

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
DIRETORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

MÁRIO ELIAS MARINHO VIEIRA

**PROTÓTIPO PARA AUXÍLIO DE IDENTIFICAÇÃO DO TIPO DE
PISADA BASEADA EM SENSORES PIEZOELÉTRICOS E REDES
NEURAIS ARTIFICIAIS**

DISSERTAÇÃO

PONTA GROSSA

2018

MÁRIO ELIAS MARINHO VIEIRA

**PROTÓTIPO PARA AUXÍLIO DE IDENTIFICAÇÃO DO TIPO DE
PISADA BASEADA EM SENSORES PIEZOELÉTRICOS E REDES
NEURAS ARTIFICIAIS**

Dissertação apresentada como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica, do Departamento de Eletrônica, da Universidade Tecnológica Federal do Paraná.

Orientador: Prof. Dr. Sergio Luiz Stevan Jr

PONTA GROSSA

2018

Ficha catalográfica elaborada pelo Departamento de Biblioteca
da Universidade Tecnológica Federal do Paraná, Câmpus Ponta Grossa
n.07/19

V658 Vieira, Mário Elias Marinho

Protótipo para auxílio de identificação do tipo de pisada baseada em sensores piezoelétricos e redes neurais artificiais / Mário Elias Marinho Vieira. 2019.

83 f.; il. 30 cm

Orientador: Prof. Dr. Sergio Luiz Stevan Junior

Dissertação (Mestrado em Engenharia Elétrica) - Programa de Pós-Graduação em Engenharia Elétrica. Universidade Tecnológica Federal do Paraná, Ponta Grossa, 2019.

1. Pés - Anomalias - Tratamento. 2. Classificação. 3. Redes neurais (Computação). 4. Detectores. 5. Engenharia de protótipos. I. Sergio Luiz Stevan Junior. II. Universidade Tecnológica Federal do Paraná. III. Título.

CDD 621.3



Universidade Tecnológica Federal do Paraná
Campus de Ponta Grossa
Diretoria de Pesquisa e Pós-Graduação
**PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA ELÉTRICA**



FOLHA DE APROVAÇÃO

Título de Dissertação Nº 43/2018

**PROTÓTIPO PARA AUXÍLIO DE IDENTIFICAÇÃO DO TIPO DE PISADA
BASEADA EM SENSORES PIEZOELÉTRICOS E REDES NEURAIS ARTIFICIAIS**

por

Mário Elias Marinho Vieira

Esta dissertação foi apresentada às quatorze horas do dia **21 de setembro de 2018** como requisito parcial para a obtenção do título de MESTRE EM ENGENHARIA ELÉTRICA, com área de concentração em Controle e Processamento de Energia, linha de pesquisa em Instrumentação e Controle do Programa de Pós-Graduação em Engenharia Elétrica. O candidato foi arguido pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

Prof. Dr. Leandro Martinez Vargas (UEPG)

Prof. Dr. Hugo Valadares Siqueira (UTFPR)

Prof. Dr. Murilo Oliveira Leme (UTFPR)

Prof. Dr. Sergio Luiz Stevan Jr (UTFPR) -
Orientador

Prof. Dr. Angelo Marcelo Tuset (UTFPR)
Coordenador do PPGE

A FOLHA DE APROVAÇÃO ASSINADA ENCONTRA-SE NO DEPARTAMENTO DE
REGISTROS ACADÊMICOS DA UTFPR - CÂMPUS PONTA GROSSA

Dedico este trabalho a Deus, minha
família e amigos pelo suporte e carinho.

AGRADECIMENTOS

Palavras não podem quantificar minha gratidão e aqui agradeço de forma geral a todos que me ajudaram diretamente ou indiretamente a conquistar mais esse sonho, sem vocês não andaria metade dos meus passos.

À Deus, toda honra, glória e louvor.

À minha esposa Tatiana Vieira e meu filho Elias Vieira, os quais são minha motivação e suporte. Amo vocês.

Aos meus pais e irmãos, pela força, alegria e orações em todos os meus sonhos.

Ao meu orientador Dr. Sergio L. Stevan Jr., o qual me guiou em todos os desafios acadêmicos com sabedoria e companheirismo.

Ao José Jair Alves Mendes Júnior, amigo fundamental nos momentos que mais precisei.

Aos meus amigos Lucas Nascimento, Régis Cardozo, Wesley F. La Blanca, Paulo Redkva, Fabrício Vieira, Mauro Ricetti, Caroline Peixoto e Lucas V. Bonfati; que participaram e me ajudaram a concluir este trabalho.

Ao CIEBE (Centro de Instrumentação em Engenharia Biomédica e Esportiva), em que tive orgulho de participar em sua criação ao lado de pessoas sensacionais, agregando valor à nossa UTFPR - PG.

A sabedoria faz a força do homem; e o conhecimento lhe dá poder. A estratégia é a chave para a guerra, assim como bons conselhos são a chave para a vitória (Bíblia, Provérbios 24:4-5).

RESUMO

VIEIRA, Mário Elias Marinho. **Dispositivo para auxílio de identificação do tipo de pisada baseada em sensores piezoelétricos e redes neurais artificiais.** 2018. 83 f. Dissertação (Mestrado em Engenharia Eletrônica) - Universidade Tecnológica Federal do Paraná. Ponta Grossa, 2018.

Este trabalho tem como objetivo o desenvolvimento de uma palmilha instrumentada, baseada em sensores piezoelétricos cerâmicos e redes neurais artificiais para identificação do tipo de pisada; e assim auxiliar em análises e diagnósticos de profissionais da saúde. A pressão plantar é resultante do contato da região plantar (inferior do pé) com uma superfície, podendo ser medida por meio de plataformas baropodométricas ou palmilhas instrumentadas. Essa variável é utilizada em estudos de correção postural, análise do movimento, correção do tipo de pisada e identificação de doenças na região plantar. O dispositivo contém uma palmilha instrumentada com 13 sensores dividida em regiões plantares (retropé, mediopé, antepé e hálux), acoplada à uma placa central que realiza o condicionamento e transmissão sem fio dos dados. Como receptor e armazenamento dos dados, foi utilizado um dispositivo móvel (*smartphone*) via comunicação Bluetooth[®]. Foram coletados os dados de pressão plantar de 14 pessoas com média de idade de $28,7 \pm 8,8$ anos, utilizados como entrada em uma rede neural artificial (RNA) MLP (*Multi-Layer Perceptron*) para classificação do tipo de pisada de cada indivíduo. Todos os indivíduos realizaram um procedimento de caminhar 10 vezes um percurso de 10 metros com o dispositivo instalado, totalizando 100 metros. Após a coleta de dados realizada, um profissional da saúde avaliou cada um dos indivíduos para fornecer a saída desejada da RNA em supinada, pronada e neutra. Os dados foram processados e divididos em amostras, as quais foram utilizadas como base de dados da RNA. Como métodos de treinamento da RNA, foram aplicados *holdout* e validação cruzada. A MLP contendo 21 neurônios na camada escondida, utilizando validação cruzada, obteve 99,63% de acerto para todo o conjunto de dados. Adicionalmente, tem-se os resultados obtidos divididos em acurácia, sensibilidade, especificidade e eficiência (matriz de confusão) por tipo de pisada; apresentando os mínimos e máximos respectivamente: 99,7% e 100% em acurácia (neutra, supinada e pronada), 99,7% e 100% em sensibilidade (neutra e pronada), 99,8% e 100% em especificidade (supinada e pronada), e por último, 99,7% e 100% em eficiência (neutra e pronada). Baseando-se nesses valores é possível afirmar que a RNA possui maior dificuldade de distinguir a pisada supinada da neutra. Com isso, conclui-se que é possível utilizar o protótipo desenvolvido para medição de pressão plantar, assim como a MLP projetada para classificar o tipo de pisada de um indivíduo.

Palavras-chave: Pressão plantar. Palmilha instrumentada. Tipo de pisada. MLP. Classificação automática.

ABSTRACT

VIEIRA, Mário Elias Marinho. **Device to assist in type of footprint identification based on piezoelectric sensor and artificial neural network**. 2018. 83 p.
Dissertation (Master Degree in Electrical Engineer) Federal University of Technology - Paraná. Ponta Grossa, 2018.

The aim of this work is the development of an instrumented insole, based on ceramic piezoelectric sensors and artificial neural networks to identify the type of footprint; and thus assist in the analysis and diagnosis of health specialists. The plantar pressure is the result of the contact of the plantar region (lower foot) with a surface, and can be measured by baropodometric platforms or instrumented insoles. This variable is used in studies of postural correction, movement analysis, correction of the type of footfall and identification of diseases in the plantar region. The device contains an instrumented insole with 13 sensors divided into plantar regions (hindfoot, midfoot, forefoot and hallux), coupled to a central board that performs conditioning and wireless transmission of the data. As a receiver and data storage, a mobile device (smartphone) was used via Bluetooth[®] communication. Plantar pressure data were collected from 14 people with mean age of 28.7 ± 8.8 years, used as input in an artificial neural network (RNA) MLP (Multi-Layer Perceptron) to classify the type of footprint of each one. All subjects performed a procedure of walking 10 times a course of 10 meters with the device installed, totaling 100 meters. After data collection, a health professional evaluated each individual to provide the desired output of RNA in supinated, pronated and neutral. The data were processed and divided into samples, which were used as RNA database. As methods of RNA training, holdout and cross validation were applied. The MLP containing 21 neurons in the hidden layer, using cross-validation, obtained a 99.63% accuracy for the entire data set. In addition, the obtained results are divided in accuracy, sensitivity, specificity and efficiency (confusion matrix) by type of footprint; showing the lower and higher values respectively: 99.7% e 100% in accuracy (neutral, supinated and pronated), 99.7% and 100% in sensitivity (neutral and pronated), 99.8% and 100% in specificity (supinated and pronated), and finally, 99.7% and 100% in efficiency (supinated and pronated). Based on these values, it can be stated that RNA presented the best performance in the classification of the type of footprint in pronated and there is a greater difficulty to distinguish supinated from neutral. It is concluded that it is possible to use the device developed for plantar pressure measurement, as well as the MLP designed to classify the type of footprint.

Keywords: Plantar pressure. Instrumented insole. Type of footprint. MLP. Automated classification.

LISTA DE FIGURAS

Figura 1 - Plataforma baropodométrica de medição estática	17
Figura 2 - Esteira baropodométrica para medição dinâmica	18
Figura 3 - Exemplos de palmilhas e sapatilhas instrumentadas.....	18
Figura 4 - Sistema <i>in-shoe</i> PEDAR [®]	19
Figura 5 - Sistema <i>in-shoe</i> F-SCAN [®]	19
Figura 6 - Dispositivo <i>in-shoe</i> Biofoot [®]	20
Figura 7 - Palmilha instrumentada para análise de impacto em saltos	21
Figura 8 - Divisão das regiões plantares do pé: a) retropé, b) mediopé e c) antepé	23
Figura 9 - Tipos de alinhamentos ósseos para o pé direito, sendo a) pisada pronada, b) pisada neutra e c) pisada supinada (visão posterior).....	24
Figura 10 - Representação de material piezoelétrico e seus dipolos a) em repouso e b) com aplicação de força mecânica ou tensão.	27
Figura 11 - Sensor piezoelétrico comercial: (a) modelo, (b) ações sobre o sensor e (c) resposta em relação ao tempo	28
Figura 12 - Sinal obtido de um sensor piezoelétrico de diâmetro de 15mm em função da aplicação de impulsos crescentes de força	29
Figura 13 - Resultante do modelo do piezoelétrico	31
Figura 14 - Jornada do sinal até sua classificação pela RNA	32
Figura 15 - Amplificador de carga	33
Figura 16 - Representação simplificada do funcionamento de um Sistema neural dados os estímulos e suas respostas.....	35
Figura 17- Modelo de um neurônio artificial	37
Figura 18 - Representação de uma MLP com uma camada de entrada, duas camadas escondidas e uma camada de saída.	39
Figura 19 - Método de validação cruzada usando <i>k-fold</i> usando k como 5.....	43
Figura 20 - Etapas para o desenvolvimento	47
Figura 21 - Método para aquisição de dados dos indivíduos em movimento	48
Figura 22- Fluxo do protocolo de coleta de dados	48
Figura 23 - Processos de desenvolvimento deste estudo	51
Figura 24 - Palmilha instrumentada com a identificação das regiões plantares e seu comprimento.....	53
Figura 25 - Dispositivo para aplicar o método de análise do sensor piezoelétrico	54
Figura 26 - Resultado de cada sensor por amostra da palmilha 1	55
Figura 27 - Relação de proporção entre os sensores da palmilha 1	55
Figura 28 - Resultado de cada sensor por amostra da palmilha 2	56
Figura 29 - Relação de proporção entre os sensores da palmilha 1	56

Figura 30 - Apresentação das partes do dispositivo: palmilha com sensores; b) conexões; c) circuitos de aquisição e condicionamento; d) processamento; e), transmissão;.....	57
Figura 31 - Esquemático elétrico da placa de aquisição e condicionamento de sinais	59
Figura 32 - Placa de Circuito Impresso projetada para aquisição e condicionamento de sinais	60
Figura 33 - Placa de aquisição de pressão plantar: (a) perspectiva, (b) face superior e (c) face inferior.....	61
Figura 34 - Placa central desenvolvida: aquisição, condicionamento e transmissão dos dados.	61
Figura 35 - Dispositivo completo vestido pelo indivíduo, placa central conectada na palmilha instrumentada inserida no calçado.....	62
Figura 36 - Sinal de pressão plantar conforme o passo é realizado.....	65
Figura 37 - Sinal de pressão plantar durante três passos em sequência	66
Figura 38 - Sinal de pressão plantar durante um passo, dividido nas regiões plantares e com os sensores identificados: retropé, mediopé, antepé e hálux	66
Figura 39 - Sinal de pressão plantar (esquerda) por tipo de pisada.....	67
Figura 40 - Erro quadrático médio para treinamento e validação no método de validação cruzada	68
Figura 41 - Média das taxas de acerto e seus respectivos desvios-padrões para a etapa de treinamento no método <i>holdout</i>	69
Figura 42 - Média das taxas de acerto e seus respectivos desvios-padrões para a etapa de teste no método <i>holdout</i>	69
Figura 43 - Média das taxas de acerto e seus respectivos desvios-padrões para todo o conjunto de dados no método <i>holdout</i>	70
Figura 44 - Matrizes de confusão para a topologia com 19 neurônios para as etapas de treinamento, validação e teste, além de todas as amostras da base. Os valores em (S) representam a pisada supinada, (N) pisada neutra e (P) pisada pronada.....	70
Figura 45 - Média das taxas de acerto e desvios-padrões para treinamento no método de validação cruzada.....	71
Figura 46 - Média das taxas de acerto e seus respectivos desvios-padrões para a etapa de teste no método de validação cruzada	72
Figura 47 - Média das taxas de acerto e seus respectivos desvios-padrões para a etapa de teste no método de validação cruzada	72
Figura 48 - Matrizes de confusão para a topologia com 21 neurônios (escolhidos pelo método de validação cruzada) para as etapas de treinamento, validação e teste, além de todas as amostras da base. Os valores em (S) representam a supinada, (N) neutra e (P) pronada.....	73

LISTA DE TABELAS

Tabela 1 - Relação de dispositivos <i>in-shoe</i> pelo seu sensor utilizado.....	25
Tabela 2-Trabalhos selecionados para comparação de resultados	44
Tabela 3 - Análise de desempenho em relação à matriz de confusão para toda a base de dados para uma rede de 19 neurônios escolhida pelo método de validação cruzada.	71
Tabela 4 - Análise de desempenho em relação à matriz de confusão para toda a base de dados para uma rede de 21 neurônios escolhida pelo método de validação cruzada.	73
Tabela 5 - Comparação do resultado da RNA desenvolvida com referências	74

LISTA DE SIGLAS

RNA	Rede Neural Artificial
MLP	<i>Multilayer Perceptron</i>
USB	<i>Universal Serial Bus</i>
MAV	<i>Mean Absolute Value</i>
RMS	<i>Root Mean Square</i>
WL	<i>Waveform Length</i>

LISTA DE SÍMBOLOS

A	Área das placas de um capacitor
b	Limiar de ativação da RNA
C	Capacitância do piezoelétrico
C	Capacitores
D	Vetor deslocamento elétrico
d	Tensor dos coeficientes piezoelétrico de deformação
d_1	Número de entradas da RNA
E	Vetor do campo elétrico aplicado
E_{QM}	Erro médio quadrático da RNA
F	Força aplicada ao piezoelétrico
f_c	Frequência de corte do filtro
G	Gradiente local do erro da RNA
g'	Derivada da função de ativação (vetor gradiente)
I	Potenciais de ativação para RNA
k	Constante piezoelétrica
M	Média dos dados
M_1	Número de neurônios escondidos da RNA
MAV	Saída do sinal em Média do Valor Absoluto
N	Quantidade de dados do sinal
n	Quantidade de entradas da RNA
$n^{(1)}$	Quantidade de neurônios na camada escondida da RNA
$n^{(2)}$	Quantidade de neurônios na camada de saída da RNA
n_c	Quantidade de classes a serem identificadas pela RNA

q	Carga resultante do piezoelétrico
R	Resistores
S	Vetor das deformações, ou tensor das deformações
s	Matriz do acoplamento elastic
S	Desvio padrão dos dados
SD	Saída desejada da RNA
SO	Saída obtida pela RNA
V	Tensão elétrica nos terminais do piezoelétrico
V_{OFF}	Tensão elétrica de <i>offset</i>
W	Peso sináptico da RNA
x	Distância das placas do capacitor
x	Sinais de entrada da RNA
x_1	Dado a ser normalizado
x_{norm}	Dado x normalizado
y	Saída da RNA
β	Constante da função de ativação da RNA
ϵ	Matriz dos coeficientes dielétricos
ϵ_0	Permissividade dielétrica do vácuo
ϵ_R	Permissividade dielétrica do material
η	Taxa de aprendizagem da RNA
σ	Vetor de tensão mecânica
Σ	Combinador linear da RNA
u	Potencial de ativação da RNA

SUMÁRIO

1 INTRODUÇÃO	14
1.1 OBJETIVOS.....	15
1.1.1 Objetivo Geral.....	15
1.1.2 Objetivos Específicos.....	15
1.2 PROBLEMAS/PREMISSAS.....	16
1.3 ESTADO DA ARTE.....	16
1.4 JUSTIFICATIVA.....	21
2 REFERENCIAL TEÓRICO	23
2.1 PRESSÃO PLANTAR E TIPOS DE PISADA.....	23
2.2 SENSORES.....	25
2.2.1 Sensores Piezoelétricos.....	26
2.2.1.1 Modelo de um piezoelétrico.....	29
2.3 CONDICIONAMENTO DE SINAL.....	31
3 REDE NEURAL ARTIFICIAL	35
3.1.1 Conceitos Teóricos.....	36
3.1.2 Rede <i>Perceptron</i> Multicamadas.....	38
3.1.3 Processos de Treinamento e Validação.....	40
4 METODOLOGIA	46
5 DESENVOLVIMENTO	51
5.1 PALMILHA INSTRUMENTADA.....	52
5.1.1 CARACTERÍSTICAS E NORMALIZAÇÃO DO SENSOR.....	53
5.2 PLACA CENTRAL.....	56
5.3 PRÉ-PROCESSAMENTO DOS DADOS.....	62
5.4 IMPLEMENTAÇÃO DA REDE NEURAL.....	63
6 RESULTADOS E DISCUSSÃO	65
6.1 DADOS DE PRESSÃO PLANTAR.....	65
6.2 IDENTIFICAÇÃO DO TIPO DE PISADA.....	68
7 CONCLUSÕES	76
REFERÊNCIAS	78

1 INTRODUÇÃO

A ação resultante entre o contato dos pés e uma superfície chama-se pressão plantar, reação do solo impactando os membros inferiores (FRANCO, 2015). Essa ação pode ser apresentada durante as atividades diárias, esportivas, entre outras. A sua resposta dá-se pela variação característica do terreno, pela locomoção humana ou pela combinação de ambos (RODRIGUES et al, 2014). A pressão plantar é uma das variáveis que pode ser usada no estudo da biomecânica e biocinética, auxiliando em análises sobre o tipo de pisada, em movimentos como: andar, correr, saltar e aterrissar (CHENG et al, 2018; MICKEL et al, 2016; GUIMARAES et al, 2000; RODRIGUES et al, 2014).

