0,097
<b>V6 FB</b>	-0,654	-0,232	-0,128	1,191	-0,897	1,294	-0,388	-1,344	1,230	0,565	1,255	-0,868	2,518	2,174	-0,605	1,034	0,788

## CAPÍTULO 4

### 4 RESULTADOS E DISCUSSÃO

Este capítulo dedica-se à apresentação dos resultados obtidos neste trabalho, mostrando a análise feita ao PCA e respetiva discussão. Só serão apresentados os resultados relativos a um dos sensores inerciais, servindo de exemplo de interpretação para os restantes.

Inicialmente, são analisado detalhadamente os PCAs (da marcha normal e das quedas) do sensor na cintura para as métricas não-temporais, de modo a se perceber todos os passos que serão feitos na análise. Esta análise vai servir de exemplo para toda as análises dos PCAs.

Além disso, é aplicado o PCA para a marcha normal com *fall slip*, de modo a identificar as métricas para prevenção desta queda e servir de exemplo para análise de outras possíveis quedas.

#### 4.1 Teste *t-student*

Para o caso da marcha normal e das quedas, na Tabela 5 está representado as médias das métricas da marcha normal e das quedas com respetiva diferença das médias, e resultado do teste *t-student* é mostrado na Tabela 6, onde *h* retorna a decisão do teste para o sensor da cintura, *h\_R* para o sensor da coxa direita, *h\_R1* corresponde ao sensor da canela direita, *h\_L* ao sensor da coxa esquerda e *h\_L1* ao sensor da canela esquerda.

Como métricas para aplicar ao PCA são as que retornaram pelo menos 1 num dos sensores, ou seja, HRV, SMA, EAP, EML, EV, aMaxAP, aMaxML, aMaxV, aMinAP, aMinML, aMinV, aMinRIAP, aMinRIML, aMinRIV, PPvRIAP, PPvRIML e PPvRIV.

Para a marcha normal com *fall slip* o resultado do teste *t-student* é mostrado na Tabela 7, sendo as métricas para aplicação do PCA as que retornaram pelo menos 1 num dos sensores.

Assim, no fim da aplicação do teste *t-student* obtém-se um número inferior de métricas conseguindo obter melhores resultados através do PCA.

Tabela 5 - Médias para cada métrica com respectiva diferença entre as médias de cada tipo de marcha.

	HRAP	HRML	HRV	SMA	EAP	EML	EV	STDCAP	STDCML	STDCV	aMaxAP	aMaxML	aMaxV	aMinAP	aMinML	aMinV	aMinRIAP	aMinRIML	aMinRIV	PPvAP	PPvML	PPvV	PPvRIAP	PPvRIML	PPvRIV	PowerAP	PowerML	PowerV
<i>Straight</i>	0,457	1,555	0,384	8,767	17,63	18,824	265,195	0,182	0,184	0,558	4,667	3,669	7,485	0,433	0,488	0,955	-0,624	-0,567	-0,724	2,517	1,241	1,027	11635,5	1963,63	17788,3	1,155	0,995	1,078
<i>Quedas</i>	0,764	1,545	0,793	13,44	7,14	4,821	9,967	0,255	0,223	0,317	10,163	11,009	15,325	0,314	0,321	0,489	-0,268	-0,306	-0,355	1,759	1,106	0,942	7371,61	793,006	11591,7	0,833	0,896	1,225
<i>Diferença</i>	-0,307	0,01	-0,409	-4,673	10,49	14,003	255,228	-0,073	-0,039	0,241	-5,496	-7,34	-7,84	0,119	0,167	0,466	-0,356	-0,261	-0,369	0,758	0,135	0,085	4263,89	1170,63	6196,67	0,322	0,099	-0,147

Tabela 6 - Resultado da aplicação do teste *t-student*.

	HRAP	HRML	HRV	SMA	EAP	EML	EV	STDCAP	STDCML	STDCV	aMaxAP	aMaxML	aMaxV	aMinAP	aMinML	aMinV	aMinRIAP	aMinRIML	aMinRIV	PPvAP	PPvML	PPvV	PPvRIAP	PPvRIML	PPvRIV	PowerAP	PowerML	PowerV
<i>h</i>	0	0	1	1	1	1	1	0	0	0	1	1	1	0	1	1	1	1	1	0	0	0	1	1	1	0	0	0
<i>h_L</i>	0	0	0	1	1	1	1	0	0	0	1	1	1	1	1	1	1	1	0	0	0	0	1	1	1	0	0	0
<i>h_L1</i>	0	0	0	1	0	1	0	0	0	0	1	1	1	1	1	1	1	1	1	0	0	0	1	1	1	0	0	0
<i>h_R</i>	0	0	0	1	1	1	1	0	0	0	0	0	1	1	1	1	1	1	1	0	0	0	0	1	1	0	0	0
<i>h_R1</i>	0	0	0	1	1	1	1	0	0	0	1	1	1	1	1	0	1	0	1	0	0	0	1	1	1	0	0	0

Tabela 7 - Resultado do teste *t-student* para a marcha normal com *fall slip*.

	HRAP	HRML	HRV	SMA	EAP	EML	EV	STDCAP	STDCML	STDCV	aMaxAP	aMaxML	aMaxV	aMinAP	aMinML	aMinV	aMinRIAP	aMinRIML	aMinRIV	PPvAP	PPvML	PPvV	PPvRIAP	PPvRIML	PPvRIV	PowerAP	PowerML	PowerV
<i>h</i>	0	0	1	0	0	0	0	0	0	0	0	1	1	1	1	0	1	0	0	0	0	0	0	0	0	0	0	0
<i>h_L</i>	0	0	0	1	0	0	0	0	0	0	1	1	1	0	0	1	0	1	0	0	0	0	1	1	1	0	0	0
<i>h_L1</i>	0	0	0	1	0	0	0	0	0	0	1	0	1	0	0	0	1	0	0	0	0	0	0	1	1	0	0	0
<i>h_R</i>	1	0	0	0	1	0	1	0	0	0	0	0	1	0	0	0	1	0	1	0	0	0	0	1	1	0	0	0
<i>h_R1</i>	0	0	0	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0

## 4.2 Análise da marcha normal

Inicialmente é necessário determinar o número de componentes principais a analisar. Um método para determinar esse número é o teste de *Cattell's Scree* [57], como se viu no capítulo anterior. O *scree plot* para este exemplo é mostrado na Figura 22, em que aparecem dois pontos de inflexão: um no segundo e outro no quarto componente principal. Por outro lado, a Tabela 8 mostra que cerca de 45.5% da variação total é explicada pelo primeiro componente, 67% pelos dois primeiros componentes, 84% pelos três primeiros componentes principais e 97% pelos quatro últimos. Posto isto, como o quarto componente principal é um ponto de inflexão e representa 97% da variação total são escolhidos os quatro primeiros componentes principais.




Figura 22 - Representação dos valores próprios em *scree plot* no sensor da cintura na marcha normal.

Componentes	Valores Próprios	% de variância	Variância cumulativa (%)
PC1	7,731	45,474	45,474
PC2	3,625	21,321	66,794
PC3	2,918	17,162	83,956
PC4	2,183	12,843	96,799
PC5	0,544	3,200	100

Tabela 8 - Variações dos componentes principais no sensor da cintura na marcha normal.

Os coeficientes dos quatro primeiros componentes principais para cada métrica estão representados na Tabela 8. Os valores a negrito são as métricas mais relevantes para cada PC que caracterizam a marcha normal tendo como critério de seleção os coeficientes em valor absoluto serem menores que 0.2. Nesta situação específica, como são dados apenas de marcha normal, as métricas com valor absoluto maior que 0.2 são as que apresentam maior peso de correlação não sendo assim relevantes para caracterizar a marcha.

Tabela 9 - Coeficientes dos componentes principais no sensor da cintura na marcha normal.

	<b>PC1</b>	<b>PC2</b>	<b>PC3</b>	<b>PC4</b>
<b>HRV</b>	<b>-0,147</b>	<b>-0,153</b>	-0,452	0,235
<b>SMA</b>	0,319	<b>0,173</b>	<b>0,176</b>	<b>-0,015</b>
<b>EAP</b>	0,314	<b>0,009</b>	-0,232	<b>-0,162</b>
<b>EML</b>	0,278	<b>0,023</b>	-0,347	<b>-0,124</b>
<b>EV</b>	0,342	<b>0,023</b>	<b>0,101</b>	<b>0,159</b>
<b>aMaxAP</b>	0,353	<b>-0,022</b>	<b>0,112</b>	<b>0,015</b>
<b>aMaxML</b>	0,320	<b>-0,173</b>	<b>-0,097</b>	<b>0,084</b>
<b>aMaxV</b>	0,356	<b>0,040</b>	<b>0,048</b>	<b>0,058</b>
<b>aMinAP</b>	<b>-0,188</b>	0,428	<b>0,118</b>	<b>0,069</b>
<b>aMinML</b>	<b>0,037</b>	<b>0,150</b>	0,458	-0,355
<b>aMinV</b>	-0,330	<b>0,009</b>	<b>-0,130</b>	-0,209
<b>aMinRIAP</b>	<b>-0,030</b>	0,394	<b>0,117</b>	-0,252
<b>aMinRIML</b>	<b>-0,148</b>	0,300	<b>-0,078</b>	0,438
<b>aMinRIV</b>	<b>0,109</b>	<b>-0,049</b>	0,323	0,522
<b>PPvRIAP</b>	<b>0,039</b>	0,493	<b>-0,183</b>	<b>-0,039</b>
<b>PPvRIML</b>	<b>-0,076</b>	-0,418	<b>0,165</b>	-0,328
<b>PPvRIV</b>	0,207	0,204	-0,361	-0,235

Para analisar as métricas que anteriormente foram determinadas como relevantes para cada PC, de modo a obter as que melhor caracterizam a marcha normal, é verificado a percentagem para cada métrica da variação explicada do conjunto dos componentes principais. Para verificar essa percentagem recorre-se a Tabela 9 e a Tabela 8, obtendo-se a Tabela 10. Assim, as métricas que apresentarem maior percentagem são as que explicam melhor a relevância de cada métrica para a marcha normal. Assim a que caracteriza melhor a marcha é aMinRIV, sendo a seguir PPvRIAP e aMinAP. Ainda com aproximadamente 67 % o HRV, aMinML, aMinRIAP, aMinRIML e PPvRIML. Para SMA, EV, aMaxAP, aMaxML e aMaxV apresentam 51 %, no entanto, de modo a obter as que caracterizam melhor a marcha normal, estas já não são consideradas, sendo o número de métricas iniciais reduzido para metade. Ou seja, as métricas encontradas que caracterizam a marcha normal são aMinRIV, PPvRIAP, aMinAP, HRV, aMinML, aMinRIAP, aMinRIML e PPvRIML.

Tabela 10 – Percentagem da variância total para cada métrica da combinação dos componentes principais.

	<b>PCs</b>	<b>Variação (%)</b>
<b>HRV</b>	PC1/PC2	66,794
<b>SMA</b>	PC2/PC3/PC4	51,326
<b>EAP</b>	PC2/PC4	34,164
<b>EML</b>	PC2/PC4	34,164
<b>EV</b>	PC2/PC3/PC4	51,326
<b>aMaxAP</b>	PC2/PC3/PC4	51,326
<b>aMaxML</b>	PC2/PC3/PC4	51,326
<b>aMaxV</b>	PC2/PC3/PC4	51,326
<b>aMinAP</b>	PC1/PC3/PC4	75,479
<b>aMinML</b>	PC1/PC2	66,794
<b>aMinV</b>	PC2/PC3	38,483
<b>aMinRIAP</b>	PC1/PC3	62,636
<b>aMinRIML</b>	PC1/PC3	62,636
<b>aMinRIV</b>	PC1/PC2/PC3	83,956
<b>PPvRIAP</b>	PC1/PC3/PC4	75,479
<b>PPvRIML</b>	PC1/PC3	62,636

De uma forma a visualizar melhor os coeficientes dos PCs são representados nos biplots que se seguem (Figura 23). No entanto, devido ao número de PCs foram apenas escolhidos os biplots mais representativos (com as métricas que apresentam uma maior variação). Na Tabela 11 é apresentado a variação para cada combinação. Assim é analisado os biplots de PC1-PC2, PC1-PC3 e PC1-PC4.

Tabela 11 - Variação para cada combinação dos componentes principais no sensor da cintura na marcha normal.

<b>PCs</b>	<b>Variação (%)</b>
PC1 e PC2	66.79
PC1 e PC3	62.64
PC1 e PC4	58.32
PC2 e PC3	38.48
PC2 e PC4	34.16
PC3 e PC4	30



Como se pode verificar na Figura 23, para o PC1 e PC2 algumas métricas estão agrupadas, com um ângulo pequeno entre elas, que indica uma maior correlação, e que leva a perceber que estas tendem a variar mais ou menos da mesma maneira, ou seja, têm o mesmo comportamento (por exemplo, se o valor de uma aumentar, a outra também aumenta), conseguindo-se reduzir as métricas. Assim, as métricas agrupadas são aMaxV, EML, EV, EAP e aMaxAP, sendo representadas por aMaxV (a que contém maior magnitude), de seguida tem-se aMinRIV e aMaxML, exibidas por aMaxML, PPvRIV e SMA, aMinRIAP e PPvRIAP, e por último temos aMinRIML e aMinAP, tendo sido escolhida para estes últimos grupos a última métrica como representante de cada grupo. Outra possível análise é verificar se determinadas métricas se comportam de forma oposta, por exemplo, PPvRIV e HRV estão em quadrantes opostos, sendo assim simétricos - se uma aumentar a outra diminui.

