

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

CRISTIAN LOPES

**IDENTIFICAÇÃO DE PESSOAS ATRAVÉS DA VIBRAÇÃO
MECÂNICA NO SOLO EM FUNÇÃO DO IMPACTO
CAUSADO PELA MARCHA HUMANA: UM ESTUDO DE
CASO COM O USO DE GEOFONE E MÁQUINA DE
VETORES DE SUPORTE**

Porto Alegre

2018

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

**IDENTIFICAÇÃO DE PESSOAS ATRAVÉS DA VIBRAÇÃO
MECÂNICA NO SOLO EM FUNÇÃO DO IMPACTO
CAUSADO PELA MARCHA HUMANA: UM ESTUDO DE
CASO COM O USO DE GEOFONE E MÁQUINA DE
VETORES DE SUPORTE**

Projeto de Diplomação apresentado ao
Departamento de Engenharia Elétrica da Universidade
Federal do Rio Grande do Sul, como parte dos
requisitos para Graduação em Engenharia Elétrica.

ORIENTADOR: Prof. Dr. Alexandre Balbinot

Porto Alegre

2018

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

CRISTIAN LOPES

**IDENTIFICAÇÃO DE PESSOAS ATRAVÉS DA VIBRAÇÃO
MECÂNICA NO SOLO EM FUNÇÃO DO IMPACTO
CAUSADO PELA MARCHA HUMANA: UM ESTUDO DE
CASO COM O USO DE GEOFONE E MÁQUINA DE
VETORES DE SUPORTE**

Este projeto foi julgado adequado para fazer jus aos créditos da Disciplina de “Projeto de Diplomação”, do Departamento de Engenharia Elétrica e aprovado em sua forma final pelo Orientador e pela Banca Examinadora.

Orientador: _____

Prof. Dr. Alexandre Balbinot, UFRGS

Doutor pela UFRGS – Porto Alegre, Brasil

Banca Examinadora:

Ma. Karina de Oliveira Alves de Moura, UFRGS

Doutoranda no PPGEE, UFRGS – Porto Alegre, Brasil

Profa. Dra. Leia Bernardi Bagesteiro, UFRGS

Doutora pela UNIS – Guildford, Reino Unido

Prof. Dr. Rafael Antônio Comparsi Laranja, UFRGS

Doutor pela UFRGS – Porto Alegre, Brasil

Porto Alegre, janeiro de 2018.

DEDICATÓRIA

Dedico este trabalho à minha mãe, da mesma forma que ela se dedicou a mim em todos esses anos. Dedico este trabalho ao meu esforço para conclusão do mesmo neste meu 23º ano de vida. Finalmente, compartilho este trabalho e dedico o mesmo a toda forma de conhecimento livre e aberto, como todo o conhecimento deveria ser.

AGRADECIMENTOS

Agradeço ao Prof. Dr. Eng. Alexandre Balbinot, pelo tempo e esforço compartilhados na orientação deste trabalho.

Agradeço aos voluntários Arthur, Gyrão, Leandro, Leoni e Wagner que além de participarem da coleta de dados, participaram diariamente no meu crescimento profissional neste ano.

Aos voluntários para a coleta de dados do Laboratório IEE, André, Badaraco, Gabriela e Karina.

Aos amigos e colegas Anelize, Augusto, Carlos, Gustavo, Juliana e Vitor que além de colaborarem na coleta de dados, participaram de tantos outros momentos vividos na época da graduação.

Por fim, agradeço ao Jonas, por compartilhar comigo dúvidas, choros, desesperos, lamentações e até alegrias nestes incríveis e longos 5 anos e meio de graduação.

RESUMO

A utilização da marcha humana como característica biométrica comportamental em sistemas de segurança que realizam a identificação de pessoas apresenta um grande potencial e é um tópico que tem ganhado destaque, recentemente, na área de pesquisa biométrica. O presente trabalho explora a possibilidade de identificação de pessoas através da vibração mecânica gerada no solo pela marcha humana. Para tanto, um sistema de instrumentação composto por um conjunto de 5 geofones, seus respectivos condicionadores de sinais e um módulo de aquisição A/D é proposto para a medição da vibração mecânica gerada no solo pela marcha. Com este sistema, a coleta de uma base de dados com 50 caminhadas individuais com duração de 5 segundos de 12 usuários é realizada. Essa base de dados é posteriormente utilizada para o estudo da possibilidade de identificação de pessoas através da marcha. São treinados modelos SVM para a classificação de um passo a fim de avaliar a influência na taxa de acerto das características utilizadas e da quantidade e posição dos sensores utilizados como entrada do sistema. Por fim, o melhor classificador é escolhido e testado em dados que não foram utilizados na etapa de treinamento. Os resultados obtidos mostram que a quantidade e posição dos sensores utilizados influenciam na taxa de acerto, sendo o melhor classificador obtido com a utilização dos 5 sensores. Ainda, os resultados apresentam que a utilização em conjunto de características no domínio do tempo e no domínio da frequência obtém uma melhor taxa de acerto do que a utilização de características em apenas um domínio. O classificador obtido apresenta uma taxa de acerto na classificação de um passo de 87,0% quando testado no subconjunto de teste. Avaliando o modelo quando são classificados apenas os passos que apresentam uma predição com nível de confiança maior que 50%, consegue-se obter uma taxa de acerto de 93,5%. Finalmente, a avaliação da classificação de uma caminhada de 5 segundos do usuário apresenta uma taxa de acerto de 99,2%. Dessa forma, a utilização da vibração gerada pela marcha humana na identificação de pessoas se mostra viável e de grande potencial para sistemas biométricos.

Palavras-chaves: Marcha Humana, Identificação de Pessoas, Máquina de Vetores de Suporte, Vibração Estrutural, Geofone.

ABSTRACT

The use of human gait as a biometric behavioral characteristic in security systems that perform people identification has a great potential and has been attracting attention recently in biometric research. This work explores the possibility of people identification through footstep induced ground vibration. With this aim, an instrumentation system consisting of a set of 5 geophones, their signal conditioners and an A/D acquisition module is proposed for measurement of the mechanical vibration generated by human gait. With this system, data acquisition of 50 walks with 5 seconds duration of 12 users is performed. This database is used to study the possibility of people identification through their walking pattern. SVM models are trained for footstep classification in order to evaluate influence in accuracy rate of features and sensors quantity and position used as input of the system. Finally, the best classifier is chosen and tested on data that is not used in the training stage. The results obtained show that the quantity and position of the sensors influence the accuracy rate, being the best classifier obtained with the use of 5 sensors. Furthermore, the results show that using time domain features together with frequency domain features obtain a better accuracy rate than using features in only one domain. The chosen classifier shows an accuracy rate in step level classification of 87.0% when tested in test set. By evaluating the model when only the steps with confidence level higher than 50% are classified, it is obtained an accuracy rate of 93.5%. Finally, the evaluation of the classification of traces with 5 seconds duration of the user presents an accuracy rate of 99.2%. Thus, the use of the vibration generated by human gait in people identification is shown to be viable and of great potential for biometric systems.

Keywords: Human Gait, People Identification, Support Vector Machine, Structural Vibration, Geophone.

SUMÁRIO

1	INTRODUÇÃO.....	13
2	REVISÃO BIBLIOGRÁFICA.....	16
2.1.	Biometria e Identificação através da Marcha.....	16
2.2.	Sensores Sísmicos Utilizados na Área.....	22
2.3.	Máquina de Vetores de Suporte.....	29
3	MÉTODO EXPERIMENTAL.....	39
3.1.	Geofone e Projeto do Condicionador de Sinais.....	41
3.2.	Procedimento de Calibração dos Circuitos de Condicionamento.....	47
3.3.	Procedimento para a Coleta de Dados.....	49
3.4.	Metodologia de Segmentação e Extração de Características.....	51
3.5.	Implementação do Modelo SVM para Identificação de Pessoas.....	58
3.6.	Procedimento para Comparação dos Classificadores.....	63
4	RESULTADOS E DISCUSSÕES.....	65
4.1.	Simulação do Circuito de Condicionamento.....	65
4.2.	Calibração dos Circuitos de Condicionamento.....	66
4.3.	Segmentação e Extração de Características.....	69
4.4.	Comparação dos Classificadores.....	73
4.5.	Avaliação do Modelo no Conjunto de Teste.....	79
5	CONCLUSÕES.....	85
6	PROPOSTA PARA TRABALHOS FUTUROS.....	88
	REFERÊNCIAS BIBLIOGRÁFICAS.....	90
	ANEXO A: Função para detecção de picos por Eli Billauer.....	93

LISTA DE FIGURAS

Figura 1 – Típica composição de um Sistema Biométrico.....	17
Figura 2 - Ciclo da marcha normal e suas etapas.	19
Figura 3 - Representação esquemática das dimensões da passada no plano bi-dimensional. ...	20
Figura 4 – Típica força de reação do solo gerada por um passo	20
Figura 5 - Princípio de funcionamento de um sensor inercial.	24
Figura 6 – Típica resposta simulada em frequência da transmissibilidade.	25
Figura 7 - (a) Típica faixa dinâmica em frequência de sensores inerciais e (b) valores (em Euros) por resolução dos respectivos sensores/transdutores.	28
Figura 8 – Ilustração de um problema de classificação binária com SVM.	31
Figura 9 - Diagrama de blocos do sistema de instrumentação proposto para a coleta de dados.	39
Figura 10 - Diagrama de blocos do sistema para treinamento e teste do modelo SVM.....	40
Figura 11 - Resposta em frequência em circuito aberto do geofone RTC-4.5Hz-395.	42
Figura 12 – Esquemático do circuito de alimentação.....	43
Figura 13 - Esquemático do circuito de condicionamento do sinal do geofone.....	45
Figura 14 - Cadeia de Medidas Teórica do sistema de instrumentação proposto.	47
Figura 15 - (a) Posição dos geofones e local de caminhada; (b) Local do ensaio.....	50
Figura 16 - Sinal típico de marcha adquirido com o sistema.	52
Figura 17 - Segmentação de um passo com janelas de 0,1 segundos.....	54
Figura 18 - Fluxograma da etapa de segmentação dos sinais.....	55
Figura 19 - Fluxograma da etapa de extração de características.	57
Figura 20 - Separação dos dados em treinamento e validação.	59
Figura 21 - Fluxograma da etapa de treinamento e validação de um modelo.	61
Figura 22 - Fluxograma da etapa de teste do modelo.....	62
Figura 23 – Resposta em frequência simulada do circuito de condicionamento.....	66
Figura 24 - Resposta em frequência experimental do circuito de condicionamento.....	67
Figura 25 - Cadeia de Medidas Experimental.	69
Figura 26 - (a) Número de passos segmentados por sujeito; (b) Número de passos segmentados por gravação.....	70
Figura 27 - Típico exemplo de passos segmentados em uma gravação com geofone RTC-4.5Hz-395.	71
Figura 28 - FFT em dB e localização dos picos da FFT do passo P5 da Figura 27.	72
Figura 29 - (a) Sinal decimado com fator de 25; (b) Localização dos picos do sinal no tempo.	72
Figura 30 - Taxa de acerto média por sensores utilizados.....	74
Figura 31 - Passo P4 da Figura 27 coletado com (a) sensor 1; (b) sensor 2; (c) sensor 3; (d) sensor 4; (e) sensor 5.	76
Figura 32 - Taxa de acerto média por características utilizadas.....	78
Figura 33 - Matriz de confusão na avaliação do modelo no conjunto de teste.....	80

Figura 34 - Taxa de acerto e taxa de segmentos classificados por limiar do nível de confiança.	82
Figura 35 - Quantidade de passos por gravação no conjunto de teste.....	83
Figura 36 - Matriz de confusão na avaliação do modelo classificando caminhadas do conjunto de teste.	84

LISTA DE TABELAS

Tabela 1 - Amplitudes de saída para diferentes amplitudes de entrada e ganho obtido a partir de uma regressão linear com cada conjunto de pontos.....	68
Tabela 2 - Taxa de acerto dos classificadores com relação aos sensores utilizados.	73
Tabela 3 - Taxa de acerto dos classificadores com relação às características utilizadas.....	77

LISTA DE ABREVIATURAS

ADC: *Analog to Digital Converter*

DAQ: *Data Acquisition*

EER: *Equal Error Rate*

FBA: *Force Balance Accelerometer*

HMM: *Hidden Markov Model*

kNN: *k-Nearest Neighbor*

MEMS: *Micro-electromechanical Systems*

MLP: *Multilayer Perceptron*

PCA: *Principal Component Analysis*

PID: *Proporcional Integral Derivativo*

RBF: *Radial Basis Function*

RNA: *Rede Neural Artificial*

SV: *Support Vector*

SVM: *Support Vector Machine*

1 INTRODUÇÃO

A Biometria é uma área que permite o reconhecimento, a verificação ou a identificação de pessoas baseado em suas características físicas ou comportamentais consideradas únicas. As características físicas utilizadas em Métodos Biométricos com maior destaque na atualidade são: a impressão digital, a face, a íris e a retina. No caso das características comportamentais, podem ser citadas: a voz, a maneira de andar e a assinatura. Portanto, um sistema biométrico é um sistema de reconhecimento de padrões que compara características discriminatórias de dados adquiridos com características de dados armazenados. Assim, todo Sistema Biométrico tipicamente é constituído por quatro módulos: módulo de aquisição de dados, módulo de extração de características, módulo de classificação e módulo de dados armazenados (UNAR *et al.*, 2014).

Com o aumento da criminalidade, assim como, da necessidade de proporcionar ambientes mais seguros, os Sistemas Biométricos têm recebido maior interesse por parte da sociedade. Aliado a isso, cresce também a necessidade de sistemas em tempo real e menos invasivos. Nesse cenário, a utilização da marcha humana em Sistemas Biométricos de segurança e vigilância é considerada uma das áreas de estudo emergentes na atualidade (BOUCHRIKA, 2015).

A marcha humana é o resultado de um processo envolvendo o cérebro, a medula espinhal, os nervos periféricos, os músculos, os ossos e as articulações (WITTLE, 2007). Dessa forma, é possível esperar que cada pessoa apresente alguma característica específica durante o ato da caminhada, podendo ser, então, utilizada como uma característica comportamental em Sistemas Biométricos. De forma geral, pode-se separar esta área da Biometria em três grandes núcleos de pesquisas: escolha do sensor utilizado e variável física

medida; pesquisa da melhor característica descritiva da marcha; e escolha do melhor classificador (DERLAKTA & BOGDAN, 2015).

Segundo GAFUROV (2007), são três os tipos de métodos de captura de dados para caracterizar a marcha para a identificação de pessoas, sendo eles: métodos baseados em visão computacional, métodos baseados em sensores portados pela pessoa e métodos baseados em sensores dispostos no piso. Em relação a esses três grupos, os que utilizam visão computacional necessitam de um campo de visão sem obstrução e os que utilizam sensores portados pela pessoa necessitam que o usuário carregue um dispositivo consigo para a coleta de dados. Já os métodos baseados em sensores dispostos no piso possibilitam uma forma de coleta de dados sem obstrução e a distância (PAN *et al.*, 2017).

Segundo VERA-RODRIGUEZ *et al.* (2013), em métodos baseados em sensores dispostos no piso constata-se, usualmente, a utilização de dois tipos de sensores: sensores *switch* e sensores de pressão. Contudo, esses sensores necessitam de uma instalação mais elaborada no piso ou local de interesse. Com esta motivação, propõe-se, neste trabalho, a utilização de sensores de baixo custo instalados de forma esparsa no piso para caracterizar vibrações mecânicas devido à marcha humana.

Com relação aos classificadores, segundo os resultados do trabalho de (YUN, 2011) e do trabalho de (SUUTALA & RÖNING, 2008) os melhores resultados obtidos com classificadores na identificação de pessoas através da análise da marcha foram com Rede Neural Perceptron Multicamadas (MLP) e Máquina de Vetores de Suporte (SVM). Dentre esses dois classificadores, as SVMs foram selecionadas por este trabalho, visto que, a determinação dos coeficientes do modelo é um problema convexo (BISHOP, 2013). Ainda, as SMVs possuem apenas um parâmetro ajustável, além do próprio *kernel*, no momento do treinamento do modelo (CAMPBELL & CRISTIANINI, 1998).

Em função das colocações anteriores, o objetivo principal deste trabalho é avaliar a possibilidade de identificação de pessoas a partir de medidas da vibração gerada no solo pela marcha humana. Em um primeiro momento, propõe-se a criação e calibração de um sistema de instrumentação composto por geofones capaz de medir a vibração no solo gerada por passos. Em seguida, propõe-se criar uma base de dados com sinais de vibração coletados a partir de caminhadas individuais de pessoas em uma área instrumentada. Por fim, o trabalho visa utilizar esses sinais para a criação e comparação de modelos SVM capazes de identificar a pessoa associada à caminhada.

2 REVISÃO BIBLIOGRÁFICA

Neste capítulo será abordada uma revisão de conceitos básicos de Biometria, Sensores Sísmicos e Máquina de Vetores de Suporte. Esses conceitos serão abordados em função da área proposta de aplicação deste trabalho, ou seja, a área de detecção de passos e identificação de pessoas pelo formato da marcha executada. Serão apresentados ainda sensores e métodos utilizados, além de resultados de trabalhos que já foram realizados na respectiva área de interesse desta monografia.

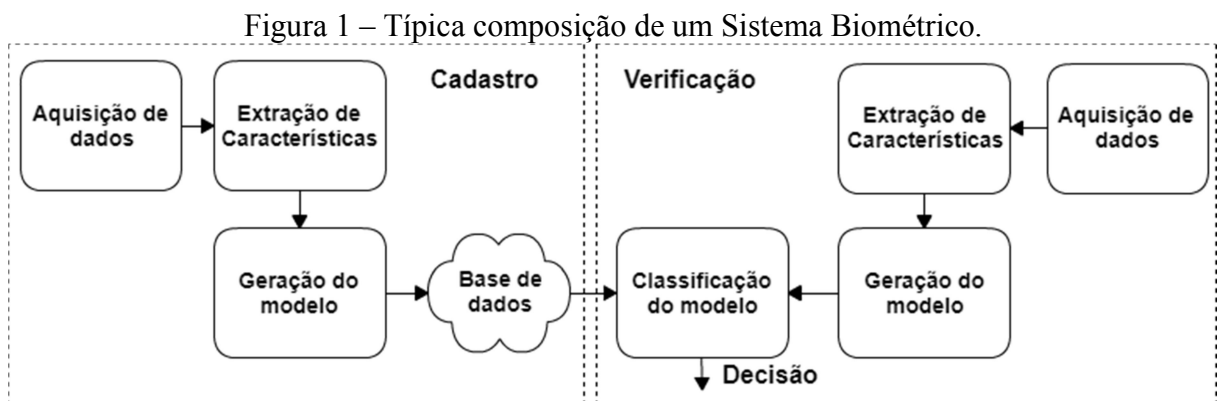
2.1. BIOMETRIA E IDENTIFICAÇÃO ATRAVÉS DA MARCHA

Sistemas de segurança normalmente requerem procedimentos de reconhecimento pessoal confiáveis para confirmar ou determinar a identidade de uma pessoa. Nesse sentido, tipicamente são utilizados três tipos de métodos na autenticação de pessoas: métodos baseados em conhecimento, como por exemplo, senhas de acesso; métodos baseados em propriedade, como por exemplo, cartões de acesso; e métodos baseados em características, como por exemplo, impressão digital. Métodos baseados em conhecimento e propriedade podem ser esquecidos, perdidos ou roubados, enquanto que métodos baseados em características são, geralmente, muito mais difíceis de serem falsificados. Assim, a utilização de sistemas de segurança baseados em Biometria é uma área de interesse crescente (GAFUROV, 2007).

A Biometria é uma área que permite a verificação, a identificação ou o reconhecimento de pessoas baseado em suas características físicas ou comportamentais consideradas únicas. Entende-se por verificação quando o usuário submete uma Característica Biométrica ao sistema afirmando possuir uma identidade particular e o sistema faz uma comparação *1 versus 1* validando ou não a identidade do usuário. Já a identificação ocorre quando o sistema tenta reconhecer o usuário através de uma Característica Biométrica

fazendo uma comparação *I versus N* e gerando como resposta a identidade do usuário. O reconhecimento é uma extensão da identificação, em que o sistema faz uma comparação *I versus N* e retorna como resposta se o indivíduo se encontra na lista de usuários cadastrados no sistema ou não (UNAR *et al.*, 2014).

Um Sistema Biométrico é um sistema de reconhecimento de padrões que compara características discriminatórias de dados adquiridos com características de dados armazenados. Todo Sistema Biométrico tipicamente é constituído por quatro módulos: módulo de aquisição de dados, módulo de extração de características, módulo de classificação e módulo de dados armazenados. No módulo de aquisição, ocorre a captura do dado biométrico de um indivíduo. No módulo de extração, o dado é processado e são extraídas as características salientes ou discriminatórias. No módulo de classificação, as características do dado analisado são comparadas com as dos dados armazenados para a posterior classificação do dado analisado como pertencente a uma pessoa específica. O módulo de dados armazenados contém amostras de modelos biométricos de usuários previamente cadastrados (UNAR *et al.*, 2014). A Figura 1 ilustra a composição de um sistema biométrico típico.



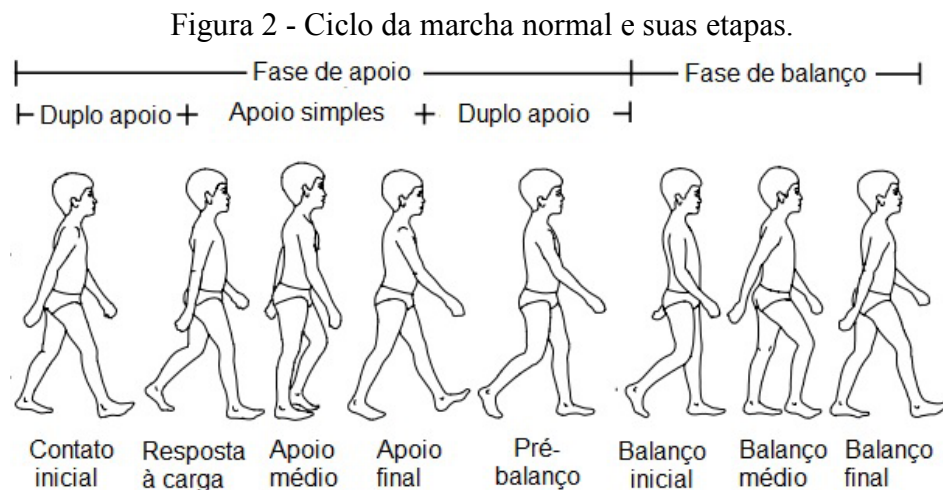
FONTE: Adaptado de (UNAR *et al.*, 2014).