Para a medição da pressão plantar, são necessários dispositivos instrumentados que possam apresentar seu resultado e variação conforme o contato dos pés na superfície. Estes podem medir a pressão plantar tanto em condições estáticas (enquanto o indivíduo está parado) ou em condições dinâmicas (durante a execução de atividades como andar, correr ou saltar). Esses conceitos podem ser aplicados na preparação de um atleta, reconhecimento de condição médica, padrões de marcha entre faixas etárias e até mesmo análises veterinárias (GUIMARAES et al, 2000; CRUZ et al, 2011; RODRIGUES et al, 2014; MICKEL et al, 2016; CHENG et al, 2018). Com base nessa diferenciação de aplicação, há dois tipos principais de dispositivos para medição da pressão plantar: plataformas baropodométricas (estáticas) e palmilhas instrumentadas (*in-shoe*) (RAZAK et al, 2012; CAMPOS, MF; HEIMBECHER, C.T.; ULBRICHT, L., 2018).

As palmilhas instrumentadas permitem a coleta de dados em atividades fora do ambiente consultório/laboratorial. Dessa forma, abre-se outras oportunidades de variação da pressão plantar em função da atividade, por exemplo: subir/descer escadas e rampas, caminhadas em distintos terrenos, saltos e aterrissagens, além de permitir o monitoramento da pressão plantar no cotidiano do indivíduo (RAZAK et al, 2012; MANUPIBUL.; CHAROENSUK.; KAIMUK., 2014).

Este trabalho tem como escopo o desenvolvimento de um dispositivo *in-shoe*(dentro do calçado) para aquisição de pressão plantar em condições dinâmicas, utilizando um sensor de baixo custo, acessível e simples manutenção. A palmilha desenvolvida poderá ser testada em ambientes hospitalares, consultórios e centros de avaliação física.

Com base nos dados coletados, foram realizados o processamento dos dados de forma a auxiliar em diagnósticos, monitoramentos e avaliações físicas e fisioterapêuticas. Além da apresentação dos dados ao usuário, este sistema realiza a classificação do tipo de pisada, podendo obter três diferentes resultados: pronada, supinada e neutra.

O trabalho se divide em três frentes que serão detalhadas posteriormente: sendo a primeira a confecção da palmilha instrumentada e o sensor responsável pela medição da pressão plantar; a segunda é baseada no desenvolvimento de uma placa para aquisição, condicionamento e transmissão dos dados; a terceira e última ocorre à normalização dos sinais e aplicação dos mesmos em um sistema de classificação de padrões.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

Desenvolver um protótipo que permita a medição de pressão plantar em situações dinâmicas e proporcione a identificação automática do tipo de pisada, baseado em palmilha instrumentada por sensores piezoelétricos (medição) e redes neurais artificiais (identificação) para auxiliar profissionais da saúde em avaliações físicas, monitoramento e diagnósticos.

1.1.2 Objetivos Específicos

- Realizar uma revisão bibliográfica sobre medição de pressão plantar, sensores e técnicas de processamento;
- Definir a quantidade mínima de sensores para as análises de tipo de pisada;
- Desenvolver uma palmilha instrumentada para medição de pressão plantar;
- Projetar uma placa de aquisição de sinais;
- Elaborar uma metodologia padronizada para aquisição de pressão plantar por meio de palmilhas instrumentadas;
- Realizar o pré-processamento do sinal elétrico de pressão plantar coletado;

- Desenvolver uma ferramenta de análise e interpretação do sinal por meio de redes neurais artificiais para identificação do tipo de pisada;
- Analisar e discutir os resultados obtidos.

1.2 PROBLEMAS/PREMISSAS

Este trabalho é respaldado na seguinte indagação: é possível a utilização de sensores piezoelétricos de baixo custo de aquisição para a classificação de tipos de pisada pela pressão plantar baseados em redes neurais artificiais?

A premissa deste estudo apoia-se no fato de identificar o tipo de pisada com sensores de baixo custo de aquisição e que possua condições de utilização em situações dinâmicas.

1.3 ESTADO DA ARTE

Os equipamentos miniaturizados são cada vez mais aplicados para sistemas de medições dinâmicas, sendo leves e com comunicação sem fio para transmissão dos dados. Esse avanço proporcionou que soluções para cuidados da saúde, esportes, medicina e fisioterapia se desenvolvessem, e dentre elas, surgiram soluções para o monitoramento da pressão plantar de indivíduos (RAZAK et al, 2012; FRANCO et al, 2015).

De uma forma geral, os sistemas existentes de análise de pisada são classificados em *in-shoe* e plataformas. A tecnologia de plataforma de distribuição de pressão é dedicada para análises em local fixo, em que a pessoa ou animal pisa ou anda descalça sobre uma plataforma instalada no chão (CRUZ et al, 2011; FRANCO et al, 2015; WAFAI et al, 2015). A Figura 1 apresenta um exemplo desse equipamento. Esses sistemas de medição da pressão plantar são chamados de baropodômetros, os quais são aplicados em posições estáticas ou dinâmicas limitadas.

Figura 1 - Plataforma baropodométrica de medição estática




Fonte: Arkipelogo (2015)

Os baropodômetros comerciais normalmente utilizam plataformas capacitivas para a aquisição da pressão plantar. Essas utilizam o seguinte conceito em seu funcionamento: a pressão exercida sobre a placa superior aproxima-a da placa inferior (placas paralelas), alterando a capacitância total da placa. Essa variação de capacitância (em Farad, F) é transformada em variação de tensão elétrica (volts, V), correlacionando essas grandezas com pressão, como libra por polegada quadrada (psi, do inglês *pound square inch*) ou Pascal (Pa) (RAZAK et al, 2012; ARKIPELOGO, 2015).

A Figura 2 apresenta a utilização de plataformas para condições dinâmicas limitadas, chamado de pista de marcha, na qual a pessoa pode realizar alguns passos simulando sua passada natural do cotidiano (ARKIPELOGO, 2015). Esses sistemas em plataformas são muito utilizados para medições em condições de consultórios, laboratórios e estudos específicos. Eles são limitados se for necessário obter os dados em situações de condições externas e individuais, como os abrangidos pelos sistemas *in-shoe*. ;

A tecnologia *in-shoe* possui o sistema de aquisição da pressão plantar instalado dentro do calçado do indivíduo. Esse tipo de sistema fornece liberdade nas coletas de dados, para que possam ser realizadas em ambiente externo e em condições do cotidiano da pessoa em questão; além de condições específicas, como em corridas em pistas, saltos e aterrissagens (MUELLER; STRUBE, 1996; CATALFAMO et al, 2008; MANUPIBUL; CHAROENSUK; KAIMUK, 2014; RODRIGUES et al, 2014).

Figura 2 - Esteira baropodométrica para medição dinâmica



Fonte: Razak et al (2012)

A principal característica dos sistemas *in-shoe* é sua mobilidade para aquisição de dados em diferentes situações, sendo fundamental para medições dinâmicas (RAZAK, 2012; MANUPIBUL; CHAROENSUK; KAIMUK, 2014), como apresentado na Figura 3. Este modelo de sistema é baseado na medição de pressão plantar entre o pé do indivíduo e a sola do tênis, tendo como interface entre as partes uma palmilha instrumentada (MUELLER; STRUBE, 1996; CATALFAMO et al, 2008; RAZAK, 2012; MANUPIBUL; CHAROENSUK; KAIMUK, 2014; RODRIGUES et al, 2014).

Figura 3-Exemplos de palmilhas e sapatilhas instrumentadas



Fonte: Mendes Junior et al (2016)

No mercado atual, existem vários modelos de sistemas *in-shoe*, usualmente desenvolvidos fora do Brasil. Para efeito de análise do estado da arte, foram escolhidos três modelos específicos do mercado e um dispositivo acadêmico. Entre os mais difundidos estão o Pedar[®], o F-Scan[®] e o BIOFOOT[®].

O sistema Pedar[®] é um sistema eletrônico com massa de 400g, tendo cabos entre a palmilha e sua central. A central pode ser fixada até cintura e comunica os dados para um computador via USB, *Bluetooth*[®] e fibra óptica (Figura 4). Existe a possibilidade de gravação dos dados em um cartão de memória (PEDAR, 2015). Os

sensores são especificados como piezoelétricos, porém não são classificados em seu tipo (como flexíveis e cerâmicos) e podem chegar ao número de 99 sensores no sistema (PEDAR, 2015; CAMPOS; HEIMBECHER; ULBRICHT, 2018). Sua alimentação é feita internamente por baterias (PEDAR, 2015).

Figura 4 - Sistema *in-shoe* PEDAR®



Fonte: Razak et al (2012)

O sistema F-Scan® possui 322g de massa, sendo sua central instalada no tornozelo do indivíduo (Figura 5). Esse sistema comunica com o computador por meio de dois tipos de protocolos: USB (*Universal Serial Bus*) e WI-FI (TEKSCAN, 2015). Os sensores são classificados como resistivos, além de que esta palmilha pode ser encontrada em quatro modelos comerciais: *Standard, Long-Handle, Sport e XL* (TEKSCAN, 2015). Este equipamento também possui alimentação interna por meio de bateria, com autonomia de mais de duas horas de coleta de dados (TEKSCAN, 2015).

Figura5 - Sistema *in-shoe* F-SCAN®



Fonte: Razak et al (2012)

Os dois dispositivos mencionados (FScan[®] e Pedar[®]) podem ser aplicáveis tanto em diagnósticos médicos, avaliações esportivas, fisioterapia e desenvolvimento motor (PEDAR, 2015; TEKSCAN, 2015).

Outro exemplo de equipamento comercial apresentado é o Biofoot[®], o qual é composto por 64 sensores piezoelétricos de 5 mm de espessura de 5 mm de diâmetro (Figura 6). Os sensores são distribuídos de acordo com a fisiologia do pé de tal forma de que a maior densidade de sensores está sobre as principais áreas ósseas, onde as pressões tendem a serem maiores (especialmente no antepé). O dispositivo fornece os dados na unidade física de kilo Pascal (kPA), o qual os transmite em uma distância de até de 200 metros. Sua frequência de aquisição pode ser configurada na faixa de frequência de 50 a 250 Hz (CAMPOS; HEIMBECHER; ULBRICHT, 2018).

Além de dispositivos comerciais, outros sistemas *in-shoe* são desenvolvidos para pesquisas e estudos específicos. Manipibul, Charoensuk e Kaimuk (2014) desenvolveram uma palmilha instrumentada, apresentada na Figura 7, para medição de pressão plantar em atividades humanas pesadas. A principal aplicação desta palmilha foi a simulação de pouso de paraquedistas, na qual esta atividade possui um alto impacto dos pés em contato com o solo.

Figura 6 - Dispositivo *in-shoe* Biofoot[®]




Fonte: Campos, Heimbecher e Ulbricht (2018)

Este sistema utiliza sensores Flexforce (Figura 7 a)), os quais são sensores que possuem alteração de sua resistência (devido à resistência interna do material) pela aplicação de força mecânica sobre o mesmo. A palmilha instrumentada é

composta por oito sensores distribuídos conforme a Figura 7 b). Com o circuito de condicionamento, isto produz uma tensão elétrica de saída em que sua variação é proporcional à força na área do sensor. Um microcontrolador Arduino™ MEGA® transmite os dados por módulos de comunicação X-Bee® (comunicação sem fio com frequência de transmissão de 2,4 GHz) para o seu sistema de visualização de dados (MANUPIBUL; CHAROENSUK; KAIMUK, 2014). Esse sistema é alocado na região do tornozelo, conforme apresentado na Figura 7 c).

Figura 7 - Palmilha instrumentada para análise de impacto em saltos



Fonte: Manupibul, Charoensuk e Kaimuk (2014)

Segundo Razak et al (2012), sistemas *in-shoe* necessitam de alguns requisitos básicos para um bom funcionamento, como:

- ser móvel,
- possuir a menor quantidade de cabos possíveis,
- ser confortável dentro do tênis,
- ser leve (em torno de 300g),
- ter um baixo custo de concepção; e
- apresentar um baixo consumo de energia (desejável maior autonomia).

Com base nesses requisitos, a sequência do trabalho apresenta o detalhamento do dispositivo desenvolvido, assim como o processamento de dados e a RNA.

1.4 JUSTIFICATIVA

Tendo em vista os sistemas de medição de pressão plantar apresentados, o presente trabalho trata da concepção de um dispositivo, ele possui características que justificam seu desenvolvimento e utilização apresentados a seguir, fomentando

assim este estudo. Um exemplo que pode ser destacado é a resistência mecânica do sensor para suportar os impactos e pressões em que é submetido.

O dispositivo proposto neste trabalho é *in-shoe*, ou seja, permite a análise de dados em condições dinâmicas, com aquisição de dados provenientes de sensores de baixo custo comercial, proporcionando, inclusive, seu uso para fins de diagnóstico com uso descartável. Por exemplo, o Flexiforce é ideal para aplicações de alto esforço mecânico, justificando ser mais caro (U\$19,95 (SPARKFUN, 2018)) que o sensor piezoelétrico cerâmico (U\$0,08 (BAÚ DA ELETRÔNICA, 2018)). Porém, em condições de uso como caminhada e corrida de baixa intensidade a utilização do sensor mais barato é viável, podendo até ser descartados após sua aplicação (0,5% do valor de comparação), uma condição obrigatória em determinados ambientes hospitalares (pacientes em isolamento) e outros ambientes controlados.

Este dispositivo também fornece a possibilidade de classificação inteligente referente a identificação do tipo de pisada do indivíduo, enquanto os demais dispositivos comerciais, possuem o objetivo de apresentar os dados para monitoramento e visualização.

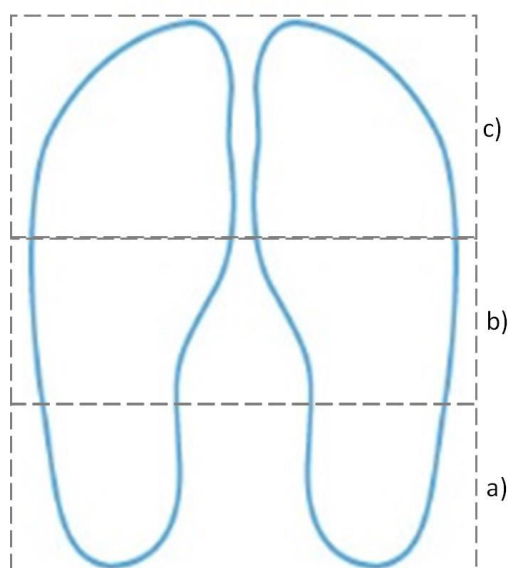
Após apresentar o estado da arte em relação a equipamentos que realizam a medição da pressão plantar, o próximo capítulo é dedicado as referências e conceitos que serão utilizados no desenvolvimento desse trabalho, tanto no âmbito de pressão plantar e suas características, como no sensor e seu condicionamento de sinal.

2 REFERENCIAL TEÓRICO

A locomoção humana é baseada no contato dos pés com o solo, superfície que muitas vezes é dura e exerce pressões no corpo. Parte do amortecimento durante a ação é realizado pelas articulações (como o joelho e o tornozelo), porém, o impacto causado pela locomoção pode ser atenuado com um melhor posicionamento das diversas estruturas atuantes da pessoa, melhorando o tipo de pisada e da sua marcha (GUIMARÃES et al, 2000; SILVA, 2015).

Para melhor compreensão deste trabalho, é necessário a apresentação de dois conceitos relacionados a ortopedia: tipos de formação do arco plantar e os tipos de pisadas. Além disso, neste trabalho, o pé é dividido em três grandes regiões: Retropé ou calcanhar (Figura 8 a)); Mediopé ou centro do pé (Figura 8 b)); e Antepé ou metatarso com hálux (Figura 8 c)), as quais serão abordadas durante todo o desenvolvimento deste dispositivo e suas análises.

Figura 8 - Divisão das regiões plantares do pé: a) retropé, b) mediopé e c) antepé



Fonte: adaptado de Guimarães (2000)

2.1 PRESSÃO PLANTAR E TIPOS DE PISADA


Segundo Guimarães et al (2000), a estrutura anatômica do pé determina a estabilidade da pisada, fornecendo dados para análises de dores e fortalecimento dos membros inferiores. Para uma melhor visualização da parte anatômica plantar,

há três principais tipos de formações do arco plantar, sendo apresentados na Figura 9.

A grande diferença entre os tipos de formação do arco plantar encontra-se no alinhamento entre as regiões do pé (SILVA, 2015).

Além da formação do arco plantar, há três tipos principais de pisada que são fundamentais para aplicação deste trabalho (SILVA, 2015). O primeiro tipo é a pronadora (pisada pronada), na qual é caracterizada pelo desalinhamento para dentro das estruturas ósseas do tornozelo, gerando maior aplicação de força na região interna do pé (Figura 9 a)). O segundo tipo é o neutro (pisada neutra), a pisada é realizada de forma correta, distribuindo melhor a pressão em todo o pé (Figura 9b)). O terceiro tipo é a supinadora (pisada supinada) apresentado na Figura 9c), tendo a pisada para fora, forçando a parte externa do pé (GUIMARÃES et al, 2000; SILVA, 2015).

Figura 9 - Tipos de alinhamentos ósseos para o pé direito, sendo a) pisada pronada, b) pisada neutra e c) pisada supinada (visão posterior).



Fonte: adaptado de Norris (2011)

Este estudo é sobre a pressão plantar em movimentos considerados dinâmicos, sendo a marcha o principal deles. Segundo Sanches (2007) a marcha humana é composta pelo movimento alternado de ambas as pernas em sequência, necessitando que o indivíduo esteja ereto e que os movimentos ocorram apoiados.

Esse movimento é base na locomoção humana e é dividido em algumas ações: o ciclo normal inicia-se com o contato da região do retopé do membro de referência com a superfície, passando pelas fases de apoio e balanço, terminando quando essa mesma região do mesmo membro entra em contato novamente com a

superfície. Porém o ciclo único da marcha é composto por cada uma dessas fases (balanço e apoio), com os membros da direita e da esquerda.

A marcha humana foi o movimento escolhido para ser aplicado nas coletas de dados deste estudo, tendo como inspiração a movimentação cotidiana dos indivíduos. As etapas e os requisitos para realização desse procedimento serão detalhados na metodologia.

2.2 SENSORES

A pressão plantar é um tipo de pressão imposta de um corpo a outro. Logo, a escolha do sensor para esta aplicação é um sensor de pressão, em que os mais comuns são conhecidos como sensores de carga: capacitivos, resistivos e piezoelétricos (RAZAK et al, 2012). Seu funcionamento básico é atuar como sensor entre uma pressão exercida em grandeza elétrica (tensão, corrente ou variação de resistência).

Para exemplificar esse conceito em equipamentos comerciais, a Tabela 1 apresenta alguns sistemas de medição de pressão plantar pelo seu sensor utilizado e se há a presença de sensores inerciais. Alguns dispositivos utilizam sensores inerciais para fornecer dados de forma a complementar à análise a ser realizada. Pela análise da Tabela 1, reforça-se que os mais utilizados são os sensores resistivos, capacitivos e piezoelétricos.

Tabela 1 - Relação de dispositivos *in-shoe* pelo seu sensor utilizado

Dispositivo	Sensor Utilizado	Sensor inercial
F-Scan	Resistivo	----
Motivo	Capacitivo	Acelerômetro 3D
Pedar [®]	Piezoelétrico	----
Footwork	Capacitivo	----
Biofoot [®]	Piezoelétrico	----
Parótica	Hidrocélula, piezoresistivo	----
Dynafoot2	Resistivo	Acelerômetro
Wiisel	Resistivo	Acelerômetro/Giroscópio
Sennopro Insole	Sensor têxtil	Acelerômetro/Giroscópio/Magnetômetro
Sensor Medica Flexinfit	Resistivo	----

Fonte: adaptado de Ramirez-Bautista et al (2017)

Segundo Razak et al (2012), existem cinco fatores para se analisar antes de escolher um sensor na medição de pressão plantar, sendo eles: linearidade, histerese, sensibilidade por temperatura, área de sensibilidade e faixa de pressão suportada. Adicionalmente a esses fatores, este trabalho considerou também o custo de aquisição do sensor, a facilidade de encontrá-lo no mercado nacional, capacidade de repetição referente ao mesmo sinal, zona morta e grandeza. Por atender todos esses requisitos, o sensor piezoelétrico cerâmico foi escolhido para ser aplicado nesse projeto, o qual será detalhado a seguir.