Além disso, na Figura 23, Figura 24 e Figura 25 está representado a cinzento uma circunferência (coincidente no valor 0.2 definido anteriormente) que foi inserida unicamente para uma melhor análise. Assim, as métricas que estão dentro dessa circunferência são as que tem uma menor variação, sendo que quanto menor o comprimento da linha menor será a variação. Com a análise nas figuras seguintes dos biplots, obtem-se HRV, aMinML, aMinRIV, PPvRIML, aMinRIAP, PPvRIAP, aMinRIML e aMinAP, confirmando o método anterior, pois obteve-se as mesmas métricas. Assim, para os próximos PCAs é analisado os biplots que estão apresentados no Anexo IV para a marcha normal e no Anexo V para as quedas. E os *scree plots* para a determinação dos PCs estão no Anexo VI para a marcha normal e quedas.




Figura 23 - Representação dos coeficientes e dos scores do 1º e 2º componente através do biplot no sensor 4 na marcha normal.




Figura 24 - Representação dos coeficientes e dos scores do 1º e 3º componente através do biplot no sensor 4 na marcha normal.

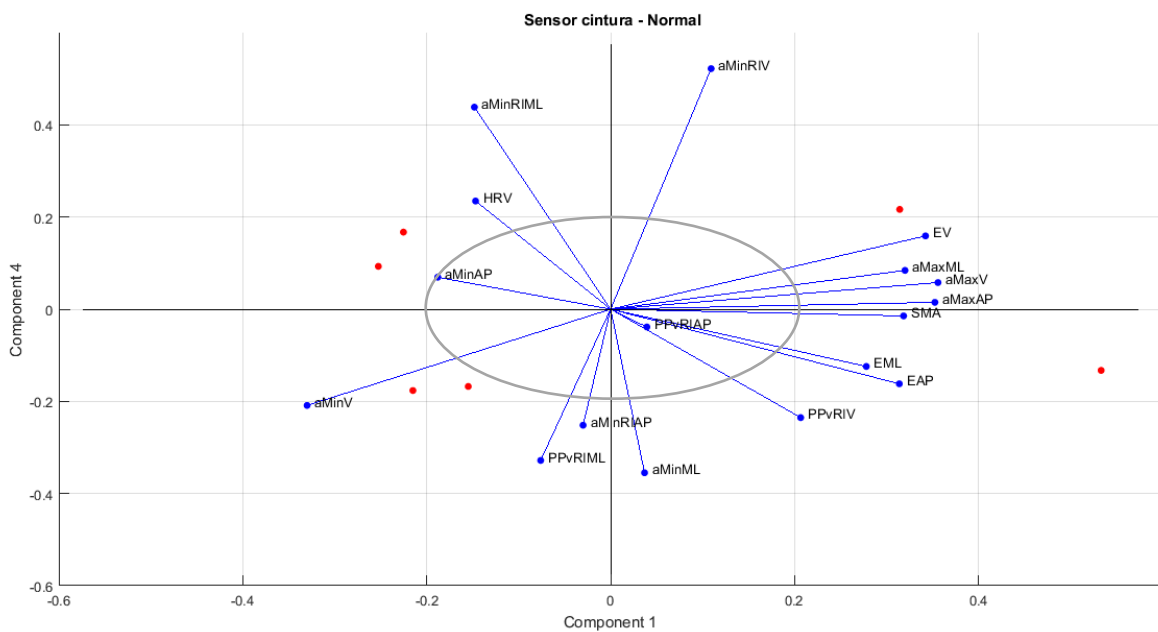


Figura 25 - Representação dos coeficientes e dos scores do 1º e 4º componente através do biplot no sensor 4 na marcha normal.

No caso dos restantes sensores, a análise dos resultados é feita de forma idêntica à descrita anteriormente. Assim para a coxa direita, as métricas que caracterizam a marcha são aMaxAP, aMinRIML, HRV e EAP. No entanto para a coxa esquerda tem-se aMinRIV, aMinRIML e aMaxV. Como a posição do sensor para as coxas é a mesma, estes resultados não

vão de encontro ao esperado, pois o ciclo da marcha é igual em ambas as pernas, e seria espectável que as métricas para caracterizar a marcha fossem as mesmas. Ao incluir todas estas métricas (junção da coxa direita com a esquerda), obtêm-se aMaxAP, aMinRIML, HRV, EAP, aMinRIV e aMaxV.

Para a canela esquerda tem-se aMaxAP, HRV e aMaxV. Contudo para a canela direita tem-se HRV, EML, aMaxML, aMinRIAP, aMinV, PPvRIV e aMinML. Aqui surge a mesma situação que no caso anterior, ou seja, para as canelas a marcha normal é caracterizada por aMaxAP, HRV, aMaxV, EML, aMaxML, aMinRIAP, aMinV, PPvRIV e aMinML.

### 4.3 Análise das quedas

No caso das quedas, o método de análise é similar ao da marcha normal, contudo os PCs apresentam menos explicabilidade como se pode ver, por exemplo, na Tabela 12, para o sensor da cintura. Isso sucede devido a matriz aplicada no PCA ser constituída por diferentes tipos de quedas e haverem poucas observações para cada tipo de queda.

Tabela 12 - Variações dos componentes principais nas quedas para o sensor da cintura.

Componentes	Valores Próprios	% de variância	Variância cumulativa (%)
PC1	6,224	36,610	36,610
PC2	3,151	18,535	55,145
PC3	1,712	10,071	65,216
PC4	1,232	7,249	72,465
PC5	1,194	7,024	79,489

No fim da análise para o sensor da cintura como métricas que caracterizam as quedas obteve-se aMinRIML, aMinV, HRV, PPvRIML e aMinRIV. No sensor da coxa direita tem-se aMinRIML, aMaxV, aMinRIV e EV. O sensor da coxa esquerda apresenta aMinRIML, EAP, aMaxV e HRV, obtendo-se assim para as coxas aMinRIML, aMaxV, aMinRIV, EV, EAP e HRV. Para as canelas, pelo mesmo método das coxas, obtêm-se SMA, aMinRIML, EML, aMinRIAP, aMinAP, aMinML, PPvRIML, aMinV, PPvRIV e aMinRIV.

#### 4.4 Comparação da análise da marcha normal com as quedas

Na Tabela 13 está apresentado um resumo das métricas que caracterizam cada tipo de marcha. Após uma análise pode-se verificar que para determinada posição em cada tipo de marcha, algumas métricas repetem-se. Isto significa que as métricas repetidas caracterizam a marcha normal e as quedas. Como antes da aplicação do PCA foi aplicado o teste *t-student*, em que se obtém as métricas que melhor se distinguem para cada tipo de marcha, as métricas obtidas que caracterizam ambos os tipos de marcha são as que melhor previnem as quedas. Assim, na Tabela 13 são apresentadas as métricas para a prevenção das quedas.

Tabela 13 – Resumo das métricas que caracterizam cada tipo de marcha.

Marcha Normal			Quedas		
Cintura	Coxas	Canelas	Cintura	Coxas	Canelas
HRV	HRV	HRV	HRV	HRV	SMA
aMinAP	EAP	EML	aMinV	EAP	EML
aMinML	aMaxAP	aMaxAP	aMinRIML	EV	aMinAP
aMinRIAP	aMaxV	aMaxML	aMinRIV	aMaxV	aMinML
aMinRIML	aMinRIML	aMaxV	PPvRIML	aMinRIML	aMinV
aMinRIV	aMinRIV	aMinML		aMinRIV	aMinRIAP
PPvRIAP		aMinV			aMinRIML
PPvRIML		aMinRIAP			PPvRIML
		PPvRIV			PPvRIV

Tabela 14 -Métricas relevantes para a prevenção das quedas.

Cintura	Coxas	Canelas
HRV	HRV	EML
aMinRIML	EAP	aMinML
aMinRIV	aMaxV	aMinV
PPvRIML	aMinRIML	aMinRIAP
	aMinRIV	PPvRIV

#### 4.5 Análise do PCA da marcha normal com *fall slip*

Além de conseguir prever as quedas é também importante prever um determinado tipo de queda específico, de modo a poder tomar ação preventiva específica para cada queda. No

entanto devido à pouca quantidade de dados, apenas possível fazer este tipo de análise para a marcha normal com *fall slip* (queda que tem maior número de dados).

Para esta análise é exposto como exemplo a análise detalhada para o sensor da cintura. Contudo é mencionado os resultados das restantes análises. No Anexo III está representado a matriz que é aplicada a este PCA, no Anexo VII encontra-se os biplots resultantes do PCA e para saber o número de PCs está no Anexo VIII os *scree plots*.

Iniciando pela análise da cintura, através da Figura 26 e da Tabela 15 verifica-se que são selecionados 4 PCs (mesmo método de seleção do exemplo anterior).

Tabela 15 - Variações dos componentes principais para análise da marcha normal com *fall slip* no sensor da cintura.

<b>Componentes</b>	<b>Valores Próprios</b>	<b>% de variância</b>	<b>Variância cumulativa (%)</b>
PC1	6.621	38.947	38.947
PC2	3.683	21.664	60.611
PC3	1.934	11.375	71.986
PC4	1.280	7.531	79.517




Figura 26 - Representação dos valores próprios em *scree plot* para análise da marcha normal com *fall slip* no sensor da cintura.

Nesta análise é de realçar que as métricas importantes são aquelas que têm maior variação, pois são as que distinguem melhor a marcha normal da queda em questão. Na Tabela 16 estão representadas a negrito as identificadas para cada PC, tendo como critério de seleção os coeficientes em valor absoluto maiores que 0.2.

Tabela 16 - Representação dos coeficientes dos componentes principais no sensor da cintura para a marcha normal com *fall slip*.

	<b>PC1</b>	<b>PC2</b>	<b>PC3</b>	<b>PC4</b>
<b>HRAP</b>	0,024	<b>0,449</b>	-0,004	<b>-0,226</b>
<b>HRV</b>	-0,189	<b>0,360</b>	0,055	-0,130
<b>SMA</b>	0,057	<b>0,441</b>	<b>-0,205</b>	-0,166
<b>EAP</b>	<b>0,335</b>	0,011	-0,039	0,066
<b>EV</b>	<b>0,343</b>	-0,057	<b>-0,288</b>	-0,127
<b>aMaxAP</b>	<b>0,367</b>	0,000	0,038	0,060
<b>aMaxML</b>	<b>0,371</b>	0,035	0,079	-0,011
<b>aMaxV</b>	<b>0,341</b>	0,012	<b>-0,272</b>	-0,160
<b>aMinAP</b>	<b>-0,308</b>	0,100	<b>-0,354</b>	0,020
<b>aMinML</b>	-0,176	-0,066	<b>-0,436</b>	<b>-0,259</b>
<b>aMinV</b>	<b>-0,347</b>	0,049	<b>0,247</b>	0,149
<b>aMinRIAP</b>	-0,099	-0,051	<b>-0,389</b>	<b>0,484</b>
<b>aMinRIML</b>	-0,010	<b>-0,411</b>	-0,104	<b>0,208</b>
<b>aMinRIV</b>	0,165	-0,158	-0,159	-0,017
<b>PPvRIAP</b>	0,133	<b>0,285</b>	-0,028	<b>0,642</b>
<b>PPvRIML</b>	0,155	-0,060	<b>0,474</b>	-0,051
<b>PPvRIV</b>	0,134	<b>0,414</b>	0,001	<b>0,269</b>

Para determinar as métricas que são relevantes para prever a queda é analisada a percentagem da variação explicada pelo conjunto dos componentes principais para cada métrica (Tabela 17). Assim obtém-se a EAP, EV, aMaxAP, aMaxML, aMaxV, aMinAP e aMinV.

Tabela 17 - Percentagem da variância total para cada métrica da combinação dos componentes principais para a marcha normal com *fall slip*.

	<b>PCs</b>	<b>Varição (%)</b>
<b>HRAP</b>	PC2/PC4	29.195
<b>HRV</b>	PC2	21.664
<b>SMA</b>	PC2/PC3	33.040
<b>EAP</b>	PC1	38.947
<b>EV</b>	PC1/PC3	50.322
<b>aMaxAP</b>	PC1	38.947
<b>aMaxML</b>	PC1	38.947
<b>aMaxV</b>	PC1/PC3	50.322
<b>aMinAP</b>	PC1/PC3	50.322
<b>aMinML</b>	PC3/PC4	18.906
<b>aMinV</b>	PC1/PC3	50.322
<b>aMinRIAP</b>	PC3/PC4	18.906
<b>aMinRIML</b>	PC2/PC4	29.195
<b>PPvRIAP</b>	PC2/PC4	29.195
<b>PPvRIML</b>	PC3	11.375
<b>PPvRIV</b>	PC2/PC4	29.195

De modo a confirmar que a seleção das métricas foi bem efetuada, são analisados também os biplots da Figura 27, Figura 28 e Figura 29. As métricas relevantes nesta situação são as que estão fora da elipse. Contudo neste caso não são escolhidas todas as métricas da junção dos resultados dos biplots, mas sim as que são em comum em ambos os biplots de forma a se obter apenas as mais relevantes. No fim da análise toda as métricas aMaxML, EAP, aMaxV, aMaxAP, EV, aMinV e aMinAP são selecionadas, confirmando assim o outro método.