As Características Biométricas utilizadas em sistemas de segurança podem ser divididas em dois grupos: características físicas e características comportamentais. Características físicas são aquelas definidas por aspectos anatômico-fisiológicos da pessoa, como por exemplo, a impressão digital, a face, a íris, a retina, etc. Características comportamentais são aquelas definidas pelo modo como a pessoa exerce certa atividade, como por exemplo, a voz, a maneira de andar, a assinatura, etc. Ressalta-se que essa classificação não é ortogonal, visto que, a maioria das características comportamentais pode ser afetada por características anatômico-fisiológicas (VERA-RODRIGUEZ *et al.*, 2013.). Para uma característica poder ser utilizada como uma Característica Biométrica é necessária que ela satisfaça os seguintes critérios (JAIN *et al.*, 2004):

- universalidade: cada pessoa deve possuir a característica;
- distinção: duas pessoas quaisquer devem ser suficientemente diferenciadas em termos da característica;
- permanência: a característica deve ser suficientemente invariante em um dado período de tempo;
- mensurável: a característica deve poder ser medida.

Como mencionado no Cap. de Introdução deste trabalho, a marcha humana é o resultado de um processo envolvendo o cérebro, a medula espinhal, os nervos periféricos, os músculos, os ossos e as articulações (WITTLE, 2007). Acredita-se que, por este processo envolver uma série de fatores anatômico-fisiológicos e psicológicos de uma pessoa, a marcha humana possa ser utilizada como uma Característica Biométrica sendo mensurável e apresentando universalidade, distinção e permanência. Dessa forma, é esperado que, dado uma sequência de passos, possa ser extraída alguma característica discriminadora considerando as variações espaço-temporais das observações (YUN, 2011).


O ato de caminhar possui duas condições necessárias básicas: 1) o movimento periódico de cada pé de uma posição de suporte para a próxima e 2) a força de reação do solo, aplicada através dos pés, suficiente para suportar o corpo. Este movimento periódico das pernas é a essência da natureza cíclica da marcha humana (VAUGHAN *et al.*, 1999). A Figura 2, como exemplo, apresenta as etapas de um único ciclo de marcha. O ciclo inicia quando o calcanhar faz contato com o solo, iniciando então a fase de apoio. Assim que o pé que iniciou o ciclo perde contato com o solo, inicia-se a fase de balanço que dura até o momento anterior ao toque novamente do calcanhar com o solo.



FONTE: Adaptado de (VAUGHAN *et al.*, 1999).

Além do aspecto periódico da marcha humana, ela apresenta ainda um aspecto espacial. O aspecto espacial define as distâncias e posicionamentos dos pés no ciclo da marcha. A Figura 3 ilustra os parâmetros que podem ser extraídos de um ciclo. As principais distâncias que definem um ciclo são o comprimento do passo, o comprimento da passada, a largura do passo e o ângulo de cada pé relativo à linha de progressão (VAUGHAN *et al.*, 1999).

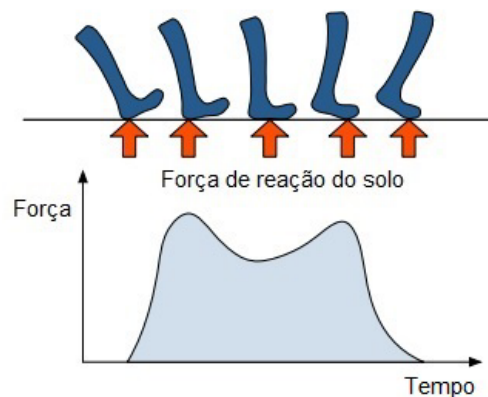
Figura 3 - Representação esquemática das dimensões da passada no plano bi-dimensional.



FONTE: Adaptado de (VAUGHAN *et al.*, 1999).

Uma forma de caracterizar algum padrão na marcha é através da força de reação do solo gerada entre o pé e a superfície durante a fase de apoio. Essa força pode ser medida no domínio do tempo, gerando uma forma de onda contendo características referentes a cada etapa da fase de apoio da marcha. A Figura 4 ilustra a típica forma de onda da componente vertical da força de reação do solo gerada por um passo. O primeiro pico apresentado é o resultado do impacto do calcanhar com o solo e pode chegar a 120% do peso corporal devido à necessidade de manter o equilíbrio durante o ato da caminhada. Na metade da fase de apoio, toda a superfície ativa do pé está em contato com o solo, gerando um descarregamento da superfície. Por fim, o segundo pico de carregamento ocorre na fase da propulsão, gerada pelos dedos prestes a perder o contato com o solo (DERLAKTA & BOGDAN, 2015).

Figura 4 – Típica força de reação do solo gerada por um passo



FONTE: Adaptado de (YUN, 2011).

Segundo EKIMOV & SEBATIER (2006), a força de reação do solo gerada por um passo gera também uma vibração mecânica no mesmo. Essa vibração mecânica pode ser modelada como a oscilação de uma partícula sísmica em determinada posição R . Portanto, de acordo com este modelo, a resposta em frequência da velocidade de oscilação da partícula $V(\omega, R, t)$ na frequência f ($\omega = 2\pi f$) a uma distância R da atividade humana resulta da multiplicação da força de reação do solo $F(\omega, t)$ pela função de transferência do solo no local $T(\omega, R)$ como mostrado na Equação (1):

$$V(\omega, R, t) = F(\omega, t) \times T(\omega, R) \quad (1)$$

Portanto, considerando-se a função de transferência do solo no local linear e invariante no tempo, pode-se esperar recuperar características discriminatórias de cada pessoa na medição de passos através de sensores de vibração dispostos no solo. Possibilitando, assim, este tipo de sistema de medida e sua correspondente aquisição de dados ser avaliada quanto à viabilidade da sua utilização em Sistemas Biométricos.

Como citado na Introdução deste trabalho, três métodos são normalmente utilizados em Sistemas de Biometria baseados na marcha humana (GAFUROV, 2007). Por exemplo, os métodos baseados em visão computacional são aqueles que realizam o reconhecimento de uma pessoa baseado em características extraídas de uma sequência de vídeo (cinemetria) da pessoa caminhando. No trabalho de LIU & SARKAR (2006), por exemplo, foi realizada a identificação de pessoas através da silhueta a partir de uma base de dados consistindo de 1870 sequências de vídeo de caminhadas de 122 sujeitos obtendo uma taxa de identificação de 95%. Por outro lado, métodos baseados em sensores portados pelo usuário utilizam, normalmente, acelerômetros dispostos em alguma parte do corpo da pessoa. No trabalho de AILISTO *et al.* (2005), foram utilizados acelerômetros fixados à cintura do usuário para a

construção de uma base de dados com 36 sujeitos a partir da qual foi obtido um *Equal Error Rate* (EER) de 6,4% na autenticação de pessoas.

Ainda, podem ser citados alguns trabalhos que utilizaram métodos baseados em sensores dispostos no piso para a identificação através da marcha. No trabalho de YUN (2011), foram utilizados sensores *switch* para a identificação de pessoas em uma base de dados com 10 usuários cadastrados sendo obtida uma taxa de identificação de 96%. No trabalho de DERLAKTA & BOGDAN (2015), foram utilizadas células de carga para a identificação de pessoas em uma base de dados com 200 usuários cadastrados sendo obtida uma taxa de acerto de 97,4%.

Por fim, pode-se ainda avaliar a possibilidade da utilização de sensores que medem a vibração gerada no solo a partir de passos para a identificação de pessoas. No trabalho de PAN *et al.* (2015), foi utilizado um geofone, modelo SM-24, para a identificação de pessoas em uma base de dados com 5 usuários sendo obtida uma taxa de identificação de 63% na classificação de um passo e de 83% na classificação de uma sequência de 5 passos. Em um trabalho mais recente dos mesmos autores (PAN *et al.*, 2017), foi utilizado o mesmo sensor para a identificação de pessoas em uma base de dados com 10 usuários, sendo obtida uma taxa de acerto de 83% na classificação de um passo e de 97% na classificação de uma sequência de 7 passos.

2.2. SENSORES SÍSMICOS UTILIZADOS NA ÁREA

Sensores de vibração são aqueles que, de forma bem resumida, operam de acordo com diferentes princípios mecânicos ou óticos para medir a vibração de um sistema observado. Esses sensores medem indiretamente a vibração derivada da medição de uma quantidade mecânica, que pode ser: deslocamento, velocidade ou aceleração. Além da classificação quanto à quantidade medida, podem-se classificar esses sensores de acordo com o

procedimento de medição, ou seja, medição relativa ou absoluta. Entende-se por medição absoluta, aquela dada em relação a um referencial inercial (COLLETTE, 2011). Por fim, classificam-se ainda os sensores de acordo com seu comportamento passivo ou ativo.

Sensores sísmicos podem ser definidos, de forma simplificada, como dispositivos que medem o movimento do solo quando o mesmo é excitado por uma perturbação. Estes sensores são um caso particular de sensores de vibração que utilizam o princípio da inércia de um corpo em repouso para seu funcionamento. O princípio da inércia deve ser utilizado por conta da medição ser realizada em um referencial em movimento, ou seja, o sensor está se movendo com o solo e não há nenhuma referência não perturbada disponível. Assim, sensores sísmicos utilizam uma massa inercial como referência e medem o movimento do solo em relação a essa massa. Ressalta-se ainda que, de acordo com o princípio da inércia, só é possível observar movimento da massa se há uma aceleração, assim, deslocamento e velocidade podem ser estimados, mas suas componentes contínuas não podem ser medidas (HAVSKOV & AGUACIL, 2012).

A grande maioria dos sensores sísmicos comerciais são sensores com medida absoluta, chamados de sensores inerciais, que se baseiam no princípio de um simples oscilador harmônico (COLLETTE *et al.*, 2011). O princípio básico de funcionamento de um sensor inercial é apresentado na Figura 5, onde o sensor é constituído de uma massa m (chamada de massa sísmica) acoplada ao ponto de medição através de uma suspensão, representada por uma mola k e um amortecedor viscoso c .

De acordo com COLLETTE *et al.* (2011) o sistema massa mola pode ser representado pela Equação (2):

$$m\ddot{x} + c(\dot{x} - \dot{\omega}) + k(x - \omega) = 0 \quad (2)$$

Considerando-se ω como o deslocamento vertical da terra e x como o deslocamento da massa, pode-se escrever o movimento relativo y da massa em relação à terra através da Equação (3):

$$y = x - \omega \quad (3)$$

Assim, reescrevendo a Equação (2) em função de y , obtém-se a Equação (4):

$$m\ddot{y} + c\dot{y} + ky = -m\ddot{\omega} \quad (4)$$


Utilizando a Transformada de Laplace, reescreve-se a Equação (4), chegando-se na Equação (5):

$$ms^2Y + csY + kY = -ms^2W \quad (5)$$

Por fim, pode-se escrever a transmissibilidade $T_{\omega y}(s)$ relacionando o deslocamento vertical da terra $W(s)$ com o deslocamento relativo da massa $Y(s)$ de acordo com a Equação (6):

$$T_{\omega y}(s) = \frac{Y(s)}{W(s)} = \frac{-ms^2}{ms^2 + cs + k} \quad (6)$$


Figura 5 - Princípio de funcionamento de um sensor inercial.



Fonte: COLLETTE *et al.*, 2011.

Da Equação (6), é possível representar o valor absoluto da resposta em frequência da função de transmissibilidade (utilizando $s = j\omega$) considerando a medição de $Y(s)$, $\dot{Y}(s)$ ou $\ddot{Y}(s)$, apresentada na Figura 6. A frequência de ressonância do oscilador é representada pelo parâmetro $\omega_0 = \sqrt{k/m}$.

Figura 6 – Típica resposta simulada em frequência da transmissibilidade.



Fonte: COLLETTE *et al.*, 2011.

Na Figura 6, observa-se que com a medição do deslocamento relativo da massa em relação à terra $Y(s)$ pode-se estimar o deslocamento da terra $W(s)$ nas frequências superiores a ω_0 , já que a função de transferência apresenta uma resposta plana. De forma similar, quando se mede a velocidade da massa em relação à terra $\dot{Y}(s)$, pode-se estimar a velocidade da terra $\dot{W}(s)$ nas frequências acima de ω_0 . Esta última abordagem é o princípio de funcionamento de um geofone. Ainda da análise da Figura 6, nota-se que a aceleração da terra $\ddot{W}(s)$ pode ser estimada a partir da medição do deslocamento relativo da massa em relação à

terra $Y(s)$ na região abaixo de ω_0 , onde a resposta é plana. Este é o princípio de funcionamento de um acelerômetro (COLLETTE *et al.*, 2011).

Um geofone é um sensor inercial que utiliza um ímã, acoplado à massa, envolto por uma bobina que, quando excitada pelo ímã, gera uma tensão elétrica na saída proporcional à velocidade da terra. Como apresentado na Figura 6 pela curva pontilhada, um geofone apresenta uma resposta em frequência plana acima da sua frequência de ressonância. Dessa forma, geofones podem ser utilizados para medir vibrações que estejam acima da sua frequência de ressonância. Em geofones comerciais, a frequência de ressonância se encontra em torno das unidades ou dezenas de Hz (PAKHOMOC *et al.*, 2004).

Além da frequência de ressonância do sistema do eixo principal (vertical), o geofone apresenta uma frequência de ressonância do sistema do eixo perpendicular (horizontal) ao eixo de trabalho, denominada frequência espúria. Essa frequência ocorre devido à liberdade de movimento lateral da bobina, que é mantida tão pequena quanto possível, entretanto é fundamental para permitir a liberdade de movimento no eixo vertical. A frequência espúria define o limite superior da banda útil para medições com o geofone (FABER & MAXWELL, 1996).

Acelerômetros são sensores inercias que apresentam diferentes tipos de efeitos para a medição da aceleração. Os mais usuais são o efeito capacitivo, o efeito piezoelétrico e o efeito piezoresistivo. Todos esses efeitos podem ser utilizados para a medição do deslocamento relativo da massa inercial a fim de estimar a aceleração da terra. Diferente do geofone, acelerômetros apresentam uma faixa dinâmica útil abaixo da sua frequência de ressonância, como apresentado na Figura 6 pela linha contínua. Portanto, para medição de vibrações com frequências mais baixas, acelerômetros são tipicamente selecionados no lugar dos geofones (PAKHOMOC *et al.*, 2004).

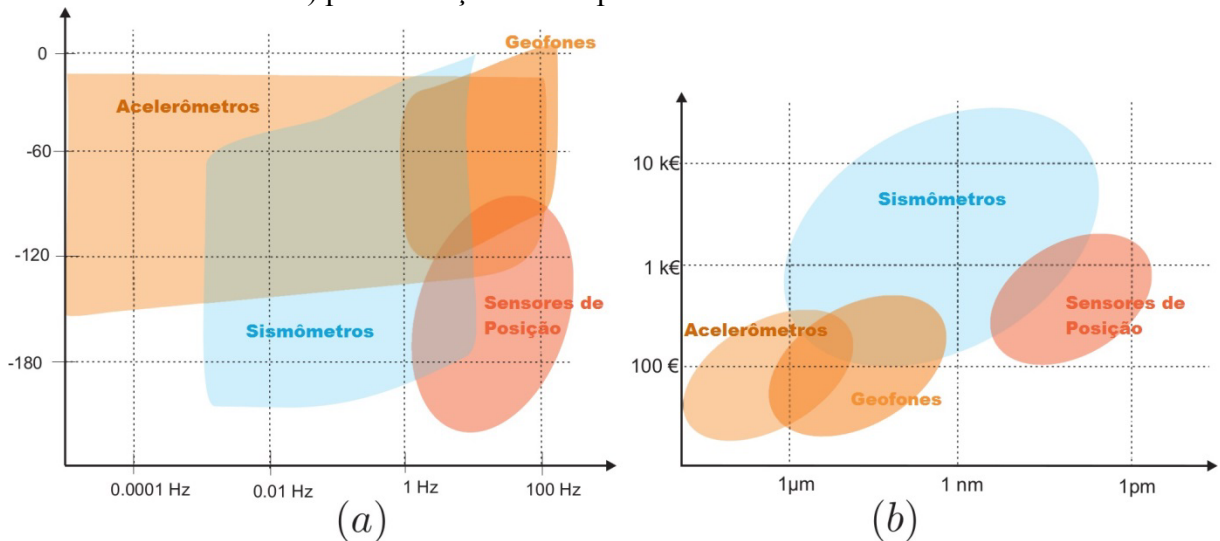
Os acelerômetros podem ser classificados em dois tipos: passivos ou ativos. Acelerômetros passivos usam os efeitos já descritos anteriormente em malha aberta na medição da aceleração. Por outro lado, acelerômetros ativos, chamados de *Force Balance Accelerometers* (FBA), utilizam uma realimentação com o intuito de gerar uma força contrária proporcional ao deslocamento da massa para mantê-la estática. Assim, medindo a força necessária para manter a massa estática, é possível estimar a aceleração do solo. O interesse de manter a massa estática é evitar medições não lineares causadas por grandes deslocamentos da massa e aumentar a faixa dinâmica (STUART-WATSON & TAPSON, 2004). Um exemplo de acelerômetros FBA são os acelerômetros MEMS, que, na sua grande maioria, utilizam um sensor de deslocamento capacitivo.

Outro sensor sísmico bastante utilizado é o sismômetro. Assim como os acelerômetros, sismômetros utilizam uma realimentação para limitar o movimento da massa sísmica. Sismômetros, normalmente, medem o deslocamento (ou a velocidade) da massa relativo à terra e utilizam uma realimentação proporcional-integral-derivativa (PID) para manter a massa com deslocamento pequeno (COLLETTE *et al.*, 2011). Comparado a acelerômetros e geofones, sismômetros são instrumentos mais sofisticados usados para a medição de tremores de terra. A Figura 7 ilustra uma comparação das características desses sensores inerciais realizada em 2012.

Analisando a Figura 7 (a), percebe-se que se encontram no mercado acelerômetros e sismômetros que podem ser utilizadas na medição de frequências abaixo de 1 Hz, enquanto geofones não são comumente encontrados nessa faixa de frequência. A Figura 7 (b) ilustra a diferença de preço e resolução entre geofones, acelerômetros e sismômetros na correspondente data do artigo analisado. De acordo com esses dados, observa-se que, usualmente, sismômetros possuem o preço mais elevado em relação ao preço de acelerômetros e geofones. Nota-se ainda, que além do preço mais elevado, sismômetros

costumam possuir uma resolução melhor. Por fim, na comparação entre acelerômetros e geofones, que possuem uma faixa de preços semelhantes, geofones tipicamente possuem uma melhor resolução.

Figura 7 - (a) Típica faixa dinâmica em frequência de sensores inerciais e (b) valores (em Euros) por resolução dos respectivos sensores/transdutores.



FONTE: Adaptado de COLLETTE *et al.*, 2012.

Com relação à aplicação abordada por este trabalho, os sensores sísmicos usualmente empregados na detecção de passos são acelerômetros e geofones. Segundo o trabalho de SABATIER & EKIMOV (2008), utilizando um acelerômetro, modelo PCB 356B18, foi possível detectar vibrações geradas por passos a 17 m do sensor em uma área urbana. Ainda neste trabalho, foi utilizado um geofone, modelo GS-32CT, com o qual foi possível detectar vibrações geradas por passos a 94 m do sensor em uma área não urbana. Nos trabalhos de PAKHOMOC *et al.* (2005), foram utilizados geofones, modelos GS-14-L3 e GS-20DX, para a coleta de passos em um gramado a céu aberto. Os resultados mostraram que foi possível realizar a detecção dos passos a 20 m de distância dos sensores.

Por fim, no trabalho de PAN *et al.* (2015) foi utilizado um geofone, modelo SM-24, para coleta de passos e identificação de pessoas em uma área interna de um prédio. Foi

possível coletar passos a distâncias de 8 m do sensor. Portanto, de acordo com os resultados apresentados por esses trabalhos, acelerômetros e geofones podem ser utilizados para a medição de vibrações geradas por passos, sendo a escolha entre qual utilizar dependente da faixa de frequência da aplicação, da distância de posicionamento do sensor em relação às passadas geradas na marcha humana e da resolução necessária para a correspondente detecção dos passos.

2.3. MÁQUINA DE VETORES DE SUPORTE

Segundo DERLAKTA & BOGDAN (2015), os métodos de classificação mais comumente utilizados em trabalhos na área biométrica utilizando a marcha humana são Redes Neurais Artificiais (RNAs), *k-Nearest Neighbor* (kNN), *Hidden Markov Model* (HMM), Máquina de Vetores de Suporte (SVM) e *Random Forest*. No trabalho de YUN (2011), alguns destes métodos foram comparados utilizando uma base de dados coletada a partir de sensores *switch*. Dessa forma, foram extraídas características espaço-temporais (variação temporal do formato e posição da pegada na matriz de sensores) das caminhadas de 10 usuários sendo obtidas melhores taxas de acerto com os classificadores MLP e SVM, 96,64% e 95,88%, respectivamente. No trabalho de SUUTALA & RÖNING (2008), também foram comparados alguns destes métodos utilizando uma base de dados coletada com um sensor chamado de *ElectroMechanical Film* (EMFi) para medir a força de reação no solo gerada pela marcha de 10 voluntários. A partir dos dados da força de reação do solo as melhores taxas de acerto foram obtidas novamente com os classificadores MLP e SVM, 93,67% e 95,33%, respectivamente.