2.2.1 Sensores Piezoelétricos

Os sensores piezoelétricos possuem a característica de apresentar uma mudança de carga elétrica proporcional a direção aplicada ao estresse mecânico. O contrário também ocorre, ou seja, haverá uma deformação proporcional a uma aplicação de um campo elétrico (WEBSTER, 1999). Por essas suas características, esses sensores são amplamente usados tanto em dispositivos comerciais, industriais (pela sua robustez a diversas condições, como a variação de temperatura (AHMAD et al, 2014)) e em aplicações médicas (com monitoramento de pacientes e análise de movimentos) (PARK et al, 2015). Os materiais piezoelétricos são geralmente construídos a base de titanato de bário ($BaTiO_3$) e titanatozirconato de chumbo ($PbZrO_3$) (IRSCHIK; KROMMER; VETYUKOV, 2010).


Esses materiais podem ser divididos quanto ao seu material de origem. Apresentados em: monocristalinos (como o sal de rochelle e o quartzo), poliméricos (como o polifluoreto de vinilideno), metálicos (metais a base de platino com nanoporos) e policristalinos (como otitanatozirconato de chumbo) (MOREIRA FILHO, 2014).

Mesmo a propriedade da piezoeletricidade ter sido descoberta por Jacques e Pierre Curie em 1880 (WEBSTER, 1999), muitas aplicações têm sido desenvolvidas usando esse material. Atuadores, ventiladores e limpadores ultrassônicos piezoelétricos são algumas das aplicações usando o seu princípio como fonte geradora de eletricidade (transdutores eletromecânicos) (MURATA SENSORS, 2001). Em circuitos eletrônicos, são encontrados largamente em filtros cerâmicos e de ondas acústicas e ressonadores (MURATA SENSORS, 2001). Seu uso como

sensor dinâmico de força, vibração, pressão, sensor ultrassônico, de toque, choque mecânico e acelerômetro é bem recorrente (WEBSTER, 1999; MURATA SENSORS, 2001). Porém, outras aplicações recentes demonstram novos conceitos para seu uso, como um sistema de monitoramento de pulso (IKARI et al, 2014) e gerador de tensão a partir de exalação humana (INDIACom, 2015).

A Figura 10 ilustra a distribuição cristalina de um material piezoelétrico. As cerâmicas piezoelétricas são feitas de cristais com altas constantes dielétricas. Em repouso, sem receber qualquer estímulo, os cristais se apresentam como a Figura 10 a), em que os seus dipolos estão orientados de forma aleatória. A polarização destes cristais pode ocorrer de duas formas: na aplicação de uma tensão elétrica (V) ou na deformação mecânica (F). Ocorre, a partir desse fenômeno, a polarização de todos os dipolos, orientados na direção da força ou tensão aplicadas (Figura 10 b)) (WEBSTER, 1999; MURATA SENSORS, 2001). Por isso, na apresentação de uma destas forças, há uma carga resultante nas extremidades do material. Como mencionado, tanto a força resultante quanto a diferença de potencial resultante são proporcionais as forças aplicadas, logo é visto a aplicabilidade deste material.

Figura 10 - Representação de material piezoelétrico e seus dipolos a) em repouso e b) com aplicação de força mecânica ou tensão.

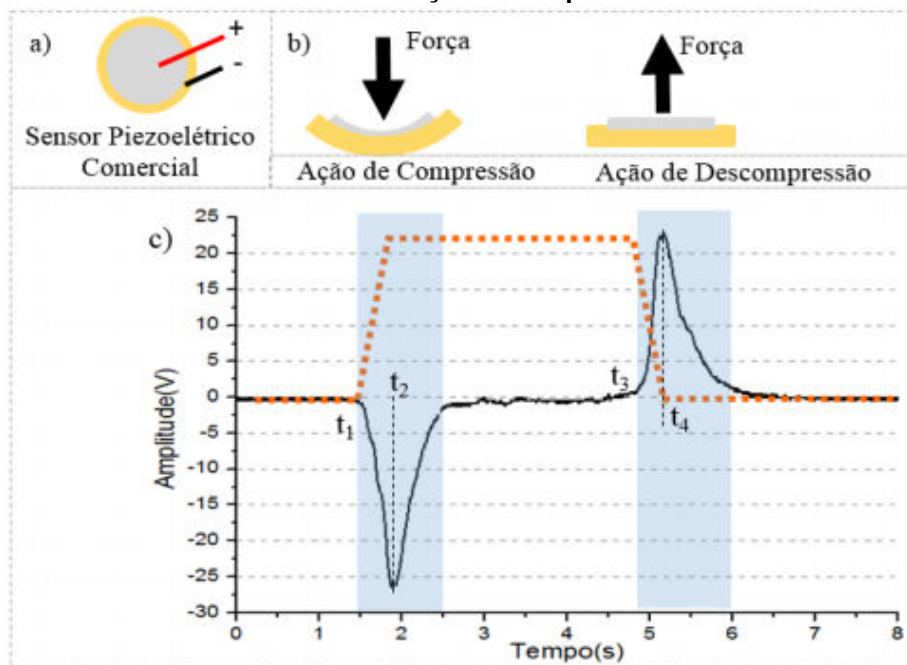


Fonte: Santos et al (2016)

A Figura 11 apresenta o sensor piezoelétrico comercial (Figura 11 a)) e seu sinal em comparação com a ação do movimento (Figura 11 c)). Durante o período de t_1 a t_2 (Figura 11 c)), ocorre a aplicação da força, provocando o pico de tensão (Figura 11 b)). Se a força continuar sendo aplicada, o sinal volta para o valor de repouso (entre t_2 e t_3). Parando a aplicação de força (t_3), há uma resposta de amplitude oposta (t_4), com pico abrupto, e em seguida o sistema volta para o repouso (após t_4). Para forças estáticas, o sistema permanece na tensão de repouso; porém em diferenças de forças, há a mudança no valor de tensão. Logo, a

resposta do piezoelétrico ocorre de forma dinâmica e por isso só pode ser usado em sistemas de medição dinâmica e não estática.

Figura 11-Sensor piezoelétrico comercial: (a) modelo, (b) ações sobre o sensor e (c) resposta em relação ao tempo



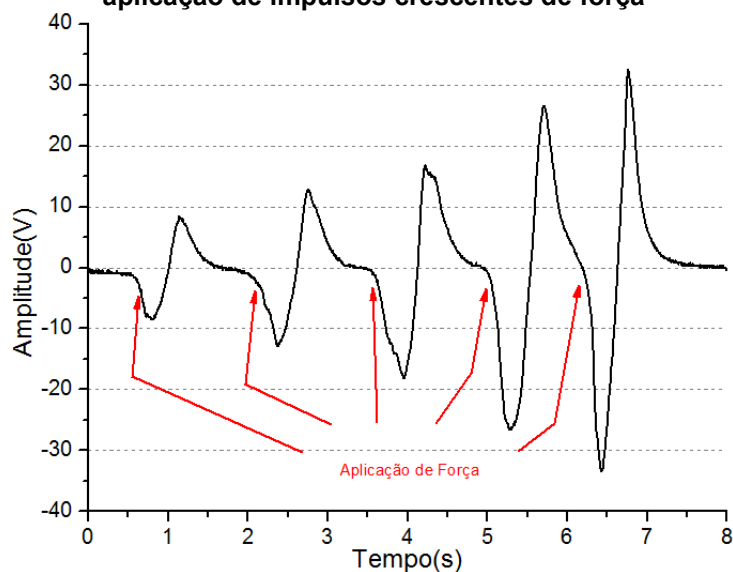
Fonte: Vieira et al (2016)

A Figura 12 apresenta uma aquisição de sinais provenientes de um sensor piezoelétrico de 15 mm para diferentes forças (sendo estas, crescentes). Por meio disto, pode-se analisar que: a tensão resultante do sensor é dependente da força, quanto menor a força, menor a amplitude da tensão (sendo que o contrário também é verdadeiro); e que dependendo do valor da força, a amplitude de tensão pode ultrapassar altos valores (como pode ser visto na Figura 12, na última aplicação de força, o sensor forneceu mais de 60 V pico-a-pico) (VIEIRA et al, 2016).

Após apresentados os conceitos e o funcionamento do piezoelétrico cerâmico, conclui-se que esse sensor atende todos os requisitos listados no começo da seção e assumisse a sua condição de uso para a aplicação aqui estudada.

Ao término da escolha do sensor, faz-se necessária a escolha do circuito de condicionamento de sinal, para que a resposta do mesmo seja inserida e interpretada na etapa de processamento dos sinais.

Figura 12 - Sinal obtido de um sensor piezoelétrico de diâmetro de 15mm em função da aplicação de impulsos crescentes de força



Fonte: Vieira et al (2016)

2.2.1.1 Modelo de um piezoelétrico

O efeito piezoelétrico incorpora uma relação de grandezas elétricas e mecânicas devido a sua natureza. Esse efeito pode ser escrito de forma matricial simplificada (equação (1)) para representar um material de resposta linear tanto no processo de conversão mecânica (1ª linha) quanto no processo de conversão elétrica (2ª linha).

$$\begin{bmatrix} \mathbf{D} \\ \mathbf{S} \end{bmatrix} = \begin{bmatrix} d & \varepsilon \\ \mathbf{s} & d \end{bmatrix} \begin{bmatrix} \boldsymbol{\sigma} \\ \mathbf{E} \end{bmatrix} \quad (1)$$

Em que:

D é o vetor de deslocamento elétrico (em C/m²);

S é vetor das deformações, ou tensor das deformações (adimensional);

d é o tensor dos coeficientes piezoelétricos de deformação, a qual é um acoplamento das relações mecânicas e elétricas devido ao efeito piezoelétrico (dada tanto em C/m ou m/V);

ε é a matriz dos coeficientes dielétricos relacionados à permissividade dielétrica (em F/m);

s é a matriz de acoplamento elástico (em m²/N);

σ é o vetor de tensão mecânica (em N/m²); e

E é o vetor de campo elétrico aplicado (em V/m).

Essa representação matricial possui todos os três eixos modelados com as suas respectivas tensões elétricas e mecânicas. Entretanto, se está sendo considerada apenas uma direção em que o piezoelétrico está sofrendo compressão, o seu modelamento é reduzido para apenas uma face e um eixo. Dessa forma, o mesmo pode ser considerado como um capacitor de placas paralelas fora da região de ressonância mecânica. Isso é corroborado pelo seu modelo, pois prevê a permissividade do material e a sua relação entre carga (C) e tensão (V), assim como um capacitor.

A carga resultante do piezoelétrico pode ser equacionada como (2)

$$q = kF \quad (2)$$

Em que:

q é a carga resultante do piezoelétrico (em C);

k é a constante piezoelétrica (em C/N), a qual é uma simplificação dos tensores da variável d da equação (5); e

F é a força aplicada ao piezoelétrico (em N).

Sabendo que a relação de tensão elétrica é dada por (3)

$$V = \frac{q}{C} \quad (3)$$

em que:

V é a tensão elétrica nos terminais do piezoelétrico, uma simplificação do vetor D da equação (5) em (em V);

q é a carga em (em C); e

C é a capacitância do piezoelétrico (em F).

E que, para um capacitor de placas paralelas, a sua capacitância é dada seguinte equação:

$$C = \varepsilon_0 \varepsilon_R \frac{A}{x} \quad (4)$$

em que:

A é a área das placas (em m^2);

ε_0 é a permissividade dielétrica do vácuo, a qual equivale 8,85 pF/m;

ε_R é a permissividade dielétrica do material (adimensional); e

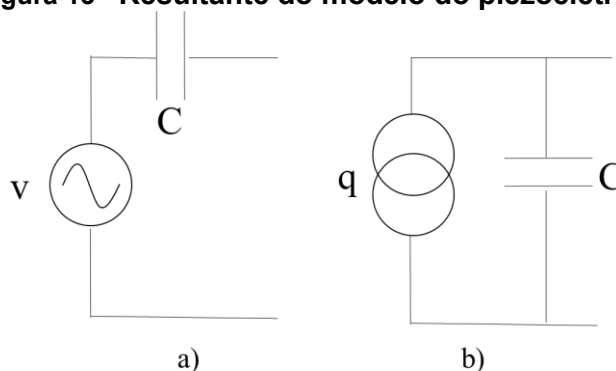
x é a distância das placas (em m).

Pode-se substituir (2) na (3) e a sua resultante na (4) e assim, tem-se a equação (5):

$$V = \frac{kFx}{\epsilon_0 \epsilon_R A} \quad (5)$$

Esta equação correlaciona as demais variáveis e simplifica a equação (1) para apenas um eixo. Dessa forma, pode-se comparar eletricamente o piezoelétrico de duas formas: como uma fonte de tensão com a capacitância intrínseca (C) dada por (5) (Figura 13 a)) ou como uma fonte de carga com uma capacitância intrínseca (C) em paralelo dada por (2) e (3) (Figura 13 b)).

Figura 13 - Resultante do modelo do piezoelétrico




Fonte: adaptado de Hansen (2014)

2.3 CONDICIONAMENTO DE SINAL

A fim de esclarecer o condicionamento de sinal neste trabalho, a Figura 14 apresenta as transformações que serão necessárias para que o sinal de pressão plantar seja classificado corretamente pela Rede Neural Artificial. Iniciando na Figura 14 a) com a pressão plantar [N/m²] aplicada na palmilha instrumentada com os sensores que em b) geram tensão elétrica dinâmica [V]. Na etapa c) o sinal é atenuado [V] e possui sua frequência modelada. Após isso, em d) o sinal é transmitido e recebido via comunicação sem fio com uma taxa de transmissão [mV/bit], que no caso é limitado pela configuração do dispositivo móvel. Após o recebimento dos dados, eles são armazenados no próprio *smartphone*. A próxima etapa é a segmentação do sinal em passos e), nela, cada passo possui os dados de

todos os sensores em um único vetor. Por último, com o objetivo de melhorar o desempenho da RNA, os passos são normalizados f) com saída bipolar [V].

Figura 14 - Jornada do sinal até sua classificação pela RNA



Fonte: autoria própria


Cada item dessa jornada será detalhado nas seções seguintes, porém o mais importante é a compreensão do fluxo como um todo e da justificativa para cada valor apresentado.

Eletricamente, os sensores piezoelétricos possuem alta impedância (YANEZ et al, 2005) e dependendo da força aplicada, o sinal do piezoelétrico pode possuir alta amplitude quando aplicado um degrau com força abrupta (conforme pode ser visualizado nas Figuras 11 e 12). Por este motivo, uma das formas de condicionar um sensor piezoelétrico é utilizar um amplificador de carga, de modo a que apresentem uma razão de atenuação ao invés de amplificação para enquadramento à faixa de leitura de um sistema de medição.

De uma forma geral, como apresentado na Figura 15, o amplificador de carga é um integrador de corrente que produz uma tensão de saída proporcional ao valor da integral da corrente de entrada. É ideal a sua utilização quando a entrada possui um dispositivo com característica de alta capacitância, como é o caso do piezoelétrico (KARKI, 2000).

O amplificador da Figura 15 comporta-se como um filtro passa-faixa ativo. Considerando que 98% das componentes de força de caminhada tem frequência abaixo de 10 Hz e 99% abaixo de 15 Hz, e ainda que é necessário realizar o desacoplamento DC, conforme critérios descritos por (KARKI, 2000).

Figura 15 - Amplificador de carga



Fonte: adaptado de Hansen (2014)

De uma forma geral, pode-se aproximar os valores do amplificador de carga utilizando as equações de (6) a (9), devido ao fato que não há modelo específico e seu projeto se deve as características do sensor em que está acoplado (no caso, a cerâmica piezoelétrica). As equações (6) e (7) apresentam os valores da frequência de corte alta (f_{cHP}) e baixa (f_{cLP}) do circuito, respectivamente. A equação (8) apresenta as equações para cálculo dos valores de tensão de offset (V_{OFF}) utilizando um divisor de tensão alocado na entrada não inversora do amplificador operacional e a equação (9) a equação do ganho do sistema (*Ganho*).

$$f_{cHP} = \frac{1}{2\pi R_1 C_1} \quad (6)$$

$$f_{cLP} = \frac{1}{2\pi R_2 C_2} \quad (7)$$

$$V_{OFF} = \frac{5R_4}{R_3 + R_4} \quad (8)$$

$$Ganho = -\frac{R_2}{R_1} \quad (9)$$

A única característica extraída dos sinais foi a Média do Valor Absoluto (*Mean Absolute Value, MAV*). O *MAV* apresenta uma média para os sinais considerando apenas o seu valor absoluto, sem levar em consideração a sua magnitude e é dada pela equação 10

$$MAV = \frac{1}{N} \sum_{n=1}^N |x_n| \quad (10)$$

em que:

MAV é a saída do sinal pela característica MAV ;

N é a quantidade de dados do sinal e;

X_n é o sinal em seu n -ésimo valor.

Para finalização do banco de dados, todos os sinais foram normalizados pelos sinais de cada canal utilizando o método do z -score. Com esse método, a variável normalizada possui média nula e a variância unitária. O z -score é realizado por meio da equação (11)

$$x_{norm} = \frac{x - M}{S} \quad (11)$$

em que

x é o dado a ser normalizado;

M é a média dos dados;

S é o desvio padrão dos dados; e

x_{norm} é o dado x normalizado.

Após a apresentação das principais iniciativas de condicionamento dos sinais provenientes da pressão plantar, o algoritmo de classificação de padrões escolhido para esse trabalho é a Rede Neural Artificial, o qual será apresentado no capítulo a seguir.

3 REDE NEURAL ARTIFICIAL


Como o objetivo deste estudo é realizar a identificação do tipo de pisada do indivíduo com base em sua pressão plantar ao movimentar-se, é necessário utilizar-se de um método que reconheça padrões e que identifique comportamentos.

O cérebro humano, por meio de experiências e resultados, possui a capacidade de criar regras de classificações e identificar padrões pela sua própria maneira. Com base nisso, uma das técnicas que se pode utilizar é o uso de um sistema computacional, tendo como escolha a Rede Neural Artificial (RNA). A principal vantagem da RNA sobre outros métodos computacionais é sua capacidade de aprender e se adaptar com base em eventos e a generalização de seu conhecimento, mesmo não tendo uma base analítica ou espacial do ambiente em que está inserida, mas necessitando de adequações dos sinais ou dados de entrada.

Segundo Silva, Spatti e Flauzino (2010), Redes Neurais Artificiais (RNAs) são modelos computacionais inspirados no sistema nervoso dos seres vivos. Com base nisso, pode-se destacar algumas características fundamentais em suas aplicações: organização de dados, tolerância a falhas, armazenamento distribuído e facilidade de prototipagem.

Para melhor ilustrar o funcionamento básico de sistemas neurais (artificiais), a Figura 16 apresenta o fluxo de informações que compõem a interação entre os envolvidos. O processo inicia-se com estímulos de ambientes externos, os quais são considerados como sinais de entrada do processo. Esses estímulos são captados por receptores, os quais podem ser representados por canais de entrada. Após a recepção desses estímulos, eles são transmitidos e recebidos pela rede neural, não seguindo apenas um fluxo contínuo.

Figura 16 - Representação simplificada do funcionamento de um Sistema neural dados os estímulos e suas respostas



Fonte: Haykin (2003)

A Rede Neural interage com as informações, se adaptando conforme analisa e entende os efeitos advindos dos estímulos. Com base nesses efeitos, ocorre a

retroalimentação das informações (em treinamento supervisionado), até que por sua vez, tenha uma resposta considerada satisfatória após seu aprendizado.

3.1.1 Conceitos Teóricos

O início do conceito de inspirar-se em neurônios biológicos para computação e solução de problemas ocorreu na década de 1940, quando McCulloch e Pitts utilizaram desse método para um modelamento matemático (MCCULLOCH; PITTS, 1943). Com a concepção de neurônios artificiais já estabelecida, o primeiro método de treinamento de uma rede neural artificial foi criado no final da mesma década, conhecido como regra de aprendizado de Hebb, baseado nos conceitos de Hebb (1949). De forma simplificada, a regra de Hebb diz que se um neurônio é excitado, os seus vizinhos são excitados, se são inibidos, seus vizinhos também são inibidos.

Segundo Silva, Spatti e Flauzino (2010), os estudos sobre RNA continuaram nas próximas duas décadas, até que em 1969, Minsky e Papert publicaram o clássico livro nomeado *Perceptrons - introduction to computational geometry*, o qual apresentaram uma limitação das redes neurais desenvolvidas até então o momento. Minsky e Papert afirmaram que as RNAs só solucionariam problemas com classes linearmente separáveis.