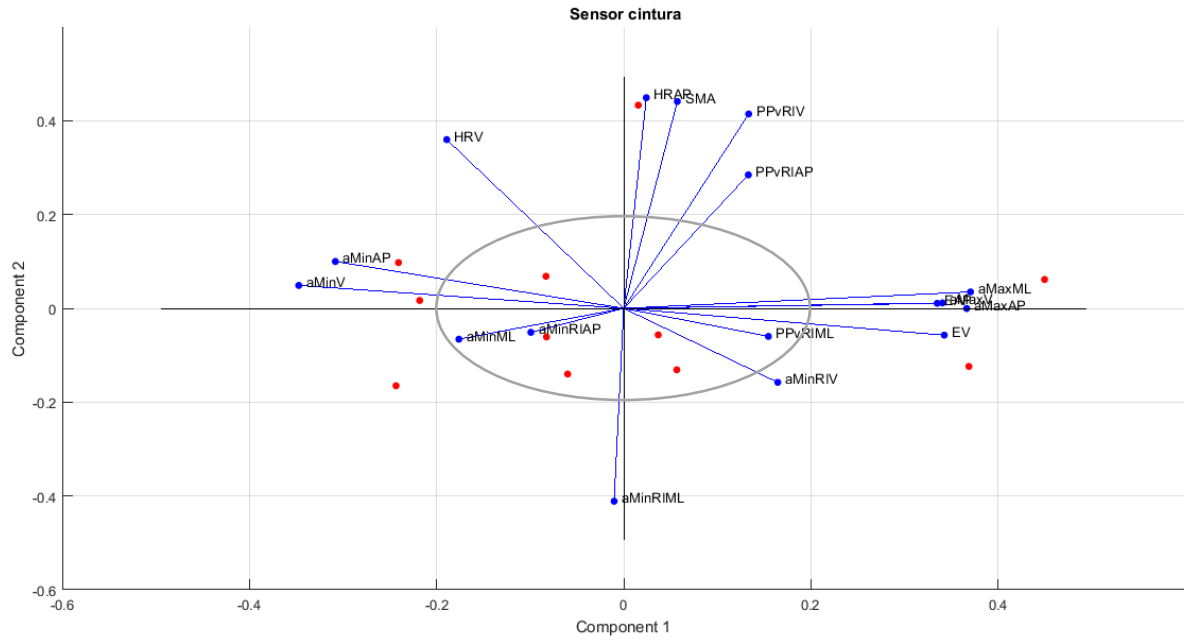


Figura 27 - Representação do biplot para o 1º e 2º PC na análise da marcha normal com *fall slip* no sensor da cintura.




Figura 28 - Representação do biplot para o 1º e 3º PC na análise da marcha normal com *fall slip* no sensor da cintura.






Figura 29 - Representação do biplot para o 1º e 4º PC na análise da marcha normal com *fall slip* no sensor da cintura.

Na Tabela 18 são apresentadas as métricas que permitem prever as quedas. Estas métricas foram obtidas seguindo o mesmo raciocínio do caso anterior para o sensor da cintura. Com a única diferença que para as coxas e para as canelas foram consideradas as métricas comuns a ambos os lados.

Tabela 18 - Resumo das métricas relevantes para detetar *fall slip*.

<b>Cintura</b>	<b>Coxas</b>	<b>Canelas</b>
EAP	EAP	EAP
EV	EV	EV
aMinAP	aMinAP	aMinAP
aMinV	aMinML	aMaxAP
aMaxAP	aMinV	aMaxML
aMaxML	aMaxAP	aMinRIV
aMaxV	aMaxML	PPvRIML

## CAPÍTULO 5

### 5 CONCLUSÕES E PERSPETIVAS FUTURAS

O objetivo deste trabalho centrou-se num estudo de uma análise da marcha, conseguindo encontrar um método inicial para prever quedas, mais especificamente as quais métricas mais relevantes para prever quedas. Para esse estudo foram utilizados módulos de sensores inerciais desenvolvidos na Universidade do Minho, constituídos por acelerómetro, giroscópio e magnetómetro.

Ao longo deste trabalho, os objetivos pretendidos tiveram de ser ajustados devido às limitações discutidas na secção 3.3.3. Como foi dito, o uso destes módulos sensoriais introduziram algumas limitações práticas que não permitiram atingir os bons resultados que se almejavam nem uma grande variedade e quantidade de dados. Assim, com a aplicação do PCA em poucos dados, os resultados obtidos poderão levar a conclusões pouco relevantes, no entanto foi explorado o método que se aplicaria no caso de prevenção das quedas em tempo real.

Todo o processamento dos dados foi efetuado em Matlab, que permite a visualização dos dados obtidos através dos sensores inerciais, o cálculo das métricas e análise do PCA.

Com este trabalho conclui-se que para prevenção de todos os tipos de quedas estudados neste trabalho são especialmente importantes: na cintura o HRV, aMinRIML, aMinRIV e PPvRIML. Nas coxas tem-se HRV, EAP, aMaxV, aMinRIML, aMinRIV e nas canelas, EML, aMinML, aMinV, aMinRIAP e PPvRIV.

Para a prevenção da *fall slip*, no sensor da cintura tem-se EAP, EV, aMinAP, aMinV, aMaxAP, aMaxML e aMaxV. Nas coxas, EAP, EV, aMinAP, aMinML, aMinV, aMaxAP e aMaxML. Por último, nas canelas, EAP, EV, aMinAP, aMaxAP, aMaxML, aMinRIV e PPvRIML.

Como perspetivas futuras vai-se endereçar o uso de módulos sensoriais nos quais não ocorram falhas na transmissão de dados, de modo a obter um grande número de dados. Com uma grande quantidade de dados (um número elevado de observações) ter-se-ão resultados mais fiáveis na aplicação do PCA.

Na aplicação do PCA, com uma grande quantidade de dados tornará possível separar as diferentes quedas de modo a prever o tipo de queda, ou seja, vai haver mais observações para cada tipo de queda, sendo assim possível dividir em diferentes PCAs consoante o tipo de queda, e o PCA dar resultados plausíveis.

De modo a prever se a queda irá acontecer realmente, poder-se-á recorrer a um algoritmo de *machine learning* como por exemplo *Support Vector Machines*.

Além disso seria interessante efetuar o cálculo das métricas em tempo real e fazer um estudo da eficácia das métricas na prevenção de quedas.

Numa fase posterior, seria interessante fazer este estudo para pessoas patológicas, tendo elas maior risco de queda. Além disso, de modo a diminuir as lesões nas pessoas terá de ser implementado um sistema em tempo real de modo a se poder atuar atempadamente ao prever a queda.

## BIBLIOGRAFIA

- [1] H. B. Menz, S. R. Lord, and R. C. Fitzpatrick, "Acceleration patterns of the head and pelvis when walking on level and irregular surfaces," *Gait Posture*, vol. 18, pp. 35–46, 2003.
- [2] W. P. Berg, H. M. Alessio, E. M. Mills, and C. Tong, "Circumstances and consequences of falls in independent community-dwelling older adults," *Age Ageing*, vol. 26, no. 4, pp. 261–268, 1997.
- [3] A. Ejupi, S. R. Lord, and K. Delbaere, "New methods for fall risk prediction.," *Curr. Opin. Clin. Nutr. Metab. Care*, vol. 17, no. 5, pp. 407–411, 2014.
- [4] P. Boissy, S. Choquette, M. Hamel, and N. Noury, "User-based motion sensing and fuzzy logic for automated fall detection in older adults.," *Telemed. J. E. Health.*, vol. 13, no. 6, pp. 683–693, 2007.
- [5] M. Kangas, I. Vikman, J. Wiklander, P. Lindgren, L. Nyberg, and T. Jämsä, "Sensitivity and specificity of fall detection in people aged 40 years and over.," *Gait Posture*, vol. 29, pp. 571–574, 2009.
- [6] R. N. Kirkwood, P. A. Araújo, and C. S. Dias, "Biomecânica da marcha em idosos caidores e não caidores : uma revisão da literatura," *Rev. Bras. Cienc. e Mov.*, vol. 14, no. 4, pp. 103–110, 2006.
- [7] C. L. Vaughan, B. L. Davis, and J. C. O'Connor, *Dynamics of Human Gait*. 1992.
- [8] V. Lugade, V. Lin, and L.-S. Chou, "Center of mass and base of support interaction during gait," *Gait Posture*, vol. 33, no. 3, pp. 406–411, 2011.
- [9] M. Kangas, A. Konttila, I. Winblad, and T. Jämsä, "Determination of simple thresholds for accelerometry-based parameters for fall detection," *Annu. Int. Conf. IEEE Eng. Med. Biol. - Proc.*, pp. 1367–1370, 2007.
- [10] C. F. Lai, S. Y. Chang, H. C. Chao, and Y. M. Huang, "Detection of cognitive injured body region using multiple triaxial accelerometers for elderly falling," *IEEE Sens. J.*, vol. 11, no. 3, pp. 763–770, 2011.
- [11] M. Mubashir, L. Shao, and L. Seed, "A survey on fall detection: Principles and approaches," *Neurocomputing*, vol. 100, pp. 144–152, 2013.
- [12] J. Liu, X. Zhang, and T. E. Lockhart, "Fall Risk Assessments Based on Postural and Dynamic Stability Using Inertial Measurement Unit," *Saf. Health Work*, vol. 3, no. 3, p. 192, 2012.

- [13] K. Aminian and B. Najafi, "Capturing human motion using body-fixed sensors: Outdoor measurement and clinical applications," *Comput. Animat. Virtual Worlds*, vol. 15, no. 2, pp. 79–94, 2004.
- [14] V. A. Lugade and L.-S. Chou, "Balance control and stability during gait - an evaluation of fall risk among elderly adults," vol. 3481236, no. September, p. 123, 2011.
- [15] H. Luukinen, M. Herala, K. Koski, R. Honkanen, P. Laippala, and S. L. Kivelä, "Fracture risk associated with a fall according to type of fall among the elderly.," *Osteoporos. Int.*, vol. 11, no. 7, pp. 631–4, 2000.
- [16] J. Huang, W. Xu, S. Mohammed, and Z. Shu, "Posture estimation and human support using wearable sensors and walking-aid robot," *Rob. Auton. Syst.*, vol. 73, no. 0, p. -, 2014.
- [17] J. Huang, P. Di, K. Wakita, T. Fukuda, and K. Sekiyama, "Study of Fall Detection Using Intelligent Cane Based on Sensor Fusion," *Int. Symp. Micro-NanoMechatronics Hum. Sci. MHS 2008. Nagoya, 6-9 Nov.*, pp. 495–500, 2008.
- [18] T. Tamura, T. Yoshimura, M. Sekine, M. Uchida, and O. Tanaka, "A wearable airbag to prevent fall injuries," *IEEE Trans. Inf. Technol. Biomed.*, vol. 13, no. 6, pp. 910–914, 2009.
- [19] M. J. Mathie, A. C. F. Coster, N. H. Lovell, and B. G. Celler, "Accelerometry: providing an integrated, practical method for long-term, ambulatory monitoring of human movement.," *Physiol. Meas.*, vol. 25, no. 2, pp. R1–R20, 2004.
- [20] F. Bianchi, S. J. Redmond, M. R. Narayanan, S. Cerutti, and N. H. Lovell, "Barometric pressure and triaxial accelerometry-based falls event detection," *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 18, no. 6, pp. 619–627, 2010.
- [21] K. Aminian, K. Rezakhanlou, E. De Andres, C. Fritsch, P. F. Leyvraz, and P. Robert, "Temporal feature estimation during walking using miniature accelerometers: an analysis of gait improvement after hip arthroplasty.," *Med. Biol. Eng. Comput.*, vol. 37, pp. 686–691, 1999.
- [22] B. Auvinet, G. Berrut, C. Touzard, L. Moutel, N. Collet, D. Chaleil, and E. Barrey, "Reference data for normal subjects obtained with an accelerometric device," *Gait Posture*, vol. 16, no. 2, pp. 124–134, 2002.
- [23] A. Sousa, "Controlo Postural em Marcha Humana: Análise Multifactorial," pp. 85–86, 2010.
- [24] V. Lugade, V. Lin, A. Farley, and L.-S. Chou, "An artificial neural network estimation of gait balance control in the elderly using clinical evaluations.," *PLoS One*, vol. 9, no. 5, p. e97595, 2014.
- [25] M. Iosa, T. Marro, S. Paolucci, and D. Morelli, "Stability and harmony of gait in children with cerebral palsy," *Res. Dev. Disabil.*, vol. 33, no. 1, pp. 129–135, 2012.