Portanto, observa-se que tanto as RNAs quanto as SVMs podem ser utilizados na classificação de indivíduos a partir de características extraídas da marcha. Assim, o método escolhido por este trabalho são as SVMs, visto que, elas são amplamente utilizadas na

resolução de problemas de classificação. Ainda, as SVMs apresentam propriedades importantes para problemas de otimização, como por exemplo, a determinação dos parâmetros do modelo é um problema de otimização convexo (BISHOP, 2013). Como forma de caracterização dessas propriedades, uma pequena revisão de conceitos de um classificador SVM é apresentada nos parágrafos que seguem.

As SVMs são modelos de aprendizado de máquina supervisionado que podem ser utilizados para a resolução de problemas de classificação ou regressão em dados. Para os problemas de classificação, as SVMs são utilizadas na obtenção de fronteiras para a separação de dados pertencentes a duas classes. Um problema deste tipo pode ser formulado por um conjunto de treinamento T com n elementos $\mathbf{x}_i \in X$ etiquetados pelos seus respectivos rótulos $y_i \in Y$, em que X constitui o espaço de dados e $Y \in \{-1, +1\}$. Dado este problema e assumindo que os dados são linearmente separáveis, pode ser definida uma fronteira linear, denominada hiperplano, capaz de separar os dados, representada pela Equação (7), em que $f(\mathbf{x})$ é o hiperplano, \mathbf{w} é o vetor normal ao hiperplano e $b/\|\mathbf{w}\|$ é a distância do hiperplano até a origem (LORENA & CARVALHO, 2007):

$$f(\mathbf{x}) = \mathbf{w} \cdot \mathbf{x} + b = 0 \quad (7)$$


A Equação (7) pode ainda ser estendida para o caso em que os dados não são linearmente separáveis, ou seja, não é possível dividir de forma satisfatória os dados de treinamento por um plano linear. Nesses casos, pode-se utilizar uma função $\phi(\mathbf{x})$ para mapear o conjunto de dados de treinamento para um espaço de maior dimensão, chamado de espaço de características, onde os dados são linearmente separáveis (CAMPBELL & CRISTIANINI, 1998). Assim, reescreve-se a Equação (7) utilizando $\phi(\mathbf{x})$, obtendo-se a Equação (8):

$$f(\mathbf{x}) = \mathbf{w} \cdot \phi(\mathbf{x}) + b = 0 \quad (8)$$

Da Equação (8), nota-se que o hiperplano divide os dados no espaço de características em duas regiões: $\mathbf{w} \cdot \boldsymbol{\phi}(\mathbf{x}) + b > 0$ e $\mathbf{w} \cdot \boldsymbol{\phi}(\mathbf{x}) + b < 0$. Assim, pode-se definir uma função de tomada de decisão $g(\mathbf{x}) = \text{sign}(f(\mathbf{x}))$, em que $\text{sign}(\cdot)$ é a função sinal, para a classificação de novas entradas \mathbf{x}_i nas classes -1 ou $+1$ de acordo com o sinal de $f(\mathbf{x}_i)$ (LORENA & CARVALHO, 2007).

Ainda da Equação (8), observa-se que para definir os parâmetros \mathbf{w} e b são necessárias outras condições adicionais ao problema, visto que são infinitos os hiperplanos capazes de separar o conjunto de pontos linearmente no espaço de características. Para isso, define-se o conceito de margem, que é definida como a menor distância entre a fronteira de decisão e qualquer um dos pontos, ilustrada pela Figura 8. Desta forma, o hiperplano escolhido é aquele que maximiza a margem (BISHOP, 2013).

Figura 8 – Ilustração de um problema de classificação binária com SVM.



FONTE: Adaptado de (HEARST *et al.*, 1998).

Segundo BISHOP (2013), considerando a desigualdade $y_i f(\mathbf{x}_i) \geq 0$ válida para todos os pontos do problema abordado, visto que é considerado que para todo i o ponto \mathbf{x}_i é corretamente classificado, é possível definir a distância de um ponto \mathbf{x}_i a fronteira de decisão no espaço de características pela Equação (9):

$$\frac{y_i f(\mathbf{x}_i)}{\|\mathbf{w}\|} = \frac{y_i(\mathbf{w} \cdot \boldsymbol{\phi}(\mathbf{x}_i) + b)}{\|\mathbf{w}\|} \quad (9)$$

Nesse contexto, a margem é obtida pela distância perpendicular do ponto \mathbf{x}_i mais próximo do conjunto de treinamento ao hiperplano. Assim, se deseja otimizar os parâmetros \mathbf{w} e b a fim de maximizar esta distância (BISHOP, 2013). A margem maximal pode, então, ser obtida pela solução do problema apresentado na Equação (10):

$$\operatorname{argmax}_{\mathbf{w}, b} \left\{ \frac{1}{\|\mathbf{w}\|} \min_i [y_i(\mathbf{w} \cdot \boldsymbol{\phi}(\mathbf{x}_i) + b)] \right\} \quad (10)$$

A resolução do problema de otimização apresentado pela Equação (10) é muito complexa e, desta forma, é necessário converter o problema para um problema equivalente mais simples de ser resolvido fixando $y_i(\mathbf{w} \cdot \boldsymbol{\phi}(\mathbf{x}_i) + b) = 1$ para os pontos que estão mais próximos do hiperplano, sendo esta representação conhecida como hiperplano canônico (BISHOP, 2013). Assim, todos os pontos do conjunto de treinamento satisfarão a condição apresentada pela Equação (11):

$$y_i(\mathbf{w} \cdot \boldsymbol{\phi}(\mathbf{x}_i) + b) \geq 1, \quad \forall i = 1, \dots, n \quad (11)$$

Analisando a Equação (10) em conjunto com a condição imposta pela Equação (11), verifica-se que a maximização da margem de separação dos dados em relação à $\mathbf{w} \cdot \boldsymbol{\phi}(\mathbf{x}_i) + b = 0$ pode ser obtida pela minimização de $\|\mathbf{w}\|$ (LORENA & CARVALHO, 2007). Dessa

forma, o problema a ser otimizado é apresentado pela Equação (12), sujeito as condições da Equação (11):

$$\operatorname{argmin}_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2 \quad (12)$$

Analisando a Equação (12), observa-se que a função objetivo do problema é convexa. Aliado a isto, observa-se que os pontos que satisfazem a condição imposta pela Equação (11) são, também, convexos. Desta forma, o problema apresenta um único mínimo global. Para a resolução desse tipo de problema pode ser introduzida a utilização de uma função Lagrangiana, que engloba as condições à função objetivo, também conhecida como forma primal (LORENA & CARVALHO, 2007), apresentada pela Equação (12), em que as variáveis $\alpha_i \geq 0$ são os multiplicadores de Lagrange:

$$L(\mathbf{w}, b, \boldsymbol{\alpha}) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^n \alpha_i (y_i (\mathbf{w} \cdot \boldsymbol{\phi}(\mathbf{x}_i) + b) - 1) \quad (13)$$

Assim, minimizando a Equação (12) colocando as derivadas de $L(\mathbf{w}, b, \boldsymbol{\alpha})$ em relação a \mathbf{w} e b igual a zero, encontram-se as condições apresentadas pela Equação (14) e pela Equação (15):

$$\mathbf{w} = \sum_{i=1}^n \alpha_i y_i \boldsymbol{\phi}(\mathbf{x}_i) \quad (14)$$

$$\sum_{i=1}^n \alpha_i y_i = 0 \quad (15)$$

Substituindo a Equação (14) e a Equação (15) na Equação (13), obtém-se a forma dual do problema de otimização, apresentada pela Equação (16), sujeita as restrições apresentadas pela Equação (17) e pela Equação (18).

$$\tilde{L}(\boldsymbol{\alpha}) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j k(\mathbf{x}_i, \mathbf{x}_j) \quad (16)$$

$$\alpha_i \geq 0, \quad \forall i = 1, \dots, n \quad (17)$$

$$\sum_{i=1}^n \alpha_i y_i = 0 \quad (18)$$

Na Equação (16), o termo $k(\mathbf{x}_i, \mathbf{x}_j) = \boldsymbol{\phi}(\mathbf{x}_i) \cdot \boldsymbol{\phi}(\mathbf{x}_j)$ é a função *kernel* que recebe dois pontos do espaço de entradas \mathbf{x}_i e \mathbf{x}_j e computa o produto escalar desses pontos no espaço de características. É comum empregar a função *kernel* sem conhecer o mapeamento $\boldsymbol{\phi}$, que é gerado implicitamente (LORENA & CARVALHO, 2007). Segundo BISHOP (2013), um exemplo de função *kernel* é a *Radial Basis Function* (RBF), definida pela Equação (19), onde o parâmetro σ^2 é a variância da função Gaussiana:

$$k(\mathbf{x}_i, \mathbf{x}_j) = e^{-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}} \quad (19)$$

Maximizando $\tilde{L}(\boldsymbol{\alpha})$ em relação a $\boldsymbol{\alpha}$ respeitando as restrições impostas pela Equação (17) e pela Equação (18), encontra-se o hiperplano com margem maximal, sendo que apenas os pontos mais próximos ao hiperplano apresentam multiplicadores de Lagrange associados maiores que zero ($\alpha_i > 0$). Enquanto todos os outros pontos apresentam $\alpha_i = 0$. Os pontos que apresentam $\alpha_i > 0$ são denominados vetores de suporte (SVs) e são os pontos mais informativos do conjunto de treinamento. Assim, todos os outros pontos podem ser descartados para a tomada da decisão na classificação de novos dados (CAMPBELL & CRISTIANINI, 1998).

Dado que $\boldsymbol{\alpha}^*$ é a solução do problema dual e \mathbf{w}^* e b^* da forma primal, \mathbf{w}^* pode ser determinado pela Equação (14). Já b^* pode ser determinado a partir das condições de Karush-Khun-Tucker, que devem ser satisfeitas para problemas de otimização com restrições dessa

forma (LORENA & CARVALHO, 2007). Utilizando as condições de Khün-Tucker, encontra-se que b^* pode ser obtido a partir da Equação (20), em que n_{SV} denota o número de SVs e SV representa o conjunto dos SVs.

$$b^* = \frac{1}{n_{SV}} \sum_{x_i \in SV} \left(y_i - \sum_{x_j \in SV} \alpha_j y_j k(\mathbf{x}_i, \mathbf{x}_j) \right) \quad (20)$$

Finalmente, o classificador $g(x)$ pode ser reescrito a partir dos valores otimizados w^* obtido na Equação (14) e b^* obtido na Equação (20), como é apresentado pela Equação (21):

$$g(x) = \text{sign}(f(x)) = \text{sign} \left(\sum_{i=1}^n \alpha_i^* y_i k(\mathbf{x}, \mathbf{x}_i) + b^* \right) \quad (21)$$

Até então, foi considerado que todos os dados de treinamento são linearmente separáveis seja no espaço de entradas ou no espaço de características. Entretanto, segundo LORENA & CARVALHO (2007), em situações reais os dados, geralmente, não são linearmente separáveis. Isso se deve a presença de ruídos e valores discrepantes nos dados. Assim, é necessário modificar a condição apresentada na Equação (11) de forma a permitir que alguns pontos sejam incorretamente classificados. Isso é feito introduzindo as variáveis ξ_i , chamadas de variáveis de folga, para todo $i = 1, \dots, n$, obtendo-se a Equação (22):

$$y_i(\mathbf{w} \cdot \boldsymbol{\phi}(\mathbf{x}_i) + b) \geq 1 - \xi_i, \quad \xi_i \geq 0 \quad \forall i = 1, \dots, n \quad (22)$$

Esse tipo de problema é conhecido como SVM com margens suaves, já que agora é permitido que alguns dados de treinamento sejam classificados incorretamente. Analisando a Equação (22), nota-se que para pontos em que $\xi_i > 1$, ocorre um erro no conjunto de treinamento. Ainda, um valor de $\xi_i \in (0, 1]$, indica um dado entre as margens. Assim, para

levar em conta este efeito na função objetivo, a Equação (12) é modificada inserindo os termos ξ_i na otimização, como é apresentado pela Equação (23):

$$\operatorname{argmin}_{w,b,\xi} \frac{1}{2} \|\mathbf{w}\|^2 + C \left(\sum_{i=0}^n \xi_i \right) \quad (23)$$

O parâmetro C é um termo de regularização que controla a relação entre a complexidade do modelo e a quantidade de erros nos dados de treinamento. Quanto maior o valor de C , mais a solução do problema resultará em um modelo que não tolera erros nos dados de treinamento, podendo ocorrer o problema de super-ajustamento. Por outro lado, quanto menor o valor de C , mais a solução do problema resultará num modelo menos complexo com erros nos dados de treinamento, podendo ocorrer o problema de sub-ajustamento (LORENA & CARVALHO, 2007). Assim, o valor de C e o *kernel* utilizado, são os únicos parâmetros que podem ser ajustados através dos dados de validação enquanto se treina um classificador SVM (CAMPBELL & CRISTIANINI, 1998).

Como realizado anteriormente, o problema de otimização dado pela Equação (23), sujeito as restrições da Equação (22), pode ser resolvido com a introdução de uma função Lagrangiana. Tornando as derivadas parciais desta função nulas, pode-se obter a sua forma dual (LORENA & CARVALHO, 2007) apresentada na Equação (24), sujeita as restrições apresentadas pela Equação (25) e pela Equação (26):

$$\tilde{L}(\boldsymbol{\alpha}) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j k(\mathbf{x}_i, \mathbf{x}_j) \quad (24)$$

$$0 \leq \alpha_i \leq C, \quad \forall i = 1, \dots, n \quad (25)$$

$$\sum_{i=1}^n \alpha_i y_i = 0 \quad (26)$$

Novamente, dado que α^* é a solução do problema dual e w^* , b^* e ξ^* da forma primal, w^* pode ser determinado pela Equação (14). As variáveis ξ_i podem ser determinadas pela Equação (27):

$$\xi_i^* = \max \left\{ 0, 1 - y_i \sum_{j=1}^n y_j \alpha_j^* k(\mathbf{x}_j, \mathbf{x}_i) + b^* \right\} \quad (27)$$

Já b^* é determinado novamente utilizando as condições de Karush-Khun-Thucker. Os pontos que apresentam $\alpha_i > 0$ são os SVs, entretanto, desta vez, os SVs não estão todos sobre a margem. No caso de $0 < \alpha_i < C$, o SV está sobre a margem, já no caso de $\alpha_i = C$, o SV está fora da margem podendo ser corretamente ou erroneamente classificado (BISHOP, 2013). Assim, o valor de b^* é dado pela Equação (28), em que n_{SV_M} denota o número de SVs sobre a margem, SV_M representa o conjunto dos SVs sobre a margem e SV o conjunto de todos os SVs.

$$b^* = \frac{1}{n_{SV_M}} \sum_{x_i \in SV_M} \left(y_i - \sum_{x_j \in SV} \alpha_j^* y_j k(\mathbf{x}_i, \mathbf{x}_j) \right) \quad (28)$$

Por fim, o classificador $g(x)$ é definido da mesma forma que é apresentado na Equação (21).

O classificador SVM definido até então trata do caso em que se quer classificar dados pertencentes a apenas duas classes. No entanto, na prática, normalmente os problemas a serem resolvidos são multiclass. Assim, são necessários métodos que combinam classificadores SVMs de duas classes a fim de se construir um classificador multiclass (BISHOP, 2013).

Segundo BISHOP (2013), um método utilizado para a classificação multiclass com K classes é realizado de forma que se constroem K classificadores, onde cada classificador é treinado para separar uma das classes de todas as outras. Esse método é chamado de *one-*

versus-all. Na classificação de um novo ponto, a classe vencedora é aquela que apresenta o maior resultado da função $f(x)$ associada ao seu classificador, ou seja, a classe que apresenta a maior distância entre o hiperplano e o ponto a ser classificado, satisfazendo a Equação (29):

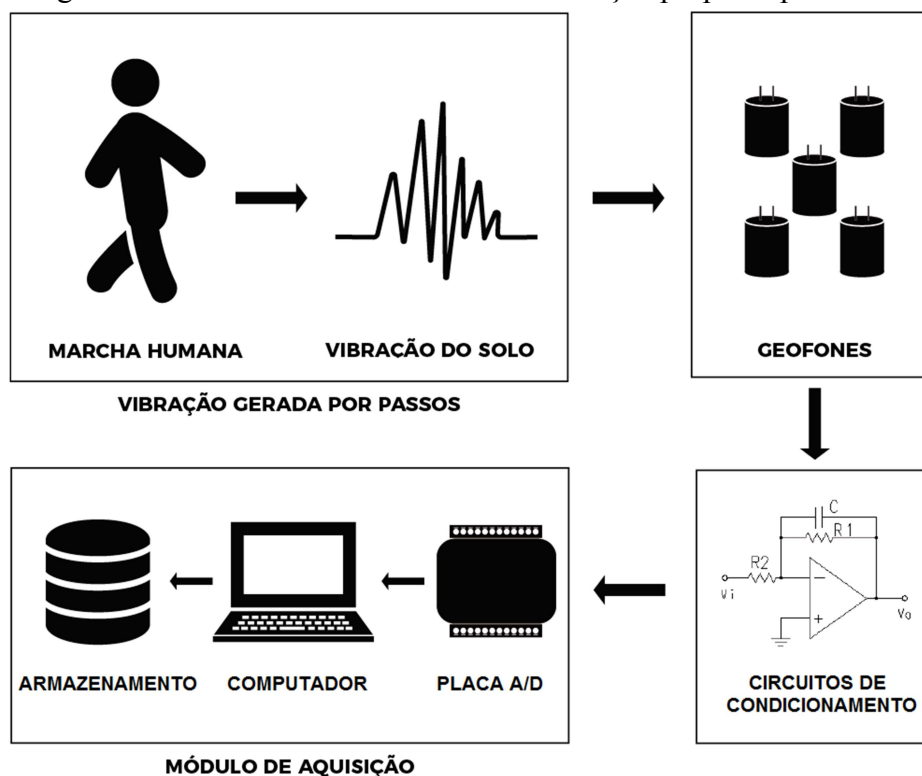
$$f(x) = \max_k f_k(x) \quad (29)$$

Por fim, outro método utilizado é a construção de $K(K - 1)/2$ classificadores binários entre todos os pares de classes possíveis. Este método é conhecido com *one-versus-one*. Neste método, a classe vencedora na classificação de um novo ponto é aquela que possui o maior número de votos dentre todos os $K(K - 1)/2$ classificadores (BISHOP, 2013).

3 MÉTODO EXPERIMENTAL

Neste capítulo será apresentada uma descrição detalhada do sistema e dos métodos experimentais propostos, neste trabalho, para a avaliação da possibilidade de identificação de pessoas através da vibração gerada no solo pela caminhada. O sistema para a coleta de dados consiste de um arranjo de cinco sensores para caracterizar a vibração no solo com seus respectivos circuitos de condicionamento em conjunto com um módulo de aquisição para a coleta e armazenamento dos dados. O diagrama de blocos do sistema proposto para a coleta de dados é apresentado na Figura 9.

Figura 9 - Diagrama de blocos do sistema de instrumentação proposto para a coleta de dados.




Na Figura 9, é possível observar no primeiro bloco a variável medida pelo sistema que é a vibração gerada no solo pela marcha humana. O segundo bloco apresenta o arranjo de 5 geofones utilizados para a medição dos sinais gerados pela marcha. A saída do segundo bloco é a tensão elétrica gerada pelos geofones que é amplificada e filtrada no terceiro bloco pelos

circuitos de condicionamento. No quarto bloco, cada saída do circuito de condicionamento é digitalizada pelo ADC da placa DAQ e lida pelo computador através do *software LabVIEW 2016*. Por fim, esses dados são armazenados em arquivos que serão utilizados posteriormente na criação do modelo SVM para classificação de pessoas.

Além do sistema para a coleta de dados, o trabalho ainda apresenta o sistema para criação e avaliação do modelo SVM para identificação de pessoas através da marcha. Esse sistema foi desenvolvido utilizando a linguagem de programação *Python 3.5.3*. O mesmo pode ser subdividido em cinco etapas, como é apresentado no diagrama de blocos da Figura 10.

Figura 10 - Diagrama de blocos do sistema para treinamento e teste do modelo SVM.



Na Figura 10, o primeiro bloco apresenta a parte de leitura dos dados, em que os dados armazenados são carregados pelo sistema. Em seguida, cada uma das gravações passa pelo processo de segmentação, em que os passos são segmentados para a posterior análise. No terceiro bloco, ocorre a extração das características do passo. Na sequência, as características extraídas dos dados de treinamento são, então, utilizadas pelo bloco quatro para o treinamento do modelo SVM. Por fim, o modelo SVM treinado é testado com as características extraídas dos dados de teste e os resultados são armazenados para a posterior análise estatística.

Dessa forma, as etapas experimentais do projeto consistem:

- 1) no projeto e construção de um sistema de instrumentação para a coleta de dados;
- 2) na aquisição de dados para a construção de uma base de dados com sinais de vibração gerada por passos em um ambiente específico;

- 3) na criação de um sistema para treinamento e teste de um modelo SVM capaz de identificar pessoas através dos dados coletados na etapa anterior.

Os blocos dos sistemas apresentados na Figura 9 e na Figura 10, assim como, as etapas experimentais do projeto serão descritos detalhadamente nas seções seguintes.

3.1. GEOFONE E PROJETO DO CONDICIONADOR DE SINAIS


O sensor utilizado para a medição da vibração gerada no solo por passos humanos foi um geofone, modelo RTC-4.5Hz-395. Foi projetado um circuito de condicionamento para o geofone para a filtragem do sinal na banda de interesse e elevação da tensão elétrica de saída. O geofone RTC-4.5Hz-395 apresenta um princípio de funcionamento como descrito na Seção 2.2. Ele é composto por um ímã, acoplado a uma massa inercial, que excita uma bobina quando ocorre o movimento relativo entre a massa e a bobina, gerando uma tensão elétrica na saída proporcional à velocidade do carregamento mecânico na interface piso-sensor/transdutor. O geofone escolhido apresenta a resposta em frequência de um filtro passa-altas com frequência de ressonância em 4,5 Hz com tolerância de $\pm 0,5$ Hz e apresenta sua frequência espúria acima de 160 Hz (RTC-4.5Hz-395, 2012). A resposta em frequência em circuito aberto do geofone fornecida pelo fabricante é apresentada na Figura 11.