Após esse acontecimento, o próximo passo fundamental do desenvolvimento das RNAs só foi realizado no meio da década de 1980, quando Rumelhart, Hinton e Williams desenvolveram um algoritmo que introduziu o conceito de ajustes dos pesos da rede em mais de uma camada, baseado na regra Delta, nomeado *backpropagation* (do inglês, retropropagação do erro). Método para encontrar o vetor gradiente que será detalhado ainda nesse capítulo.

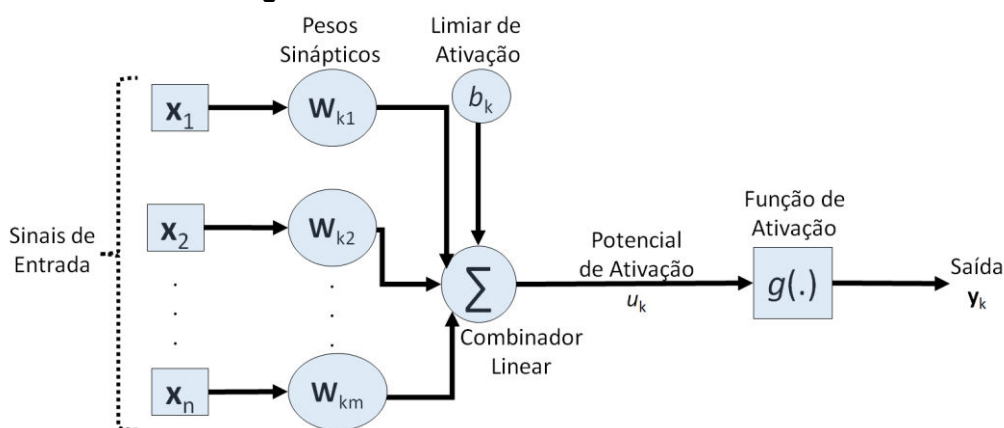
Uma RNA é composta por um ou mais neurônios artificiais, que são compostos por alguns elementos básicos: pesos sinápticos, limiar de ativação, combinador linear, potencial de ativação, função de ativação e saída.

A Figura 17 apresenta um neurônio artificial genérico, contendo todos os elementos citados acima. Os termos em x são os sinais de entrada, partindo de $x^{(1)}$ (primeiro elemento) até x_n (n -ésimo elemento), sendo cada um deles um valor medido, coletado ou recebido de um meio externo. Cada sinal de entrada é interligado a um peso sináptico, identificados como W_{km} ($W_k^{(1)}$ como primeiro elemento até m -ésimo elemento). Os pesos sinápticos ponderam cada entrada

conforme sua relevância para saída (y_k), e com isso pode-se determinar qual entrada influencia mais o resultado do apresentado pelo neurônio.

O combinador linear (Σ) é responsável pelo somatório entre todos produtos gerados das entradas e seus respectivos pesos sinápticos, gerando um valor que será usado para a definição do potencial de ativação (u_k). Além do combinador linear, faz-se necessária a utilização do limiar de ativação (b_k).

Figura 17-Modelo de um neurônio artificial



Fonte: Haykin (2003)

Matematicamente, a equação (12) representa a definição do potencial de ativação, em que pode-se afirmar que seu valor é resultado da subtração entre o combinador linear e o limiar de ativação (*offset*).

$$u_k = \sum_{i=1}^n (w_i x_i) - b_k \quad (12)$$

Após a determinação do potencial de ativação, sabe-se que a saída do neurônio só será ativada quando u_k for maior que o limiar. Porém, a saída y_k não é influenciada somente pelo potencial de ativação, mas também por uma função limitante, chamada de função de ativação (g), apresentado na equação (13).

$$y_k = g(u_k) \quad (13)$$

As funções de ativação podem ser divididas em dois grupos: totalmente diferenciável ou parcialmente diferenciável. Dentre as várias funções de ativação

existem, duas das mais utilizadas (e que são empregadas nas RNAs desenvolvidas neste trabalho) são as funções logística e tangente hiperbólica.

A função logística pode ser descrita pela equação (14), seu resultado sempre será um valor real entre zero e um; e β é uma constante real, relacionada ao nível de inclinação da função logística (comparada ao seu ponto de inflexão).

$$g_1(u) = \frac{1}{1 + e^{-\beta u}} \quad (14)$$

É importante ressaltar que função logística é do tipo totalmente diferenciável, isso em todo o seu domínio de definição. Quando β for um valor muito grande, o comportamento dessa função pode ser comparado à uma função degrau simples.

A segunda função de ativação abordada nesse estudo é a tangente hiperbólica. Matematicamente, essa função pode ser descrita pela equação (15). A maior diferença entre as funções é que o resultado da função hiperbólica pode ser qualquer valor real entre -1 e 1.

$$g_2(u) = \frac{1 - e^{-\beta u}}{1 + e^{-\beta u}} \quad (15)$$

Assim como na primeira função aqui apresentada, β é uma constante relacionada ao nível de inclinação da função tangente hiperbólica, a qual, se tiver um valor muito grande, terá comportamento comparado à uma função degrau bipolar. Lembrando que as entradas da RNA devem ser limitadas em dois intervalos fixos: de zero até um e de menos um até um, matematicamente representados da seguinte forma $[0, 1]$ e $[-1, 1]$.

3.1.2 Rede *Perceptron* Multicamadas


A primeira rede *Perceptron* foi desenvolvida por Frank Rosenblatt no final da década de 1950, a qual é considerada a configuração mais simples de uma RNA. Utilizando a Figura 17 como base, pode-se simplificar o funcionamento da rede *Perceptron* com um neurônio artificial, incorporando o limiar de ativação entre os pesos sinápticos. Vale ressaltar que essa rede possui somente uma camada de

neurônios, a qual é um limitante para solução somente de problemas com classes linearmente separáveis.

Com a evolução da *Perceptron*, a rede *Perceptron* multicamadas (MLP - *Multilayer Perceptrons*) possui mais de uma camada escondida de neurônios, condição inicial para solução de problemas com classes não linearmente separáveis. A rede MLP é conhecida por ser aplicável em diversos problemas, mas os mais relevantes são: aproximação universal de funções, reconhecimento de padrões (motivo de sua escolha), identificação e controle de processos, previsão de séries temporais e otimização de sistemas (SILVA; SPATTI; FLAUZINO, 2010).

Para ilustrar seu funcionamento, a Figura 18 apresenta sua camada de entrada, duas camadas neurais escondidas e a camada de saída.

Figura 18 - Representação de uma MLP com uma camada de entrada, duas camadas escondidas e uma camada de saída.



Fonte: Haykin (2003)

Após a apresentação da Figura 18, foram introduzidos dois conceitos novos que a MLP se diferencia da rede *Perceptron* comum: entradas e saídas entre camadas escondidas. Neste modelo, as camadas escondidas interagem por meio de entradas e saídas entre elas; logo, as saídas da primeira camada escondida são as entradas da segunda camada escondida, e assim sucessivamente. Isso aumenta as variações dos pesos, que por sua vez, influencia na relevância das entradas se cada variação proposta é uma ação que a rede utiliza para melhorar seu desempenho.

Por sua vez, a saída da RNA não é mais composta somente por um único neurônio, tal como indicado anteriormente para um *Perceptron* simples, mas podendo sim por um ou mais neurônios, transformando-se assim em camada neural

de saída. Com isso, a rede neural pode ser contemplada em problemas que contém mais de uma resposta para o mesmo processo. Com todas essas diferenças, fica evidente a melhora de capacidade para solução de problemas entre as redes.

As definições matemáticas da MLP serão apresentadas conforme utilizadas na seção de desenvolvimento da rede neural, facilitando assim a apresentação dos conceitos.

3.1.3 Processos de Treinamento e Validação

Silva, Spatti e Flauzino (2010) descrevem os passos de treinamento de uma MLP de forma simplificada. O processo de treinamento baseia-se na retropropagação do erro (gradiente descendente) os quais são (para uma MLP com uma camada escondida):

1. Inicialização de todos os pesos sinápticos da rede com valores aleatórios.
2. Inserção da entrada na rede (passo *forward*) para que se propagem até a saída e se tenha um valor na saída.
3. Cálculo do erro entre obtido e o desejado para a rede.
4. Cálculo do gradiente local do erro da camada de saída, a qual é obtido pela equação (16):

$$\mathbf{G}^{(2)} = (\mathbf{SD} - \mathbf{SO}) \times g'(\mathbf{I}^{(2)}) \quad (16)$$

em que:

$\mathbf{G}^{(2)}$ é o gradiente local do erro da camada de saída;

$\mathbf{I}^{(2)}$ são os potenciais de ativação para a camada de saída;

\mathbf{SO} é a saída obtida;

\mathbf{SD} é a saída desejada e;

g' é a derivada da função de ativação (vetor gradiente).

5. Ajuste dos pesos sinápticos entre a camada escondida e a camada de saída é dada pela equação (17), o qual pode ser definida como método de otimização do gradiente ótimo:

$$\mathbf{W}^{(2)}(t+1) = \mathbf{W}^{(2)}t + \eta \mathbf{G}^{(2)} \mathbf{SO} \quad (17)$$

em que:

η representa a taxa de aprendizagem ou passo do algoritmo e;
 $\mathbf{W}^{(2)}$ são os pesos sinápticos da camada escondida e a camada de saída.

6. Cálculo do gradiente $\mathbf{G}^{(1)}$, correspondente a camada escondida e a camada de entrada, dado pela equação (18)

$$\mathbf{G}^{(1)} = (\mathbf{G}^{(2)} - \mathbf{W}^{(2)}) \times g'(\mathbf{I}^{(1)}) \quad (18)$$

7. Ajuste dos pesos sinápticos $\mathbf{W}^{(1)}$ por (19)

$$\mathbf{W}^{(1)}(t+1) = \mathbf{W}^{(1)}(t) + \eta \delta^{(1)} \mathbf{x} \quad (19)$$

8. Cálculo do erro quadrático médio (E_{QM}) para critério de parada, com M dados do erro, dado por (20)

$$E_{QM} = \frac{1}{M} \sum \left(\frac{1}{2} \sum (\mathbf{SD} - \mathbf{SO})^2 \right) \quad (20)$$

9. Os passos de 2 ao 9 são repetidos até obter-se um erro abaixo do delimitado ou atingir o número máximo de interações (épocas).

Durante o processo de desenvolvimento da rede neural, é necessário determinar a quantidade de camadas escondidas e o número de neurônios que irão compor essas camadas. O primeiro caso é mais simples, pois cada camada escondida está relacionada à complexidade do processo em que a rede neural é submetida. Por exemplo, para uma classificação de uma região convexa são necessárias apenas duas camadas ao todo, a camada escondida e a própria camada de saída da rede. Mas para classificação de padrões em regiões não convexas, são utilizadas no mínimo duas camadas escondidas mais a camada de saída, sendo o limite de camadas escondidas estipulado pelo próprio processo.

Porém, para determinação da quantidade de neurônios de cada camada, é necessária uma avaliação de topologias, tomando como base de técnicas e heurísticas a fim de melhorar o desempenho do treinamento e execução da MLP.

O primeiro passo aconselhado é a escolha de uma faixa para a variação da quantidade de neurônios. Para isso, foram usadas as heurísticas de Fletcher-Gloss e da usada na plataforma Weka. A heurística de Fletcher-Gloss define a quantidade

de neurônios na camada escondida ($n^{(1)}$) entre um valor definido por (21) (SILVA; SPATTI; FLAUZINO, 2010).

$$2\sqrt{n} + n^{(2)} \leq n^{(1)} \leq 2n + 1 \quad (21)$$

Em que

n é a quantidade de entradas e;

$n^{(2)}$ é a quantidade de neurônios na saída.

A segunda heurística escolhida é a utilizada pela plataforma Weka (do inglês, *Waika to environment for knowledge analysis*), dada pela equação (22).

$$n^{(1)} = \frac{n + n_c}{2} \quad (22)$$

Em que


n_c é o número de classes a serem identificadas.

Entretanto, para analisar qual quantidade de neurônios e qual conjunto de pesos sinápticos devem ser usados, há técnicas para avaliação de topologias de redes neurais (SILVA; SPATTI; FLAUZINO, 2010). Uma delas é a avaliação de aprendizagem de máquina é o *holdout* (HAYKIN, 2003). Nesta, a base de dados é dividida em dois grandes subconjuntos: um para treinamento e outro para teste. Estes dados podem ser separados de forma aleatória ou não. A parte de treinamento é usada para a estimação do modelo neural enquanto que a do teste é usada para analisar a generalização da rede. Entretanto, com uma abordagem aleatória, pode ser que nem todos os dados participem do processo de treinamento, teste e validação em todas as suas execuções.

O segundo método é a validação cruzada, na qual se baseia no conceito de avaliar a aptidão de cada topologia versus uma base de dados diferente da utilizada em seu ajuste. Existem três tipos de validação cruzada (*k-fold*, aleatória e por unidade), sendo a *k-fold* (do inglês, *k-partições*) a utilizada neste trabalho (HAYKIN, 2003).

A Figura 19 apresenta o método de validação cruzada utilizando o tipo *k-fold*. Para execução desse tipo de validação, a primeira ação é dividir a base de dados em k partes, no exemplo, 5 partes. Após a repartição da base, serão selecionados $k-1$ partes da base para etapa de treinamento e a outra parte para os testes.

Figura 19 - Método de validação cruzada usando *k-fold* usando *k* como 5.



Fonte: Silva, Spatti e Flauzino (2010)

O número de ensaios desse método tem que ser exatamente o mesmo de partes divididas, a fim de que todos os conjuntos possuam ensaios realizados e que a base seja inteira treinada e testada. Para concluir, segundo (SILVA; SPATTI; FLAUZINO, 2010) o desempenho global da topologia candidata será obtido da média entre os desempenhos individuais após k partições.

A RNA desenvolvida, MLP, possui arquitetura *feedforward*, a qual possui três camadas: uma camada de entrada, uma camada escondida e uma camada de saída. De forma matemática, pode-se ser representada por (23)

$$\mathbf{y}_k = g^{(2)}(\mathbf{W}_k^{(2)} g^{(1)}(\mathbf{W}_k^{(1)} \mathbf{x})) \quad (23)$$

Nessa representação, cada etapa está sendo representada de forma vetorial e matricial. De forma a analisar cada iteração, a equação pode ser escrita como (24)

$$\mathbf{y}_k = g_2 \left(\sum_{j=0}^{M_1} \mathbf{W}_{kj}^{(2)} g_1 \left(\sum_{i=0}^{d_1} \mathbf{W}_{ji}^{(1)} \mathbf{x}_i \right) \right) \quad (24)$$

em que:

M_1 é o número de neurônios escondidos;

d_1 é o número de entradas.

A camada de entrada aloca cada um dos 39 dados de cada amostra e a camada de saída possui 3 neurônios, a qual se refere a quantidade de classes. Para a camada escondida, analisou-se a quantidade mínima de neurônios que providencia uma alta taxa de acerto, o que acarreta em otimização da rede e de menor tempo de execução.

Cada método apresentado foi utilizado como referência para o desenvolvimento do estudo, porém não são limitantes para a realização do mesmo.

Os resultados e suas comparações entre os tipos de validação e parametrização da MLP serão apresentados na seção 6.2.

Os resultados da RNA neste trabalho não são absolutos, pois se tratam de um protótipo não validado por algum estudo adicional. Portanto, a confirmação da qualidade do resultado deste protótipo será realizada por meio de comparação com outros trabalhos publicados que possuem as mesmas duas características: medição de pressão plantar e RNA como classificador de padrões.

A fim de colocar como nível de comparação para esse estudo, a Tabela 2 apresenta os quatro trabalhos os quais seus resultados serão confrontados no capítulo 6 com o protótipo desenvolvido.

A primeira coluna apresenta do tipo de RNA utilizada para classificação de alguma característica ou padrão. A segunda informação é relacionada ao método de coleta de pressão plantar. O objetivo é estabelecido para o entendimento do resultado e do contexto do estudo.

Tabela 2-Trabalhos selecionados para comparação de resultados

RNA	Método	Objetivo	Acerto	Referência
MLP	Não especificado	Identificar torção no tornozelo (simulado)	98,45%	(NASSERI et al, 2009)
Não especificada	<i>In-shoe</i>	Identificar o tipo de região plantar	96,00%	(OSSAMI; MIOSSO; FLEURY, 2014)
MLP	<i>In-shoe</i> (F-Scan)	Identificar assimetria ao andar	94,00%	(WAFAI et al, 2014)
(BPNN) <i>Back-propagation neural network</i>	<i>In-shoe</i>	Predizer o tipo da palmilha mais apropriada para cada perfil de pé	75,00%	(WANG; WANG; CHANG, 2013)

Fonte: autoria própria

A taxa de acerto é sempre o valor apresentado como final em cada um dos trabalhos. Por último, é apresentada a referência de comparação para identificação do estudo.

Com base na Tabela 2, identifica-se que o protótipo será considerado bem-sucedido se atingir o valor mínimo de 98,46% de acerto, para assim possuir o melhor desempenho dentre os escolhidos como comparação.

Após a apresentação nesse capítulo do classificador utilizado nesse estudo, a RNA, o próximo capítulo apresenta as metodologias escolhidas para serem aplicadas em todas as etapas do desenvolvimento, com o objetivo de obter o melhor resultado e padronizar para futuras replicações.

4 METODOLOGIA

Este trabalho enquadra-se em metodologia experimental, em que as variáveis são manipuladas diretamente com o objeto de estudo relacionado. Pela manipulação destas variáveis, proporciona-se o estudo entre as relações de causas e efeitos de determinados fenômenos (CERVO; BERVIAN; DA SILVA, 2007). Quanto à análise de dados, este trabalho possui análise quantitativa, em que os dados são analisados por meio de números e abordagem estatística.

A Figura 20 apresenta as etapas que foram desenvolvidas no processo deste trabalho. A primeira etapa (Figura 20 a)) foi a definição dos sensores que são responsáveis pela medição de pressão plantar (seção 2.2) e dos requisitos da palmilha instrumentada, entre as principais tem-se:

- **Conforto:** não ser notada pelo indivíduo ao realizar o movimento;
- **Naturalidade:** não influenciar na maneira do indivíduo se locomover;
- **Naturalidade:** ter comunicação sem fio para facilitar a realização dos movimentos;
- **Padronização:** não ter diferenciação entre as palmilhas; e
- **Autonomia:** ter autonomia de energia para isolar o indivíduo da rede elétrica, assim como não limitar sua utilização em relação a estrutura no ambiente (tomada, cabos, etc).

Para finalizar a etapa que define os sensores, foi necessário analisar o sensor adquirido/comprado, para identificar diferenças entre fabricantes, lotes de fabricação e de construção. Tendo o objetivo de conhecer essas diferenças a fim de minimizá-las, foi aplicado o método proposto por La Banca, Vieira e Stevan Jr (2018) para garantir a repetitividade e estabilização na utilização do mesmo. O método se resume em conhecer o comportamento do sensor para n amostras, porém com o mesmo ambiente (controlado). Assim, pode-se comparar as respostas dos sensores, obter o *offset* original entre eles e sua faixa de operação.

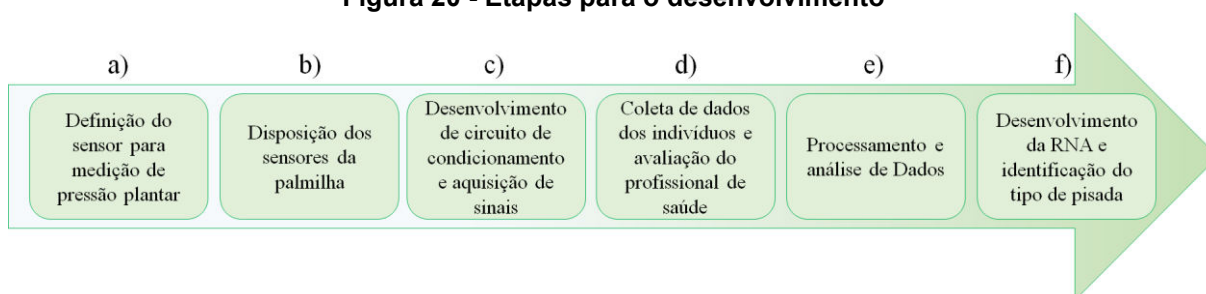
Cada sensor foi submetido quinze vezes ao peso padrão, onde foram registrados os valores de tensão de pico (volts, V). Após todas as coletas realizadas, os sensores foram comparados, os quais foram proporcionados por palmilha, aplicando a relação onde o sensor com o maior sinal (pico) foi definido como 100% e todos os outros sensores uma porcentagem dele. Com esse valor definido, foi

possível realizar a correção de *offset* e amplitude máxima de cada sensor. O experimento e seus resultados serão detalhados na seção de desenvolvimento.