- [26] T. Lockhart and J. Liu, "Differentiating fall-prone and healthy adults using local dynamic stability," *Ergonomics*, vol. 51, no. 12, pp. 1860–1872, 2008.
- [27] J. B. Dingwell and J. P. Cusumano, "Nonlinear time series analysis of normal and pathological human walking.," *Chaos*, vol. 10, no. 4, pp. 848–863, 2000.
- [28] U. Laessoe, H. C. Hoeck, O. Simonsen, T. Sinkjaer, and M. Voigt, "Fall risk in an active elderly population--can it be assessed?," *J. Negat. Results Biomed.*, vol. 6, p. 2, 2007.
- [29] J. B. Dingwell and L. C. Marin, "Kinematic variability and local dynamic stability of upper body motions when walking at different speeds," *J. Biomech.*, vol. 39, no. 3, pp. 444–452, 2006.
- [30] W. Zijlstra and A. L. Hof, "Assessment of spatio-temporal gait parameters from trunk accelerations during human walking," *Gait Posture*, vol. 18, no. 2, pp. 1–10, 2003.
- [31] U. Lindemann, L. Lundin-Olsson, K. Hauer, M. Wengert, C. Becker, and K. Pfeiffer, "Maximum step length as a potential screening tool for falls in non-disabled older adults living in the community.," *Aging Clin. Exp. Res.*, vol. 20, no. 5, pp. 394–399, 2008.
- [32] a Sant'Anna, N. Wickström, R. Zügner, and R. Tranberg, "A wearable gait analysis system using inertial sensors Part I: Evaluation of measures of gait symmetry and normality against 3D kinematic data," *BIOSIGNALS 2012 - Proc. Int. Conf. Bio-Inspired Syst. Signal Process.*, pp. 180–188, 2011.
- [33] S. Jiang, B. Zhang, and D. Wei, "The Elderly Fall Risk Assessment and Prediction Based on Gait Analysis," *2011 IEEE 11th Int. Conf. Comput. Inf. Technol.*, pp. 176–180, 2011.
- [34] D. M. Karantonis, M. R. Narayanan, M. Mathie, N. H. Lovell, and B. G. Celler, "Implementation of a real-time human movement classifier using a triaxial accelerometer for ambulatory monitoring," *IEEE Trans. Inf. Technol. Biomed.*, vol. 10, no. 1, pp. 156–167, 2006.
- [35] A. M. Sabatini, C. Martelloni, S. Scapellato, and F. Cavallo, "Assessment of walking features from foot inertial sensing," *IEEE Trans. Biomed. Eng.*, vol. 52, no. 3, pp. 486–494, 2005.
- [36] J. J. Kavanagh and H. B. Menz, "Accelerometry: A technique for quantifying movement patterns during walking," *Gait Posture*, vol. 28, no. 1, pp. 1–15, 2008.
- [37] N. Cau, V. Cimolin, M. Galli, H. Precilios, E. Tacchini, C. Santovito, and P. Capodaglio, "Center of pressure displacements during gait initiation in individuals with obesity," *J. Neuroeng. Rehabil.*, vol. 11, no. 1, p. 82, 2014.
- [38] D. Lafond, H. Corriveau, R. Hébert, and F. Prince, "Intrasession reliability of center of pressure measures of postural steadiness in healthy elderly people," *Arch. Phys. Med. Rehabil.*, vol. 85, no. 6, pp. 896–901, 2004.
- [39] E. P. Doheny, D. McGrath, B. R. Greene, L. Walsh, D. McKeown, C. Cunningham, L. Crosby, R. A. Kenny, and B. Caulfield, "Displacement of centre of mass during quiet

- standing assessed using accelerometry in older fallers and non-fallers,” *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS*, pp. 3300–3303, 2012.
- [40] M. J. Floor-Westerdijk, H. M. Schepers, P. H. Veltink, E. H. F. Van Asseldonk, and J. H. Buurke, “Use of inertial sensors for ambulatory assessment of center-of-mass displacements during walking,” *IEEE Trans. Biomed. Eng.*, vol. 59, no. 7, pp. 2080–2084, 2012.
- [41] J. Howcroft, J. Kofman, and E. D. Lemaire, “Review of fall risk assessment in geriatric populations using inertial sensors,” *J. Neuroeng. Rehabil.*, vol. 10, no. 1, p. 91, 2013.
- [42] R. Ganea, a. Paraschiv-Ionescu, C. Büla, S. Rochat, and K. Aminian, “Multi-parametric evaluation of sit-to-stand and stand-to-sit transitions in elderly people,” *Med. Eng. Phys.*, vol. 33, no. 9, pp. 1086–1093, 2011.
- [43] a Weiss, T. Herman, M. Plotnik, M. Brozgol, N. Giladi, and J. M. Hausdorff, “An instrumented timed up and go: the added value of an accelerometer for identifying fall risk in idiopathic fallers,” *Physiol. Meas.*, vol. 32, no. 12, pp. 2003–2018, 2011.
- [44] G. Cola, M. Avvenuti, A. Vecchio, G.-Z. Yang, and B. Lo, “An On-Node Processing Approach for Anomaly Detection in Gait,” *IEEE Sens. J.*, vol. 15, no. 11, pp. 6640–6649, 2015.
- [45] M. Schwenk, K. Hauer, T. Zieschang, S. Englert, J. Mohler, and B. Najafi, “Sensor-derived physical activity parameters can predict future falls in people with dementia.,” *Gerontology*, vol. 60, no. 6, pp. 483–92, 2014.
- [46] M. SÃ¡nchez, J. Bussmann, W. Janssen, H. Horemans, S. Chastin, M. Heijenbrok, and H. Stam, “Accelerometric assessment of different dimensions of natural walking during the first year after stroke: Recovery of amount, distribution, quality and speed of walking,” *J. Rehabil. Med.*, vol. 47, no. 8, pp. 714–721, 2015.
- [47] J. A. Lee, S. H. Cho, Y. J. Lee, H. K. Yang, and J. W. Lee, “Portable activity monitoring system for temporal parameters of gait cycles,” *J. Med. Syst.*, vol. 34, no. 5, pp. 959–966, 2010.
- [48] M. Henriksen, H. Lund, R. Moe-Nilssen, H. Bliddal, and B. Danneskiold-Samsøe, “Test–retest reliability of trunk accelerometric gait analysis,” *Gait Posture*, vol. 19, no. 3, pp. 288–297, 2004.
- [49] L. S. Chou, K. R. Kaufman, M. E. Hahn, and R. H. Brey, “Medio-lateral motion of the center of mass during obstacle crossing distinguishes elderly individuals with imbalance,” *Gait Posture*, vol. 18, no. 3, pp. 125–133, 2003.
- [50] S. a. England and K. P. Granata, “The influence of gait speed on local dynamic stability of walking,” *Gait Posture*, vol. 25, no. 2, pp. 172–178, 2007.
- [51] N. Wang, E. Ambikairajah, N. H. Lovell, and B. G. Celler, “Accelerometry based classification of walking patterns using time-frequency analysis,” *Proc. 29th Int. Conf. IEEE EMBS*, vol. 2007, pp. 4899–902, 2007.

- [52] H. G. Kang and J. B. Dingwell, "Intra-session reliability of local dynamic stability of walking," *Gait Posture*, vol. 24, no. 3, pp. 386–390, 2006.
- [53] D. R. Thompson, S. Member, and J. Di, "Local Dynamic Stability Assessment of Motion Impaired Elderly Using Electronic Textile Pants," vol. 8, no. 6, pp. 938–943, 2011.
- [54] R. Gigi, A. Haim, E. Luger, G. Segal, E. Melamed, Y. Beer, M. Nof, M. Nyska, and A. Elbaz, "Deviations in gait metrics in patients with chronic ankle instability: a case control study,," *J. Foot Ankle Res.*, vol. 8, no. 1, p. 1, 2015.
- [55] a. Elbaz, a. Mor, G. Segal, R. Debi, N. Shazar, and a. Herman, "Novel classification of knee osteoarthritis severity based on spatiotemporal gait analysis," *Osteoarthr. Cartil.*, vol. 22, no. 3, pp. 457–463, 2014.
- [56] B. R. Greene, D. Mcgrath, L. Walsh, E. P. Doheny, D. Mckeown, C. Garattini, C. Cunningham, L. Crosby, B. Caulfield, and R. a Kenny, "Quantitative falls risk estimation through multi-sensor assessment of standing balance," *Physiol. Meas*, vol. 33, pp. 2049–2063, 2012.
- [57] M. M. Carvalho De Freitas Martins, "Universidade do Minho Escola de Engenharia ASBGo: A Smart Walker for mobility Assistance and monitoring System Aid," 2015.
- [58] M. W. Whittle, "Gait analysis: an introduction," *Library (Lond).*, vol. 3, pp. 1–220, 2002.
- [59] P. Macedo, J. a Afonso, and R. Simoes, "A Personalized Rehabilitation System Based on Wireless Motion Capture Sensors," pp. 1–9, 2014.
- [60] M. G. R. Courtney, "Determining the number of factors to retain in EFA : Using the SPSS R-Menu v2 . 0 to make more judicious estimations," *Pract. Assessment, Res. Eval.*, vol. 18, no. 8, pp. 1–14, 2013.





# ANEXO I – CONSENTIMENTO INFORMADO

## Consentimento Informado

*Leia por favor atentamente a seguinte informação e se concordar com o que lhe é apresentado, queira assinar este documento.*

Eu, Cristiana Mendes Magina, aluna no Mestrado Integrado de Engenharia Eletrónica Industrial e Computadores da Universidade do Minho, sob orientação da Professora Doutora Cristina Manuela Peixoto dos Santos, encontro-me a realizar uma Dissertação com o tema: “Técnicas de Monitorização de Marcha em Utilizadores de um Andarilho Motorizado e em Pessoas Saudáveis”.

No âmbito desta Dissertação é necessário proceder a realização de testes experimentais em pessoas saudáveis, consistindo em: marcha normal e em cinco tipos de quedas (para a frente, para trás, lateral, de joelhos e escorregar).

Para obtenção de melhores resultados e interpretação, os testes serão filmados. As gravações não serão publicadas em qualquer lado, sendo apenas utilizadas, exclusivamente, para o presente estudo.

Neste contexto venho solicitar a vossa excelência a sua participação na realização destes testes.

Li o presente documento e estou consciente da minha participação no estudo. Tive oportunidade de colocar todas as questões e as respostas esclareceram todas as minhas dúvidas. Assim, aceito voluntariamente participar neste estudo.

Nome: \_\_\_\_\_

Assinatura: \_\_\_\_\_

Data: \_\_\_/\_\_\_/\_\_\_

Os aspetos mais importantes deste estudo foram explicados ao participante, antes de solicitar a sua assinatura.

\_\_\_\_\_



# ANEXO II – PROTOCOLO

## Protocolo

### Material a Verificar:

1. Verificar que se tem os sensores inerciais.
2. Verificar que se tem cabos.
3. Verificar que se tem baterias.
4. Verificar que se tem câmara para filmar.
5. Verificar que se tem fita métrica para medir os 10 m.
6. Verificar que se tem cronómetro para o tempo de queda.
7. Verificar que o ginásio tem os colchões livres.

### Delineamento das experiências:

Antes:

1. Preparação da sala com os colchões.
2. Marcar os 10 m de comprimento.
3. Colocar as antenas todas.
4. Ligar a placa ao computador.
5. Calibrar cada sensor:
  - Apenas um único sensor ligado.
  - Retirar os valores para cada sensor e trocar os valores no Matlab.

Depois:

6. Alterar os parâmetros de cada pessoa.
7. Colocar os sensores na pessoa tendo em atenção as direções de cada um.
8. Reiniciar tudo no fim de cada experiência:
  - Desligar a placa.
  - Desligar todos os sensores.
  - Ligar todos os sensores.
  - Ligar a placa.

9. Experiência 1: Cada pessoa caminha normalmente ao longo de 10 m em linha reta, com outra pessoa ao lado a filmar. Repetir 5 vezes.
10. Colocação das proteções nos sensores.
11. Experiência 2: Cada pessoa caminha normalmente e será dito posteriormente o tipo de queda. Marcar o tempo de queda. Repetir para todos os tipos de queda.