Analisando a Figura 11, nota-se que a resposta em frequência do geofone fornecida pelo fabricante não apresenta ressonância visível, pois o sensor apresenta um resistor *shunt* interno que amortece o pico de ressonância com um fator de amortecimento de 0,7 com tolerância de $\pm 10\%$ tornando a resposta mais plana. Desta forma, o geofone apresenta sua frequência de corte inferior em 4,5 Hz¹, ponto no qual a sensibilidade está -3 dB abaixo do

¹ É importante salientar que a marcha humana típica apresenta componentes em frequências abaixo de 4,5 Hz (ANTONSSON & MANN, 1985). Entretanto, optou-se por utilizar o geofone citado (ver Fig. 11), pois o objetivo principal do presente trabalho é identificar pessoas através do impacto gerado no solo pela marcha humana. Assim, a análise para a classificação foi realizada com a energia parcial do sinal gerado pelo impacto do pé com o solo durante o ato da caminhada, considerando que a informação contida nesta energia parcial é suficiente para diferenciar duas pessoas quaisquer.

máximo. Ainda da Figura 11, nota-se que a frequência espúria aparece em 160 Hz. Por fim, a sensibilidade do sensor é de 23,4 V/(m/s) com tolerância de $\pm 10\%$ (RTC-4.5Hz-395, 2012).

Figura 11 - Resposta em frequência em circuito aberto do geofone RTC-4.5Hz-395.




FONTE: Adaptado de (RTC-4.5Hz-395, 2012).

Considerando-se os dados do fabricante do geofone (RTC-4.5Hz-395, 2012), foi possível projetar um circuito de condicionamento que fornecesse uma saída filtrada na faixa de frequência desejada e amplificada para a posterior leitura com uma placa DAQ, modelo NI USB-6009 (NI USB-6009, 2015), com uma frequência de amostragem de 1 kHz e 13 bits de resolução na configuração *single-ended*. Esse circuito foi projetado para ser alimentado com uma fonte de tensão simétrica, modelo Politerm POL-16E (POL-16E, 2011), na configuração em série fornecendo $+15V \pm 0.001V$ e $-15V \pm 0.001V$. Como foram utilizados 5 geofones espaçados um do outro (ver Figura 15), foi necessário a utilização de cabos com comprimento de até 3 m para alimentar cada circuito de condicionamento. Dessa forma, foram utilizados

dois reguladores de tensão, modelo LM7810 e LM7910, para regular a tensão em +10V com tolerância de $\pm 2\%$ e -10V com tolerância de $\pm 2\%$, evitando, assim, que cada circuito sofresse a influência da queda de tensão sobre o cabo. A Figura 12 apresenta o circuito de alimentação.

Figura 12 – Esquemático do circuito de alimentação.



Segundo SEBATER & EKIMOV (2008), a vibração gerada no solo por passos humanos se encontra tipicamente nas frequências abaixo de 100 Hz. Ainda, segundo esses autores, a amplitude de vibrações sísmicas geradas por passos a poucos metros da pessoa é da ordem de 10^{-5} m/s. Esse valor é uma estimativa para passos coletados na superfície terrestre. Assim, essas informações foram consideradas para o projeto do filtro e do ganho do circuito de condicionamento. Vale ressaltar que a faixa de frequência e a amplitude são dependentes da função de transferência do local em que os passos são coletados, assim, os valores utilizados são apenas uma estimativa e podem ser modificados após a realização de testes nos pisos que serão utilizados neste trabalho.

O projeto do circuito de condicionamento do sinal consistiu em um filtro passa-faixa de 4,5 Hz a 100 Hz com um ganho dado por dois estágios. Como o geofone já apresenta uma resposta passa-altas, foi escolhida a utilização de um filtro passa-altas passivo em 4,5 Hz de primeira ordem apenas. Por outro lado, foi escolhida a utilização de um filtro passa-baixas ativo em 100 Hz de terceira ordem para a atenuação do ruído nas altas frequências e diminuição do *aliasing*. É importante ressaltar que o projeto de todo o circuito de condicionamento foi o mais simples possível devido à característica de baixo custo do sistema proposto.

O ganho do circuito foi estimado a fim de aproveitar ao máximo a excursão de -10 V a +10 V do ADC da placa DAQ. Para a estimativa do ganho, tomou-se a estimativa inicial da vibração a ser medida na superfície terrestre da ordem de 10^{-5} m/s e multiplicou-se esse valor por um fator de 10 vezes, já que os ensaios foram realizados no segundo andar de um prédio. Assim, utilizou-se o valor de 10^{-4} m/s em conjunto com a sensibilidade do sensor para o cálculo do ganho necessário para aproveitar toda a excursão do ADC. O ganho estimado é dado pela Equação (30), onde V_{ADC} é a tensão elétrica máxima do ADC em Volts, v_{solo} é a ordem da vibração gerada no solo por passos em m/s e S_{geo} é a sensibilidade do geofone em V/(m/s):

$$G_{est} = \frac{V_{ADC}}{v_{solo} \times S_{geo}} = \frac{10}{10^{-4} \times 23,4} = 4273 \quad (30)$$

O ganho estimado é da ordem de 10^3 , assim, são necessários de dois a três estágios de ganho. Como a amplitude do sinal gerado depende de diversos fatores (tais como: função de transferência do local, peso e forma de caminhar da pessoa e proximidade do sensor), a partir da realização de alguns testes no local de ensaio, foi selecionado um ganho dado por dois estágios de magnitude total 750 para manter uma margem de segurança a fim de evitar a saturação do estágio de saída.

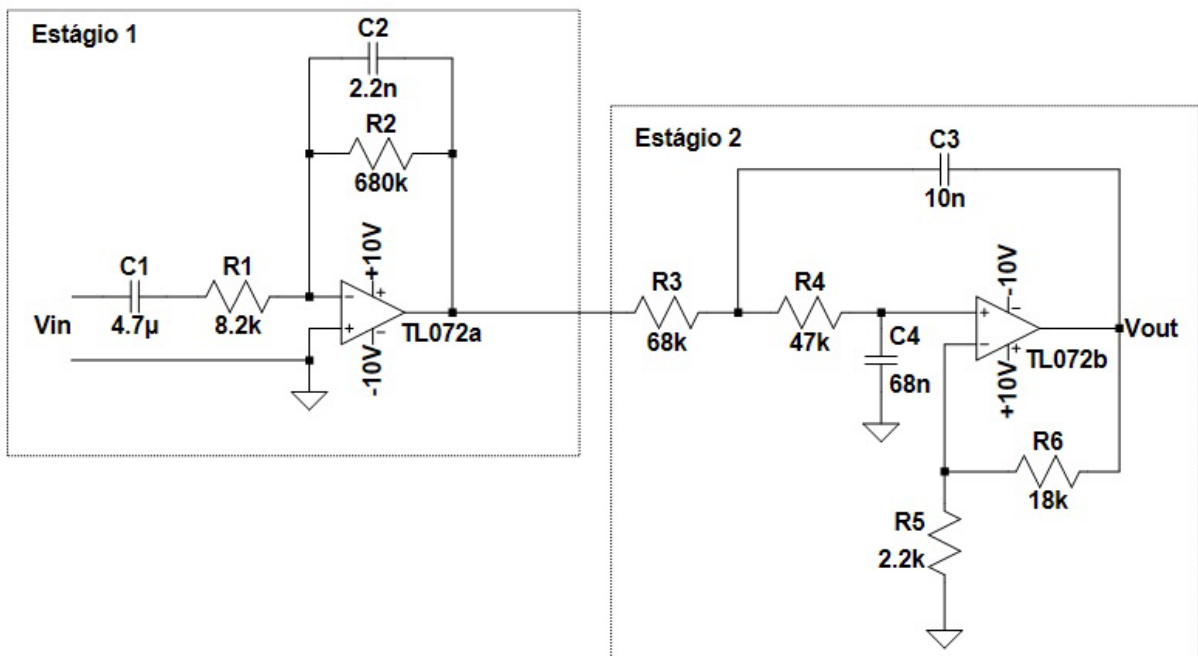
O circuito de condicionamento foi dividido em dois estágios como é apresentado na Figura 13. Como pode ser visto, o primeiro estágio apresenta um filtro passa-altas passivo na sua entrada com frequência de corte dada pela Equação (31) e um filtro passa-baixas ativo de primeira ordem com frequência de corte dada pela Equação (32) com um ganho inversor dado pela Equação (33):

$$f_{CPA} = \frac{1}{2\pi R_1 C_1} \approx 4,1 \text{ Hz} \quad (31)$$

$$f_{CPB1} = \frac{1}{2\pi R_2 C_2} \approx 106 \text{ Hz} \quad (32)$$

$$G_1 = -\frac{R_2}{R_1} \approx -82,9 \quad (33)$$

Figura 13 - Esquemático do circuito de condicionamento do sinal do geofone.



O segundo estágio apresenta um filtro passa-baixas de segunda ordem com frequência de corte dada pela Equação (34) e fator de qualidade dado pela Equação (35) na configuração *Sallen-Key* (KARKI, 2002):

$$f_{CPB2} = \frac{1}{2\pi\sqrt{R_3C_3R_4C_4}} \approx 108 \text{ Hz} \quad (34)$$

$$Q = \frac{\sqrt{R_3C_3R_4C_4}}{R_3C_4 + R_4C_4 + R_3C_3(-R_6/R_5)} \approx 0,65 \quad (35)$$

Esse estágio apresenta, ainda, um ganho definido pelo comportamento não inversor da configuração *Sallen-Key* dado pela Equação (36). Por fim, o ganho total do circuito pode ser definido pela Equação (37):

$$G_2 = 1 + \frac{R_6}{R_5} \approx 9,2 \quad (36)$$

$$G = G_1 \times G_2 \approx -762 \quad (37)$$

Após o projeto do circuito, o mesmo pôde ser simulado, utilizando o *software LTspice XVII*. Na simulação foi feita a análise AC, na qual foi levantada a resposta em frequência do circuito de 1 Hz a 500 Hz para a posterior comparação com os valores calculados e com os resultados obtidos experimentalmente.

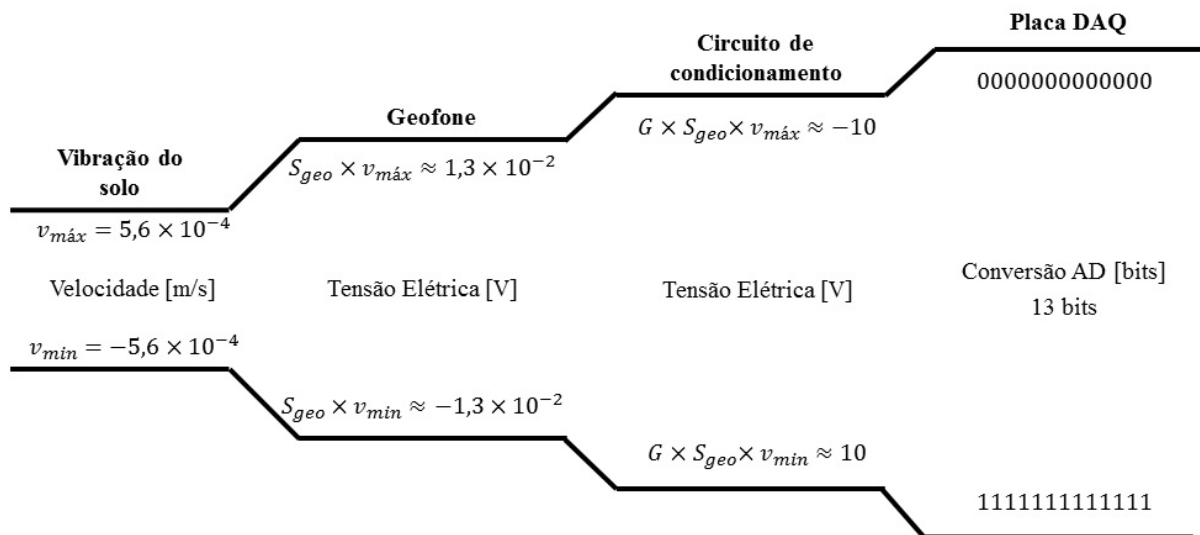
Por fim, a Cadeia de Medidas Teórica do sistema de instrumentação proposto é apresentada na Figura 14. Na cadeia de medidas teórica, S_{geo} é a sensibilidade do geofone fornecida pelo fabricante igual a $23,4 \text{ V}/(m/s)$ com tolerância de $\pm 10\%$; G é o valor teórico do ganho do circuito de condicionamento igual a -762 ; e $v_{m\acute{a}x}$ e $v_{m\acute{i}n}$ são, respectivamente, as velocidades máximas e mínimas que o sistema é capaz de ler. A partir da cadeia de medidas, é possível calcular a resolução de saída do sistema, dada pela Equação (38), e a resolução de entrada do sistema, dada pela Equação (39), onde n_{bits} é o número de bits do ADC da placa DAQ igual a 13 e as outras variáveis já foram definidas anteriormente. É importante ressaltar que em função da não disponibilidade dos dados de resolução de entrada

do geofone no *datasheet* do mesmo (RTC-4.5Hz-395, 2012), a resolução de entrada da cadeia de medidas teve que ser calculada a partir dos dados esperados na saída.

$$\text{Resolução de saída} = \frac{2V_{ADC}}{2^{n_{bits}}} \approx 2,4 \text{ mV/bit} \quad (38)$$

$$\text{Resolução de entrada} = \frac{\text{Resolução de saída}}{S_{geo} \times G} \approx 1,3 \times 10^{-7} \text{ m/s} \quad (39)$$

Figura 14 - Cadeia de Medidas Teórica do sistema de instrumentação proposto.



3.2. PROCEDIMENTO DE CALIBRAÇÃO DOS CIRCUITOS DE CONDICIONAMENTO

A calibração do circuito de condicionamento foi realizada medindo a saída do mesmo quando inserido um sinal sinusoidal com amplitude na faixa de 20 mVpp na entrada com um gerador de funções, modelo Digilent Analog Discovery 2, variando a frequência da onda de entrada de forma a se obter a resposta do circuito de 1 Hz até 500 Hz. A variação da frequência ocorreu de forma linear dentro de faixas de frequência, sendo utilizado uma resolução de 1 Hz para a faixa de 1 Hz a 10 Hz; uma resolução de 10 Hz para a faixa de 10 Hz a 100 Hz; e uma resolução de 100 Hz para a faixa de 100 Hz a 500 Hz. Assim, totalizando

23 pontos de frequências que cobrem a faixa de interesse (4,5 a 100 Hz) e cobrem ainda o comportamento do circuito fora da faixa de interesse até a frequência de Nyquist (500 Hz) a fim de verificar a atenuação da amplitude nesta frequência.

Para a medição dos sinais foi utilizado um osciloscópio, modelo Digilent Analog Discovery 2, com o qual se mediu a amplitude do sinal de entrada e do sinal de saída para o posterior cálculo do ganho em cada frequência. O ganho é dado pela Equação (40), onde $G(f)$ é o ganho do circuito na frequência f ; $V_o(f)$ é o valor da amplitude do sinal de saída na frequência f ; e $V_i(f)$ é o valor da amplitude do sinal de entrada na frequência f .

$$G(f) = \frac{V_o(f)}{V_i(f)} \quad (40)$$

Por fim, para obter-se uma estimativa do ganho do circuito na faixa de interesse, foi realizada a calibração do mesmo variando a amplitude de um sinal sinusoidal na entrada com frequência de 20 Hz. A amplitude foi variada de 4 mVpp até 20 mVpp com resolução de 2 mVpp, totalizando 9 pontos.

Neste procedimento experimental, foram utilizados o mesmo gerador de funções e osciloscópio utilizados anteriormente. Foi medida a amplitude da tensão elétrica da entrada e da saída do circuito de condicionamento 5 vezes para cada valor de entrada. Para cada conjunto de medidas, foi realizada uma regressão linear para estimativa do ganho. A partir dos 5 valores de ganhos obtidos foi calculado o ganho estimado dado pela média dos 5 valores. A incerteza padrão foi determinada como incerteza padrão do Tipo A com base no desvio padrão da média (BALBINOT, 2016).

É importante ressaltar que não foi possível calibrar os geofones devido a não disponibilidade de uma mesa vibratória com resposta em frequência adequada (calibração direta), nem de outro sensor com resolução e relação sinal ruído adequadas para a detecção de

passos no solo (calibração indireta). Dessa forma, apenas o circuito de condicionamento foi calibrado, enquanto os parâmetros do geofone utilizados na etapa experimental foram considerados os fornecidos pelo fabricante do mesmo.


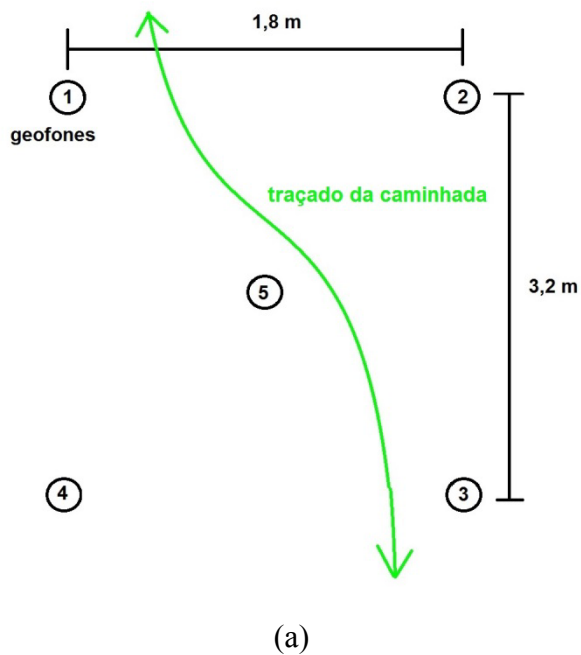
3.3. PROCEDIMENTO PARA A COLETA DE DADOS

Para a coleta e construção da base de dados, inicialmente, foram realizados alguns ensaios preliminares em possíveis locais de coleta para avaliar a possibilidade de detecção de passos no piso e a distância máxima na qual os mesmos ainda eram detectados. Assim, foram escolhidos o local de ensaio, o número de sensores e posições dos mesmos no solo para a realização da coleta. O local de ensaio foi escolhido de forma a facilitar a realização do ensaio com os equipamentos disponíveis, assim como, facilitar o controle do ambiente a ruídos externos. Os experimentos foram realizados dentro do Laboratório de Instrumentação da Graduação no Instituto Eletrotécnico da UFRGS. Foram posicionados 5 geofones sem fixação no solo sendo 4 deles formando um retângulo e o último colocado no centro deste retângulo, cujo posicionamento no plano 2D pode ser visto na Figura 15 (a). A Figura 15 (a) apresenta a disposição dos sensores e o traçado das caminhadas e a Figura 15 (b) apresenta o local do ensaio (piso do tipo parquet).

Como sistemas de biometria por marcha humana ainda são incipientes quando comparados a outros tipos de sistemas de biometria, segundo VERA-RODRIGUEZ *et al.* (2013), umas das características dos trabalhos nessa área são as pequenas bases de dados em relação às bases de dados de outras áreas da biometria, que apresentam, normalmente, centenas a milhares de pessoas. Assim, como o trabalho se insere apenas em um estudo de caso optou-se por criar uma base preliminar para validar experimentalmente o sistema proposto (conhecendo-se, porém, a influência de uma base pequena em sistemas de Inteligência Computacional). Dessa forma, foi escolhido o número de 12 participantes para o

ensaio com idades entre 22 a 37 anos e média e desvio padrão de $27,1 \pm 4,6$ anos, sendo 10 homens e 2 mulheres.

Figura 15 - (a) Posição dos geofones e local de caminhada; (b) Local do ensaio.



Cada participante foi solicitado a comparecer no local de ensaio em dois dias diferentes utilizando o mesmo calçado nos dois dias. No primeiro dia, foram coletadas 3 sessões de 10 caminhadas com 5 segundos de duração cada. No segundo dia, foram realizadas mais 2 sessões de 10 caminhadas com 5 segundos de duração cada. Assim, no total foram coletadas 50 caminhadas de 5 segundos de cada participante. As caminhadas foram realizadas de acordo com o traçado apresentado na Figura 15 (a), sendo a primeira caminhada realizada no sentido inferior-superior, a segunda caminhada no sentido superior-inferior, a terceira novamente no sentido inferior-superior e assim sucessivamente até se completarem 10 caminhadas. A cada sessão de 10 caminhadas de um participante, era solicitado que outro participante realizasse sua sessão de 10 caminhadas de forma a aleatorizar o experimento. É importante salientar que nenhuma medida foi realizada para garantir a exatidão do traçado

realizado, desta forma, todos os participantes realizaram o traçado sugerido com uma variação não medida.


Os participantes foram recomendados a caminhar na sua velocidade normal de passo. A gravação era iniciada quando o usuário já tinha iniciado a caminhada e terminada enquanto o usuário ainda caminhava. Dessa forma, o número de passos coletados em 5 segundos de caminhada para cada participante foi variável. No geral, o número médio de passos para cada caminhada foi de aproximadamente 8 passos. Assim, cada participante teve em média 400 passos gravados por cada um dos 5 sensores. No total, a base de dados apresenta aproximadamente 4800 passos de 12 pessoas diferentes medidos com cada um dos 5 sensores. Essa base de dados foi, então, utilizada para a implementação dos algoritmos de segmentação de passos, extração de características e do modelo de identificação de pessoas explicados nas seções seguintes.