Com os requisitos mapeados, foram analisados os itens para construção da palmilha instrumentada e a disposição dos sensores ao longo da palmilha (Figura 20 b)). Os sensores piezoelétricos foram dispostos nas regiões do retropé, mediopé, antepé e hálux de forma a atender a melhor disposição para a aquisição dos sinais, como já apresentado na seção anterior. A quantidade de sensores, sua disposição e sua conexão com a placa central serão detalhados na seção 4.1.

Após a alocação dos sensores, iniciou-se o projeto do circuito de condicionamento (amplificador de carga). O circuito foi implementado em *protoboard* em estágio de testes para fácil mudança dos parâmetros e componentes utilizados e por fim, foi desenvolvida uma placa de circuito impresso em forma de *shield* para facilitar a utilização pelos indivíduos (Figura 20 c)).

Figura 20 - Etapas para o desenvolvimento

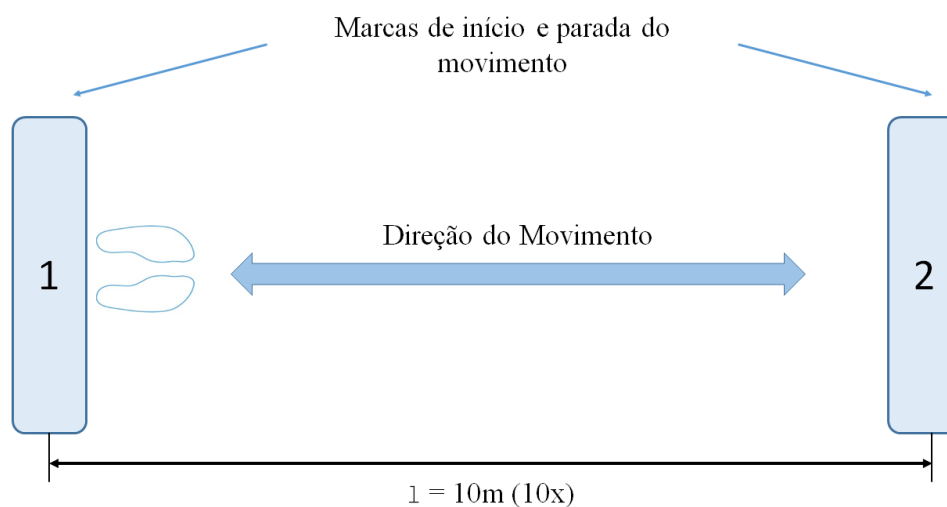


Fonte: autoria própria

Com a finalização das duas primeiras etapas, a terceira foi baseada na coleta de dados experimental, a qual foi realizada com um indivíduo por vez (Figura 20 d)). A equipe de voluntários era mista (composta por 13 indivíduos do sexo masculino e 1 indivíduo do sexo feminino), com uma média de idade de $28,7 \pm 8,8$ anos.

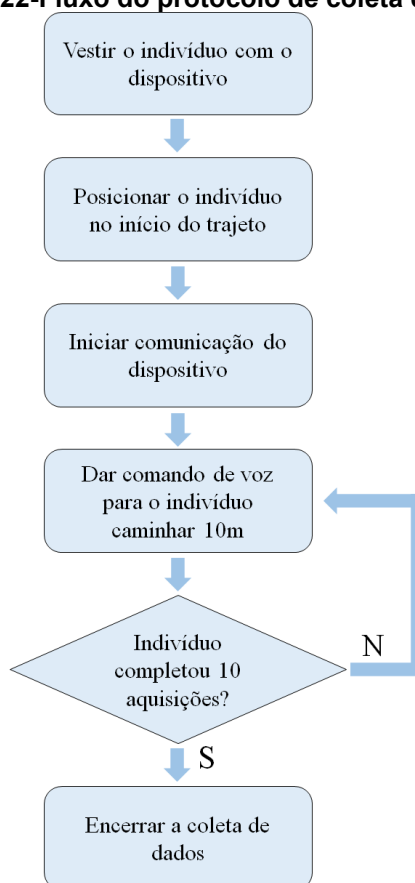
Coletar os dados dos indivíduos com processo e padronização é um requisito fundamental para esse estudo, pois a incorreta identificação do tipo de pisada do mesmo pode ser influenciado por uma base no calçado não confiável. Para isso, foi proposto um protocolo que baseia-se em deixar o indivíduo o mais confortável possível para realização da coleta, ser aplicável em diversos ambientes e de fácil execução. A Figura 21 apresenta o protocolo utilizado nas coletas de dados, onde o indivíduo inicia-se parado na região 1. O comprimento total do percurso é de 10 metros, acabando na área 2; e assim sucessivamente de 2 para 1.

Figura 21 - Método para aquisição de dados dos indivíduos em movimento



Fonte: autoria própria

Figura 22-Fluxo do protocolo de coleta de dados



Fonte: autoria própria

O requisito para conclusão da aquisição de dados é que cada indivíduo complete o percurso de 100 metros (10 vezes o comprimento) com o dispositivo instalado, transmitindo e armazenando os dados. A Figura 22 apresenta as etapas

desenvolvidas para padronizar as coletas de dados independentemente do indivíduo ou do momento da coleta.

Todo o processo de coleta de dados foi acompanhado por um fisioterapeuta, responsável por identificar o tipo de pisada de cada indivíduo. Essa resposta informada pelo profissional da saúde é utilizada como resposta desejada na etapa de identificação do tipo de pisada pela RNA (Figura 20 d)).

Vale ressaltar que o diagnóstico foi realizado somente pelo profissional da área da saúde, utilizando métodos tradicionais de avaliação em consultório. Com isso, a avaliação não faz parte do escopo deste trabalho, o tratamento ou qualquer ação sobre o tipo de pisada dos indivíduos.

Ao fim de cada coleta, os dados adquiridos foram identificados pelos seguintes parâmetros: nome do indivíduo, número da coleta, data do exercício e tipo de pisada identificado pelo fisioterapeuta.

Baseado na metodologia proposta foram coletados dados de 14 indivíduos separadamente, gerando a base de dados utilizada nesse estudo. Após a aquisição e análise visual do profissional, obtiveram-se cinco indivíduos com pisada pronada, seis indivíduos com pisada neutra e três indivíduos com pisadas supinadas.

Para possibilitar a aplicação dos equipamentos nos públicos selecionados, o projeto foi submetido para aprovação ao Comitê de Ética em Pesquisa (CEP), gerando-se um parecer consubstanciado de aceite. Nesse, consta-se o Certificado de Apresentação para Apreciação Ética (CAAE) com o número 66548217.6.0000.0105.

A penúltima etapa iniciou-se após o término da coleta de dados, a qual corresponde ao processamento dos dados (Figura 20 e)). Os dados são identificados e interpretados por um conjunto composto de uma separação dos dados (pré-processamento). É nessa etapa que ocorreu a normalização, segmentação dos dados em passos e sua separação em base de dados para serem utilizados como entrada da RNA. Cada etapa dessa está detalhada na seção 4.3 (processamento de dados).

A última etapa foi o desenvolvimento da RNA e a identificação dos tipos de pisadas das passadas coletadas (Figura 20 f)). Para sua implementação, a RNA escolhida nessa aplicação é a MLP, a qual foi desenvolvida para identificação e classificação de padrões.

Para avaliar a relação entre o número de neurônios e taxa de acerto da rede, decidiu-se mapear a taxa de acerto pela quantidade de neurônios entre uma faixa de 1 a 30 neurônios. Essa faixa foi escolhida tendo como base heurísticas de Fletcher-Gloss (15 neurônios escondidos) e da plataforma Weka (21 neurônios). Na camada escondida, a tangente hiperbólica foi utilizada como função de ativação e na camada de saída, a função logística (sigmoide).

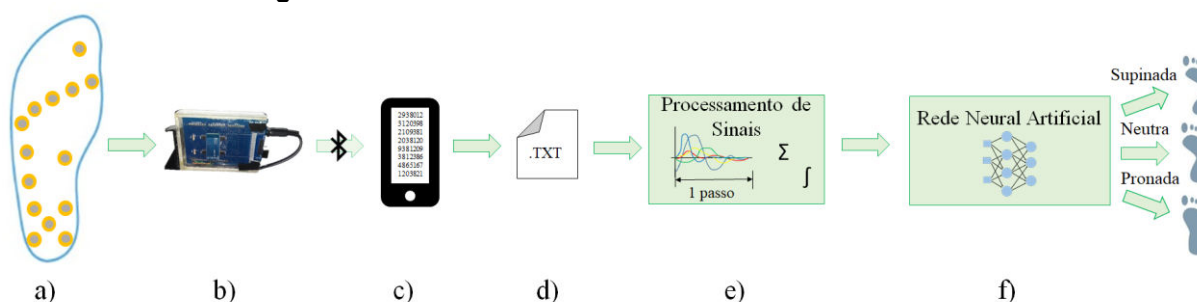
A MLP foi avaliada por dois métodos, utilizados em aprendizagem de máquina, método de *holdout* e validação cruzada (*cross-validation*). Para o método *holdout*, os dados foram divididos de forma aleatória em 80% para treinamento e 15% para teste e 5% para validação. As topologias das MLP para cada neurônio foram testadas 30 vezes para conjunto de neurônios (900 vezes ao total). Em contrapartida, para a validação cruzada foi utilizado o método de *k-fold* (ou *k*-partições). Nesse método, a base de dados foi dividida em 10 partições, com a proporção de 80% dos dados para o treinamento, 5% para validação e 15% para teste. Para cada partição, uma foi usada para o teste enquanto que as outras nove foram utilizadas para o treinamento. Para cada *k*, a quantidade de neurônios foi alterada de 1 a 30 e cada uma foi testada 5 vezes (1500 execuções ao final).

A saída desejada foi informada pela avaliação do fisioterapeuta como descrito anteriormente, comparando com o valor apresentado pela saída da RNA, gerando assim a porcentagem de acerto da rede. Seus resultados estão apresentados na seção 5.2.

5 DESENVOLVIMENTO

Este trabalho compreende várias etapas de desenvolvimento, desde o *hardware* para aquisição e armazenamento de dados até o *software* para processamento e identificação dos sinais, assim aplicando-se o conceito de sistema. Com o intuito de facilitar esse entendimento, a Figura 23 apresenta o fluxo de cada etapa do desenvolvimento, assim como uma identificação visual para cada uma.

Figura 23 - Processos de desenvolvimento deste estudo



Fonte: autoria própria

O primeiro desenvolvimento é a palmilha instrumentada com os sensores piezoelétricos, conjunto inserido dentro do calçado utilizado pelo indivíduo no momento da coleta de dados (Figura 23 a)). Os sinais de tensão elétrica provenientes dos sensores compõem a entrada do circuito de condicionamento de sinal (amplificador de carga), o qual faz parte da placa central do dispositivo (Figura 23 b)). Essa placa também é composta por um circuito de *offset* de tensão, ganho, uma placa de processamento (Arduino™ MEGA2560) e uma placa de comunicação de dados sem fio Bluetooth® (HC-06). A alimentação desse circuito é realizada por uma bateria alcalina de 9 V para isolar o indivíduo da rede de alimentação elétrica.

Os dados coletados pela placa central são transmitidos via comunicação sem fio para qualquer dispositivo móvel habilitado com tecnologia tipo Bluetooth®, em que podem ser visualizados de forma serial (Figura 23 c)). Cada coleta de dado é salva em forma de arquivo texto (.txt) e armazenada na memória do próprio dispositivo (Figura 23 d)). Cada arquivo é identificado com o nome do indivíduo, nome e data da coleta realizada. Posteriormente esses arquivos são disponibilizados para o seu processamento, identificando-se assim os passos realizados pelo

indivíduo, eliminação de ruídos inerentes ao processo de aquisição de dados e para enfim normalização desses sinais (Figura 23 e)).

Após o processamento dos sinais coletados, eles estão prontos para serem utilizados como entrada para uma rede neural artificial (RNA) que é utilizada para classificação e identificação de padrões (Figura 23 f)). Nessa última etapa do processo completo, os passos coletados são divididos em dois grupos de dados, dados de treinamento e de teste. Após o treinamento da RNA, ela é submetida a testes de validação para quantificação dos seus acertos com base na saída desejada. Após o nível de acerto da RNA ser considerado satisfatório, o processo é repetido novamente com mais dados, assim obtendo como resultado a identificação do tipo de pisada por indivíduo (neutra, pronada ou supinada).

Passando por todas essas etapas, é possível completar o fluxo do desenvolvimento deste trabalho. Com isso, essa seção apresenta de forma detalhada os principais componentes desse sistema, assim como suas características, parâmetros e aplicações.

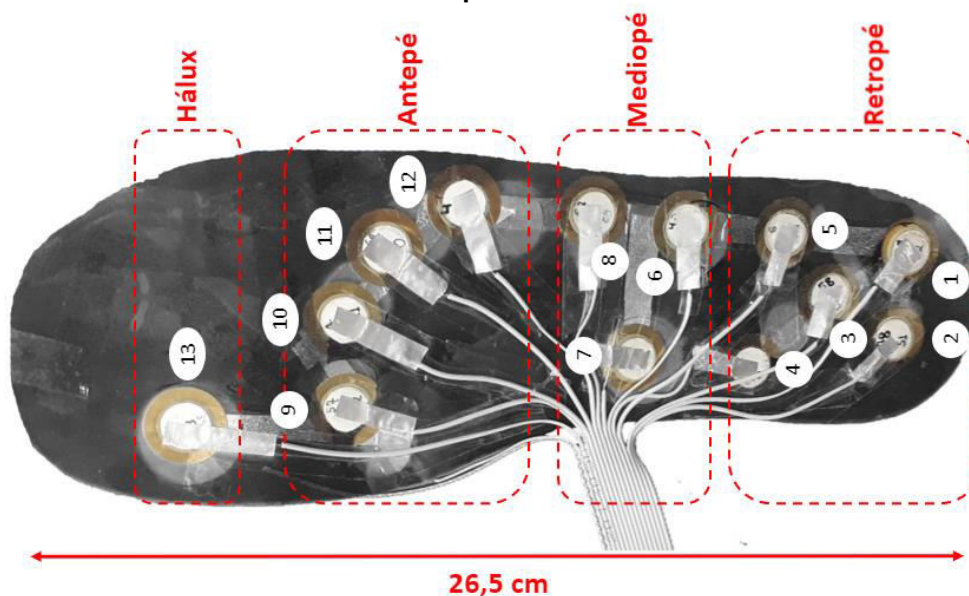
5.1 PALMILHA INSTRUMENTADA

Nos sistemas *in-shoe*, não há um consenso entre os pontos exatos para melhor absorção e medição da pressão plantar. A literatura também não fornece dados precisos explicando o detalhamento dos pontos. A grande quantidade de pesquisa procura distribuí-los entre as regiões do pé (RAZAK et al, 2012). Na Figura 24, a palmilha foi dividida entre as regiões do pé em quatro partes principais: Retropé, Mediopé, Antepé e Hálux (WAFAI et al, 2015; RODRIGUES et al, 2014; SHU et al, 2009). O Hálux (dedão) faz parte da região do Antepé, porém foi distinguido de sua região para facilitar análises posteriores em relação ao metatarso, o qual também compõe o Antepé.

Sobre a quantidade de pontos da divisão da região plantar, a premissa mais utilizada é a verificação de quais análises seriam desenvolvidas com a palmilha instrumentada (RAZAK et al, 2012). Por exemplo, no Retropé, para medição somente da pressão desta região, apenas um ponto é necessário para que se cubra a região; entretanto, para a medição do tipo de pisada, dois pontos (no mínimo) são necessários (regiões interna e externa). Esse processo se repete para

todas as outras regiões plantares (WAFAI et al, 2015; RODRIGUES et al, 2014; SHU et al, 2009). Cada região possui um número específico de sensores, sendo: 5 sensores no Retropé; 3 sensores no Mediopé; 5 sensores no Antepé; e 1 sensor no Hálux. A Figura 24 apresenta os sensores posicionados na palmilha com identificações das regiões plantares.

Figura 24 - Palmilha instrumentada com a identificação das regiões plantares e seu comprimento.



Fonte: autoria própria

Analisando a palmilha por regiões, pode-se afirmar que alguns sensores possuem funções devido a sua localização. A exemplo disso, o sensor 7 é responsável por detectar a presença de arco do tipo plano (pé chato), os sensores 6 e 8 adquirem a intensidade de pressão dos pés pronados ou supinados e os sensores de 1 a 5 são usados para a medição de pisadas tortas com o calcanhar. Além disso, cada sensor apresenta a intensidade da pressão plantar em sua região, a qual auxilia a determinar a característica de pisada do indivíduo.

Para conexão dos sensores ao circuito de condicionamento, utilizou-se um cabo flat pela sua flexibilidade, maleabilidade e de espessura viável para aplicação.


5.1.1 CARACTERÍSTICAS E NORMALIZAÇÃO DO SENSOR

Os sensores piezoelétricos de cerâmica podem apresentar diferença em sua reposta dependendo de sua fabricação, lote, fornecedor. Para evitar esse tipo de influência no resultado final, foi realizada a análise de repetitividade e estabilização

de todos os sensores utilizados nesse trabalho (LA BANCA; VIEIRA; STEVAN JR, 2018).

A Figura 25 apresenta o equipamento utilizado para coleta e normalização de dados dos sensores. Este equipamento foi desenvolvido para que o ambiente de testes seja o mais controlado e idêntico entre as amostras. O método é baseado em suspender um peso padrão por meio de um eletroímã para que quando solto a uma determinada altura, entre em contato com o sensor na fase final da queda, atingindo sempre da mesma maneira em todas as vezes.

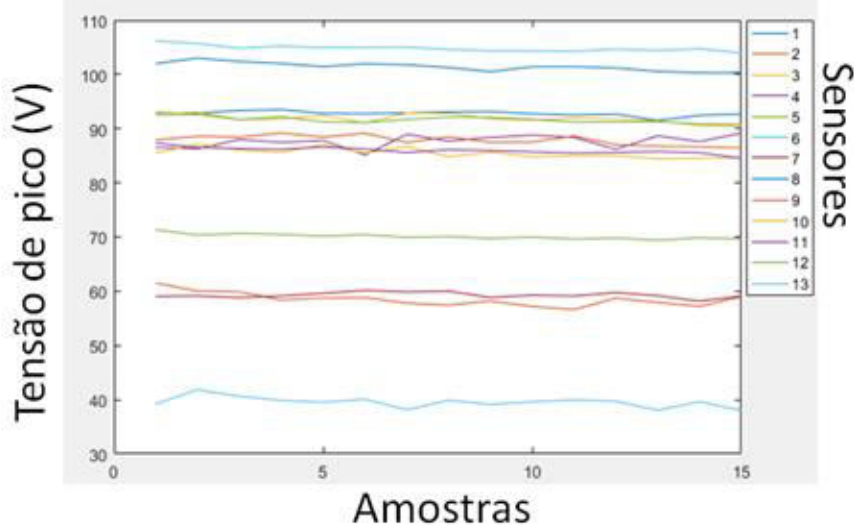
Figura 25 - Dispositivo para aplicar o método de análise do sensor piezoelétrico



Fonte: La Banca; Vieira e Stevan JR (2018)

Todos os sensores foram identificados e separados por palmilha, assim é possível criar uma relação de proporção por palmilha, assim como a correção dos valores. A Figura 26 apresenta a tensão de pico de cada sensor durante as quinze amostras coletadas da palmilha 1 (direita).

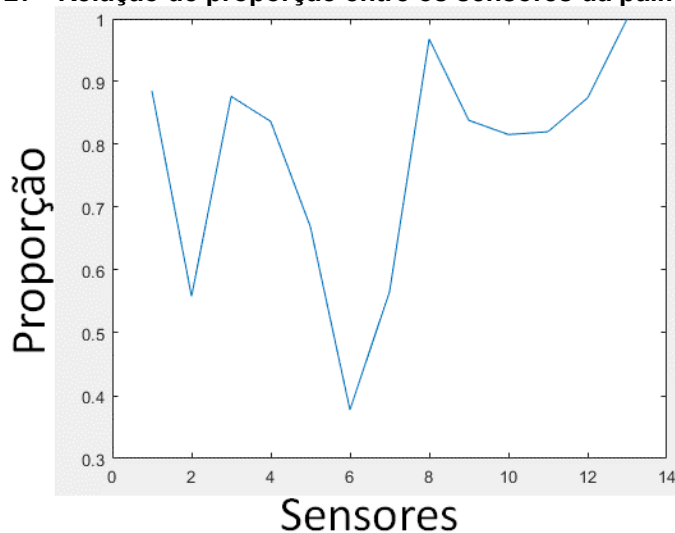
Figura 26 - Resultado de cada sensor por amostra da palmilha 1



Fonte: autoria própria

É possível perceber que o sensor 13 possui o maior valor de tensão de pico constantemente e todas as coletas. Já o sensor 6 é o que possui a maior diferença como menor valor. Considerando esses valores apresentados, a Figura 27 demonstra a relação de proporção entre os sensores, definindo o sensor 13 como 100%.