## ANEXO III – MATRIZES PARA APLICAÇÃO DO PCA

### Marcha normal:

#### Cintura

	<i>HRV</i>	<i>SMA</i>	<i>EAP</i>	<i>EML</i>	<i>EV</i>	<i>aMaxAP</i>	<i>aMaxML</i>	<i>aMaxV</i>	<i>aMinAP</i>	<i>aMinML</i>	<i>aMinV</i>	<i>aMinRIAP</i>	<i>aMinRIML</i>	<i>aMinRIV</i>	<i>PPvRIAP</i>	<i>PPvRIML</i>	<i>PPvRIV</i>
<b>V1</b>	-0,320	-0,109	-0,670	-0,667	-0,625	-0,679	-1,296	-0,564	1,284	0,404	0,635	-0,323	1,429	0,319	0,335	-0,431	-0,359
<b>V2</b>	-0,398	1,299	1,992	1,953	1,145	1,360	1,255	1,464	-0,851	0,017	-0,963	-0,160	-0,751	-0,588	0,641	-0,338	1,855
<b>V3</b>	2,011	-1,296	-0,293	0,127	-0,659	-0,907	0,059	-0,758	-0,310	-1,968	0,597	-0,691	0,672	-0,279	-0,063	-0,401	-0,022
<b>V4</b>	-0,701	1,031	-0,042	-0,275	1,427	1,164	0,983	1,094	-0,257	0,236	-1,566	0,013	0,024	1,857	-0,337	-0,466	-0,712
<b>V5</b>	-0,181	-0,715	-0,433	-0,613	-0,631	-0,282	-0,130	-0,603	-1,041	0,496	0,557	-0,784	-1,393	-0,361	-1,736	2,039	-0,943
<b>V6</b>	-0,411	-0,210	-0,555	-0,524	-0,658	-0,656	-0,872	-0,635	1,175	0,815	0,740	1,944	0,020	-0,948	1,160	-0,403	0,181

#### Coxa direita

	<i>HRV</i>	<i>SMA</i>	<i>EAP</i>	<i>EML</i>	<i>EV</i>	<i>aMaxAP</i>	<i>aMaxML</i>	<i>aMaxV</i>	<i>aMinAP</i>	<i>aMinML</i>	<i>aMinV</i>	<i>aMinRIAP</i>	<i>aMinRIML</i>	<i>aMinRIV</i>	<i>PPvRIAP</i>	<i>PPvRIML</i>	<i>PPvRIV</i>
<b>V1</b>	0,884	1,972	-0,573	1,188	0,711	-0,024	1,837	-0,147	-0,442	0,175	-1,277	-0,323	1,429	0,319	0,335	-0,431	-0,359
<b>V2</b>	-1,026	-0,508	1,906	-0,084	-0,816	1,947	0,139	-0,513	0,706	-0,924	0,974	-0,160	-0,751	-0,588	0,641	-0,338	1,855
<b>V3</b>	-0,020	-0,202	-0,752	-0,891	-0,870	-0,730	-0,698	-0,562	0,519	-1,521	0,257	-0,691	0,672	-0,279	-0,063	-0,401	-0,022
<b>V4</b>	-0,433	-0,514	0,289	1,149	-0,932	-0,143	-0,667	-0,503	-0,735	0,992	-1,235	0,013	0,024	1,857	-0,337	-0,466	-0,712
<b>V5</b>	-0,886	-0,007	-0,363	-0,162	1,392	-0,297	0,189	2,015	-1,346	0,637	0,705	-0,784	-1,393	-0,361	-1,736	2,039	-0,943
<b>V6</b>	1,481	-0,740	-0,507	-1,201	0,514	-0,752	-0,799	-0,291	1,298	0,641	0,576	1,944	0,020	-0,948	1,160	-0,403	0,181

#### Coxa esquerda

	<i>HRV</i>	<i>SMA</i>	<i>EAP</i>	<i>EML</i>	<i>EV</i>	<i>aMaxAP</i>	<i>aMaxML</i>	<i>aMaxV</i>	<i>aMinAP</i>	<i>aMinML</i>	<i>aMinV</i>	<i>aMinRIAP</i>	<i>aMinRIML</i>	<i>aMinRIV</i>	<i>PPvRIAP</i>	<i>PPvRIML</i>	<i>PPvRIV</i>
<b>V1</b>	1,237	0,664	-0,108	-0,236	-0,235	-0,590	-0,558	1,331	0,017	-0,794	-0,342	-0,323	1,429	0,319	0,335	-0,431	-0,359

<b>V2</b>	-1,570	0,756	1,453	2,022	2,003	0,982	1,653	0,232	0,314	0,048	0,277	-0,160	-0,751	-0,588	0,641	-0,338	1,855
<b>V3</b>	0,826	-1,269	-1,031	-0,365	-0,165	-0,794	-0,932	0,556	1,039	-1,517	0,049	-0,691	0,672	-0,279	-0,063	-0,401	-0,022
<b>V4</b>	-0,453	0,325	0,054	-0,328	-0,481	-0,551	0,294	0,036	-0,969	0,624	1,303	0,013	0,024	1,857	-0,337	-0,466	-0,712
<b>V5</b>	0,224	-1,277	-1,117	-0,634	-0,713	-0,596	-0,898	-0,557	0,982	1,229	0,424	-0,784	-1,393	-0,361	-1,736	2,039	-0,943
<b>V6</b>	-0,263	0,801	0,750	-0,460	-0,409	1,549	0,441	-1,598	-1,384	0,410	-1,711	1,944	0,020	-0,948	1,160	-0,403	0,181

### Canela direita

	<b>HRV</b>	<b>SMA</b>	<b>EAP</b>	<b>EML</b>	<b>EV</b>	<b>aMaxAP</b>	<b>aMaxML</b>	<b>aMaxV</b>	<b>aMinAP</b>	<b>aMinML</b>	<b>aMinV</b>	<b>aMinRIAP</b>	<b>aMinRIML</b>	<b>aMinRIV</b>	<b>PPvRIAP</b>	<b>PPvRIML</b>	<b>PPvRIV</b>
<b>V1</b>	-0,847	1,972	-0,482	-0,393	0,850	0,102	-0,387	0,946	0,453	0,365	-1,999	0,376	-0,937	1,924	0,877	0,909	-0,383
<b>V2</b>	0,877	-0,508	-0,288	-0,439	-1,085	1,668	-0,311	-0,805	0,590	0,016	0,679	0,145	1,782	-0,784	-0,503	-1,693	1,933
<b>V3</b>	0,697	-0,202	1,901	2,031	-0,066	0,179	2,037	-0,560	-1,303	-1,600	0,080	-1,223	-0,270	0,229	1,445	1,052	-0,394
<b>V4</b>	-1,466	-0,514	-0,608	-0,465	1,279	-0,463	-0,510	1,458	0,664	0,821	0,438	0,807	-0,897	-0,435	-0,014	-0,371	-0,773
<b>V5</b>	-0,180	-0,007	0,269	-0,223	0,212	-0,089	-0,391	-0,032	-1,257	-0,682	0,292	-1,211	0,073	-0,411	-0,542	0,220	0,191
<b>V6</b>	0,920	-0,740	-0,792	-0,511	-1,190	-1,397	-0,438	-1,008	0,852	1,080	0,511	1,106	0,249	-0,523	-1,264	-0,118	-0,574

### Canela esquerda

	<b>HRV</b>	<b>SMA</b>	<b>EAP</b>	<b>EML</b>	<b>EV</b>	<b>aMaxAP</b>	<b>aMaxML</b>	<b>aMaxV</b>	<b>aMinAP</b>	<b>aMinML</b>	<b>aMinV</b>	<b>aMinRIAP</b>	<b>aMinRIML</b>	<b>aMinRIV</b>	<b>PPvRIAP</b>	<b>PPvRIML</b>	<b>PPvRIV</b>
<b>V1</b>	0,183	1,474	1,528	-0,599	1,583	0,571	-0,462	2,003	-1,331	0,881	-1,425	0,376	-0,937	1,924	0,877	0,909	-0,383
<b>V2</b>	0,918	-0,928	-0,282	0,271	-0,177	-0,360	0,354	-0,376	0,532	-1,339	-0,027	0,145	1,782	-0,784	-0,503	-1,693	1,933
<b>V3</b>	1,297	-0,331	0,712	1,847	-0,085	1,790	1,845	-0,150	-0,318	-0,747	1,387	-1,223	-0,270	0,229	1,445	1,052	-0,394
<b>V4</b>	-0,870	-1,155	-0,564	-0,700	-1,314	-0,710	-0,408	-0,591	-0,186	1,016	0,418	0,807	-0,897	-0,435	-0,014	-0,371	-0,773
<b>V5</b>	-1,273	0,671	-0,068	-0,002	0,600	-0,693	-0,342	-0,243	-0,339	-0,547	-0,812	-1,211	0,073	-0,411	-0,542	0,220	0,191
<b>V6</b>	-0,255	0,268	-1,325	-0,817	-0,608	-0,597	-0,988	-0,643	1,642	0,735	0,459	1,106	0,249	-0,523	-1,264	-0,118	-0,574

### Quedas:

#### Cintura

	<b>HRV</b>	<b>SMA</b>	<b>EAP</b>	<b>EML</b>	<b>EV</b>	<b>aMaxAP</b>	<b>aMaxML</b>	<b>aMaxV</b>	<b>aMinAP</b>	<b>aMinML</b>	<b>aMinV</b>	<b>aMinRIAP</b>	<b>aMinRIML</b>	<b>aMinRIV</b>	<b>PPvRIAP</b>	<b>PPvRIML</b>	<b>PPvRIV</b>
<b>V1 FS</b>	2,398	-0,964	-0,862	1,409	-0,146	-1,343	0,077	0,886	-0,145	0,396	0,009	2,708	-0,811	-0,856	0,189	-0,788	-1,350

<b>V2 FSI</b>	0,321	1,920	2,784	2,367	0,945	1,009	3,021	1,945	-2,006	-1,175	-1,779	-0,126	-0,657	-0,483	1,279	0,320	0,994
<b>V2 FS</b>	1,724	1,991	0,055	0,678	1,222	0,404	0,718	0,270	-1,517	-2,514	-0,327	-0,307	-1,132	0,147	2,572	-0,042	2,685
<b>V2 FK</b>	0,529	0,572	-0,590	-1,242	-0,720	-0,132	0,218	0,455	-0,778	-0,485	-1,085	-0,080	0,801	-0,540	0,664	-0,596	0,585
<b>V2 FB</b>	-0,446	1,482	2,280	-0,285	0,707	1,694	1,439	0,216	-1,642	-1,578	-0,544	-1,116	0,510	1,647	0,598	1,308	-1,146
<b>V3 FF</b>	-1,114	-0,324	-0,540	-0,817	0,510	-0,875	0,413	0,749	0,568	-0,757	0,197	-0,495	-0,334	-0,172	-0,393	0,014	0,377
<b>V3 FSI</b>	-0,205	-1,005	0,048	-0,847	-1,366	-1,039	-0,906	-0,843	0,057	-0,135	1,348	-0,305	0,565	-0,854	-1,337	-0,968	-0,484
<b>V3 FS</b>	0,392	0,044	-0,664	0,144	-0,002	-0,599	-0,758	0,199	-0,261	-0,441	0,529	-0,659	-0,127	-0,958	-0,915	-1,321	-0,883
<b>V4 FF</b>	-1,325	0,406	-0,505	-0,041	-0,933	1,959	0,046	0,003	0,731	0,239	-0,979	-0,782	-0,826	-0,450	0,351	0,096	0,751
<b>V4 FS</b>	-0,748	-1,410	-0,465	-1,435	-1,163	-1,413	-0,761	-1,577	0,749	1,408	0,867	1,626	0,761	0,718	-0,600	-0,976	-0,866
<b>V4 FK</b>	-0,194	-0,120	0,010	0,824	-0,749	-0,633	-0,709	-0,851	-0,530	1,090	0,018	1,600	1,764	-1,107	1,191	-1,119	0,720
<b>V5 FSI</b>	-0,348	-0,148	-0,699	-1,129	1,387	0,066	-1,022	-0,024	-0,341	0,767	-0,287	-0,428	-1,052	-0,595	-0,612	-0,159	-0,226
<b>V5 FK</b>	-0,247	-0,167	-0,691	-0,277	1,571	0,015	-0,674	0,119	-0,041	0,508	0,097	-0,629	-0,743	0,871	-1,141	0,855	-0,718
<b>V5 FB</b>	-1,089	0,061	0,231	-0,514	-0,853	0,198	0,119	-1,380	0,820	0,271	-1,802	-0,522	-0,737	1,327	-0,939	1,798	-0,707
<b>V6 FF</b>	1,183	-0,886	-0,137	0,308	-1,166	0,073	-0,940	-0,293	1,124	0,735	1,106	0,320	-0,517	-1,172	-0,086	-1,135	-0,736
<b>V6 FSI</b>	0,501	-1,310	-0,651	-0,147	0,889	-0,944	-0,071	-0,427	0,825	0,472	1,502	0,101	-0,208	0,582	0,268	1,722	0,314
<b>V6 FS</b>	-0,677	0,089	0,525	-0,188	0,765	0,266	0,178	1,895	1,156	0,634	-0,122	-0,037	0,224	-0,280	-0,484	-0,043	-0,097
<b>V6 FB</b>	-0,654	-0,232	-0,128	1,191	-0,897	1,294	-0,388	-1,344	1,230	0,565	1,255	-0,868	2,518	2,174	-0,605	1,034	0,788