3.4. METODOLOGIA DE SEGMENTAÇÃO E EXTRAÇÃO DE CARACTERÍSTICAS

A partir da coleta dos dados, foi possível utilizar os mesmos para avaliar a possibilidade de identificação de pessoas através da marcha. A primeira etapa para a utilização dos dados é a leitura de todos os arquivos contendo os sinais de cada gravação. Na parte da leitura dos dados, cada arquivo contendo o sinal dos 5 sensores é lido e os sinais de cada um dos sensores, assim como, a identidade da pessoa associada a caminhada são armazenados em uma tabela. Nesta etapa ocorre também a separação do conjunto de dados em dados de treinamento e de teste que será explicada em detalhes na Seção 3.5. Dessa forma, essa informação também é adicionada à tabela. Cada linha da tabela apresenta o caminho do arquivo, a data da gravação, a ID do usuário, os sinais dos 5 sensores de uma gravação e o conjunto de dados ao qual aquela gravação pertence.

Após a leitura dos dados, ocorre a etapa de segmentação dos sinais. Na etapa de segmentação, cada uma das 50 gravações de cada um dos 12 usuários passa pelo algoritmo de segmentação para a extração de janelas contendo a informação referente a um passo. Antes de o sinal ser segmentado, ele passa por uma etapa de pré-processamento, onde sua média é retirada e a ele é aplicado um filtro Butterworth passa-baixas de 4ª ordem com frequência de corte em 100 Hz. A fim de facilitar o entendimento da etapa de segmentação, um sinal típico de marcha adquirido com o sistema é apresentado na Figura 16.

Figura 16 - Sinal típico de marcha adquirido com o sistema.



Como pode ser visto na Figura 16, o sinal típico de marcha adquirido apresenta, em média, 8 passos em cada gravação de 5 segundos. O algoritmo de segmentação realiza o janelamento a partir da comparação do valor da variância de pequenos segmentos do sinal com o valor da variância do sinal inteiro. Inicialmente, o sinal é dividido em 99 segmentos com 100 amostras (0,1 segundos) cada, sendo cada segmento i sobreposto a outro em 50%. Em seguida, a variância do sinal inteiro (var_{sig}) e a variância de cada um desses segmentos


($var_{seg}[i]$) são calculadas. Por fim, a variância de cada um dos segmentos é comparada com a do sinal inteiro. Caso $var_{seg}[i] > \alpha \times var_{sig}$, o segmento i é classificado como sinal de interesse (parte de um passo) e a posição inicial e final do segmento são armazenadas em dois vetores. Caso $var_{seg}[i] \leq \alpha \times var_{sig}$, os valores de posição inicial e final do segmento i são descartados. A variável α é um parâmetro da segmentação que controla o limiar para a classificação do segmento como de interesse ou não. Valores de α mais elevados fazem com que o algoritmo segmente menos passos, mas com menor possibilidade de erros de segmentação. Valores de α menos elevados fazem com que o algoritmo segmente mais passos, mas com maior possibilidade de erros de segmentação.

Após essa etapa inicial, o sistema analisa as posições iniciais e finais de cada segmento para identificar segmentos em sequência. A Figura 17 apresenta um zoom no passo 4 da Figura 16 com os respectivos segmentos sobrepostos em 50%, sendo os segmentos em verde classificados como contendo parte de um passo e os em vermelho classificados como não contendo parte de um passo. Como pode ser visto, são 7 segmentos em verde em sequência que devem ser transformados em um segmento só. Assim, nesta parte do algoritmo, o sistema só mantém a posição inicial do primeiro segmento em verde no vetor de posições iniciais e a posição final do último segmento em verde no vetor de posições finais.

É importante notar que o algoritmo descrito até então pode segmentar passos com tamanhos de janela diferentes. No caso do passo analisado na Figura 17, por exemplo, como havia 7 segmentos em sequência, a janela segmentada total apresenta 0,4 segundos. Entretanto, para a etapa de extração de características e posterior comparação das mesmas, é necessário que os segmentos apresentem o mesmo tamanho para que eles sejam mais facilmente comparáveis. Segundo os resultados do trabalho de OBERG *et al.* (1993), a frequência do passo média de homens de 20-29 anos é de 1,98 Hz, enquanto para mulheres de 20-29 anos é de 2,08 Hz. Portanto, foi escolhido um tamanho de janela de 0,5 segundos para a

segmentação dos passos. Dessa forma, nesta etapa do algoritmo, é avaliado o tamanho da janela segmentada na etapa anterior. Caso a janela apresente menos que 0,15 segundos, ela é descartada. Caso a janela apresente no mínimo 0,15 segundos, é selecionado o início da janela e os 0,5 segundos subsequentes como janela a ser analisada.

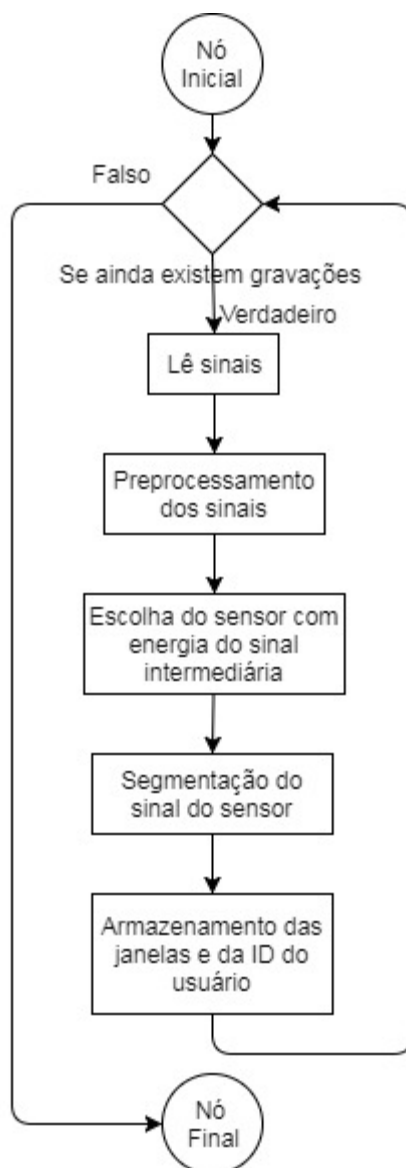
Figura 17 - Segmentação de um passo com janelas de 0,1 segundos.



Ainda quanto a etapa de segmentação, vale ressaltar que a segmentação em cada gravação foi realizada utilizando apenas o sinal de um dos 5 sensores utilizados. Tendo o início e o fim das janelas segmentadas em um sensor, as janelas dos outros sensores são extraídas utilizando os mesmos valores de início e fim já encontrados. O sensor utilizado para a segmentação de uma determinada gravação foi escolhido como aquele que apresenta um valor intermediário de variância entre todos os sensores. O sensor com valor de variância intermediária foi escolhido por duas razões. A primeira razão é que sensores com sinais de baixa energia possuem uma relação sinal ruído baixa, dificultando a segmentação. A segunda razão é que sensores com sinais de energia elevada, mesmo apresentando uma relação sinal ruído elevada, podem dificultar a segmentação devido aos efeitos da ressonância do piso que fazem com que o sinal de um passo não seja atenuado o suficiente antes da excitação gerada

pelo passo seguinte. O fluxograma com todas as etapas da segmentação é apresentado na Figura 18.

Figura 18 - Fluxograma da etapa de segmentação dos sinais.



Após a etapa de segmentação, é realizada a etapa de extração de características dos sinais segmentados. Inicialmente, ocorre uma etapa de pré-processamento em que a média da janela é retirada e o sinal da janela é dividido pela variância do mesmo. As características extraídas de uma janela podem ser subdivididas em dois grupos: características no domínio da frequência e características no domínio tempo. As características extraídas no domínio da

frequência são: o valor em dB de cada componente da FFT de 4 Hz a 100 Hz e o valor e a posição dos 3 picos da FFT com maior amplitude. As características extraídas do domínio tempo são o próprio sinal no tempo decimado com um fator de 25 vezes e o valor e a posição dos 5 picos positivos e dos 5 picos negativos do sinal com amplitude mais elevada.

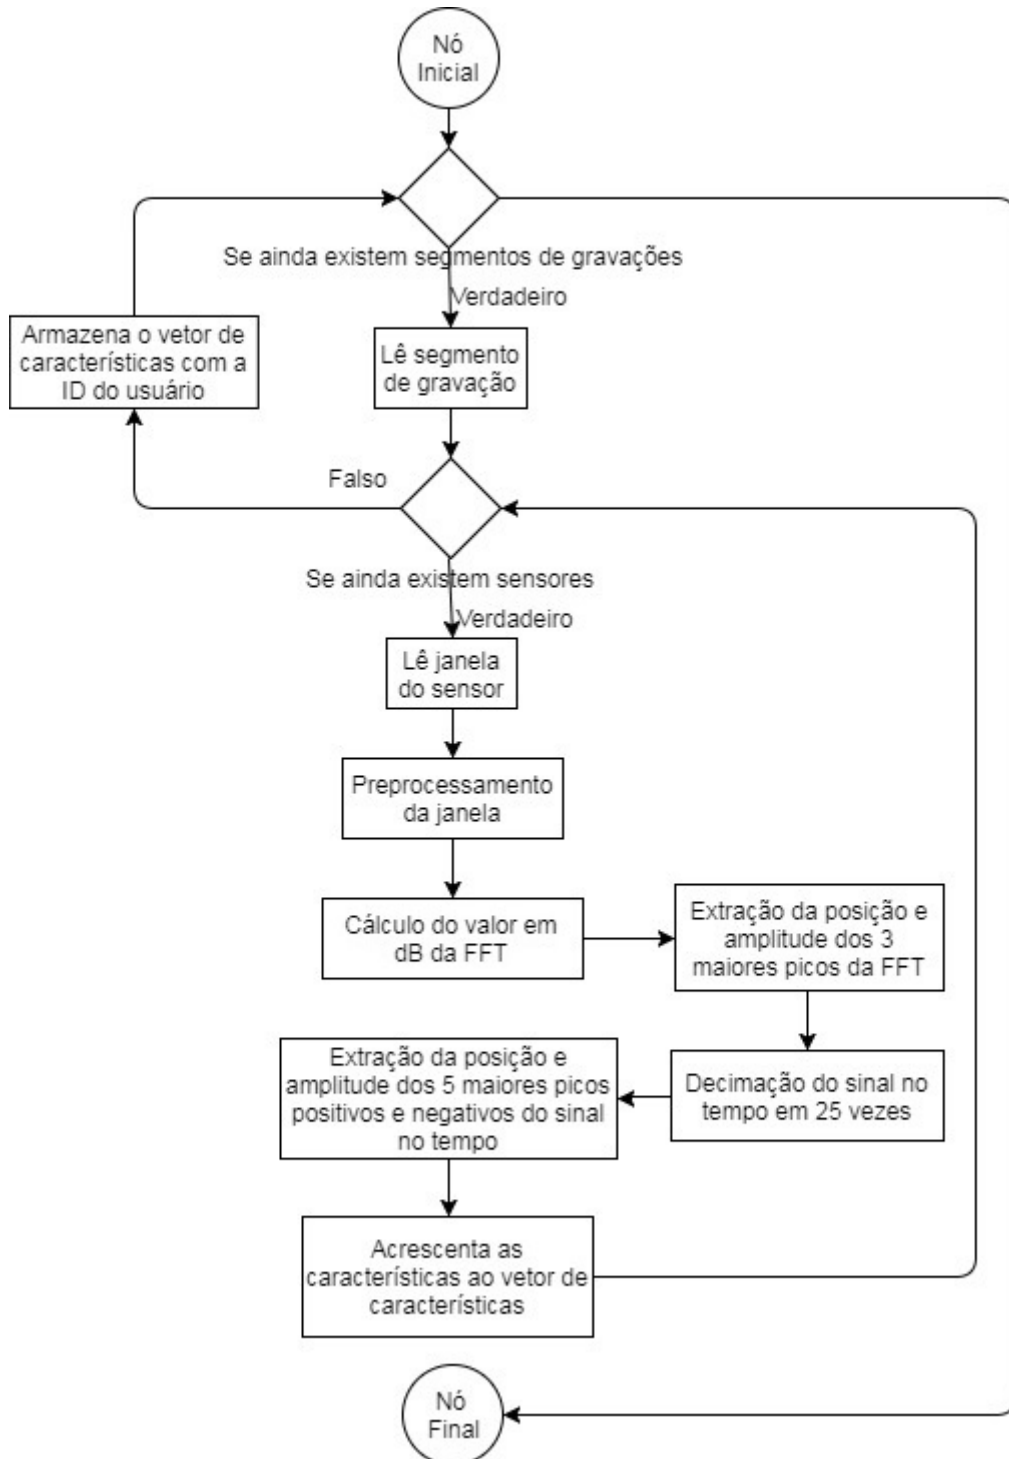
A primeira característica extraída pelo sistema é a FFT que é calculada utilizando a função *rfft()* da biblioteca *numpy* do *Python 3.5.3*. São selecionados os valores em dB nas frequências de 4 a 100 Hz totalizando 48 pontos, já que a FFT é extraída da janela de 0,5 segundos, portanto apresenta resolução de 2 Hz. Em seguida, são encontrados os picos da FFT utilizando a função *peakdet()* desenvolvida por Eli Billauer (2012) e apresentada no Anexo A. Os picos são ordenados em ordem crescente e o valor e a posição dos 3 picos com maior amplitude são adicionados ao vetor de características, totalizando mais 6 características.

A primeira característica no domínio tempo a ser extraída é o sinal decimado com um fator de subamostragem de 25. Para a decimação do sinal é utilizada a função *decimate()* da biblioteca *scipy* do *Python 3.5.3*. Como o fator de subamostragem é de 25, o sinal de 500 amostras (0,5 segundos), antes amostrado a 1 kHz, é reduzido para um sinal de 20 amostras, agora amostrado a 40 Hz. Antes da decimação a função *decimate()* aplica um filtro passa-baixas Chebyshev do Tipo 1 de 8ª ordem com frequência de corte em 20 Hz para manter a condição imposta pelo teorema de Nyquist. Por fim, os picos positivos e os picos negativos do sinal no tempo são encontrados usando novamente a função *peakdet()*. Eles são ordenados em ordem crescente e o valor e posição dos 5 picos positivos com maior amplitude e dos 5 picos negativos com maior amplitude são adicionados ao vetor de características, totalizando mais 20 pontos.

O procedimento descrito para a extração das características é repetido para o sinal de cada sensor, sendo as características de todos os sensores concatenadas em um único vetor.

No fim o vetor contém 270 características na frequência, sendo 54 de cada sensor, e 200 características no tempo, sendo 40 de cada sensor. A Figura 19 apresenta o fluxograma da etapa de extração de características.

Figura 19 - Fluxograma da etapa de extração de características.



Como se pretende avaliar a influência das características utilizadas e da quantidade e posição dos sensores utilizados na taxa de acerto do sistema, o sistema possibilita ao usuário a escolha dos sensores e das características utilizadas para o treinamento do modelo. Por fim, o vetor de características de cada segmento é, então, armazenado junto com o ID do voluntário associado àquele segmento. Na sequência, esses dados serão utilizados para o treinamento e teste do modelo SVM.

3.5. IMPLEMENTAÇÃO DO MODELO SVM PARA IDENTIFICAÇÃO DE PESSOAS

Para a identificação de pessoas através da vibração gerada no solo pela marcha humana, foram treinados e testados modelos SVM utilizando as características extraídas na Seção 3.4. Todos os procedimentos para treinamento e teste dos modelos foram realizados utilizando as funções do módulo *svm* da biblioteca *scikit-learn* do *Python 3.5.3*. Antes do treinamento, foi aplicado aos vetores de características o procedimento conhecido como *feature scaling* através da função *StandardScaler()*. Esse procedimento realiza a normalização independente de cada característica retirando a média e dividindo pela variância de todos os valores dessa característica presentes no conjunto de treinamento. É importante salientar que para o treinamento dos modelos foram utilizadas como entrada as características extraídas de cada um dos segmentos individualmente.

O primeiro passo para o treinamento é a divisão da base de dados em um subconjunto de treinamento e um subconjunto de teste. Essa divisão já ocorreu na fase anterior à segmentação dos sinais, visto que, foram separados os dados em subconjuntos a partir do número da caminhada e não do sinal já segmentado. Esse procedimento foi escolhido, pois separando os dados pelo número da caminhada impede que passos de uma mesma caminhada estejam no subconjunto de treinamento e no subconjunto de teste ao mesmo tempo. Isso seria indesejado, já que passos pertencentes a uma mesma caminhada são altamente

correlacionados, podendo, assim, ser obtido um resultado muito otimista em relação a uma situação experimental.

A separação das caminhadas ocorreu da seguinte forma: 40 caminhadas (80%) de cada pessoa foram selecionadas de forma aleatória para o subconjunto de treinamento, enquanto as outras 10 (20%) foram colocados no subconjunto de teste. Ainda, o subconjunto de treinamento foi subdividido em 8 subconjuntos de mesmo tamanho selecionados de forma aleatória a fim de ser utilizado um procedimento de validação cruzada *k-fold* para avaliar a capacidade de generalização do modelo, assim como, poder avaliar o desempenho do classificador com relação a outros classificadores. A separação dos dados no subconjunto de treinamento e no subconjunto de validação é apresentada na Figura 20. Vale ressaltar que as caminhadas para cada subconjunto foram escolhidas de forma aleatória.

Figura 20 - Separação dos dados em treinamento e validação.

Treinamento							Teste	
			80%				20%	Sujeito 1
			80%				20%	Sujeito 2
			80%				20%	...
			80%				20%	Sujeito 12

A partir dos 8 subconjuntos de treinamento, um deles foi selecionado como subconjunto de validação para a determinação dos hiperparâmetros do modelo SVM, conforme ilustra o subconjunto amarelo da Figura 20. Como, neste trabalho, foi utilizado um classificador SVM com *kernel* RBF, são dois os hiperparâmetros que devem ser otimizados no modelo: o parâmetro de regularização C e a variância do *kernel* RBF $1/\gamma$. Assim, para a seleção dos parâmetros foi utilizada uma busca em grade, onde $C \in \{0,1; 0, 1; 3; 10\}$ e $\gamma \in \{0,001; 0,003; 0,01; 0,03; 0,1\}$. Dessa forma, são 25 as possíveis combinações de

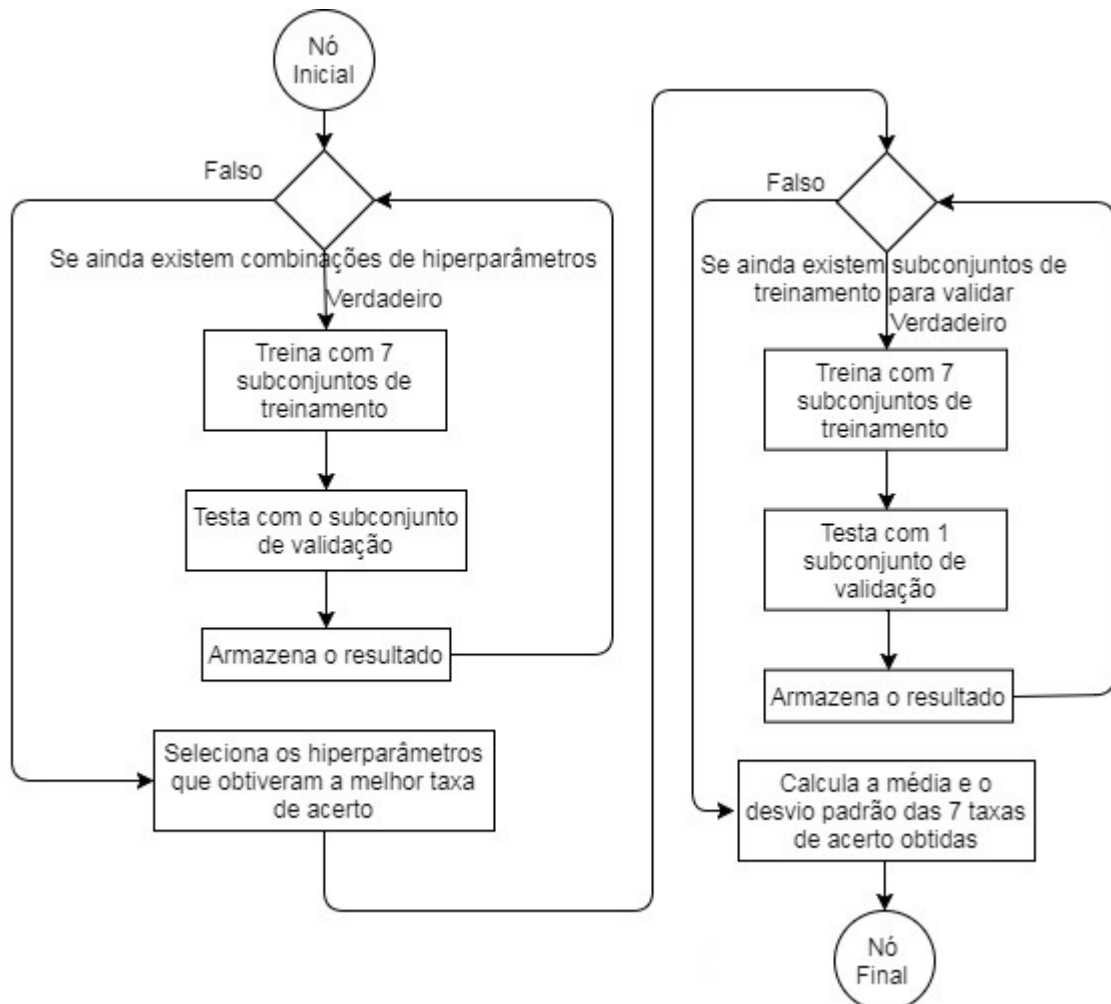
parâmetros e para cada combinação foi treinado o modelo com os 7 subconjuntos restantes no treinamento e validado com o subconjunto selecionado previamente para a determinação dos parâmetros. Os parâmetros escolhidos foram aqueles com os quais foi obtida a maior taxa de acerto.