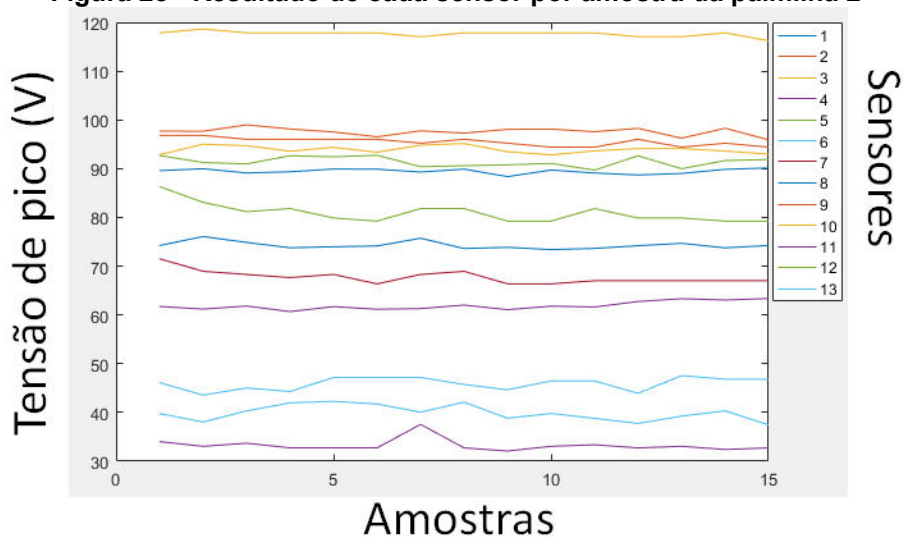
Figura 27 - Relação de proporção entre os sensores da palmilha 1



Fonte: autoria própria

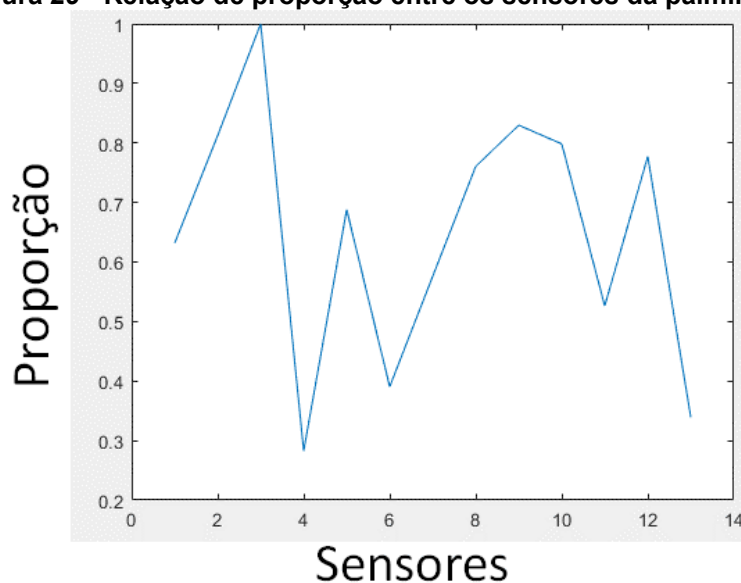
Comparando as duas Figuras percebe-se que a proporção evidencia a diferença dos valores obtidos em tensão de pico por ensaio. O sensor 6 é aproximadamente 40% do valor de pico do sensor 13. As mesmas etapas foram cumpridas para a palmilha 2 (esquerda), os quais os resultados são apresentados nas Figuras 28 e 29.

Figura 28 - Resultado de cada sensor por amostra da palmilha 2



Fonte: autoria própria

Figura 29 - Relação de proporção entre os sensores da palmilha 1



Fonte: autoria própria

Analogamente a primeira palmilha, destaca-se o sensor com o maior valor de tensão de pico (3), o qual foi definido como 1 nas proporções; e o sensor que obteve o menor valor de pico (4), com aproximadamente 30% do valor do sensor 3.


5.2 PLACA CENTRAL

A placa central do dispositivo desenvolvido pode ser dividida em aquisição, condicionamento, processamento e transmissão de dados, apresentados na Figura 30. Para alimentação da placa central e seus componentes (Figura 30 (b,c,d,e)), foi escolhida uma bateria comum de 9 V, pelo seu baixo custo, facilidade em encontrar

no mercado nacional e fornecimento de tensão/corrente elétrica satisfatório para essa aplicação.

Como demonstrado na seção anterior, a palmilha instrumentada contém 13 sensores (Figura 30a)), todos conectados à placa de aquisição de sinais (Figura 30b)) por meio de um cabo flat com 16 canais.

Figura 30 - Apresentação das partes do dispositivo: palmilha com sensores; b) conexões; c) circuitos de aquisição e condicionamento; d) processamento; e), transmissão; e f) armazenamento dos dados



Fontes: c) Texas Instruments (2015); d) Arduino (2018); e) Xin, Huang e Mok (2011).

A topologia utilizada para o condicionamento de sinal foi o amplificador de carga, ideal para atuar nos sinais dos sensores piezoelétricos, como já citado. O amplificador operacional escolhido para compor o amplificador de carga foi o modelo TL084 da Texas Instruments™ (Figura 30 c)). Este amplificador consome um baixo valor de energia da fonte de alimentação (1,4 mA por canal), possui quatro canais por circuito integrado (TEXAS INSTRUMENTS, 2015), facilidade em sua aquisição e baixo custo, principais motivos para sua escolha.

O amplificador de carga nesse projeto possui atuação direta no sinal mensurado, pois ele ageno ganho e no filtro, condicionando o sinal para seu processamento e transmissão.

O processamento local do sinal (Figura 30d)) é simples, visto que o sinal será processado adicionalmente via *software* antes de entrar na RNA. A placa embarcada tem a responsabilidade de receber o sinal coletado, amostrar, digitalizar e enviar ao transmissor sem fio. Para tal ação, o Arduino™ modelo MEGA 2560 foi escolhido por sua configuração padrão que atendem os seguintes requisitos: mínimo de 14 canais analógicos de entrada (14 sensores piezoelétricos na palmilha);

sistema de comunicação serial, utilizado no Bluetooth[®]; e menor custo de aquisição (ARDUINO, 2018).

Como principais características, esse modelo contém um processador com *clock* de 16MHz, corrente dos canais de entrada de 20 mA, peso de apenas 37g (requisito) e tensão elétrica de alimentação externa entre 7 e 12 V (dentro da faixa de atuação da bateria escolhida).

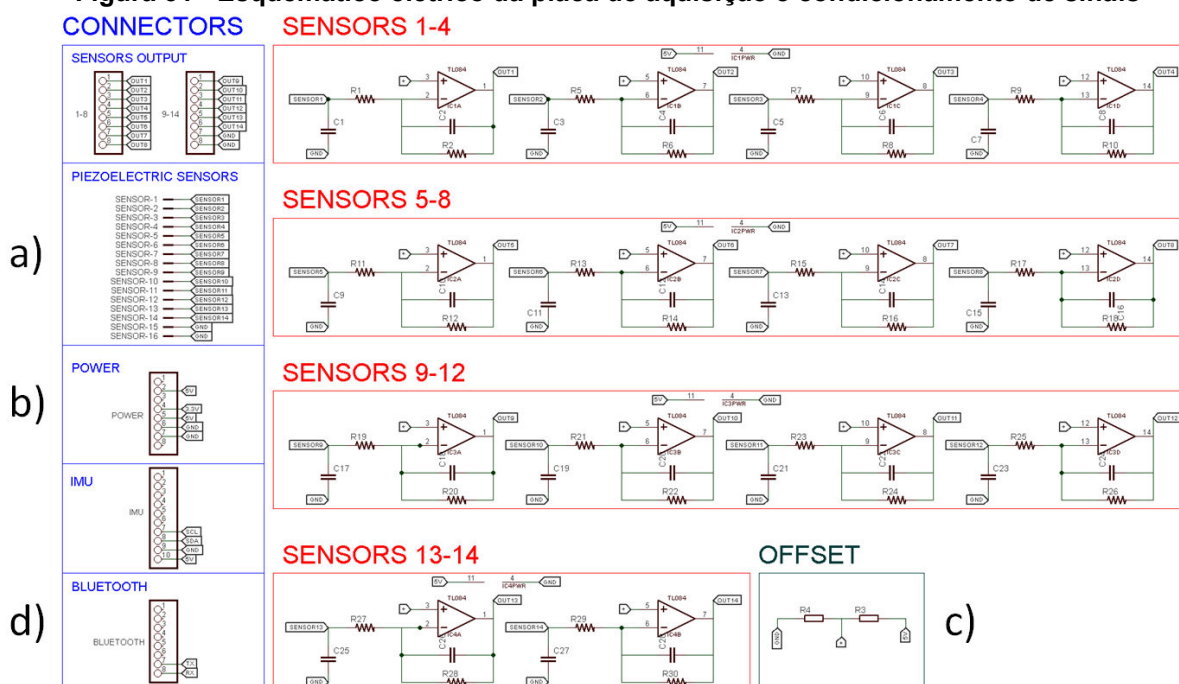
A transmissão dos dados via comunicação sem fio Bluetooth[®] é realizada pelo transmissor HC-06 (Figura 30 e)), placa já otimizada para ser de fácil aplicação junto as placas embarcadas, como, o Arduino[™] MEGA2560. Sua escolha foi devido às configurações padrões atenderem aos requisitos deste trabalho, como: baixo consumo de energia em operação (8 mA), padrão da comunicação Bluetooth[®] de 2,4 GHz na transmissão sem fio e baixo custo de aquisição (XIN; HUANG; MOK, 2011).

Os dados são recebidos por um dispositivo móvel do tipo *smartphone* (Figura 30 f)), o qual também tem que possuir comunicação Bluetooth[®] e estar pareado à placa central no momento da coleta de dados. Nenhuma aplicação foi especificada para o armazenamento dos dados coletados, mas para esse estudo, foi utilizada uma livre de licença que tinha a ação de dividir os dados recebidos em arquivos do tipo texto (.txt).

Com base nos requisitos deste estudo, o desenvolvimento da placa central do dispositivo foi direcionado para aplicação de uma *shield* (do inglês, escudo). Esse tipo de circuito é acoplado a sistemas embarcados formando uma conexão fixa, estável e direta (conectores sobrepostos). A Figura 31 apresenta o esquemático elétrico dessa *shield*, evidenciando que as conexões dos sensores (a), alimentação elétrica (b), módulo de comunicação sem fio HC-06 (d) e dos amplificadores operacionais estão projetados na mesma placa de circuito impresso. Com base nas equações (1) a (4), o amplificador de carga foi projetado.

Considerando os valores de capacitores e resistores comerciais, as frequências de corte inferior e superior calculadas, pelas equações (1) e (2), foram de 1,59 Hz e 15,91 Hz. Os filtros foram projetados com base nestas frequências tendo o filtro passa-alta composto por R_1 (1 M Ω) e C_1 (100 nF); já o filtro passa-baixa é composto por R_2 (100 k Ω) e C_2 (100 nF). Cada sensor possui seu amplificador de carga, compondo um canal do amplificador operacional, identificados numericamente e apresentados na Figura 31.

Figura 31 - Esquemático elétrico da placa de aquisição e condicionamento de sinais

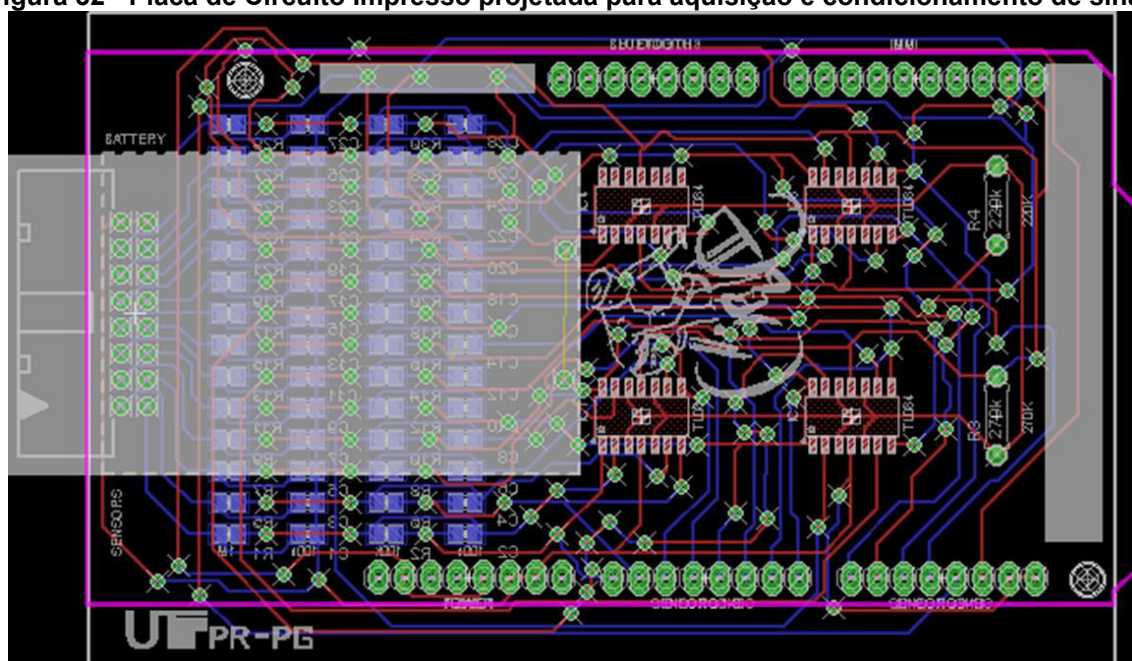


Fonte: autoria própria

Vale ressaltar a associação dos resistores de R_3 (220 k Ω) e R_4 (270 k Ω), apresentada na Figura 31 (c). Usando essa topologia, o sistema apresentará um *offset* do sinal (V_{OFF} , equação 8)), que não ficará em nível analógico de 0 V e sim o valor da queda de tensão do resistor R_4 . Essa queda de tensão é de 2,70 V, o que deixa o *offset* mais da metade do range total de alimentação (5 V) (Figura 31 b)). Tal valor foi escolhido pois a aplicação de força resulta em uma tensão mais abrupta que a saída de tensão em uma na região plantar. Desta forma, os estágios posteriores de aquisição não apresentarão problemas de saturação e de sobretensão, com o ganho de 0,1 (Ganho, equação 9)).

Com o projeto do circuito elétrico concluído, é necessário desenvolver uma placa de circuito impresso para que o esquemático apresentado possa ser implementado fisicamente. Nessa etapa foi utilizado o *software Eagle* da empresa Autodesk[®], o qual o modelo do Arduino[™] MEGA2560 já possui documentação oficial e contém todos os componentes usados nesse estudo em sua biblioteca padrão. A Figura 32 apresenta o projeto da placa de circuito impresso, onde as linhas em vermelho são as trilhas de conexão na face superior (*Top*) e as linhas em azul na face inferior (*Bottom*).

Figura 32 - Placa de Circuito Impresso projetada para aquisição e condicionamento de sinais




Fonte: autoria própria

A Figura 33 apresenta em três visões diferentes o detalhamento da placa de aquisição de pressão plantar desenvolvida, em que tem-se a visão em: perspectiva a), superior b) e inferior c). O conector dos canais de entrada da placa (Figura 33 a)) é o padrão para cabos tipo *flat*, contendo 16 pinos, 14 de sinal e dois de terra (GND), os quais compõem os canais de entrada do esquemático da Figura 32 a).

A parte superior da placa é composta por 4 circuitos integrados (modelo TL084) formando 16 possíveis canais de amplificadores de carga, região destacada Figura 33 b). A placa de comunicação de dados sem fio utiliza tecnologia Bluetooth[®] e foi conectada diretamente nos pinos de comunicação serial do Arduino[™] (Figura 33 b)). Como apresentado na equação (3), o valor de *offset* (V_{OFF}) da placa é formado pela combinação dos resistores R_3 e R_4 , os quais se encontram destacados na Figura 33 b).

Figura 33 - Placa de aquisição de pressão plantar: (a) perspectiva, (b) face superior e (c) face inferior.



Fonte: autoria própria

A parte inferior da placa de aquisição (Figura 33 c)) é composta por 28 resistores e 28 capacitores que formam todos os 14 canais de amplificação de carga, destacados na Figura 33 c). Como é um circuito em modo de *shield*, os canais analógicos e os pinos de alimentação do sistema são compartilhados entre a placa de aquisição e o Arduino™, como apresentados na Figura 33 c).

Com o objetivo de proteger fisicamente a placa central, foi projetada uma caixa protetora feita em acrílico, assim o dispositivo pode ser vestido pelo indivíduo isolando de qualquer contato físico com a placa ou sistema de alimentação elétrica (bateria). A Figura 34 apresenta a *shield* acoplada ao Arduino™ e ambos inseridos na caixa protetora.

Figura 34 - Placa central desenvolvida: aquisição, condicionamento e transmissão dos dados.



Fonte: autoria própria

Percebe-se que para facilitar o manuseio do dispositivo, o conector com os cabos da palmilha pode ser acoplado ou removido conforme necessidade, assim como a bateria (Figura 34). É possível identificar também na Figura 34 que o conector serial (USB) do Arduino™ está exposto na parte inferior da placa, facilitando assim o *upload* de novos programas sem precisar desmontar o dispositivo.

Sistemas *in-shoe* precisam ser confortáveis e não podem atrapalhar ou incomodar o indivíduo na execução de seus movimentos. Baseado nisso, foi escolhida a região do tornozelo do indivíduo para instalação da placa central do dispositivo. O cabo que conecta a palmilha instrumentada à placa central não pode atrapalhar o movimento dessa região (limitação ou rigidez). A Figura 35 apresenta o dispositivo completo já vestido pelo indivíduo durante coleta de dados. É possível observar que nenhuma parte do circuito está em contato com o indivíduo, isolando de qualquer risco. O Cabo *flat* sai do interior do calçado pela cavidade interna do mesmo, sendo conectado na parte inferior da placa central (Figura 35).

Figura 35 - Dispositivo completo vestido pelo indivíduo, placa central conectada na palmilha instrumentada inserida no calçado.



Fonte: autoria própria

Foi utilizada uma fita fixadora para melhor acomodação da placa no indivíduo, permitindo-lhe realizar os movimentos necessários sem que o sistema seja desconectado ou danificado. Além disso, uma segunda palmilha, feita do mesmo material que a primeira, foi colocada no pé oposto, a fim de nivelar o indivíduo e não ter problemas durante a sua movimentação.

5.3 PRÉ-PROCESSAMENTO DOS DADOS

Os dados não devem entrar de forma bruta (sem pré-processamento) para a rede neural. Antes, é necessário realizar um tratamento da informação. O processamento destes dados consiste na segmentação dos sinais coletados, ou seja, separar os sinais em amostras. Isso é necessário porque os indivíduos forneceram 100 metros de passadas, e devido à altura dos indivíduos, suas

propriedades anatômicas e subjetivas, o número de passadas realizadas por cada um foi diferente. Logo, necessitou-se separar cada um dos passos, pois cada passo é uma amostra.

Para a segmentação deste sinal, foram considerados sinais que estabelecessem o começo e o fim do passo. Foram usados os sinais do Sensor 1 (localizado na região do retopé) para indicar o início e o fim dos passos. Para isso, quando o Sensor 1 passa de um limiar, identifica-se o instante de tempo e os sinais de todos os outros sensores são coletados, formando uma matriz de amostras. Encerra-se a matriz quando o Sensor 1 novamente passa por um limiar.