## Coxa direita

	<b>HRV</b>	<b>SMA</b>	<b>EAP</b>	<b>EML</b>	<b>EV</b>	<b>aMaxAP</b>	<b>aMaxML</b>	<b>aMaxV</b>	<b>aMinAP</b>	<b>aMinML</b>	<b>aMinV</b>	<b>aMinRIAP</b>	<b>aMinRIML</b>	<b>aMinRIV</b>	<b>PPvRIAP</b>	<b>PPvRIML</b>	<b>PPvRIV</b>
<b>V1 FS</b>	1,472	-0,569	-0,478	3,196	0,494	-0,246	1,726	0,702	0,528	-1,250	1,241	2,708	-0,811	-0,856	0,189	-0,788	-1,350
<b>V2 FSI</b>	0,443	1,181	0,844	1,658	-0,895	0,385	0,505	0,004	-0,439	-0,694	-0,438	-0,126	-0,657	-0,483	1,279	0,320	0,994
<b>V2 FS</b>	0,230	2,833	0,124	0,438	-0,045	2,072	1,908	0,605	-0,828	-3,207	-0,989	-0,307	-1,132	0,147	2,572	-0,042	2,685
<b>V2 FK</b>	0,230	0,497	3,093	-0,053	0,185	1,791	0,295	0,475	-0,231	0,223	0,444	-0,080	0,801	-0,540	0,664	-0,596	0,585
<b>V2 FB</b>	0,337	0,907	0,783	-0,103	0,810	-0,425	0,793	-0,349	-2,889	0,471	-1,596	-1,116	0,510	1,647	0,598	1,308	-1,146
<b>V3 FF</b>	-0,368	-0,176	-0,511	-0,485	0,733	-0,214	0,042	0,930	0,161	0,459	-0,714	-0,495	-0,334	-0,172	-0,393	0,014	0,377
<b>V3 FSI</b>	-0,597	-0,870	-0,914	-0,609	-0,993	-1,114	0,896	-0,354	0,990	0,642	1,098	-0,305	0,565	-0,854	-1,337	-0,968	-0,484
<b>V3 FS</b>	-2,020	-0,700	-0,710	-0,431	-0,524	-0,340	-1,003	-1,670	0,449	0,538	1,356	-0,659	-0,127	-0,958	-0,915	-1,321	-0,883
<b>V4 FF</b>	-0,351	-0,264	-0,675	-0,696	-1,143	-0,480	0,807	-0,669	-1,250	-0,454	0,059	-0,782	-0,826	-0,450	0,351	0,096	0,751
<b>V4 FS</b>	-0,740	-0,971	-0,928	-0,594	2,543	-1,426	-0,156	-0,704	0,640	0,529	-0,669	1,626	0,761	0,718	-0,600	-0,976	-0,866
<b>V4 FK</b>	-0,589	-0,216	0,813	-0,369	-0,514	-0,138	-1,076	-0,107	1,107	0,447	1,227	1,600	1,764	-1,107	1,191	-1,119	0,720
<b>V5 FSI</b>	1,078	-0,196	0,725	0,014	-0,756	0,925	-0,121	-0,430	0,061	-0,379	0,144	-0,428	-1,052	-0,595	-0,612	-0,159	-0,226
<b>V5 FK</b>	-0,761	-0,205	-0,194	-0,379	1,644	-0,746	-1,443	1,035	0,095	0,018	0,070	-0,629	-0,743	0,871	-1,141	0,855	-0,718
<b>V5 FB</b>	1,451	0,966	0,002	0,701	0,533	0,195	-0,130	0,561	-0,737	-0,146	-1,948	-0,522	-0,737	1,327	-0,939	1,798	-0,707
<b>V6 FF</b>	-0,971	-0,977	-0,986	-0,615	-1,239	-1,262	-0,112	-0,212	0,867	0,141	1,408	0,320	-0,517	-1,172	-0,086	-1,135	-0,736



<b>V6 FSI</b>	-0,503	-1,252	-0,734	-0,731	-0,081	-0,695	-1,680	2,528	0,866	0,548	-0,390	0,101	-0,208	0,582	0,268	1,722	0,314
<b>V6 FS</b>	-0,269	-0,390	0,171	-0,665	-0,530	0,398	-0,500	-0,784	0,937	0,853	-0,289	-0,037	0,224	-0,280	-0,484	-0,043	-0,097
<b>V6 FB</b>	1,926	0,399	-0,427	-0,278	-0,221	1,320	-0,751	-1,562	-0,326	1,261	-0,013	-0,868	2,518	2,174	-0,605	1,034	0,788

## Coxa esquerda

	<b>HRV</b>	<b>SMA</b>	<b>EAP</b>	<b>EML</b>	<b>EV</b>	<b>aMaxAP</b>	<b>aMaxML</b>	<b>aMaxV</b>	<b>aMinAP</b>	<b>aMinML</b>	<b>aMinV</b>	<b>aMinRIAP</b>	<b>aMinRIML</b>	<b>aMinRIV</b>	<b>PPvRIAP</b>	<b>PPvRIML</b>	<b>PPvRIV</b>
<b>V1 FS</b>	-1,081	-0,664	2,896	-0,422	-0,912	1,457	0,127	-1,750	-3,032	-0,072	0,332	2,708	-0,811	-0,856	0,189	-0,788	-1,350
<b>V2 FSI</b>	0,468	1,071	-0,464	-0,588	0,781	-0,020	-0,627	0,636	-0,527	-0,015	-1,036	-0,126	-0,657	-0,483	1,279	0,320	0,994
<b>V2 FS</b>	-0,757	2,478	0,915	1,430	0,776	-0,563	0,545	-0,395	-0,481	-0,021	-0,034	-0,307	-1,132	0,147	2,572	-0,042	2,685
<b>V2 FK</b>	0,338	0,595	0,040	1,988	2,319	0,438	3,042	-1,132	-0,424	-1,740	-0,015	-0,080	0,801	-0,540	0,664	-0,596	0,585
<b>V2 FB</b>	-0,662	-0,240	0,488	-0,879	-0,450	0,004	-0,043	1,288	0,818	-0,630	0,926	-1,116	0,510	1,647	0,598	1,308	-1,146
<b>V3 FF</b>	-0,372	-0,652	-1,197	-0,651	-0,879	-0,418	-0,148	0,953	0,521	0,687	-0,410	-0,495	-0,334	-0,172	-0,393	0,014	0,377
<b>V3 FSI</b>	-0,378	-0,812	-0,508	-0,647	-0,653	-0,623	-1,243	0,265	0,866	-0,309	0,007	-0,305	0,565	-0,854	-1,337	-0,968	-0,484
<b>V3 FS</b>	2,106	-0,227	-0,947	-0,303	-0,232	-0,851	-0,080	0,712	0,900	0,486	0,148	-0,659	-0,127	-0,958	-0,915	-1,321	-0,883
<b>V4 FF</b>	1,075	-0,273	0,203	-0,660	-0,779	-0,319	-1,031	-0,359	0,338	0,676	-0,272	-0,782	-0,826	-0,450	0,351	0,096	0,751
<b>V4 FS</b>	-0,878	-0,109	1,170	0,453	-0,306	2,397	1,200	0,181	-1,525	-0,875	0,805	1,626	0,761	0,718	-0,600	-0,976	-0,866
<b>V4 FK</b>	1,186	2,216	-0,216	2,426	0,776	1,072	1,029	0,551	-0,545	-2,700	-1,827	1,600	1,764	-1,107	1,191	-1,119	0,720
<b>V5 FSI</b>	-1,385	-0,531	0,541	-0,721	-0,709	0,486	-0,338	0,354	0,358	1,306	-0,647	-0,428	-1,052	-0,595	-0,612	-0,159	-0,226
<b>V5 FK</b>	1,071	-0,258	-0,409	-0,211	-0,729	1,195	-0,349	2,123	0,678	0,915	1,295	-0,629	-0,743	0,871	-1,141	0,855	-0,718
<b>V5 FB</b>	-0,476	-0,449	-0,943	-0,863	1,017	-1,162	-0,409	-0,218	0,024	0,742	0,605	-0,522	-0,737	1,327	-0,939	1,798	-0,707
<b>V6 FF</b>	0,990	0,109	-0,902	-0,220	0,916	-0,625	0,341	-0,179	0,181	0,594	-2,168	0,320	-0,517	-1,172	-0,086	-1,135	-0,736
<b>V6 FSI</b>	-0,222	-1,211	0,574	0,417	-1,149	-0,849	-0,547	-1,266	0,388	0,624	0,862	0,101	-0,208	0,582	0,268	1,722	0,314
<b>V6 FS</b>	0,380	-0,244	-0,539	0,255	1,240	-0,240	-0,806	-0,323	0,585	0,589	-0,230	-0,037	0,224	-0,280	-0,484	-0,043	-0,097
<b>V6 FB</b>	-1,404	-0,798	-0,702	-0,805	-1,026	-1,378	-0,661	-1,438	0,877	-0,258	1,659	-0,868	2,518	2,174	-0,605	1,034	0,788

## Canela direita

	<b>HRV</b>	<b>SMA</b>	<b>EAP</b>	<b>EML</b>	<b>EV</b>	<b>aMaxAP</b>	<b>aMaxML</b>	<b>aMaxV</b>	<b>aMinAP</b>	<b>aMinML</b>	<b>aMinV</b>	<b>aMinRIAP</b>	<b>aMinRIML</b>	<b>aMinRIV</b>	<b>PPvRIAP</b>	<b>PPvRIML</b>	<b>PPvRIV</b>
<b>V1 FS</b>	-0,042	-0,569	-0,368	0,507	-0,310	1,386	1,690	0,350	0,057	-0,984	-0,674	0,743	-1,572	0,114	-0,264	-0,482	0,256
<b>V2 FSI</b>	1,128	1,181	0,477	1,931	1,868	0,981	2,331	0,750	-0,193	-2,346	-0,639	0,033	-1,281	0,442	-0,360	-0,345	2,302
<b>V2 FS</b>	-1,401	2,833	1,568	-0,161	-0,645	0,466	0,041	-0,320	-1,079	-1,373	-0,166	-0,756	-0,072	-0,062	0,030	-0,310	-0,200
<b>V2 FK</b>	-0,954	0,497	-0,694	0,403	-0,827	2,208	0,572	-0,134	0,669	0,062	0,898	-0,085	0,555	-0,928	3,069	-0,817	-1,510
<b>V2 FB</b>	1,352	0,907	0,723	0,109	0,909	1,502	-0,054	3,421	-1,991	-1,429	-2,298	-1,561	-1,091	1,649	0,139	-0,046	-1,123
<b>V3 FF</b>	0,618	-0,176	-1,333	0,527	-0,569	-0,079	-0,029	0,013	-0,150	-0,124	0,045	0,585	1,208	-0,508	-0,496	-0,166	2,036

<b>V3 FSI</b>	0,239	-0,870	1,346	-0,472	1,506	0,380	0,397	0,225	-1,674	-0,696	-1,449	-0,375	-0,701	0,713	-0,683	-0,138	0,502
<b>V3 FS</b>	1,663	-0,700	0,654	-0,574	0,391	-0,873	-0,154	0,920	0,762	0,691	-0,941	1,786	0,862	0,859	-0,646	0,187	-0,608
<b>V4 FF</b>	-0,511	-0,264	-1,389	2,784	-0,395	-0,567	1,059	-0,670	0,118	0,164	-0,194	-1,189	0,944	-0,142	-0,364	0,419	-0,060
<b>V4 FS</b>	0,220	-0,971	-0,345	-0,697	-0,850	-0,785	-1,406	0,030	1,164	0,897	0,620	1,202	0,255	-1,083	0,567	-0,952	-0,417
<b>V4 FK</b>	-0,673	-0,216	-1,290	-0,598	-0,707	0,205	-0,581	-0,627	1,062	0,695	0,800	1,543	0,822	-0,400	-0,402	0,773	-0,167
<b>V5 FSI</b>	0,531	-0,196	0,816	-0,503	-0,234	-0,283	-0,066	-0,593	-1,019	-0,111	-0,072	-0,866	-1,110	0,666	0,046	1,817	-1,240
<b>V5 FK</b>	-0,474	-0,205	-0,179	-0,550	0,508	-0,397	0,186	-0,432	-1,169	0,246	-0,846	-1,029	-0,306	1,792	0,403	1,478	0,641
<b>V5 FB</b>	0,234	0,966	1,082	0,479	-0,161	-1,227	-0,901	-0,553	0,285	0,606	0,453	-1,357	-0,290	-0,500	-0,743	-0,714	-0,101
<b>V6 FF</b>	0,361	-0,977	0,767	-0,915	-0,791	-0,515	-1,053	-0,758	1,287	1,085	1,289	0,490	1,165	-1,394	-0,521	-0,912	0,703
<b>V6 FSI</b>	0,968	-1,252	-0,930	-0,677	-0,943	-1,229	0,149	-1,054	0,290	0,362	1,156	0,012	-1,050	-1,266	-0,739	-1,076	0,096
<b>V6 FS</b>	-1,384	-0,390	-1,379	-0,648	-0,913	-0,009	-0,646	-0,460	0,858	1,061	1,084	0,031	-0,120	-1,179	-0,863	-0,988	-0,501
<b>V6 FB</b>	-1,874	0,399	0,474	-0,944	2,163	-1,164	-1,536	-0,106	0,721	1,194	0,933	0,793	1,783	1,228	1,827	2,272	-0,608