Em seguida, após os parâmetros do modelo terem sido selecionados, ele é avaliado utilizando ainda os dados de treinamento. Para a avaliação, um subconjunto de treinamento é mantido como subconjunto de validação para avaliar o modelo, enquanto os outros 7 subconjuntos são utilizados para o treinamento. Esse procedimento foi repetido 7 vezes, sendo cada vez selecionado um dos subconjuntos de treinamento para a validação. É importante ressaltar que o subconjunto selecionado previamente para a determinação dos parâmetros não foi utilizado, nesta etapa, para a avaliação do modelo, sendo utilizado apenas para o treinamento do mesmo. Para avaliar o desempenho do modelo, a métrica selecionada foi a taxa de acerto. Assim, foram obtidas 7 taxas de acerto das quais foi calculado a média e o desvio padrão para a posterior análise. A Figura 21 apresenta o fluxograma da etapa de treinamento e validação.

O procedimento de treinamento e validação foi realizado para diferentes configurações de modelo, sendo avaliada a influência da quantidade e da posição dos sensores utilizados, assim como, das características utilizadas (o procedimento de comparação de desempenho dos modelos é explicado em detalhes na Seção 3.6). Por fim, a configuração do modelo que obteve o melhor resultado na etapa de treinamento foi treinada novamente utilizando todos os dados do subconjunto de treinamento. Esse modelo foi testado contra os dados de teste a fim de avaliar o desempenho do mesmo contra dados não utilizados pela etapa de treinamento. Na etapa de teste, foi obtida ainda a matriz de confusão relacionando os sujeitos verdadeiros com os sujeitos classificados.

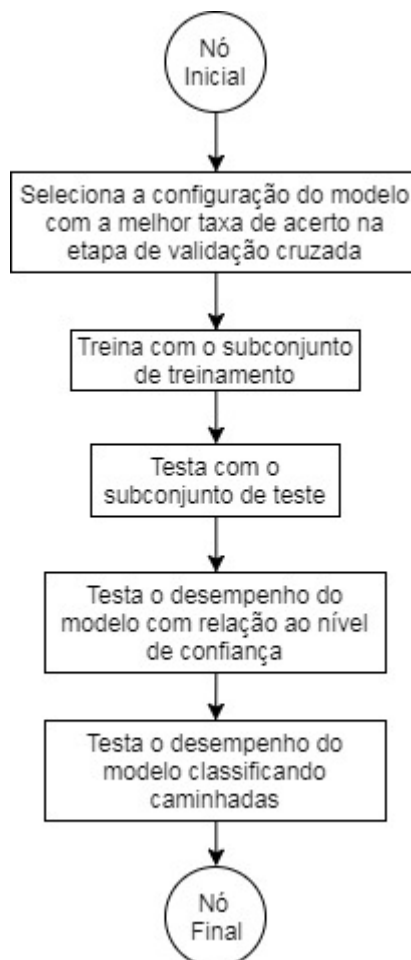
Cabe ressaltar que com relação ao teste ainda foi possível avaliar o desempenho do modelo de acordo com o nível de confiança obtido para cada predição. Para tanto, foi utilizada a estimação da probabilidade dada pela função *predict_proba()* do módulo *svm* da biblioteca *scikit-learn* do *Python 3.5.3*. Essa função retorna a probabilidade para cada usuário de que o passo seja pertencente a ele. Assim, o usuário predito é aquele que apresentar a maior probabilidade. Essa probabilidade foi, então, utilizada como um nível de confiança da predição. Dessa forma, foi avaliada a taxa de acerto do modelo com o mesmo classificando somente os passos que apresentam nível de confiança acima de determinado limiar. O resultado da avaliação é apresentado em forma de gráfico contendo a taxa de acerto, assim como, a porcentagem de passos classificados em relação ao valor do limiar utilizado.

Figura 21 - Fluxograma da etapa de treinamento e validação de um modelo.



Até agora, todas as análises foram realizadas utilizando apenas um passo segmentado para a classificação. Entretanto, outra forma de se classificar é utilizar uma sequência de passos pertencentes a uma mesma caminhada. Dessa forma, foi utilizado o subconjunto de teste para avaliar o desempenho do modelo quando a caminhada de 5 segundos do usuário é classificada. Para a classificação de uma caminhada, foram utilizados todos os passos segmentados da mesma e realizado um sistema de votação majoritária. Assim, todos os passos segmentados da caminhada predizem o usuário associado à caminhada e o usuário que obtiver mais votos é o escolhido como predição final. Esse método foi avaliado pela taxa de acerto e matriz de confusão utilizando o subconjunto de teste. O fluxograma da etapa de teste é apresentado na Figura 22.

Figura 22 - Fluxograma da etapa de teste do modelo.



3.6. PROCEDIMENTO PARA COMPARAÇÃO DOS CLASSIFICADORES

O procedimento proposto na Seção 3.5 foi realizado para diferentes classificadores, sendo avaliada a influência da quantidade e posição dos sensores utilizados, bem como, o conjunto de características utilizadas para classificação. A influência desses fatores foi analisada individualmente para cada fator. A métrica utilizada para a avaliação foi a taxa de acerto que é equivalente ao número de todas as entradas classificadas corretamente sobre o número total de entradas.

Em um primeiro momento, foram escolhidos 10 conjuntos diferentes de sensores para avaliar a influência dos mesmos na taxa de acerto. Os conjuntos escolhidos foram: só o sensor 1; só o sensor 2; só o sensor 3; só o sensor 4; só o sensor 5; os sensores 1 e 2; os sensores 3 e 4; os sensores 1, 3 e 5; os sensores 1, 2, 3 e 4; e todos os sensores. Para cada conjunto, foi utilizada como entrada do modelo um vetor contendo a concatenação de todas as características apresentadas na Seção 3.4 extraídas de cada um dos sensores pertencentes ao conjunto. Foi realizado o treinamento e a validação de cada modelo, sendo obtida a taxa de acerto média e o desvio padrão de cada um.

Em um segundo momento, foram escolhidos 8 conjuntos de características a fim de se avaliar o desempenho do modelo com relação as mesmas. Dessa forma, os conjuntos escolhidos foram: só a FFT; só a amplitude e a posição dos picos da FFT; só o sinal decimado; só a amplitude e a posição dos picos do sinal no tempo; a FFT e a amplitude e a posição dos picos da FFT; o sinal decimado e a amplitude e a posição dos picos do sinal no tempo; a FFT e o sinal decimado; e todas as características. Como entrada de cada modelo, foi utilizado o conjunto de características extraídas de todos os 5 sensores concatenadas, sendo a taxa de acerto média junto com seu desvio padrão calculada para cada classificador.

Por fim, os resultados obtidos foram analisados e foi escolhido o melhor classificador com relação aos sensores utilizados e o melhor classificador com relação às características

utilizadas. Utilizando o conjunto de sensores e o conjunto de características que obtiveram o melhor desempenho, foi treinado um classificador utilizando todos os dados do subconjunto de treinamento. O desempenho desse novo modelo foi, então, avaliado contra o subconjunto de teste, simulando, assim, uma situação experimental.

4 RESULTADOS E DISCUSSÕES

Neste capítulo serão apresentados os resultados obtidos a partir do método experimental proposto neste trabalho. São abordados e discutidos, inicialmente, os resultados da simulação e calibração dos circuitos de condicionamento. Em seguida, exemplos de sinais obtidos com a construção da base de dados são apresentados para retratar o resultado obtido na segmentação e extração de características. Na sequência, são comparados classificadores com relação à quantidade e posição dos sensores utilizados e com relação às características utilizadas. Por fim, os resultados obtidos com o modelo selecionado na identificação de pessoas através da vibração gerada no solo pela marcha humana são apresentados e comparados com os resultados obtidos por outros trabalhos da área.


4.1. SIMULAÇÃO DO CIRCUITO DE CONDICIONAMENTO

O resultado da simulação da resposta em frequência do circuito de condicionamento realizado com o *software LTspice XVII* é apresentado na Figura 23. Observa-se a amplitude do ganho dada em dB no traço contínuo e a fase dada em graus (°) no traço pontilhado. A simulação mostra que o valor máximo da amplitude é de 57,2 dB que é equivalente a 724 na escala linear, valor que está 5% abaixo do valor calculado de 762. Era esperado que o valor calculado fosse maior que o valor obtido com a simulação, já que para o cálculo do ganho foi considerado apenas o comportamento da parte resistiva do circuito, ignorando a atenuação em função do filtro. Ainda, a simulação mostra a resposta passa faixas do circuito, sendo o valor de -3 dB em relação ao máximo em 3,8 Hz para o filtro passa altas e o valor de -6 dB em relação ao máximo em 104 Hz para o filtro passa baixas. Ambos os valores de frequência de corte estão dentro da faixa de 10% do valor de 4,1 Hz e 106 Hz calculados, respectivamente.

Analisando ainda a Figura 23, observa-se que o valor da amplitude em 500 Hz está 40 dB abaixo do valor máximo, valor este que equivale a 100 na escala linear. Sendo assim, o

ganho na frequência de Nyquist é igual a 100 vezes menor que ganho máximo. Em relação ao filtro passa altas, observa-se que o valor em 1 Hz está a -12,2 dB em relação ao máximo, valor este que está dentro do esperado para um filtro de primeira ordem, considerando que em 1 Hz ainda não foi completada uma década em relação a frequência de corte.

Figura 23 – Resposta em frequência simulada do circuito de condicionamento.

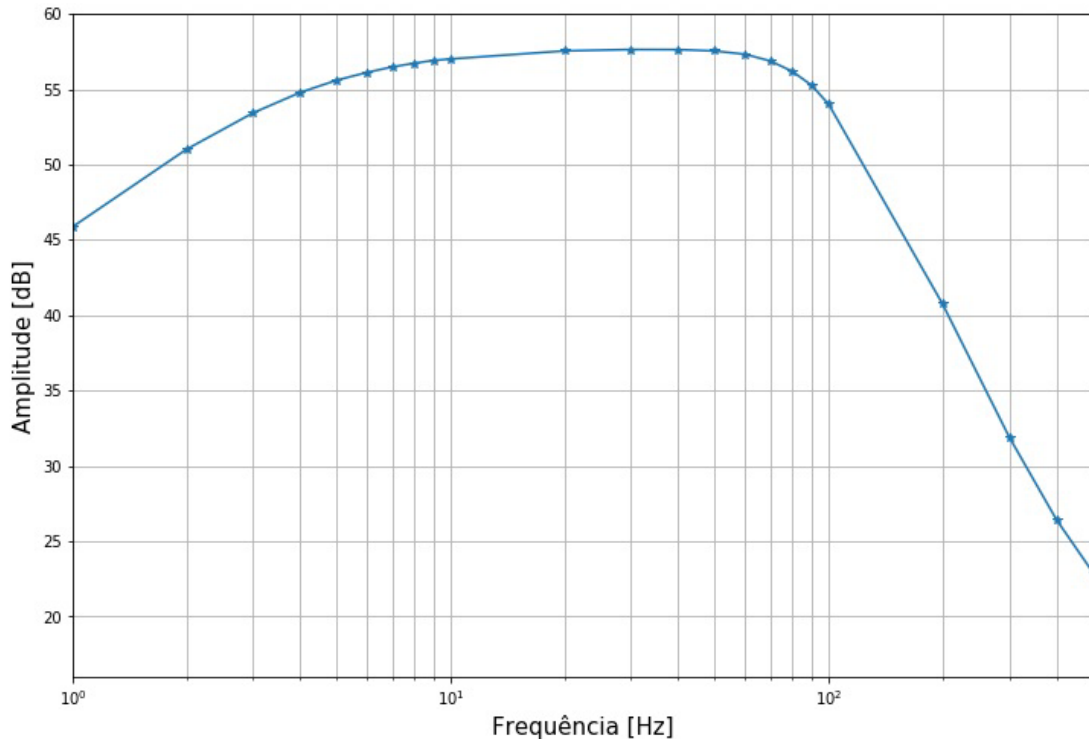


4.2. CALIBRAÇÃO DOS CIRCUITOS DE CONDICIONAMENTO

A resposta em frequência levantada experimentalmente do circuito de condicionamento é apresentada na Figura 24. Inicialmente, pode-se fazer a comparação visual entre o resultado obtido na Figura 23 e o resultado obtido na Figura 24, notando-se que as formas das duas curvas se assemelham. Assim como na simulação, o valor máximo da amplitude do ganho obtido na medida experimental foi em torno de 57 dB. Na resposta em frequência experimental, o valor de -3 dB para o filtro passa-altas encontra-se entre 3 e 4 Hz e o valor de -6 dB para o filtro passa-baixas encontra-se um pouco acima de 100 Hz, valores estes que estão condizentes com o esperado pelo equacionamento teórico e a pela simulação.

Pode-se avaliar, ainda, os valores obtidos experimentalmente em 1 Hz que encontra-se em torno de 11 dB abaixo do máximo. Finalmente, o valor em 500 Hz obtido experimentalmente encontra-se a 35 dB abaixo do máximo.

Figura 24 - Resposta em frequência experimental do circuito de condicionamento.



Na estimativa do ganho, os resultados obtidos a partir da inserção de uma onda de 20 Hz na entrada e variação de amplitude de 4 mVpp a 20 mVpp com a respectiva medição da saída 5 vezes para cada valor é apresentado na Tabela 1. A partir das regressões lineares realizadas para cada um dos 5 conjuntos de pontos, foram obtidas os ganhos também apresentados na Tabela 1. Assim, calculando-se a média e o desvio padrão da média com os dados da Tabela 1, obtém-se o ganho estimado e sua incerteza padrão do Tipo A apresentado na Equação (41):

$$G_{est} = 740 \pm 3,53 \quad (41)$$

Tabela 1 - Amplitudes de saída para diferentes amplitudes de entrada e ganho obtido a partir de uma regressão linear com cada conjunto de pontos.

Vin [mVpp]	Vout [Vpp]				
4	2,95	2,99	3,07	2,99	2,94
6	4,38	4,36	4,36	4,54	4,51
8	6,02	5,91	5,9	6,01	5,97
10	7,49	7,44	7,34	7,45	7,50
12	9,00	8,78	8,79	8,81	8,93
14	10,5	10,3	10,4	10,5	10,3
16	11,9	11,8	11,9	11,9	11,7
18	13,5	13,5	13,5	13,4	13,4
20	15,0	14,9	15,0	14,9	14,9
Ganho	752	734	742	741	732

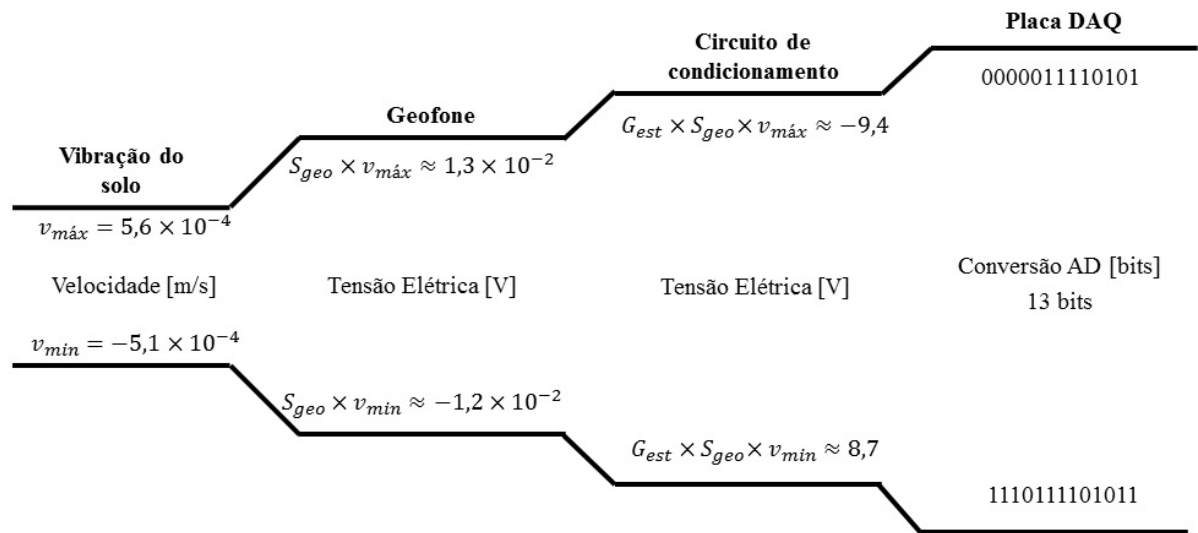
O ganho experimental é equivalente a 740, valor este que está 3% abaixo da estimativa teórica de 762. Assim, conclui-se que o circuito de condicionamento apresenta um comportamento dentro do esperado pelo projeto, podendo, então, ser utilizado para condicionar o sinal do geofone na coleta dos dados.

Por fim, a Cadeia de Medidas Experimental do sistema de instrumentação é apresentada na Figura 25. Para a construção da Cadeia de Medidas Experimental, foi utilizado o ganho experimental, assim como, os valores de saturação do sistema medidos. Na cadeia de medidas experimental, S_{geo} é a sensibilidade do geofone fornecida pelo fabricante igual a $23,4 V/(m/s)$ com tolerância de $\pm 10\%$; G_{est} é o valor do ganho experimental do circuito de condicionamento igual a $-740 \pm 3,53$; e $v_{m\acute{a}x}$ e $v_{m\acute{i}n}$ são, respectivamente, as velocidades máximas e mínimas que o sistema é capaz de medir. Assim como foi realizado na parte teórica, utilizando a cadeia de medidas, é possível calcular a resolução de saída do sistema, dada pela Equação (42), e a resolução de entrada do sistema, dada pela Equação (43). Ressalta-se que, como não foi possível calibrar o geofone, a resolução de entrada do sistema foi calculada a partir dos dados esperados na saída.

$$\text{Resolução de saída} = \frac{2V_{ADC}}{2^{n_{bits}}} \approx 2,4 \text{ mV/bit} \quad (42)$$

$$\text{Resolução de entrada} = \frac{\text{Resolução de saída}}{S_{geo} \times G} \approx 1,4 \times 10^{-7} \text{ m/s} \quad (43)$$

Figura 25 - Cadeia de Medidas Experimental.




4.3. SEGMENTAÇÃO E EXTRAÇÃO DE CARACTERÍSTICAS

Para avaliar o algoritmo de segmentação dos passos, são necessárias algumas considerações iniciais. Como na coleta da base de dados os usuários foram solicitados a caminhar na sua velocidade normal de passo e foram gravados 5 segundos de cada caminhada, não se tem o número exato de passos dado por cada usuário. Ainda, como a gravação de cada caminhada iniciou após o usuário já ter começado a mesma e terminou enquanto o usuário ainda caminhava, o primeiro passo e o último passo podem ser coletados apenas parcialmente. Dessa forma, tomando-se a estimativa média da duração de um passo de 0,5 segundos, estima-se que em uma caminhada de 5 segundos obtêm-se 8 passos, excluindo-se o passo inicial e o passo final. Como foram gravadas 50 caminhadas de cada um dos 12 usuários, estima-se que foram coletados 400 passos por usuário e 4800 passos no total.

Inicialmente, o valor de α (variável que controla o limiar de segmentação) foi escolhido como 0,4 a partir do teste de valores entre 0,3 a 0,7 com resolução de 0,1. Assim, para avaliar o algoritmo de segmentação realizou-se a segmentação em todas as caminhadas coletadas, com um valor de α igual a 0,4. Com esse procedimento, foi obtido um total de 4464 passos segmentados. Como o número total de passos coletados é estimado em 4800, estima-se que 93% dos passos coletados foram segmentados.

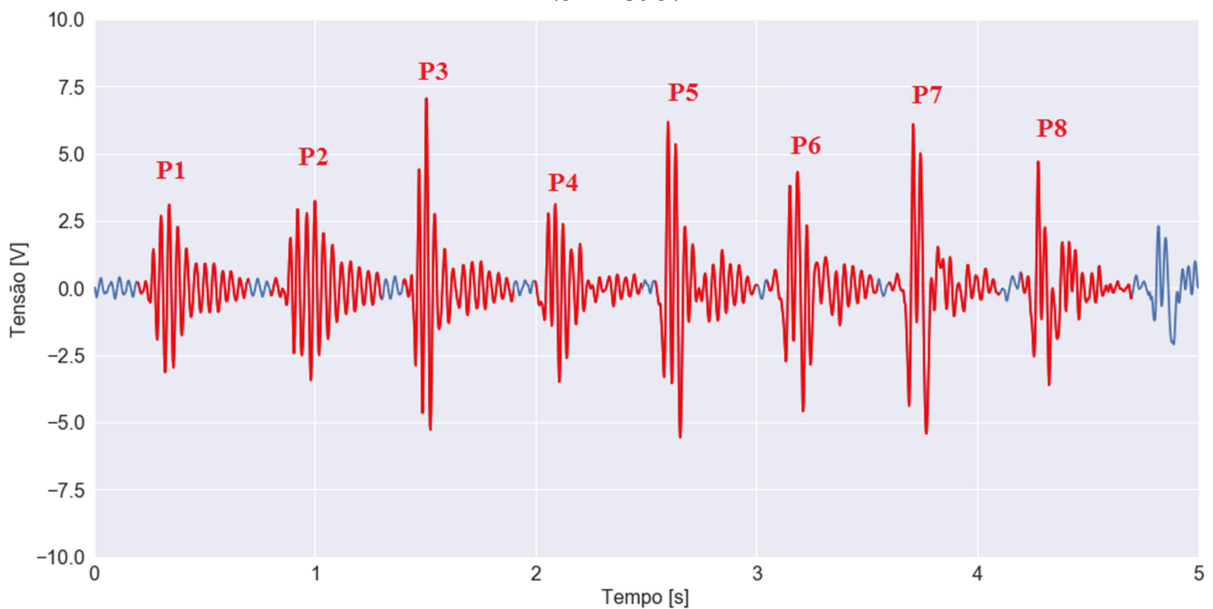
Para analisar o algoritmo de segmentação em detalhes, foi analisado o número de passos segmentados por pessoa, bem como, o número de passos segmentados por gravação. A Figura 26 (a) apresenta o número de passos segmentados para cada usuário em forma de gráfico de barras. A Figura 26 (b) apresenta o número de gravações por quantidade de passos segmentados em forma de gráfico de barras. Analisando-se a Figura 26 (a), observa-se que a pessoa com mais passos segmentados apresenta 417 passos, enquanto a pessoa com menos passos segmentados apresenta 333 passos. Em média, foram segmentados 372 passos por pessoa com desvio padrão de 24,1 passos. Analisando-se a Figura 26 (b), observa-se que 85% das gravações tiveram entre 7 e 9 passos segmentados. Em média, foram segmentados 7,4 passos por gravação com desvio padrão de 0,9 passos.