Cada indivíduo possui passadas de tamanhos diferentes e mesmo assim, para o mesmo indivíduo, cada passada pode possuir diferentes períodos. Com base nessa premissa, houve a necessidade de normalizar a quantidade de períodos que foram capturados sinais por cada sensor de forma a unificar as amostras pela quantidade de dados entra cada passo. Todos os passos coletados foram analisados de forma gráfica, os quais percebeu-se que o maior passo continha 16 intervalos de tempo (amostragem na coleta de dados). Por isso, decidiu-se unificar todos os demais passos para 16 dados (um para cada intervalo). Logo, cada amostra possui ao total 16 intervalos de tempo por sensor, e como são 13 sensores, é uma matriz 16 x 13, ou um vetor de 208 posições. Para os demais passos que continham uma menor quantidade de dados (menor que 16 períodos) foram completados com o valor 0. Dessa forma, não há alteração nas amostras. Para configurar a entrada da RNA, foi utilizado o *MAV* e a normalização já aplicada, deixando essa entrada estacionária, sem *offset* e buscando o melhor desempenho possível da RNA.

5.4 IMPLEMENTAÇÃO DA REDE NEURAL

Durante a etapa de treinamento, os pesos sinápticos foram gerados aleatoriamente ($W_{ji}^{(1)}$ com valores positivos e negativos e $W_{ji}^{(2)}$ apenas com valores positivos). Isso porque a função tangente hiperbólica mapeia sinais negativos e positivos, enquanto que a função logística apenas sinais positivos, pois a saída possui apenas valores positivos.

O ajuste dos pesos sinápticos foi feito por meio da regra delta generalizada utilizando retropropagação do erro (*backpropagation*). A taxa de aprendizagem escolhida foi de $5 \cdot 10^{-3}$. Os critérios de parada da rede foram a quantidade máxima de épocas (10^4) e a precisão do erro quadrático médio ($5 \cdot 10^{-7}$).

Dentre o conjunto de dados para o treinamento, uma parcela (5% da base) foi utilizada para o processo de generalização para a escolha do melhor conjunto de pesos sinápticos $W_{ji}^{(1)}$ e $W_{ji}^{(2)}$ de tal forma que este conjunto não foi usado para o treinamento dos pesos. A cada 10 épocas, o conjunto de validação foi submetido aos pesos sinápticos atuais e o seu erro quadrático médio foi salvo. Após a rede terminar de ser treinada com os critérios de quantidade máxima de épocas e da precisão do erro quadrático médio, os pesos relacionados ao menor erro quadrático para o conjunto de validação foram escolhidos. Dessa forma, tende-se a diminuir a possibilidade de sobre-treinamento (*overfitting*) dos dados, a qual é prejudicial para a generalização da rede.

6 RESULTADOS E DISCUSSÃO

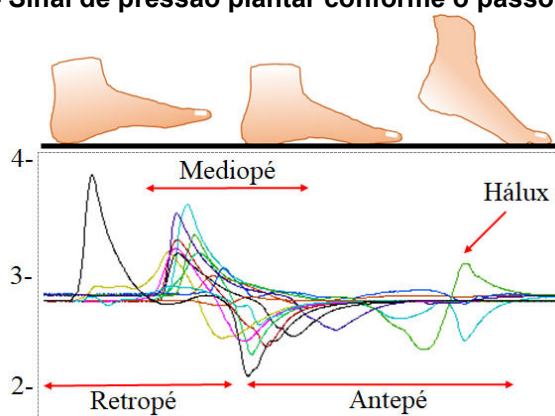
Os resultados foram divididos em duas etapas de apresentação, sendo a primeira relacionada a coleta de dados de pressão plantar dos indivíduos e suas análises. O objetivo dessa etapa é validar a possibilidade da utilização de sensores piezoelétricos de cerâmica para este processo. Com isso, ter a visibilidade necessária dos dados para que sejam usados como sinais de entrada da MLP.

Na sequência, são apresentados os resultados de classificação da RNA desenvolvida, identificando o tipo de pisada de cada indivíduo em supinada, pronada e neutra.

6.1 DADOS DE PRESSÃO PLANTAR

Como a palmilha instrumentada desenvolvida possui 13 sensores (divididos em quatro regiões plantares: retropé, mediopé, antepé e hálux), cada sensor apresenta a sua resposta conforme são ativados no momento da pisada, sendo o tempo de ativação e sua intensidade dependentes da ação do indivíduo. A Figura 36 demonstra o comportamento de cada sensor conforme cada etapa no processo da pisada. O movimento inicia-se com o contato do retropé na superfície, passando pelo médiopé e antepé, terminando com o contato do hálux (sensor n°13).

Figura 36 - Sinal de pressão plantar conforme o passo é realizado




Fonte: autoria própria

Cada passo possui todas as fases de ativação de cada sensor em função do tempo, desde o pico superior no início da curva (compressão), voltando para a origem e pico inferior (descompressão) ao final da curva (Figura 36). Por sua vez, a Figura 37 apresenta as curvas que evidenciam que conforme o movimento do

indivíduo, os sinais adquiridos pelo dispositivo são alterados e se comportam de forma singular, contendo três passos em sequência, cada um com suas características.


Figura 37 - Sinal de pressão plantar durante três passos em sequência



Fonte: autoria própria

Dividindo os sinais de cada sensor por região plantar da palmilha, a Figura 38 apresenta os níveis de ativação por segmento, todos do mesmo passo.

Figura 38 - Sinal de pressão plantar durante um passo, dividido nas regiões plantares e com os sensores identificados: retopé, mediopé, antepé e hálux



Fonte: autoria própria

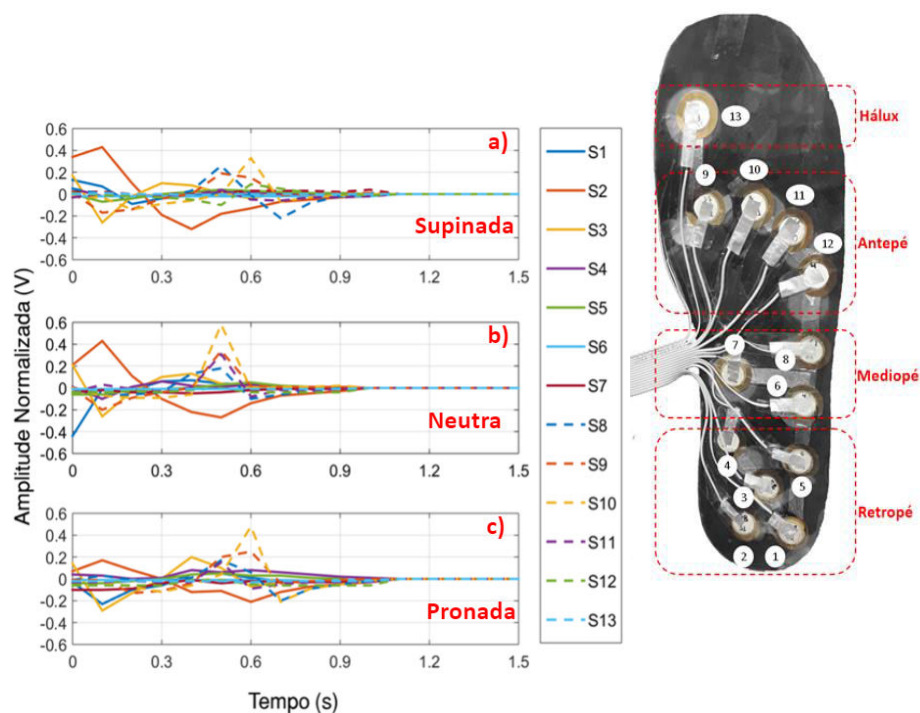
Após a apresentação do comportamento dos sensores conforme o movimento do indivíduo verificou a possibilidade de comparação entre os sinais e os tipos de pisada. Para essa análise, a Figura 39 apresenta no mesmo quadro os sinais de um passo para cada tipo de pisada: supinada a), neutra b) e pronada c) com os dados normalizados.

A maior distinção entre as curvas conforme o tipo de pisada é a amplitude dos sensores principais da região plantar acionada. Como por exemplo, no caso da supinada e neutra, os sensores 2 e 3 (retopé) possuem comportamento parecido, sendo os principais ativados no início do movimento. Para a pisada pronada, esses sensores também são ativados, mas com uma amplitude menor em períodos de tempo diferentes.

Já para a região do antepé, a maior variação de valores está na parte dos cinco sensores que compõe a região plantar. Os sensores mais acionados na pisada

supinada são os 9 e 10 e para a neutra é o 11. Evidenciando a diferença do acionamento por região plantar e seu tipo de pisada.

Figura 39 - Sinal de pressão plantar (esquerda) por tipo de pisada



Fonte: autoria própria

Não houve diferença visual nessa análise para os sensores do mediopé e hálux. Em relação ao mediopé, acredita-se em sua justificativa para casos de pé planos, onde não foi obtido nenhum caso durante a coleta de dados nesse estudo.


Assim, conclui-se que existe uma diferença no padrão dos valores de pressão plantar por tipo de pisada, contudo, para sua classificação, é necessária a implementação de algoritmos de aprendizagem de máquina, como uma RNA. Isso é corroborado pelo teorema de Stone-Weierstrass, o qual afirma que uma estrutura como uma MLP de uma camada de entrada, uma camada escondida e uma camada de saída é capaz de mapear/aproximar qualquer função não-linear, desde que sua camada escondida seja larga o suficiente. Logo, existe uma solução para esse problema usando MLP, basta encontrá-la.

6.2 IDENTIFICAÇÃO DO TIPO DE PISADA

A partir dos treinamentos da MLP descritos na seção 3.4.3, obteve-se resultados para o treinamento, o teste e o conjunto total de dados usando como separação dos dados e método de treinamento *holdout* e validação cruzada.

A Figura 40 apresenta o comportamento do erro quadrático médio (EQM) das etapas de treinamento e validação do método de validação cruzada, evidenciando a parada antecipada para cada configuração da RNA proposta. O propósito desse tipo de implementação é a máxima generalização da rede com o menor sobre-treinamento (HAYKIN, 2003). Pode-se observar que a Figura 40 possui o eixo de épocas, o qual é dividido pelas faixas das quantidades dos neurônios.

Figura 40 - Erro quadrático médio para treinamento e validação no método de validação cruzada



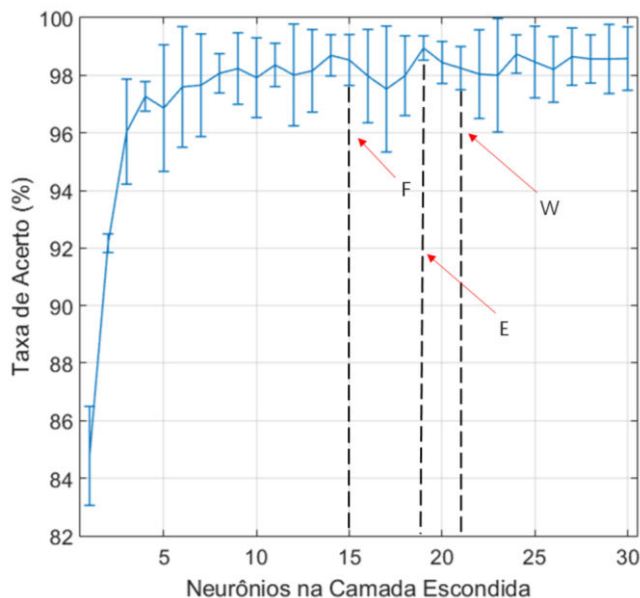
Fonte: autoria própria

As Figuras 41, 42 e 43 apresentam as médias e os desvios padrões dos resultados para as etapas de treinamento, teste e validação, respectivamente, para o método *holdout* com a variação dos neurônios na camada escondida. Percebe-se nas três curvas que há um aumento na taxa de acerto com o aumento da quantidade de neurônios. Para o treinamento, a MLP apresentou média em torno de 99,63%, para o teste, 97,30%, validação 100% e para todo o conjunto de dados, 99,30% de

acerto. Além disso, os desvios padrões são variáveis em todos os pontos, podendo chegar de $\pm 0,50$ a $\pm 3,50\%$ em todos os casos.

Analisando a quantidade de neurônios e realizar a decisão da quantidade de neurônios na camada escondida, escolheu-se como critério avaliar entre as 3 curvas a os valores possuíam a maior média no teste com menor desvio padrão com a menor quantidade de neurônios possível. Isso pode ser feito porque com valores acima de 5 neurônios, percebe-se que a MLP estabiliza a taxa de acerto para essa aplicação, com valores flutuando nas médias apresentadas anteriormente. Dessa forma, a topologia que mais atendeu esses critérios foi a topologia com 19 neurônios, destacada como (E) nas Figuras 41, 42 e 43, juntamente com os neurônios pelos critérios de Fletcher-Gloss (F) e Weka (W).

Figura 41-Média das taxas de acerto e seus respectivos desvios-padrões para a etapa de treinamento no método *holdout*




F	W	E
15	21	19

Fonte: autoria própria


Figura 42 - Média das taxas de acerto e seus respectivos desvios-padrões para a etapa de teste no método *holdout*

F	W	E
15	21	19



Fonte: autoria própria

Figura 43 - Média das taxas de acerto e seus respectivos desvios-padrões para todo o conjunto de dados no método *holdout*



Fonte: autoria própria

F	W	E
15	21	19

Figura 44 - Matrizes de confusão para a topologia com 19 neurônios para as etapas de treinamento, validação e teste, além de todas as amostras da base. Os valores em (S) representam a pisada supinada, (N) pisada neutra e (P) pisada pronada.

Trein		Obtido		
		S	N	P
Desejado	S	242 99,2%	2 0,8%	0 0,0%
	N	2 0,3%	617 99,7%	0 0,0%
	P	0 0,0%	0 0,0%	436 100,0%

Val		Obtido		
		S	N	P
Desejado	S	6 100,0%	0 0,0%	0 0,0%
	N	0 0,0%	27 100,0%	0 0,0%
	P	0 0,0%	0 0,0%	17 100,0%

Teste		Obtido		
		S	N	P
Desejado	S	38 92,7%	3 7,3%	0 0,0%
	N	1 0,8%	122 99,2%	0 0,0%
	P	0 0,0%	0 0,0%	86 100,0%

Total		Obtido		
		S	N	P
Desejado	S	286 98,3%	5 1,7%	0 0,0%
	N	3 0,4%	766 99,6%	0 0,0%
	P	0 0,0%	0 0,0%	539 100,0%

Fonte: autoria própria

A Figura 44 apresenta as matrizes de confusão para a topologia com este conjunto de pesos sinápticos escolhidos para as etapas de treinamento, teste, validação e para todos os conjuntos de dados. Além da quantidade de acertos são apresentadas as suas respectivas porcentagens.

A Tabela 3 apresenta a análise de desempenho para a matriz de confusão levando em consideração toda a base de dados. Pode-se perceber que a pisada neutra e a pisada pronada possuíram alto desempenho em todos os parâmetros, acima de 99,00%, sendo a pronada com maior taxa de eficiência no processo de classificação. Mesmo a pior classificação que é a supinada, em todos os aspectos obteve-se um resultado maior que 98,00%, evidenciando a alta taxa de acerto.

Tabela 3 - Análise de desempenho em relação à matriz de confusão para toda a base de dados para uma rede de 19 neurônios escolhida pelo método de validação cruzada.

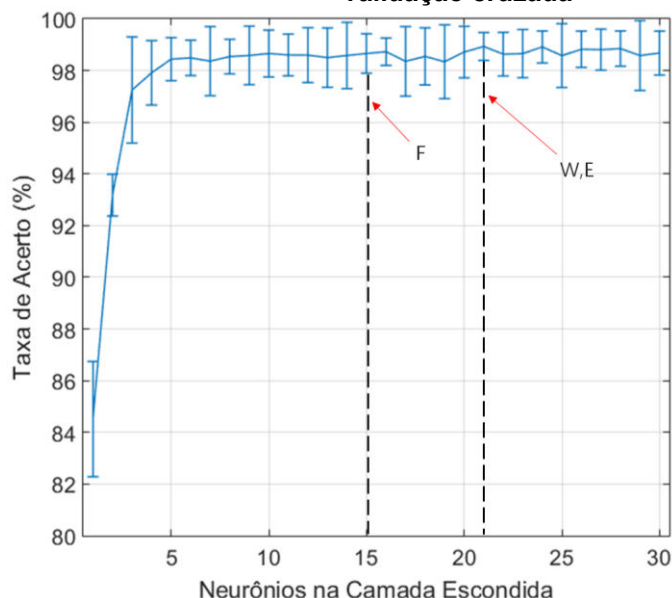
Parâmetro	Tipo de Pisada		
	Supinada	Neutra	Pronada
Acurácia	99,50%	99,50%	100,00%
Sensibilidade	98,30%	99,60%	100,00%
Especificidade	99,80%	99,40%	100,00%
Eficiência	99,00%	99,50%	100,00%

Fonte: autoria própria

Utilizando método de validação cruzada, as Figuras 45, 46 e 47 apresentam as médias das taxas de acerto e seus respectivos desvios padrões para as etapas de treinamento e teste e para toda a base de dados. Percebe-se que há um mesmo padrão observado pelo método *holdout*, entretanto, nota-se que os desvios padrões

para as três curvas permanecem constantes (cerca de $\pm 3,00\%$ para o teste e $\pm 0,50\%$ para o treinamento e toda a base de dados).

Figura 45-Média das taxas de acerto e desvios-padrões para treinamento no método de validação cruzada




F	W	E
15	21	21

Fonte: autoria própria

Sobre as médias, nota-se que houve alguma diferença (a partir de 5 neurônios, como a análise passada) para cerca de 99,83% para o treinamento (acréscimo de 0,20%), 98% para o teste (acréscimo de 0,70%), validação se manteve em 100% e 99,63% para a quantidade total de dados. Logo, a maior diferença nos resultados foi na etapa de teste com diferença de 0,70%.

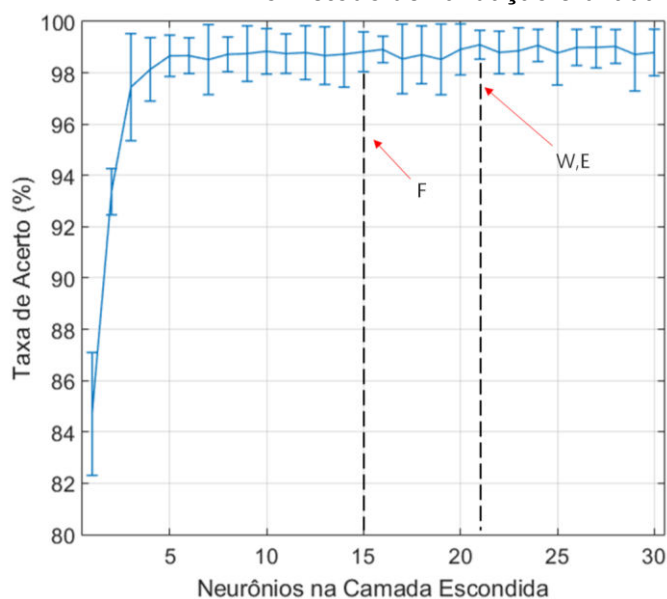
Figura 46 - Média das taxas de acerto e seus respectivos desvios-padrões para a etapa de teste no método de validação cruzada



F	W	E
15	21	21

Fonte: autoria própria

Figura 47 - Média das taxas de acerto e seus respectivos desvios-padrões para a etapa de teste no método de validação cruzada



F	W	E
15	21	21

Fonte: autoria própria

Com os mesmos critérios utilizados anteriormente, a melhor rede foi considerada com 21 neurônios, sendo também destacada nas Figuras 45, 46 e 47. A Figura 48 apresenta a sua respectiva matriz de confusão.

A Tabela 4 apresenta a análise de desempenho do classificador para a matriz com todos os dados da Figura 48. Percebe-se que o mesmo padrão se repetiu para matriz de confusão anterior os seus respectivos avaliadores, entretanto, com esse método, a rede apresentou uma melhora no seu desempenho. A pisada supinada continua classificada erroneamente com a pisada neutra e vice-versa, com menor frequência, o que ocasionou o aumento de sua sensibilidade e por consequência, sua eficiência.

Utilizando o método de validação cruzada com 21 neurônios na camada escondida acertou 99,63% das classificações em todo o conjunto de dados. Desta forma, analisando a matriz de confusão com a mesma RNA, observa-se os valores mínimos e máximos na classificação de cada tipo de pisada; tendo como principais resultados: 100% de todos os requisitos da pronada; 99,70% em todos os requisitos da neutra; e 99,70% de acurácia na supinada.

Figura 48 - Matrizes de confusão para a topologia com 21 neurônios (escolhidos pelo método de validação cruzada) para as etapas de treinamento, validação e teste, além de todas as amostras da base. Os valores em (S) representam a supinada, (N) neutra e (P) pronada.