## Canela esquerda

	<b>HRV</b>	<b>SMA</b>	<b>EAP</b>	<b>EML</b>	<b>EV</b>	<b>aMaxAP</b>	<b>aMaxML</b>	<b>aMaxV</b>	<b>aMinAP</b>	<b>aMinML</b>	<b>aMinV</b>	<b>aMinRIAP</b>	<b>aMinRIML</b>	<b>aMinRIV</b>	<b>PPvRIAP</b>	<b>PPvRIML</b>	<b>PPvRIV</b>
<b>V1 FS</b>	0,705	-1,046	-0,036	-0,428	-0,012	-0,614	-1,006	-0,879	-1,381	1,108	-0,547	0,743	-1,572	0,114	-0,264	-0,482	0,256
<b>V2 FSI</b>	1,729	0,752	-0,294	-0,330	-0,304	-0,023	-0,296	-0,230	-0,783	-0,121	0,078	0,033	-1,281	0,442	-0,360	-0,345	2,302
<b>V2 FS</b>	0,226	2,683	0,035	0,034	0,269	0,058	2,517	0,893	-0,359	-2,132	-0,070	-0,756	-0,072	-0,062	0,030	-0,310	-0,200
<b>V2 FK</b>	0,428	-0,110	-0,245	-0,469	-0,185	0,003	1,349	-0,248	0,567	-0,939	0,159	-0,085	0,555	-0,928	3,069	-0,817	-1,510
<b>V2 FB</b>	0,046	-0,369	-0,285	-0,413	-0,407	-0,405	0,666	-0,649	1,094	-0,052	-0,191	-1,561	-1,091	1,649	0,139	-0,046	-1,123
<b>V3 FF</b>	0,657	0,336	-0,248	-0,143	-0,339	0,808	-0,311	0,087	-1,547	-2,075	-0,814	0,585	1,208	-0,508	-0,496	-0,166	2,036
<b>V3 FSI</b>	-0,630	0,367	-0,140	-0,146	-0,038	0,852	0,181	0,153	-1,864	-0,214	-0,520	-0,375	-0,701	0,713	-0,683	-0,138	0,502
<b>V3 FS</b>	1,663	1,992	3,972	1,314	3,894	3,492	0,397	3,470	-0,894	-0,063	0,255	1,786	0,862	0,859	-0,646	0,187	-0,608
<b>V4 FF</b>	1,038	-0,227	-0,314	3,646	-0,281	-0,550	-0,988	-0,448	1,262	-1,174	-0,291	-1,189	0,944	-0,142	-0,364	0,419	-0,060
<b>V4 FS</b>	-0,242	-0,168	-0,344	-0,265	-0,170	-0,212	-0,120	0,841	0,515	0,680	-2,028	1,202	0,255	-1,083	0,567	-0,952	-0,417
<b>V4 FK</b>	-0,788	0,148	-0,258	-0,361	-0,459	0,075	0,952	-0,500	0,064	-0,027	1,208	1,543	0,822	-0,400	-0,402	0,773	-0,167
<b>V5 FSI</b>	-0,988	-0,570	-0,236	-0,463	-0,365	0,091	-0,824	-0,594	-0,074	0,817	1,054	-0,866	-1,110	0,666	0,046	1,817	-1,240
<b>V5 FK</b>	-0,777	0,003	0,072	-0,024	0,346	-0,382	-0,216	-0,139	0,169	0,238	1,116	-1,029	-0,306	1,792	0,403	1,478	0,641
<b>V5 FB</b>	0,386	-0,399	-0,305	-0,158	-0,380	-0,457	0,892	-0,402	1,557	0,646	0,199	-1,357	-0,290	-0,500	-0,743	-0,714	-0,101
<b>V6 FF</b>	-0,218	-0,779	-0,362	-0,442	-0,323	-1,021	-1,328	0,170	1,133	0,570	-1,077	0,490	1,165	-1,394	-0,521	-0,912	0,703
<b>V6 FSI</b>	-0,385	-1,246	-0,335	-0,449	-0,335	-0,771	-0,886	-0,884	-0,061	1,059	-0,621	0,012	-1,050	-1,266	-0,739	-1,076	0,096
<b>V6 FS</b>	-0,440	-0,471	-0,361	-0,513	-0,391	-0,683	-1,024	-0,079	0,734	1,103	-0,342	0,031	-0,120	-1,179	-0,863	-0,988	-0,501
<b>V6 FB</b>	-2,410	-0,898	-0,316	-0,390	-0,519	-0,259	0,047	-0,563	-0,134	0,575	2,431	0,793	1,783	1,228	1,827	2,272	-0,608

## Marcha normal com *fall slip*:

### Cintura

	<i>HRAP</i>	<i>HRV</i>	<i>SMA</i>	<i>EAP</i>	<i>EV</i>	<i>aMaxAP</i>	<i>aMaxML</i>	<i>aMaxV</i>	<i>aMinAP</i>	<i>aMinML</i>	<i>aMinV</i>	<i>aMinRIAP</i>	<i>aMinRIML</i>	<i>aMinRIV</i>	<i>PPvRIAP</i>	<i>PPvRIML</i>	<i>PPvRIV</i>
<i>V1</i>	-1,154	-0,753	-0,497	-0,335	-0,408	0,106	-0,777	-0,375	0,445	-0,027	0,393	-0,408	1,276	0,566	0,475	0,035	-0,379
<i>V2</i>	0,215	-0,790	0,390	2,789	1,837	1,607	1,790	2,187	-1,400	-0,427	-1,604	-0,210	-0,193	-0,380	0,706	0,130	1,304
<i>V3</i>	-0,157	0,348	-1,246	0,108	-0,451	-0,062	0,587	-0,620	-0,933	-2,486	0,346	-0,856	0,766	-0,058	0,175	0,065	-0,123
<i>V4</i>	-0,348	-0,933	0,221	0,402	2,194	1,463	1,516	1,719	-0,887	-0,201	-2,358	0,000	0,329	2,171	-0,033	-0,001	-0,648
<i>V5</i>	-0,551	-0,688	-0,879	-0,057	-0,416	0,398	0,396	-0,424	-1,564	0,069	0,296	-0,969	-0,626	-0,143	-1,089	2,538	-0,824
<i>V6</i>	-0,839	-0,797	-0,561	-0,201	-0,450	0,123	-0,350	-0,465	0,351	0,400	0,524	2,347	0,327	-0,756	1,098	0,064	0,031
<i>V1 FS</i>	0,401	1,998	-0,310	-0,875	-0,467	-1,461	-0,469	-0,247	0,752	0,770	0,429	1,164	-1,358	-1,133	-0,233	-0,753	-0,888
<i>V2 FS</i>	1,964	1,515	2,354	-0,347	-0,438	0,129	0,093	-0,423	0,314	-0,602	0,335	-0,527	-1,891	0,268	1,919	0,151	2,395
<i>V3 FS</i>	-0,399	0,561	0,599	-0,761	-0,464	-0,784	-1,202	-0,443	0,715	0,376	0,575	-0,724	-0,227	-1,274	-1,230	-1,399	-0,507
<i>V4 FS</i>	-0,774	-0,255	-0,712	-0,646	-0,488	-1,524	-1,205	-0,950	1,038	1,247	0,671	0,557	1,242	1,067	-0,946	-0,980	-0,494
<i>V6 FS</i>	1,641	-0,205	0,640	-0,077	-0,448	0,003	-0,381	0,041	1,167	0,882	0,392	-0,375	0,354	-0,328	-0,841	0,150	0,132

### Coxa direita

	<i>HRAP</i>	<i>HRV</i>	<i>SMA</i>	<i>EAP</i>	<i>EV</i>	<i>aMaxAP</i>	<i>aMaxML</i>	<i>aMaxV</i>	<i>aMinAP</i>	<i>aMinML</i>	<i>aMinV</i>	<i>aMinRIAP</i>	<i>aMinRIML</i>	<i>aMinRIV</i>	<i>PPvRIAP</i>	<i>PPvRIML</i>	<i>PPvRIV</i>
<i>V1</i>	-1,362	1,079	0,180	-0,070	1,205	0,420	2,555	0,221	-1,029	-0,219	-1,562	-0,408	1,276	0,566	0,475	0,035	-0,379
<i>V2</i>	-0,798	-0,929	-0,649	2,598	-0,233	2,519	0,629	-0,236	0,059	-0,806	0,284	-0,210	-0,193	-0,380	0,706	0,130	1,304

<b>V3</b>	-0,021	0,128	-0,547	-0,262	-0,283	-0,332	-0,320	-0,298	-0,118	-1,125	-0,303	-0,856	0,766	-0,058	0,175	0,065	-0,123
<b>V4</b>	-0,213	-0,306	-0,651	0,858	-0,342	0,293	-0,285	-0,224	-1,307	0,218	-1,527	0,000	0,329	2,171	-0,033	-0,001	-0,648
<b>V5</b>	-1,428	-0,782	-0,482	0,156	1,845	0,129	0,687	2,919	-1,885	0,028	0,064	-0,969	-0,626	-0,143	-1,089	2,538	-0,824
<b>V6</b>	0,011	1,706	-0,727	0,001	1,019	-0,355	-0,435	0,041	0,620	0,030	-0,042	2,347	0,327	-0,756	1,098	0,064	0,031
<b>V1 FS</b>	1,446	1,206	0,086	-0,715	-0,586	-0,707	-0,170	-0,357	0,836	-0,208	1,516	1,164	-1,358	-1,133	-0,233	-0,753	-0,888
<b>V2 FS</b>	-0,043	0,216	2,819	-0,402	-0,869	0,470	-0,116	-0,369	0,066	-1,741	-0,289	-0,527	-1,891	0,268	1,919	0,151	2,395
<b>V3 FS</b>	1,302	-1,579	-0,020	-0,836	-1,120	-0,754	-0,982	-0,640	0,791	1,194	1,609	-0,724	-0,227	-1,274	-1,230	-1,399	-0,507
<b>V4 FS</b>	1,269	-0,558	-0,238	-0,950	0,488	-1,305	-0,730	-0,525	0,899	1,187	-0,029	0,557	1,242	1,067	-0,946	-0,980	-0,494
<b>V6 FS</b>	-0,162	-0,182	0,229	-0,377	-1,124	-0,380	-0,832	-0,534	1,068	1,441	0,278	-0,375	0,354	-0,328	-0,841	0,150	0,132

## Coxa esquerda

	<i>HRAP</i>	<i>HRV</i>	<i>SMA</i>	<i>EAP</i>	<i>EV</i>	<i>aMaxAP</i>	<i>aMaxML</i>	<i>aMaxV</i>	<i>aMinAP</i>	<i>aMinML</i>	<i>aMinV</i>	<i>aMinRIAP</i>	<i>aMinRIML</i>	<i>aMinRIV</i>	<i>PPvRIAP</i>	<i>PPvRIML</i>	<i>PPvRIV</i>
<b>V1</b>	-0,261	0,718	-0,476	0,398	0,155	-0,296	-0,122	1,788	-0,313	-1,358	-0,838	-0,408	1,276	0,566	0,475	0,035	-0,379
<b>V2</b>	-0,141	-1,356	-0,453	2,108	2,872	1,619	2,367	0,885	0,040	-0,645	-0,164	-0,210	-0,193	-0,380	0,706	0,130	1,304
<b>V3</b>	0,257	0,415	-0,971	-0,614	0,240	-0,546	-0,544	1,151	0,904	-1,970	-0,413	-0,856	0,766	-0,058	0,175	0,065	-0,123
<b>V4</b>	-0,671	-0,531	-0,563	0,575	-0,143	-0,249	0,837	0,723	-1,488	-0,158	0,951	0,000	0,329	2,171	-0,033	-0,001	-0,648
<b>V5</b>	-0,688	-0,030	-0,973	-0,708	-0,425	-0,304	-0,505	0,237	0,836	0,354	-0,005	-0,969	-0,626	-0,143	-1,089	2,538	-0,824
<b>V6</b>	0,917	-0,390	-0,441	1,338	-0,056	2,309	1,002	-0,618	-1,983	-0,339	-2,328	2,347	0,327	-0,756	1,098	0,064	0,031
<b>V1 FS</b>	-0,929	-0,777	0,041	-0,121	-0,682	-0,337	-0,632	-1,235	-0,462	0,787	0,737	1,164	-1,358	-1,133	-0,233	-0,753	-0,888
<b>V2 FS</b>	-0,158	-0,460	2,575	-0,570	-0,429	-0,674	-0,482	-0,855	0,486	0,807	0,228	-0,527	-1,891	0,268	1,919	0,151	2,395
<b>V3 FS</b>	-0,123	2,338	0,393	-0,993	-0,580	-0,722	-0,706	-0,546	1,000	1,004	0,480	-0,724	-0,227	-1,274	-1,230	-1,399	-0,507

<b>V4 FS</b>	-0,769	-0,578	0,488	-0,513	-0,591	-0,180	-0,248	-0,694	0,098	0,475	1,396	0,557	1,242	1,067	-0,946	-0,980	-0,494
<b>V6 FS</b>	2,567	0,651	0,380	-0,900	-0,360	-0,620	-0,966	-0,835	0,883	1,044	-0,045	-0,375	0,354	-0,328	-0,841	0,150	0,132