Figura 26 - (a) Número de passos segmentados por sujeito; (b) Número de passos segmentados por gravação.



Por fim, um exemplo típico de passos segmentados em uma gravação de um sensor é apresentado na Figura 27. Observa-se os 8 passos da gravação segmentados em vermelho, e um nono passo, por não estar completo, não sendo segmentado. Analisando-se a forma de onda, observa-se que os passos do início da gravação, bem como, os passos do fim da gravação são semelhantes entre si. Esse efeito é devido à função de transferência do local do ensaio que é dependente da posição do passo em relação ao sensor. Entretanto, como passos próximos apresentam formas de onda semelhantes, é possível concluir que a função de transferência varia suavemente com a posição.

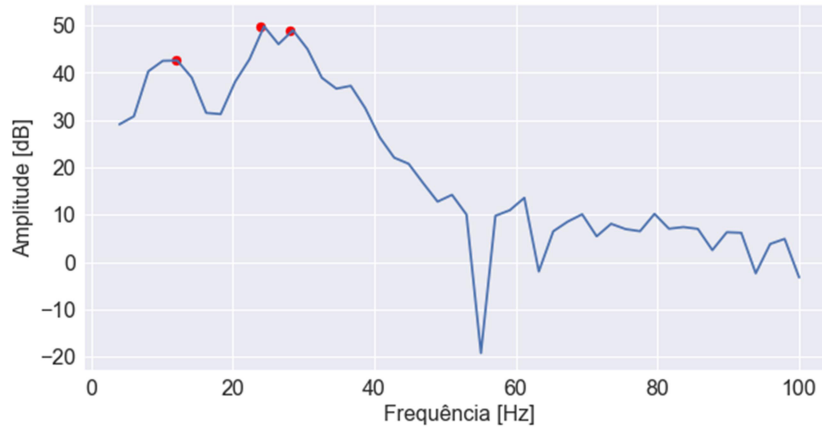
Figura 27 - Típico exemplo de passos segmentados em uma gravação com geofone RTC-4.5Hz-395.



A análise da etapa de extração de características é realizada a partir do passo P5 da Figura 27. A Figura 28 apresenta a FFT do sinal em dB com a localização dos 3 picos com maior amplitude, dos quais foram extraídas a amplitude e a posição na frequência. Observa-se do sinal no domínio da frequência que a maior parte da energia do sinal está concentrada nas frequências abaixo de 50 Hz. O vetor de características da FFF contém 48 amostras correspondentes as frequências de 4 Hz a 100 Hz. O vetor de características dos picos da FFT


contém 6 amostras, sendo 3 referentes a amplitude dos picos e 3 referentes a posição dos mesmos.

Figura 28 - FFT em dB e localização dos picos da FFT do passo P5 da Figura 27.




A Figura 29 apresenta as características extraídas no domínio tempo do passo P5 da Figura 27. A Figura 29 (a) apresenta o sinal decimado com um fator de 25. Observa-se que o sinal decimado contém apenas as baixas frequências (abaixo de 20 Hz) que são aquelas que apresentam boa parte da quantidade de energia do sinal (conforme Figura 28). A Figura 29 (b) apresenta a localização dos 5 maiores picos positivos e negativos do sinal no tempo, dos quais foram extraídas a amplitude e a posição no tempo. O vetor de características do sinal decimado contém 20 amostras, como se o sinal estivesse sendo amostrado a 40 Hz. O vetor de características dos picos do sinal no tempo também apresenta 20 amostras, sendo 10 referentes às amplitudes e 10 referentes às posições no tempo dos picos.

Figura 29 - (a) Sinal decimado com fator de 25; (b) Localização dos picos do sinal no tempo.



(a)



(b)

4.4. COMPARAÇÃO DOS CLASSIFICADORES

Para comparar os classificadores, foi realizada a separação da base de dados de forma aleatória, entretanto, foi utilizada a mesma separação para a validação cruzada de todos os classificadores. Assim, garante-se que os resultados obtidos sejam mais facilmente comparáveis entre si. A primeira avaliação de classificadores foi realizada com relação aos sensores utilizados para o treinamento do modelo. Para cada conjunto de sensores foi realizada a determinação dos parâmetros C e α do modelo SVM e a posterior avaliação do modelo com a validação cruzada *k-fold*. A taxa de acerto e o desvio padrão da mesma para cada conjunto de sensores são apresentados na Tabela 2. Os mesmos resultados são apresentados em forma de gráfico de barras com os respectivos intervalos de confiança na Figura 30.


Tabela 2 - Taxa de acerto dos classificadores com relação aos sensores utilizados.

Sensores utilizados	Taxa de acerto \pm Desvio padrão
1	61,7% \pm 2,8%
2	65,1% \pm 3,5%
3	74,1% \pm 2,5%
4	72,1% \pm 3,0%
5	77,8% \pm 2,1%
1, 2	65,0% \pm 2,5%
3, 4	73,7% \pm 3,0%
1, 3, 5	85,7% \pm 2,1%
1, 2, 3, 4	84,0% \pm 2,8%
1, 2, 3, 4, 5	86,2% \pm 2,7%

Comparando-se o resultado dos classificadores quanto aos sensores utilizados para a classificação, observa-se que ocorre uma variação de mais de 15% entre os resultados obtidos utilizando apenas um dos sensores. Dessa forma, é possível concluir que a posição dos

sensores interfere na taxa de acerto. Ainda, analisando-se em detalhes, observa-se que os sensores 1 e 2, bem como, os sensores 3 e 4 apresentam suas taxas de acerto média dentro do intervalo de confiança de um desvio padrão em relação ao outro. Este comportamento pode ser explicado pelo posicionamento dos sensores, sendo os sensores 1 e 2, bem como, os sensores 3 e 4 próximos entre si. Já o sensor 5, que fica centralizado no meio do retângulo, apresenta a maior taxa de acerto entre todos os sensores. Um fator determinante para esse resultado é o posicionamento desse sensor, que por estar no centro do local de caminhada, apresenta uma relação sinal ruído maior que a dos outros sensores.

Figura 30 - Taxa de acerto média por sensores utilizados.



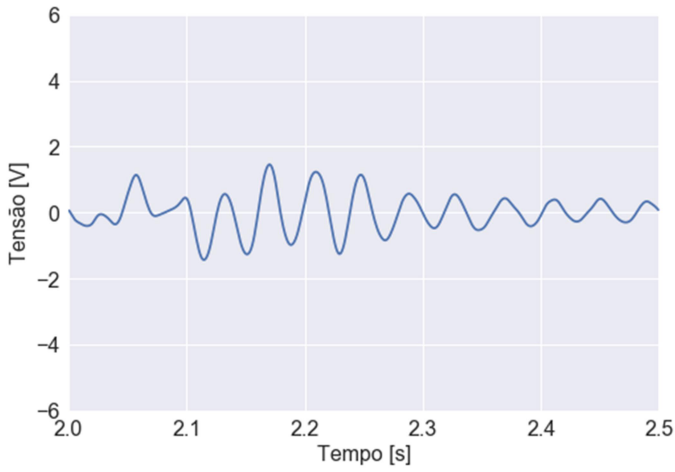
Na análise do resultado da classificação para um conjunto de sensores, observa-se que a classificação com os sensores 1 e 2 não obtém um resultado melhor do que a classificação com apenas um desses sensores. O mesmo ocorre para a classificação com os sensores 3 e 4 que não obtém um resultado melhor do que a classificação com apenas um desses sensores. Assim, como já mencionado anteriormente, por esses sensores estarem próximos entre si, a

informação que eles trazem juntos pode ser muito semelhante à informação trazida por cada um individualmente.


Observa-se que o conjunto de sensores 1, 3 e 5 obtém um melhor resultado que o conjunto de sensores 1, 2, 3 e 4, apesar do último apresentar mais sensores no conjunto. Novamente, pode-se explicar este resultado pelo posicionamento dos sensores, sendo o primeiro conjunto formado por 3 sensores em posições distintas do piso, enquanto o último formado por 4 sensores com os sensores 1 e 2 e os sensores 3 e 4 posicionados próximos entre si. Por fim, o conjunto com o melhor resultado é o conjunto com todos os sensores, entretanto, ressalta-se que o conjunto com 3 sensores apresenta uma diferença de apenas 0,5% com relação ao resultado do conjunto com todos os sensores. Assim, conclui-se que a quantidade de sensores utilizados para a classificação é importante para a melhora do resultado, entretanto, para uma utilização otimizada dos sensores, é importante posicioná-los no piso considerando-se a estrutura do local de ensaio a fim de evitar sensores com sobreposição de informação.

De forma a ilustrar com mais clareza as conclusões obtidas do posicionamento dos sensores, a Figura 31 apresenta o passo P4 da Figura 27 coletado com cada um dos sensores. Analisando-se a Figura 31, observa-se que, como já concluído anteriormente, a forma de onda dos sensores 1 e 2, assim como, a forma de onda dos sensores 3 e 4 são muito semelhantes entre si, apesar das diferenças de amplitude. Já a forma de onda do sensor 5 é diferente das demais. Assim, fica evidente a influência da escolha da posição dos sensores para se obter um classificador otimizado com relação ao número de sensores utilizados. Dessa forma, a posição dos sensores e quantidade dos mesmos deve ser escolhida de acordo com a variação da função de transferência do piso do local de ensaio com relação à posição.


Figura 31 - Passo P4 da Figura 27 coletado com (a) sensor 1; (b) sensor 2; (c) sensor 3; (d) sensor 4; (e) sensor 5.




(a)




(b)



(c)



(d)



(e)

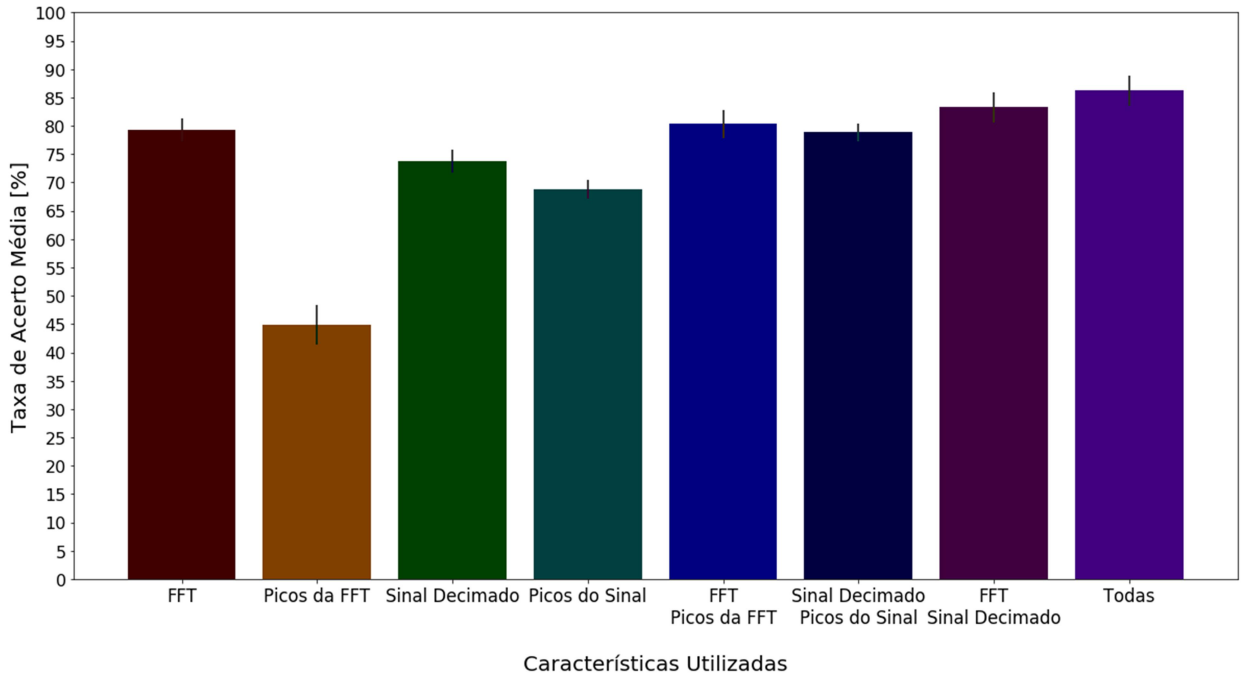
A segunda avaliação de classificadores foi com relação às características utilizadas como entrada do modelo. Assim como foi realizado para os sensores, para cada conjunto de características foi determinado os parâmetros C e α do modelo SVM e, utilizando esses parâmetros, foi realizada a validação cruzada k -fold do modelo. Os resultados obtidos para cada classificador são apresentados na Tabela 3. Para facilitar a visualização, os mesmos resultados são apresentados em forma de gráfico de barras com os respectivos intervalos de confiança na Figura 32.

Tabela 3 - Taxa de acerto dos classificadores com relação às características utilizadas.

Características utilizadas	Taxa de acerto \pm Desvio padrão
FFT	79,3% \pm 2,0%
Picos da FFT	44,9% \pm 3,5%
Sinal Decimado	73,8% \pm 2,0%
Picos do Sinal	68,7% \pm 1,7%
FFT e Picos da FFT	80,3% \pm 2,5%
Sinal decimado e Picos do Sinal	78,9% \pm 1,6%
FFT e Sinal Decimado	83,3% \pm 2,7%
Todas	86,2% \pm 2,7%

Comparando-se os resultados quando só um grupo de características é utilizado, percebe-se que os melhores resultados são obtidos com a FFT e com o sinal decimado. Utilizando apenas os valores em dB da FFT ou apenas o sinal decimado, já é possível chegar a uma taxa de acerto acima de 70%. Já utilizando apenas os picos da FFT, a taxa de acerto não chega nem a 50% e utilizando apenas os picos do sinal no tempo a taxa de acerto não passa de 70%. Assim, nota-se que os picos na frequência ou no tempo não conseguem apresentar toda a informação do sinal relevante para a classificação de pessoas seja na frequência ou no tempo.

Figura 32 - Taxa de acerto média por características utilizadas.



Analisando-se os resultados utilizando apenas as características no tempo e apenas as características na frequência, percebe-se que as características na frequência obtêm uma taxa de acerto média superior. Entretanto, a diferença do resultado entre as taxas de acerto média dos dois grupos é de apenas 1,4%. Assim, não é possível afirmar se há alguma vantagem em utilizar apenas as características no tempo ou na frequência.

Nota-se, ainda, que a utilização das características no tempo em conjunto com as características na frequência aumenta a taxa de acerto média, como pode ser observado no classificador utilizando a FFT e o sinal decimado e no classificador utilizando todas as características. O melhor resultado é obtido com todas as características, igual a $86,2\% \pm 2,7\%$. Assim, conclui-se que todas as características utilizadas podem agregar informação relevante na classificação de pessoas, sendo os valores em dB da FFT de 4Hz a 100Hz as características mais relevantes.

Em função dos resultados apresentados nesta seção, o classificador escolhido para a avaliação no conjunto de teste foi o classificador utilizando todos os sensores e todas as

características. Esse classificador foi escolhido, pois o trabalho não tem como objetivo a otimização do custo computacional para o treinamento e predição através do modelo. Entretanto, acredita-se que utilizando todos os sensores e todas as características, o vetor de características apresente variáveis possivelmente correlacionadas. Assim, se o objetivo fosse pela otimização do número de características utilizadas, poderia ser implementado alguma transformação de redução dimensional, como por exemplo, a *Principal Component Analysis* (PCA). Os resultados obtidos no conjunto de teste com o modelo escolhido são apresentados na seção seguinte.

4.5. AVALIAÇÃO DO MODELO NO CONJUNTO DE TESTE

Após a escolha dos sensores e das características utilizadas como entrada do modelo, foi possível treinar o mesmo utilizando todos os dados de treinamento seguido da avaliação nos dados de teste. A taxa de acerto obtida foi de 87,0%, que está dentro do intervalo de confiança obtido na validação cruzada. Assim, conclui-se que o modelo generaliza de forma satisfatória para dados que não foram utilizados na etapa de treinamento. A matriz de confusão, apresentando os sujeitos verdadeiros no eixo vertical em relação aos sujeitos preditos no eixo horizontal, é apresentada na Figura 33.

Analisando-se a matriz de confusão, observa-se que o sujeito com a maior taxa de acerto obtém 96,20%, enquanto o sujeito com a menor taxa de acerto obtém 74,03%. A diferença entre a melhor e a pior taxa de acerto por sujeito é superior a 20%, dessa forma, apesar da análise estar sendo feita com o resultado de apenas uma matriz de confusão, é possível se esperar que o sujeito influencie na taxa de acerto do sistema. No geral, são apenas 3 sujeitos que apresentam taxa de acerto inferior a 80%. Ainda, todos os sujeitos apresentam taxa de acerto superior a 70%.

Além disso, a matriz de confusão mostra que o maior erro sistemático, ou seja, a confusão de um usuário com outro específico apresenta uma taxa de ocorrência de 7,69%. Essa taxa de confusão ocorre para o usuário 5 com o usuário 8. Entretanto, se for analisado o usuário 5 em específico, percebe-se que ele é confundido ao menos uma vez com 7 dos 11 usuários restantes na base de dados. Assim, nota-se que os erros apresentam um aspecto mais aleatório do que sistemático. Isso indica que, possivelmente, não existem na base de dados dois usuários quaisquer que apresentam a forma de caminhar similar o suficiente para serem confundidos sistematicamente.

Figura 33 - Matriz de confusão na avaliação do modelo no conjunto de teste.

1	87.84	2.70	1.35	0.00	1.35	0.00	0.00	0.00	2.70	4.05	0.00	0.00
2	2.33	94.19	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.16	1.16	1.16
3	0.00	1.27	96.20	0.00	0.00	1.27	1.27	0.00	0.00	0.00	0.00	0.00
4	0.00	0.00	0.00	91.04	0.00	2.99	2.99	0.00	2.99	0.00	0.00	0.00
5	1.28	1.28	0.00	2.56	79.49	0.00	0.00	7.69	2.56	2.56	2.56	0.00
6	0.00	0.00	1.52	1.52	1.52	87.88	0.00	1.52	0.00	3.03	1.52	1.52
7	2.74	1.37	0.00	0.00	0.00	0.00	87.67	1.37	1.37	1.37	1.37	2.74
8	0.00	0.00	0.00	0.00	6.41	0.00	0.00	84.62	3.85	1.28	2.56	1.28
9	1.37	2.74	0.00	0.00	1.37	0.00	1.37	2.74	89.04	0.00	0.00	1.37
10	5.19	0.00	3.90	2.60	0.00	3.90	1.30	1.30	1.30	74.03	2.60	3.90
11	1.39	0.00	0.00	0.00	2.78	0.00	0.00	1.39	0.00	0.00	93.06	1.39
12	2.56	0.00	2.56	0.00	0.00	1.28	1.28	1.28	5.13	2.56	3.85	79.49
	1	2	3	4	5	6	7	8	9	10	11	12

Comparando o resultado obtido com outros trabalhos da área, observa-se que a taxa de acerto na classificação de um passo do presente trabalho, 87,0%, é maior do que as obtidas nos trabalhos de PAN *et al.* (2015) e PAN *et al.* (2017), iguais a 63% e 83%, respectivamente. Além de apresentar uma taxa de acerto maior, o presente trabalho realizou os experimentos em uma base de dados com 12 usuários, sendo a base de dados dos trabalhos citados com 5 e 10 usuários, respectivamente. Ambos os trabalhos citados utilizaram um classificador SVM, sendo que o trabalho de PAN *et al.* (2017) utiliza versões modificadas do algoritmo a fim de

introduzir as variações causadas pelas diferentes velocidades de passo de cada usuário. Alguns fatores que podem ter influenciado na obtenção de um resultado melhor pelo presente trabalho são o modelo do sensor, a quantidade de sensores utilizados e as características utilizadas.

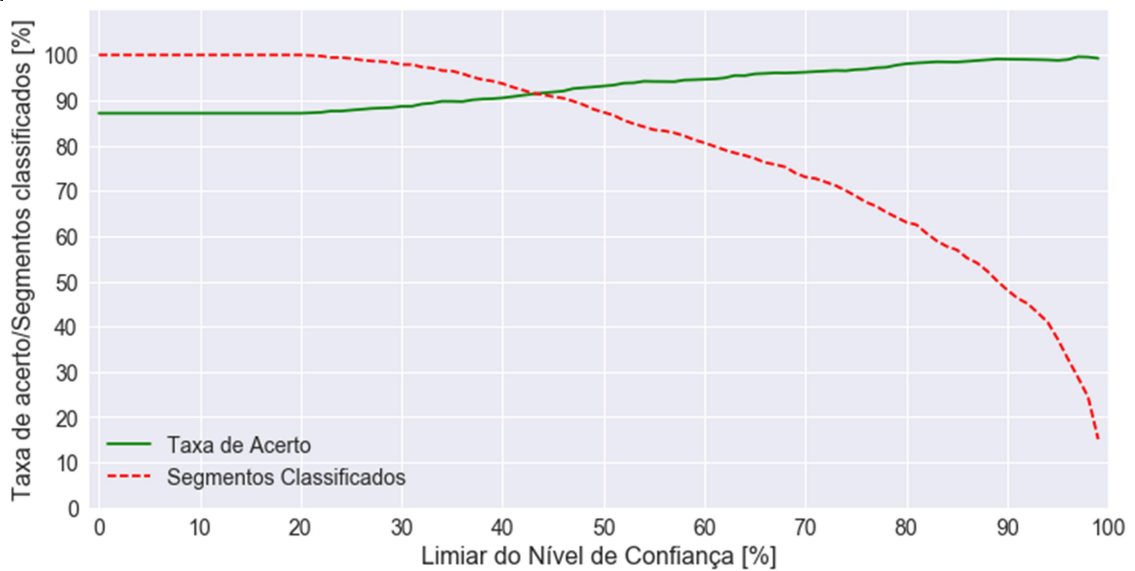
Nos dois trabalhos citados foi utilizado apenas um geofone, modelo SM-24, que apresenta frequência de ressonância em 10 Hz, ou seja, o sinal abaixo de 10 Hz é atenuado pela resposta do geofone. Já no presente trabalho, como foi utilizado um geofone com frequência de ressonância em 4,5 Hz, pode-se recuperar parte do sinal contido abaixo de 10 Hz. Além disso, neste trabalho foram utilizados 5 geofones para a classificação, o que já indicou uma melhora na taxa de acerto nos resultados obtidos na Seção 4.4. Com relação às características, no trabalho de PAN *et al.* (2015) foram utilizadas características no tempo e na frequência, entretanto, são poucas as características temporais utilizadas (variância, entropia, valores de pico e sinal parcial antes e após o pico máximo). Já no trabalho de PAN *et al.* (2017) foram utilizadas apenas características na frequência. Dessa forma, como foi apresentado na Seção 4.4, a utilização das características no tempo e na frequência escolhidas pelo presente trabalho melhora a taxa de acerto do modelo.