Trein		Obtido			Val		Obtido		
		S	N	P			S	N	P
Desejado	S	219 99,5%	1 0,5%	0 0,0%	Desejado	S	10 100,0%	0 0,0%	0 0,0%
	N	0 0,0%	586 100,0%	0 0,0%		N	0 0,0%	29 100,0%	0 0,0%
	P	0 0,0%	0 0,0%	423 100,0%		P	0 0,0%	0 0,0%	11 100,0%

Teste		Obtido			Total		Obtido		
		S	N	P			S	N	P
Desejado	S	28 96,6%	1 3,4%	0 0,0%	Desejado	S	257 99,2%	2 0,8%	0 0,0%
	N	2 2,6%	75 97,4%	0 0,0%		N	2 0,3%	690 99,7%	0 0,0%
	P	0 0,0%	0 0,0%	54 100,0%		P	0 0,0%	0 0,0%	488 100,0%

Fonte: autoria própria

Tabela 4 - Análise de desempenho em relação à matriz de confusão para toda a base de dados para uma rede de 21 neurônios escolhida pelo método de validação cruzada.

Parâmetro	Tipo de Pisada		
	Supinada	Neutra	Pronada
Acurácia	99,7%	99,7%	100,0%
Sensibilidade	99,2%	99,7%	100,0%
Especificidade	99,8%	99,7%	100,0%
Eficiência	99,5%	99,7%	100,0%

Fonte: autoria própria

Com o objetivo de comparação dos resultados da RNA utilizando pressão plantar, foram coletados quatro trabalhos que possuem as mesmas etapas de estudo: medição de pressão plantar e classificação de algum padrão por meio de redes neurais artificiais. A Tabela 5 apresenta a comparação entre os resultados das classificações para todo o conjunto de dados e suas características.

Tabela 5 - Comparação do resultado da RNA desenvolvida com referências

RNA	Método	Objetivo	Acerto	Referência
MLP	<i>In-shoe</i>	Identificar o tipo de pisada	99,63%	Este trabalho
MLP	Não especificado	Identificar torção no tornozelo (simulado)	98,45%	(NASSERI et al, 2009)
Não especificada	<i>In-shoe</i>	Identificar o tipo de região plantar	96,00%	(OSSAMI; MIOSSO; FLEURY, 2014)
MLP	<i>In-shoe</i>	Identificar assimetria ao	94,00%	(WAFAL et al, 2014)

	(F-Scan)	andar		
(BPNN)	<i>In-shoe</i>	Predizer o tipo da palmilha mais apropriada para cada perfil de pé	75,00%	(WANG; WANG; CHANG, 2013)

Fonte: autoria própria

Observa-se que os resultados apresentados na coluna “acerto” são todos acima de 75,00%, porém o maior valor é da RNA desenvolvida nesse projeto. Isso é uma evidencia da representatividade dos resultados obtidos ao classificar o tipo de pisada. O trabalho que mais se aproximou com o protótipo utilizou dados simulados, evidenciando assim a dificuldade de desenvolver uma RNA que utilize dados coletados em condições reais com essa taxa de acerto, utilizando pressão plantar.

Com base nos acertos obtidos pela RNA na identificação do tipo de pisada e sua comparação com outros trabalhos similares, é possível afirmar que este protótipo atingiu o mínimo definido para seu sucesso. Assim, finaliza-se a apresentação dos resultados e suas discussões dentro do escopo abordado por este trabalho.

7 CONCLUSÕES

Este trabalho teve como objetivo o desenvolvimento de um protótipo que permitisse a medição de pressão plantar em situações dinâmicas e proporcionasse a identificação automática do tipo de pisada, baseado em palmilha instrumentada por sensores piezoelétricos e redes neurais artificiais, a fim de auxiliar profissionais da saúde em avaliações físicas, monitoramento e diagnósticos.

No desenvolvimento do trabalho percebeu-se que os sensores piezoelétricos de cerâmica são capazes de serem aplicados na medição de pressão plantar, assim como sua utilização em sistemas *in-shoe*. Apresenta-se como uma solução de menor custo de aquisição e mais fácil de encontrar no mercado nacional, fomentando-o para aplicações descartáveis e personalizadas. A definição da quantidade mínima de sensores também foi observada, chegando ao valor de treze sensores, que se mostrou suficiente para a aplicação proposta, todavia recomenda-se para um trabalho futuro a utilização de algoritmos de otimização para quantificar a menor quantidade de sensores para cobrir a maior área da palmilha; e comparar os resultados.

O dispositivo *in-shoe* aqui proposto foi capaz de coletar dados de pressão plantar em condições dinâmicas. Os sinais de saída dos sensores foram coletados, transmitidos e armazenados para uso da rede neural posteriormente. O circuito de condicionamento de sinal mostrou-se satisfatório, pois não interferiu na movimentação do indivíduo durante as coletas de dados (requisito) e apresentou correto funcionamento na coleta e transmissão dos dados em tempo real.

O circuito de condicionamento de sinais utilizando amplificadores de carga atuou no sinal de maneira correta, adequando ao processamento e protegendo a placa embarcada. A placa central contendo a *shield* e o Arduino™ MEGA2560 apresentou correto funcionamento em todas as coletas de dados, além da alimentação elétrica com a bateria de 9 V foi suficiente, não interrompendo nenhuma coleta.

O procedimento para coleta de dados foi aplicado rigorosamente, padronizando as coletas e facilitando o entendimento dos voluntários. Foram coletados dados de 15 indivíduos, com média de idade $28,7 \pm 8,8$ anos. Todas as coletas foram acompanhadas por um profissional da saúde. Ele foi responsável pela

avaliação de cada voluntário para informar o tipo de pisada, gerando assim o resultado de comparação para a RNA desenvolvida.

Após os dados coletados, verificou-se que a etapa de pré-processamento que dividiu os sinais por passos, segmentou os dados para a entrada da rede neural, realizou a proporção entre os sensores e normalizou o sinal; foi necessária e fundamental para o correto funcionamento da RNA e seus resultados. O desenvolvimento da ferramenta de análise e interpretação do sinal foi baseado na escolha da MLP como RNA para classificar os tipos de pisada com base em dados coletados pela palmilha instrumentada, foi considerada correta, visto que a apresentação dos resultados no modelo de validação cruzada utilizando 21 neurônios na camada escondida; acertou 99,63% das classificações em todo o conjunto de dados. Adicionalmente, analisando a matriz de confusão dessa mesma configuração, pode-se destacar os valores mínimos e máximos em na classificação de cada tipo de pisada; resultando-se então: 99,7% e 100% em acurácia (neutra, supinada e pronada), 99,7% e 100% em sensibilidade (neutra e pronada), 99,8% e 100% em especificidade (supinada e pronada), e por último, 99,7% e 100% em eficiência (neutra e pronada).

Com base nesses valores e na matriz de confusão apresentados, pode-se afirmar que o conjunto de dados possui uma similaridade maior entre os tipos de pisada supinada e neutra, o que era esperado, pois eles ativam praticamente os mesmos sensores, diferenciando-se mais nas intensidades. Porém o tipo de pisada pronada, é caracterizado por acionar outros sensores e com isso facilita no tipo de identificação individual entre as pisadas.

Este trabalho conclui que é possível realizar a identificação do tipo de pisada de um indivíduo utilizando palmilhas instrumentadas com sensores piezoelétricos de cerâmica na coleta de dados e a rede neural artificial MLP para sua classificação. Em comparação com as referências selecionadas, o resultado de 99,63% é o maior na etapa de classificação, quantificando assim, com excelência a funcionalidade do protótipo.

Para trabalhos futuros, esse estudo indica que possam replicar o banco de dados das coletas de pressão plantar para outros tipos de RNA ou sistemas computacionais. Além disso, verificar a possibilidade da coleta de pressão plantar com outros sensores de custo igual ou similar, assim, pode-se ampliar a disponibilidade de equipamentos para pesquisas e aplicações. A fim de diversificar a

amostra, pode-se desenvolver mais tamanhos de palmilhas, ajustando-se para os indivíduos das futuras coletas.

REFERÊNCIAS

AHMAD, R. F.; et al. A new approach for error minimization of piezoelectric sensor output variations using fuzzy logic. 2014. IN: IEEE INTERNATIONAL CONFERENCE ON CONTROL SYSTEM, COMPUTING AND ENGINEERING, **Proceedings...** p.394-398, nov. 2014.

ARDUINO. **MEGA 2560 REV3**: TECH SPECS. 2018. Disponível em: <<https://store.arduino.cc/usa/arduino-mega-2560-rev3>>. Acesso em: 02 maio 2018.

ARKIPELOGO. **Baropodometria**: avaliação computadorizada dos pés. Disponível em: <http://arkipelago.com.br/categoria3/1/SISTEMAS_CAPACITIVOS>. Acesso em: 13 dez. 2015.

BAÚ DA ELETRÔNICA. **Cápsula piezoelétrica**: 20mm. 2018. Disponível em: <<http://www.baudaeletronica.com.br/capsula-piezoeletrica-20mm.html>>. Acesso em: 28 ago. 2018.

CAMPOS, M.F.; HEIMBECHER, C.T.; ULBRICHT, L.. Aplicações da baropodometria e estabilometria na avaliação da pressão plantar.. In: CONGRESSO BRASILEIRO DE ELETROMIOGRAFIA E CINESIOLOGIA, 5., SIMPÓSIO DE ENGENHARIA BIOMÉDICA, 10., **Anais...** Uberlândia (MG): Center Convention Uberlândia, 2018.

CATALFAMO, P.; et al. Detection of gait events using an F-Scan in-shoe pressure measurement system. **Gait & Posture**, v. 28, n. 3, p.420-426, out. 2008.

CERVO, A. L.; BERVIAN, P. A.; SILVA, R. **Metodologia científica**. 6. ed. São Paulo: Pearson Prentice Hall, 2007.

CHENG, X.; et al. Development of an e-health app for lower limb postoperative rehabilitation based on plantar pressure analysis. **Applied Sciences**, v. 8, n. 5, p.766-776, 11 maio 2018. MDPI AG. <http://dx.doi.org/10.3390/app8050766>.

CRUZ, C.; et al. Padrões de referência da pressão plantar no movimento do cão da serra da estrela. In: CONGRESSO NACIONAL DE BIOMECÂNICA, 4., **Anais...** 2011, Coimbra. p. 771 - 775.

FRANCO, P. S.; et al. Análise da variabilidade e repetibilidade da pressão plantar durante a marcha de idosos. **Revista Brasileira de Reumatologia**, v. 55, n. 5, p.427-433, 2015.

GUIMARÃES, G. V.; et al. Pés: devemos avaliá-los ao praticar atividade físico-esportiva? **Revista Brasileira de Medicina do Esporte**, v. 6, n. 2, p.57-59, 2000.

HAYKIN, S. **Redes Neurais: Princípios e Prática**. 2. ed. Bookman, 2003. 898 p.

HANSEN, S. K. E. **Design and experimental investigation of charge amplifiers for ultrasonic transducers**. 2014. 72 f. Dissertação (Mestrado) - Curso de Master's Thesis In Electrical Engineering, Department Of Physics And Technology, The Arctic University Of Norway, Norway, 2014.

HEBB, D. O. **The organization of behavior: a neuropsychological theory**. New York: John Wiley and Sons, Inc., 1949.

IKARI, T.; et al. Pulse monitoring by sol-gel composite flexible piezoelectric sensors. **IEEE International Ultrasonics Symposium**, v. 22, n. 22, p.2071-2074, set. 2014.

INTERNATIONAL CONFERENCE ON COMPUTING FOR SUSTAINABLE GLOBAL DEVELOPMENT (INDIACom), 2., 2015, New Delhi. **Voltage generation using piezoelectric sensor from Human exhalation**. New Delhi: IEEEExplore, 2015. 5 p.

IRSCHIK, H.; KROMMER, M.; VETYUKOV, Y. On the Use of Piezoelectric Sensors in Structural Mechanics: Some Novel Strategies. **Sensors**, v. 10, n. 6, p.5626-5641, 3 jun. 2010. MDPI AG. <http://dx.doi.org/10.3390/s100605626>.

KARKI, J. **Signal conditioning piezoelectric sensors: mixed signal products**. Texas Instruments, 2000. 6 p. Disponível em: <<https://www.ti.com/lit/an/sloa033a/sloa033a.pdf>>. Acesso em: 01 maio 2018.

LABANCA, W. F.; VIEIRA, M. E. M.; STEVAN JR, S. L. Development of method to analyse repeatability and stabilization of piezoelectric sensor signal. In: DYCAELS, 2018, Ponta Grossa. **Anais...** .p. 1 - 2.

LIMA, W. B. **Transdutores de deformação a base de sensores piezoelétricos**. 2013. 118 f. Dissertação (Mestrado) - Curso de Programa Francisco Eduardo Mourão Saboya de Pós-graduação em Engenharia Mecânica, Escola de Engenharia, Universidade Federal Fluminense, Niterói, 2013.

MANUPIBUL, U.; CHAROENSUK, W.; KAIMUK, P. Design and development of SMART insole system for plantar pressure measurement in imbalance human body and heavy activities. In: BIOMEDICAL ENGINEERING INTERNATIONAL CONFERENCE, 7., **Proceedings...** v. 7, n. 1, p.1-5, nov. 2014.

MCCULLOCH, W. S.; PITTS, W. H. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 5, p.115-133, 1943.

MENDES JUNIOR, J.; et al. Sensor fusion and smart sensor in sports and biomedical applications. **Sensors**, v. 16, n. 10, p.1569-1610, 23 set. 2016.

MICKEL, C.; et al. Changes in plantar pressure while running with a jogging stroller. **Journal of Functional Morphology and Kinesiology**, v. 1, n. 3, p.314-321, 10 ago. 2016.

MOREIRA FILHO, R. P. **Análise e caracterização da potência elétrica gerada com elemento piezoelétrico**. 2014. 142 f. Dissertação (Mestrado) - Curso de Programa de Pós Graduação em Engenharia Elétrica, Universidade Federal da Paraíba, João Pessoa, 2014.

MUELLER, M. J; STRUBE, M. J. Generalizability of in-shoe peak pressure measures using the F-scan system. **Clinical Biomechanics**, v. 11, n. 3, p.159-164, 1996.

MURATA SENSORS. **Piezoelectric ceramic sensors: Piezotite**. 2001. Disponível em: <<http://www.farnell.com/datasheets/43406.pdf>>. Datasheet. Acesso em: 01 maio 2018.

NASSERI, N.; et al. Detecting simulated sprained ankle plantar pressure pattern using artificial neural network. In: IEEE SYMPOSIUM ON INDUSTRIAL ELECTRONICS AND APPLICATIONS, Kuala Lumpur. **Proceedings...** . Kuala Lumpur: IEEE, 2009. p. 942 - 945.

NORRIS, C. M. **Managing sports injuries: a guide for students and clinicians**. 4. ed. Manchester: Elsevier Health Sciences, 2011. 432 p.

OSSAMI, N. L.; MIOSSO, C. J.; FLEURY, S. R. Implementation and evaluation of a system for automatic classification of feet and walking alterations using latex insoles with pressure sensors and accelerometers, based on artificial neural networks. In: PAN AMERICAN HEALTH CARE EXCHANGES, 2014, Brasilia. **Proceedings...** Brasilia: IEEE, 2014. p. 1-6.

PARK, J.-O.; et al. Wearable sensing of in-ear pressure for heart rate monitoring with a piezoelectric sensor. **Sensors**, v. 15, n. 9, p.23402-23417, 16 set. 2015.

PEDAR. **The pedar[®] system**: The quality in-shoe dynamic pressure measuring system. Disponível em: <<http://novel.de/novelcontent/pedar>>. Acesso em: 13 dez. 2015.

RAMIREZ-BAUTISTA, J. A.; et al. A review in detection and monitoring gait disorders using in-shoe plantar measurement systems. **IEEE Reviews In Biomedical Engineering**, v. 10, n. 22, p.299-309, 2017.

RAZAK, A. H. A.; et al. Foot plantar pressure measurement system: a review. **Sensors**, v. 12, n. 12, p.9884-9912, 23 jul. 2012.

RODRIGUES, J. R.; et al. Influence of application of the inelastic taping pressure of runners pronators. **Manual Therapy, Posturology & Rehabilitation Journal**, v. 12, p.224-260, 2014.

RODRIGUES, J. R.; CRAVEIRO, W. A.; LEMOS, T. V.; PASSOS, F. A. G.; MACEDO, O. G.; MATHEUS, J. P. C. Influence of application of the inelastic taping pressure of runners pronators. **Manual Therapy, Posturology & Rehabilitation Journal**, 2014, 12, p.224-260.

SANCHES, M. A. A. **Sistema microcontrolado para medição de forças na região plantar e nos membros superiores de pacientes**. 2007. 116 f. Dissertação (Mestrado) - Curso de Automação, Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista, Ilha Solteira, 2007.

SANTOS, C. P.; et al. Caracterização do sensor piezoelétrico para sua utilização em dispositivos embarcados. In: SEMINÁRIO DE ELETRÔNICA E AUTOMAÇÃO, 7., 2016, Ponta Grossa. **Anais...** Ponta Grossa: Utfpr, 2016. p. 1 - 6.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas**: curso prático. São Paulo: Artliber, 2010. 399 p.

SILVA, J. L. K. M. **Análise da correlação de métodos de avaliação da pisada relacionada à ativação neuromuscular**. 2015. 97 f. Dissertação - Pós-Graduação em Engenharia Biomédica, Universidade Tecnológica Federal do Paraná. Curitiba, 2015.

SHU L, H. T.; WANG Y, L. Q.; FENG, D.; TAO, X. In-shoe plantar pressure measurement and analysis system based on fabric pressure sensing array. **IEEE Trans. Inf. Technol. Biomed.** 2009, 14. p.767-775.

SPARKFUN. **FlexiForce pressure sensor**: 100lbs. 2018. Disponível em: <<https://www.sparkfun.com/products/8685>>. Acesso em: 28 ago. 2018.

TEKSCAN. **F-Scan System**. Disponível em: <<https://www.tekscan.com/products-solutions/systems/f-scan-system>>. Acesso em: 13 dez. 2015.

TEXASINSTRUMENTS. **TL08xx JFET-Input Operational Amplifiers**: Datasheet. 2015. Disponível em: <<http://www.ti.com/lit/ds/symlink/tl082.pdf>>. Acesso em: 02 maio 2018.

VIEIRA, M. E. M.; et al. Dispositivo para análise de pressão plantar em palmilhas utilizando piezoelétricos de baixo custo. In: CONGRESSO BRASILEIRO DE ENGENHARIA BIOMÉDICA, 25, 2016, Foz do Iguaçu. **Anais...** . Foz do Iguaçu: CBEB, 2016.

WAFAI, L.; et al. Identification of Foot Pathologies Based on Plantar Pressure Asymmetry. **Sensors**, v. 15, n. 8, p.20392-20408, ago. 2015.

WAFAI, L.; et al. Automated Classification of Plantar Pressure Asymmetry during Pathological Gait Using Artificial Neural Network. In: MIDDLE EAST CONFERENCE ON BIOMEDICAL ENGINEERING, Doha. **Proceedings...** . Doha: IEEE, 2014. p. 220 - 223.

WEBSTER, J. G. **The Measurement, Instrumentation and Sensors**: Handbook. Boca Raton: Crc Press, 1999. 2588 p.

XIMENES, M.; PERON, G. **Implementação e avaliação de uma palmilha de látex com sistema de sensores para investigação da distribuição de pressão plantar em indivíduos autistas**. 2013. 81 f. TCC (Graduação) - Curso de Engenharia Eletrônica, Universidade de Brasília, Brasília, 2013.

XIN, L.; HUANG, E.; MOK, S. **HC 06**: product data sheet. 2011. Guangzhou HC Information Technology Co., Ltd..Disponível em: <<https://www.olimex.com/Products/Components/RF/BLUETOOTH-SERIAL-HC-06/resources/hc06.pdf>>. Acesso em: 03 maio 2018

WANG, C.-S.; WANG, C.-C.; CHANG, T.-R. Neural network evaluation for shoe insoles fitness. In: INTERNATIONAL CONFERENCE ON NATURAL COMPUTATION (ICNC), 9., 2013, Taiwan. **Proceedings...** . Taiwan: IEEE, 2013. p. 157 - 162.

YAÑEZ, Y.; GARCIA-HENANDEZ, M. J.; SALAZAR, J.; TURO A.; CHAVEZ, J. A. Designing amplifiers with very low output noise for high impedance piezoelectric transducers. **NDT & E International**, 2005, 38(6): p.491-496.