## Canela direita



	<i>HRAP</i>	<i>HRV</i>	<i>SMA</i>	<i>EAP</i>	<i>EV</i>	<i>aMaxAP</i>	<i>aMaxML</i>	<i>aMaxV</i>	<i>aMinAP</i>	<i>aMinML</i>	<i>aMinV</i>	<i>aMinRIAP</i>	<i>aMinRIML</i>	<i>aMinRIV</i>	<i>PPvRIAP</i>	<i>PPvRIML</i>	<i>PPvRIV</i>
<b>V1</b>	-1,011	-0,779	0,180	-0,182	1,468	0,548	-0,039	1,438	0,186	0,065	-2,835	0,377	-0,650	2,596	0,394	0,788	-0,621
<b>V2</b>	-0,114	1,275	-0,649	0,057	-0,522	1,977	0,052	-0,560	0,356	-0,308	0,413	0,102	2,480	-0,577	-0,398	-0,899	2,317
<b>V3</b>	2,094	1,060	-0,547	2,751	0,526	0,618	2,873	-0,281	-2,000	-2,031	-0,313	-1,534	0,119	0,610	0,720	0,880	-0,635
<b>V4</b>	-0,257	-1,517	-0,651	-0,337	1,909	0,032	-0,186	2,023	0,448	0,551	0,121	0,893	-0,604	-0,168	-0,117	-0,043	-1,116
<b>V5</b>	-0,798	0,016	-0,482	0,743	0,811	0,374	-0,043	0,322	-1,943	-1,052	-0,057	-1,521	0,513	-0,140	-0,420	0,341	0,107
<b>V6</b>	0,550	1,325	-0,727	-0,564	-0,630	-0,820	-0,100	-0,792	0,682	0,828	0,209	1,251	0,716	-0,272	-0,834	0,122	-0,864
<b>V1 FS</b>	-1,709	-0,190	0,086	-0,570	-0,677	0,724	-0,028	-0,133	0,355	-0,388	0,243	0,205	-1,299	-0,127	0,059	-0,162	1,212
<b>V2 FS</b>	0,300	-0,981	2,819	-0,192	-0,754	-0,142	-0,475	-0,942	-0,028	-0,679	0,435	-1,052	-0,483	-0,257	0,802	0,317	0,343
<b>V3 FS</b>	0,704	0,802	-0,020	-0,371	-0,515	-1,402	-0,528	0,555	0,592	0,862	0,142	1,080	0,024	0,421	-0,910	1,701	-0,439
<b>V4 FS</b>	0,262	-0,038	-0,238	-0,566	-0,801	-1,319	-0,867	-0,519	0,728	1,016	0,733	0,590	-0,306	-1,007	2,163	-1,472	-0,073
<b>V6 FS</b>	-0,022	-0,972	0,229	-0,768	-0,816	-0,589	-0,661	-1,112	0,625	1,138	0,909	-0,392	-0,510	-1,078	-1,459	-1,573	-0,233

## Canela esquerda

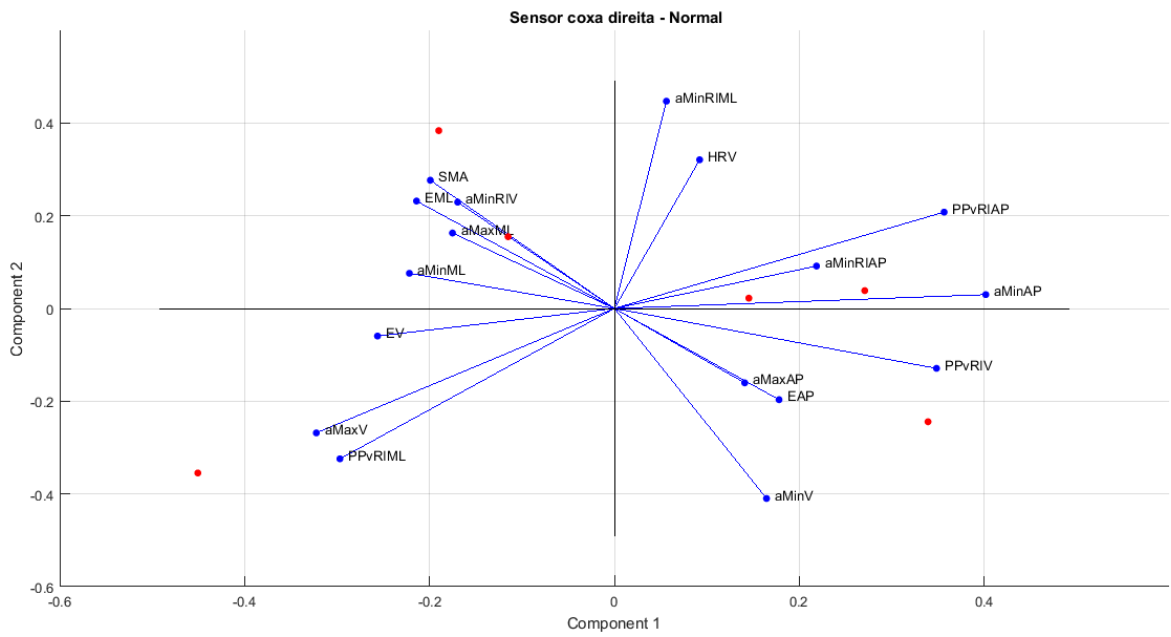

	<i>HRAP</i>	<i>HRV</i>	<i>SMA</i>	<i>EAP</i>	<i>EV</i>	<i>aMaxAP</i>	<i>aMaxML</i>	<i>aMaxV</i>	<i>aMinAP</i>	<i>aMinML</i>	<i>aMinV</i>	<i>aMinRIAP</i>	<i>aMinRIML</i>	<i>aMinRIV</i>	<i>PPvRIAP</i>	<i>PPvRIML</i>	<i>PPvRIV</i>
<b>V1</b>	2,000	-0,227	-0,332	0,017	0,321	0,934	-0,166	2,753	-1,574	0,482	-1,415	0,377	-0,650	2,596	0,394	0,788	-0,621
<b>V2</b>	-1,303	0,562	-0,849	-0,278	-0,190	-0,020	0,790	-0,269	-0,176	-2,000	-0,503	0,102	2,480	-0,577	-0,398	-0,899	2,317
<b>V3</b>	1,331	0,969	-0,720	-0,116	-0,163	2,182	2,536	0,019	-0,813	-1,339	0,420	-1,534	0,119	0,610	0,720	0,880	-0,635
<b>V4</b>	-0,376	-1,358	-0,898	-0,324	-0,519	-0,379	-0,102	-0,542	-0,714	0,632	-0,212	0,893	-0,604	-0,168	-0,117	-0,043	-1,116
<b>V5</b>	-1,360	-1,792	-0,504	-0,243	0,036	-0,361	-0,025	-0,099	-0,829	-1,116	-1,016	-1,521	0,513	-0,140	-0,420	0,341	0,107
<b>V6</b>	-0,351	-0,697	-0,591	-0,448	-0,315	-0,263	-0,782	-0,608	0,659	0,318	-0,185	1,251	0,716	-0,272	-0,834	0,122	-0,864
<b>V1 FS</b>	-0,400	0,770	-0,252	-0,281	-0,456	-0,937	-0,901	-0,866	-0,338	0,831	0,582	0,205	-1,299	-0,127	0,059	-0,162	1,212
<b>V2 FS</b>	0,353	0,382	2,085	-0,223	-0,217	-0,596	0,469	-0,235	0,613	0,073	1,172	-1,052	-0,483	-0,257	0,802	0,317	0,343
<b>V3 FS</b>	0,090	1,545	1,652	2,973	2,873	1,144	-0,356	0,682	0,116	0,557	1,575	1,080	0,024	0,421	-0,910	1,701	-0,439
<b>V4 FS</b>	-0,240	0,003	0,299	-0,531	-0,591	-0,733	-0,557	-0,254	1,427	0,731	-1,252	0,590	-0,306	-1,007	2,163	-1,472	-0,073
<b>V6 FS</b>	0,257	-0,157	0,108	-0,545	-0,779	-0,971	-0,908	-0,581	1,631	0,830	0,835	-0,392	-0,510	-1,078	-1,459	-1,573	-0,233







# ANEXO IV - REPRESENTAÇÃO DOS BIPLOTS PARA A MARCHA NORMAL


































# ANEXO V – REPRESENTAÇÃO DOS BIPLOTS PARA AS QUEDAS


























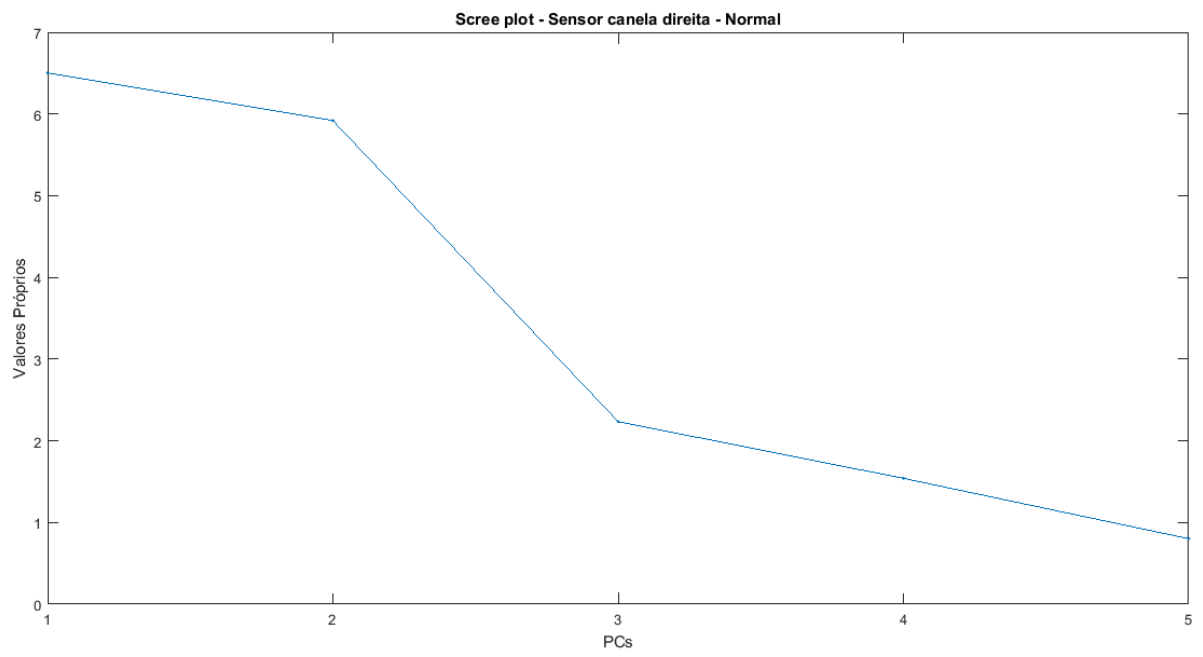




# ANEXO VI – REPRESENTAÇÃO DOS *SCREE PLOTS* PARA A ANÁLISE DA MARCHA NORMAL E DAS QUEDAS

## Marcha normal














## Quedas

















# ANEXO VII – REPRESENTAÇÃO DOS BIPLOTS PARA A ANÁLISE DA MARCHA NORMAL COM *FALL SLIP*





















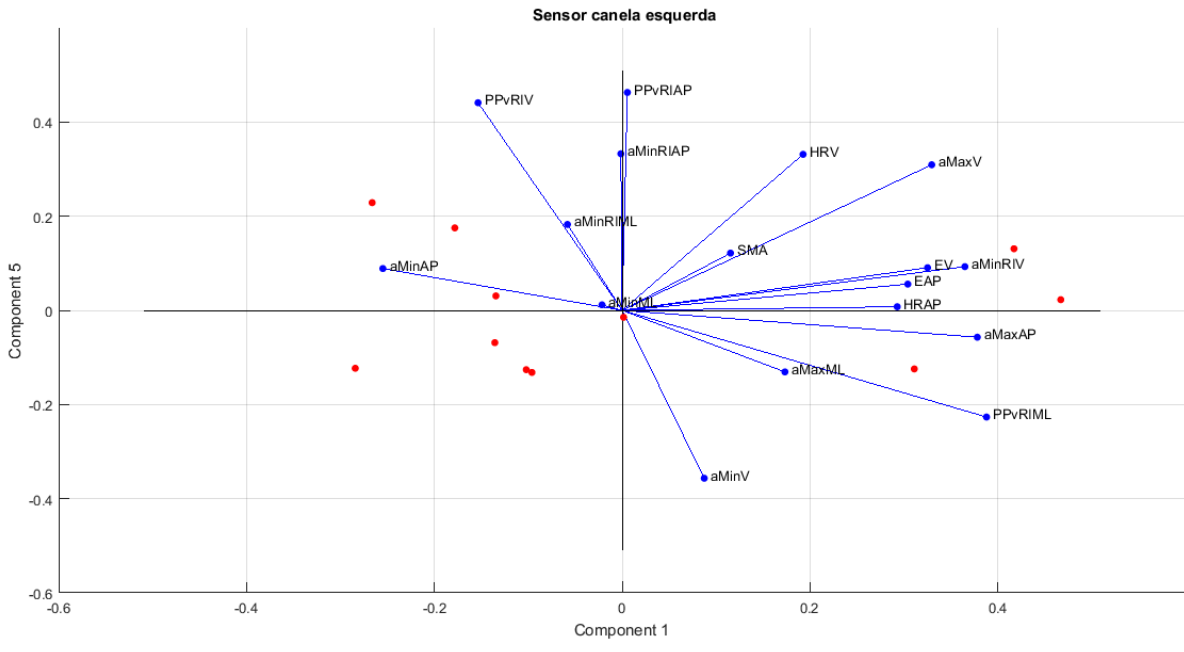




















## ANEXO VIII – REPRESENTAÇÃO DOS SCREE PLOTS DA ANÁLISE DA MARCHA NORMAL COM *FALL SLIP*