Em seguida, é apresentado o resultado da classificação dos segmentos quando os mesmos são classificados somente se o nível de confiança da predição é maior que um limiar pré-determinado. O resultado é apresentado na Figura 34, onde o traço verde/contínuo representa a taxa de acerto do sistema, enquanto o traço vermelho/tracejado representa a porcentagem de segmentos classificados com relação ao valor de limiar utilizado.

Na Figura 34, observa-se que até um limiar de nível de confiança de 20%, a taxa de acerto não varia. Já com o limiar em 50%, a taxa de acerto obtida é de 93,5% com 87,8% dos segmentos sendo classificados. Aumentando o limiar para 90%, a taxa de acerto fica superior a 99%, sendo 48,5% das janelas classificadas. Dessa forma, é possível concluir que utilizando


um limiar de nível de confiança, é possível se obter resultados superiores ao resultado obtido sem limiar, com a consequência de que uma parte dos passos segmentados não será classificada. Portanto, esta técnica pode ser utilizada para aplicações em que a taxa de erro do sistema tenha que ser muito próxima de zero e a classificação de todas as janelas não seja estritamente necessária.

Figura 34 - Taxa de acerto e taxa de segmentos classificados por limiar do nível de confiança.



Por fim, a classificação da caminhada inteira do usuário foi realizada para as caminhadas do conjunto de teste. Como a classificação da caminhada foi dependente do número de passos segmentados na mesma, inicialmente, apresenta-se na Figura 35, o número de passos segmentados em cada caminhada do conjunto de teste. Dessa forma, todas as caminhadas classificadas apresentam 5 segundos, entretanto a quantidade de passos utilizados para cada classificação foi variável apresentando uma média de 7,5 passos com desvio padrão de 0,9 passos.

Figura 35 - Quantidade de passos por gravação no conjunto de teste.



A taxa de acerto obtida na classificação de caminhadas foi de 99,2%, sendo que apenas 1 caminhada das 120 testadas foi classificada de forma errada. Esse resultado é bastante promissor, entretanto vale ressaltar que o número de caminhadas utilizadas para teste é demasiadamente pequeno e, por elas terem sido gravadas uma em sequência da outra, elas podem ser bastante correlacionadas. Dessa forma, conclui-se que a utilização de uma sequência de passos para a classificação de pessoas aumenta a taxa de acerto. Portanto, esse tipo de técnica pode ser implementada em aplicações que não precisam de uma resposta imediata quanto à identidade do usuário, podendo ser utilizado mais de um passo para a classificação do mesmo. A matriz de confusão na classificação de caminhadas do conjunto de teste é apresentada na Figura 36.

Ainda, é possível comparar o resultado obtido pelo presente trabalho na classificação de caminhadas, 99,2%, com os resultados obtidos pelo trabalho de PAN *et al.*(2015) e PAN *et al.*(2017), iguais a 83% e 97%. Novamente, o resultado obtido pelo presente trabalho é superior. Além dos fatores já apresentados anteriormente para explicar o melhor resultado obtido, outro fator importante a ser analisado na classificação de caminhadas é a quantidade de passos utilizados para a classificação. Neste trabalho foram utilizados em média 7,5 passos para a classificação de cada caminhada, já nos trabalhos citados, foram utilizados 5 e 7

passos, respectivamente. Assim, a utilização de mais passos em sequência para a classificação de uma caminhada pode ser um fator determinante no melhor desempenho apresentado por este trabalho.

Figura 36 - Matriz de confusão na avaliação do modelo classificando caminhadas do conjunto de teste.

1	100.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
2	0.00	100.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
3	0.00	0.00	100.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
4	0.00	0.00	0.00	100.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
5	0.00	0.00	0.00	10.00	90.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
6	0.00	0.00	0.00	0.00	0.00	100.00	0.00	0.00	0.00	0.00	0.00	0.00
7	0.00	0.00	0.00	0.00	0.00	0.00	100.00	0.00	0.00	0.00	0.00	0.00
8	0.00	0.00	0.00	0.00	0.00	0.00	0.00	100.00	0.00	0.00	0.00	0.00
9	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	100.00	0.00	0.00	0.00
10	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	100.00	0.00	0.00
11	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	100.00	0.00
12	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	100.00
	1	2	3	4	5	6	7	8	9	10	11	12

5 CONCLUSÕES

O presente trabalho avaliou a possibilidade de identificação de pessoas através da vibração mecânica gerada no solo pela marcha humana. Inicialmente, foi proposto um sistema para a medição desta vibração com o uso de geofones com seus respectivos circuitos de condicionamento e um módulo de aquisição A/D. Com esse sistema, foi realizada a coleta de dados de caminhadas de 12 participantes em um ambiente específico. A partir da base de dados coletada, foram realizados experimentos treinando e validando modelos SVM com o kernel RBF capazes de classificar a pessoa associada à caminhada, visando avaliar a influência da quantidade e posição dos sensores utilizados, assim como, das características utilizadas na taxa de acerto. Por fim, com a melhor configuração de modelo obtida, foi treinado um classificador de pessoas com o conjunto de treinamento e posteriormente testado no conjunto de testes da base de dados.

Na etapa de projeto e calibração do condicionador de sinal para o geofone, foi obtida a função de transferência simulada, bem como, a função de transferência experimental do filtro projetado. As funções de transferência apresentam um valor máximo de 57,2 dB para o caso simulado e 57,4 dB para o caso experimental, valores que são um pouco inferiores ao valor de 57,6 dB calculado na etapa de projeto. Ainda, as duas funções de transferência apresentam a frequência de corte do filtro passa-altas em torno de 4 Hz e a frequência de corte do filtro passa-baixas em torno de 100 Hz, da mesma forma que havia sido calculado na etapa de projeto. Dessa forma, conclui-se que o funcionamento dos circuitos está de acordo com o que foi projetado, podendo então, os mesmos serem utilizados no condicionamento do sinal do geofone na coleta da base de dados.

A base de dados coletada apresenta 50 caminhadas de 5 segundos de 12 usuários diferentes. No geral, é estimado que cada caminhada apresente 8 passos, contendo a base de dados em torno de 4800 passos no total, sendo 400 de cada usuário. Na etapa de segmentação

dos sinais, foram segmentados 4464 passos, o que seria equivalente a 93% do número total de passos da base. Ainda, o número médio de passos segmentados por caminhada foi de 7,4 passos com desvio padrão de 0,9 passos e o número total de passos segmentados por pessoa foi de 372 passos com desvio padrão de 24,1 passos.

Em seguida, a análise da taxa de acerto dos classificadores SVM treinados quanto à quantidade e à posição dos sensores utilizados e quanto às características utilizadas foi realizada. Considerando a quantidade de sensores utilizados, foi mostrado que com o aumento do número dos mesmos obtém-se, normalmente, uma melhor taxa de acerto. Na análise utilizando apenas um sensor, foi mostrado que o posicionamento do sensor no piso interfere na taxa de acerto. Além disso, foi apresentado que sensores próximos entre si apresentam uma taxa de acerto equivalente considerando-se um desvio padrão como nível de confiança. Assim, a utilização de um conjunto de sensores próximos entre si para o treinamento não melhora o resultado com relação ao resultado obtido utilizando apenas um desses sensores. Portanto, a escolha do melhor posicionamento dos sensores pode ser fundamental para que se obtenha uma taxa de acerto superior com o aumento da quantidade dos mesmos.

Considerando as características utilizadas para o treinamento do modelo, é apresentado que a utilização somente da FFT ou do sinal decimado já obtém uma taxa de acerto superior a 70%. Ainda, mostrou-se que tanto a utilização das características no domínio tempo quanto a utilização das características no domínio da frequência apresentam resultados semelhantes, não podendo ser afirmado que algum domínio contenha mais informação que o outro. Por fim, é apresentado que a utilização das características no domínio do tempo em conjunto com as características no domínio da frequência obtém o melhor resultado na validação cruzada *k-fold*, equivalente a $86,2\% \pm 2,7\%$.

O modelo escolhido na etapa precedente foi avaliado contra o subconjunto de teste. O resultado obtido na classificação de um passo foi de 87,0%, resultado este que está dentro de

um desvio padrão do resultado obtido com a validação cruzada *k-fold*, mostrando, assim, que o modelo generaliza de forma satisfatória para novos dados. A matriz de confusão apresentada na etapa de teste mostra que a taxa de acerto varia de acordo com o sujeito analisado. Na sequência, o modelo foi avaliado quanto ao nível de confiança da predição, sendo obtida uma melhora absoluta de 6,5% na taxa de acerto quando é utilizado um nível de confiança de 50%. Ainda, foi mostrado que com o este nível de confiança, 87,8% dos segmentos são classificados. Portanto, para aplicações que não necessitam a classificação de todos os segmentos, esta técnica pode ser utilizada para o aumento da taxa de acerto.

Por fim, a avaliação do modelo na classificação de caminhadas do subconjunto de teste foi realizada. O resultado obtido foi de 99,2%, sendo frisado que a quantidade de caminhadas classificadas é pequena e as mesmas são, possivelmente, correlacionadas. Dessa forma, o resultado tende a ser demasiadamente otimista. Apesar disto, o resultado obtido indica que com o aumento do número de passos utilizados para a classificação ocorre o aumento da taxa de acerto. Portanto, para aplicações em que o tempo utilizado para a predição não é um fator determinante, é possível a utilização desta técnica com o intuito de aumentar a taxa de acerto do sistema.

6 PROPOSTA PARA TRABALHOS FUTUROS

Nesta seção são apresentados alguns dos desafios propostos para a melhoria e continuação do trabalho. Esses desafios incluem tanto aspectos da etapa de estudo da possibilidade de identificação de pessoas através marcha, quanto aspectos práticos na implementação de um sistema em tempo real que identifica pessoas.

Inicialmente, considerando-se a etapa da coleta de dados podem ser abordados dois pontos. O primeiro ponto é a calibração do sensor, que não foi possível ser realizada neste trabalho, entretanto é de fundamental importância para qualquer sistema de instrumentação. O segundo ponto é a criação de um sistema mais autônomo, com o uso de baterias e comunicação sem fio para realçar a vantagem do sistema de coletar os dados a distância e de forma esparsa com relação a outros sistemas de identificação através da marcha.

Com relação à etapa de segmentação dos sinais, acredita-se que, apesar da segmentação ter apresentado um resultado satisfatório para o presente trabalho, é possível aumentar sua taxa de acerto e torná-la mais robusta. O algoritmo utilizado por este trabalho parte do pressuposto que as caminhadas foram coletadas em um ambiente controlado. Entretanto, para uma aplicação real, são diversos os tipos de ruído que podem vir a interferir na segmentação dos passos. Assim, propõe-se a melhora do algoritmo de segmentação utilizando técnicas de aprendizado de máquina.

Outro aspecto que poderia ter sido avaliado pelo presente trabalho é a comparação do desempenho utilizando diferentes métodos de classificação, como por exemplo, Regressão Logística, SVM, RNAs, etc. Em conjunto com os métodos, novas características extraídas dos passos que combinam os domínios do tempo e da frequência poderiam ser testadas, como por exemplo, Espectrograma, Transformada Wavelet, etc. Ainda sobre a comparação de classificadores, poderia ser realizada a análise estatística com testes de hipótese a fim de avaliar a significância dos resultados.

Um fator que se mostrou influenciar nos resultados foi a posição dos sensores em relação ao passo, ou seja, a variação com a posição da função de transferência do piso. Dessa forma, propõe-se a avaliação de diferentes pisos, assim como, um estudo mais detalhado de quais são os fatores da função de transferência do piso que fazem a taxa de identificação melhorar ou piorar. Para esta análise, seria indicado coletar caminhadas de usuários controlando o local médio de cada passo. Da mesma forma que o piso altera o sinal medido, pode-se esperar que o calçado utilizado pelo usuário influencie no sinal coletado. Assim, a avaliação da classificação com diferentes tipos de calçado também é proposta como objeto de estudo futuro.

Por fim, um dos aspectos mais relevantes na avaliação de sistemas biométricos é quantidade de pessoas na base de dados. Dessa forma propõe-se aumentar a base de dados a fim de avaliar se os resultados mantêm-se com o aumento da mesma. Junto com o número de pessoas, a quantidade de caminhadas coletadas também poderia ser aumentada. Dessa forma, poderia ser avaliado o comportamento do sistema em uma situação mais realista em que os dados utilizados para treinamento e validação são coletados até certa data e os dados utilizados para teste são coletados a partir dessa data.

REFERÊNCIAS BIBLIOGRÁFICAS

- AILISTO, H. J. *et al.*. Identifying people from gait pattern with accelerometers. In: **Proceedings of SPIE Volume: 5779; Biometric Technology for Human Identification II**, v. 5779, p. 7–14, mar 2005.
- ANTONSSON, E. K.; MANN R. W., The frequency content of gait, In: **Journal of Biomechanics**, v. 18, n° 1, p. 39–47, 1985.
- BALBINOT, A. **Notas de aula. Disciplina de Instrumentação**, UFRGS, 2016.
- BISHOP, C. M. **Pattern Recognition and Machine Learning**. New York: Springer, 2013. v. 53 ISBN: 978-0-3873-1073-2
- BOUCHRIKA, I. On evaluating the scalability aspect of gait-based biometric systems for larger population, In: **3rd International Conference on Control, Engineering & Information Technology**. p. 1-6, mai. 2015.
- CAMPBELL, C.; CRISTIANINI, N. Simple Learning Algorithms for Training Support Vector Machines. **Technical report, University of Bristol**. mai, 1999.
- COLLETTE, C. *et al.* Comparison of new absolute displacement sensors, In: **International Conference on Noise and Vibration Engineering**. set. 2012.
- COLLETTE, C. *et al.* Review of sensors for low frequency seismic vibration measurement. **Bulletin of the Seismological Society of America**, [S.1], v.105, p. 497-510, abr. 2015.
- DERLATKA, M.; BOGDAN, M. Ensemble kNN classifiers for human gait recognition based on ground reaction forces, In: **8th International Conference on Human System Interactions**. p. 88-93, jun. 2015.
- EKIMOV A.; SEBATIER, J. Vibration and sound signatures of human footsteps in buildings. **The Journal of the Acoustical Society of America**. v. 120, n. 2, p. 762-768. jun. 2006.
- FABER, K.; MAXWELL, P. W. Geophone spurious frequency: What is it and how does it affect seismic data?. In: **SEG Technical Program Expanded Abstracts**. Society of Exploration Geophysicists. p. 79-80. jan 1996
- GAFUROV, D. A survey of biometric gait recognition: Approaches, security and challenges. In: **Proceedings of the Annual Norwegian Computer Science Conference**, Oslo, Norway, p. 19–21, nov. 2007.
- HAVSKOV, J. AGUACIL, G. **Instrumentation in Earthquake Seismology**. Springer, 2004. p. 360. ISBN: 978-1-4020-2969-1

HEARST, M. A. *et al.* Trends and Controversies - Support Vector Machines. **IEEE Intelligent Systems**, v. 13, n. 4, p. 18–28, jul, 1998.

JAIN, A. K.; ROSS, A.; PRABHAKAR, S. An Introduction to Biometric Recognition. **IEEE Transactions on Circuits and Systems for Video Technology**. v. 14, p. 4-20. jan. 2004

KARKI, J. Analysis of the Sallen-Key Architecture. **Texas Instruments**. set. 2002.

LIU, Z.; SARKAR, S. Improved Gait Recognition by Gait Dynamics Normalization. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 28, n. 6, p. 863-876. jun 2006.

LORENA, A. C.; CARVALHO, A. C. Uma Introdução às Support Vector Machines. **Revista de Informática Teórica e Aplicada**. v. 14, n. 2. jan 2007

National Instruments. NI USB-6008/6009 *User Guide*, jun, 2015.

OBERG, T.; KARSZNIA, A.; OBERG, K. Basic gait parameters: reference data for normal subjects, 10-79 years of age. In: **Journal of rehabilitation research and development**, v. 30, n. 2, p. 210-223. fev, 1993

PAKHOMOC, A. *et al.* Current Seismic Sensor Issues for Defense and Security Applications, In: **Proceedings of SPIE Volume: 5403, Sensors, and Command, Control, Communications, and Intelligence (C3I) Technologies for Homeland Security and Homeland Defense III**, v. 5403, p. 576, set. 2004.

PAKHOMOC, A. *et al.* Testing of new seismic sensors for footstep detection and other security applications. In: **Proceedings of SPIE Volume: 5778, Sensors, and Command, Control, Communications, and Intelligence (C3I) Technologies for Homeland Security and Homeland Defense IV**, v. 5778, p. 422, ago. 2005.

PAN, S. *et al.* FootprintID: Indoor Pedestrian Identification through Ambient Structural Vibration Sensing. In: **Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies**. v. 1, n. 3, p. 1-31, set. 2017.

PAN, S. *et al.* Indoor Person Identification through Footstep Induced Structural Vibration. . In **The 16th International Workshop on Mobile Computing Systems and Applications**. p. 81-86, fev. 2015.

POLITERM, POL-16E *Datasheet*, jul 2011.

R. T. Clark, RTC-4.5Hz-395 *Datasheet*, nov 2012.

SEBATIER, J.; EKIMOV A. A Review of Human Signatures in Urban Environments Using Seismic and Acoustic Methods, In: **IEEE Conference on Technologies for Homeland Security**, p.215-220, mai. 2008.

SEBATIER, J.; EKIMOV A. Range limitation for seismic footstep detection, In: **Proceedings of SPIE - The International Society for Optical Engineering**, 6963, apr. 2008.

STUART-WATSON, D.; TAPSON, J. Simple force balance accelerometer/seismometer based on a tuning fork displacement sensor. **Review of Scientific Instruments**. [S.1], v. 75, jun. 2004.

SUUTALA, J.; RÖNING, J. Methods for person identification on a pressure-sensitive floor: Experiments with multiple classifiers and reject option. **Information Fusion Journal, Special Issue on Applications of Ensemble Methods** v. 9, p. 21–40, jan, 2008.

UNAR, J. A.; SENG, W. C.; ABBASI. A. A review of biometric technology along with trends and prospects. **The Journal of the Pattern Recognition Society**. [S.1], v. 47, p. 2673-2688, ago. 2014.

VAUGHAN, C. L.; DAVIS, B.L.; O'CONNOR, J. C. **Dynamics of human gait**. Kiboho Publishers, Cape Town, South Africa, 2nd edition, 1999. ISBN: 978-0-8732-2370-6

VERA-RODRIGUEZ, R; MASON, J. S. D.; FIERREZ, J. Comparative Analysis and Fusion of Spatiotemporal Information for Footstep Recognition. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 35, n. 4, p. 823-834, abr. 2013.

WHITTLE, M. **Gait Analysis: an introduction**. Butterworth-Heinemann, p. 244, 2007. ISBN: 978-0-7506-8883-3

YUN, J. User Identification Using Gait Patterns on UbiFloorII. **Sensors Journal, IEEE**, v. 10, n. 9, p. 1447–1460, mar. 2011.

ANEXO A: Função para detecção de picos por Eli Billauer

```

import sys
from numpy import NaN, Inf, arange, isscalar, array

def peakdet(v, delta, x = None):
    """
    Converted from MATLAB script at http://billauer.co.il/peakdet.html

    Returns two arrays

    function [maxtab, mintab]=peakdet(v, delta, x)
    %PEAKDET Detect peaks in a vector
    % [MAXTAB, MINTAB] = PEAKDET(V, DELTA) finds the local
    % maxima and minima ("peaks") in the vector V.
    % MAXTAB and MINTAB consists of two columns. Column 1
    % contains indices in V, and column 2 the found values.
    %
    % With [MAXTAB, MINTAB] = PEAKDET(V, DELTA, X) the indices
    % in MAXTAB and MINTAB are replaced with the corresponding
    % X-values.
    %
    % A point is considered a maximum peak if it has the maximal
    % value, and was preceded (to the left) by a value lower by
    % DELTA.

    % Eli Billauer, 3.4.05 (Explicitly not copyrighted).
    % This function is released to the public domain; Any use is allowed.

    """
    maxtab = []
    mintab = []

    if x is None:
        x = arange(len(v))

    v = asarray(v)

    if len(v) != len(x):
        sys.exit('Input vectors v and x must have same length')

    if not isscalar(delta):
        sys.exit('Input argument delta must be a scalar')

    if delta <= 0:

```

```
sys.exit('Input argument delta must be positive')

mn, mx = Inf, -Inf
mnpos, mxpos = NaN, NaN

lookformax = True

for i in arange(len(v)):
    this = v[i]
    if this > mx:
        mx = this
        mxpos = x[i]
    if this < mn:
        mn = this
        mnpos = x[i]

    if lookformax:
        if this < mx-delta:
            maxtab.append((mxpos, mx))
            mn = this
            mnpos = x[i]
            lookformax = False
    else:
        if this > mn+delta:
            mintab.append((mnpos, mn))
            mx = this
            mxpos = x[i]
            lookformax = True
return array(maxtab), array(mintab)
```