

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

LUCAS MEDEIROS SOUZA DO NASCIMENTO

**DESENVOLVIMENTO DE UM DISPOSITIVO PARA CLASSIFICAÇÃO
DE PISADA UTILIZANDO SENSORES INERCIAIS**

DISSERTAÇÃO

PONTA GROSSA

2019

LUCAS MEDEIROS SOUZA DO NASCIMENTO

**DESENVOLVIMENTO DE UM DISPOSITIVO PARA CLASSIFICAÇÃO
DE PISADA UTILIZANDO SENSORES INERCIAIS**

Dissertação apresentada como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica, do Programa de Pós-Graduação em Engenharia Elétrica, Diretoria de Pesquisa e Pós-Graduação, Universidade Tecnológica Federal do Paraná.

Orientador: Prof. Dr. Sergio Luiz Stevan Jr.

PONTA GROSSA

2019

Ficha catalográfica elaborada pelo Departamento de Biblioteca
da Universidade Tecnológica Federal do Paraná, Campus Ponta Grossa
n.18/20

N244 Nascimento, Lucas Medeiros Souza do

Desenvolvimento de um dispositivo para classificação de pisada utilizando
sensores inerciais. / Lucas Medeiros Souza do Nascimento, 2019.

88 f. : il. ; 30 cm.

Orientador: Prof. Dr. Sergio Luiz Stevan Jr.

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

1. Pegadas. 2. Sistemas de navegação inercial. 3. Detectores. 4. Redes
neurais (Computação). 5. Sistemas de comunicação sem fio. I. Stevan Jr.,
Sergio Luiz. II. Universidade Tecnológica Federal do Paraná. III. Título.

CDD 621.3



Ministério da Educação
Universidade Tecnológica Federal do Paraná
Diretoria de Pesquisa e Pós-Graduação
Programa de Pós-Graduação em Engenharia Elétrica



FOLHA DE APROVAÇÃO

Título de Dissertação Nº 48/2019

DESENVOLVIMENTO DE UM DISPOSITIVO PARA CLASSIFICAÇÃO DE PISADA UTILIZANDO SENSORES INERCIAIS

por

LUCAS MEDEIROS SOUZA DO NASCIMENTO

Esta dissertação foi apresentada às 16h do dia **19 de dezembro de 2019**, 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: 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. Christiane Gonçalves (UTFPR)

**Prof. Dr. Sergio Luiz Stevan Junior
(UTFPR) – Orientador**

**Prof. Dr. Ângelo Marcelo Tuset (UTFPR)
Coordenador do PPGEE**

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

À Deus em primeiro lugar, pois sem Ele
nada seria possível
Aos meus pais pela paciência e suporte
Aos meus avôs que sempre me
inspiraram
À minha namorada pelo companheirismo
Aos meus amigos por sempre
caminharem comigo
*Lucas M. Souza do
Nascimento*

AGRADECIMENTOS

Agradeço a Deus por ter me abençoado, acompanhado, me guardado ao longo dos anos, ter me dado força, sabedoria para enfrentar as dificuldades encontradas o qual sem a sua graça nunca seriam vencidas, paciência e pelo seu imprescindível amor.

Dedico meus esforços em memória do meu avô Benedito Medeiros, fonte de inspiração, exemplo de vida, criatividade, amor e responsável por despertar a paixão pela área, certamente estaria orgulhoso. Também em memória da minha avó Benedita Souza, mulher de grande sabedoria e fé.

Aos meus avôs que me inspiraram eu agradeço, o qual por meio de suas histórias me motivaram a correr atrás do meu sonho, batalhar por ele, sempre com justiça, honestidade e cuidando dos meus, sempre carregando vocês comigo. Agradeço a minha família, por todo seu suporte e pela dedicação em que me acompanharam durante os desafios, crises encontradas, das horas de conversas e momentos alegres nessa jornada. Agradeço também por suas orações e pelo carinho.

A minha namorada e amigos por andarem comigo lado a lado durante a minha graduação e também no mestrado, pelos momentos de diversão, pelos momentos de dificuldade, mas também pela amizade que com certeza permanecerá.

Agradeço meu orientador Dr. Sergio Luiz Stevan Jr. por guiar em todas as etapas, servindo de referência, sendo dedicado, profissional, impecável em suas ações e amigo. Aquele que seguiu acreditando no nosso potencial máximo.

“The world is ahead”
Gandalf

RESUMO

NASCIMENTO, Lucas Medeiros Souza do. **Desenvolvimento de um dispositivo para classificação de pisada utilizando sensores inerciais**. 2019. 88 f. Dissertação (Mestrado em Engenharia Elétrica)- Universidade Tecnológica Federal do Paraná, Ponta Grossa, 2019.

Este trabalho tem como objetivo desenvolver um dispositivo vestível, baseado em sensores inerciais e rede neural artificial (RNA) para a identificação do tipo de pisada durante a marcha, para auxílio de diagnóstico e acompanhamento a serem realizados por profissionais da área de saúde. O dispositivo contém uma central responsável pelo agrupamento e transmissão dos sinais. Os dois módulos inerciais ficam dispostos um na face posterior do osso calcâneo e outro no músculo gastrocnêmio. A recepção e armazenamento dos dados é realizado em um computador por meio do protocolo Wi-Fi™. Foram coletados dados inerciais decorrentes da marcha de 9 pessoas com média de idade de 24,8. Os dados foram utilizados para extração de características e dispostos como entradas em uma RNA do tipo *Perceptron* de múltiplas camadas (*Multilayer Perceptron*- MLP) para realização da classificação dos tipos de pisada. Todos os indivíduos se submeteram a realização do protocolo de coleta que consiste em realizar caminhadas de 5 metros de distância. Foram ainda submetidos à coleta de dados e avaliados por um profissional que classificou o tipo de pisada. Os dados foram filtrados, segmentados, normalizados e foram extraídas as características em amostras definindo a base de dados. Para a definição da configuração da RNA e a quantidade de neurônios a ser utilizada, foi empregado o método de validação cruzada *K-fold*. A MLP com melhor desempenho destacou-se a característica máximo, mínimo e DASDV para o pé direito e máximo, mínimo e WL para o pé esquerdo, todos apresentaram uma acurácia de 99,22% na etapa de teste para ambos os pés.

Palavras-chave: Marcha. Sensores inerciais. Comunicação sem fio. Rede neural artificial. Vestível.

ABSTRACT

NASCIMENTO, Lucas Medeiros Souza do. **Development a device for foot type classification using inertial sensors**. 2019. 88 p. Thesis (Master's Degree in Electrical Engineer) - Federal University of Technology - Paraná, Ponta Grossa, 2019.

This work aims to develop a wearable device, based on inertial sensors and artificial neural network (ANN) for the identification of the type of step during gait, to aid diagnosis and monitoring to be performed by health professionals. The device contains a central responsible for the grouping and transmission of the signals. The two inertial modules are arranged one on the posterior surface of the calcaneus bone and the other on the gastrocnemius muscle. The reception and storage of data is performed on a computer using the Wi-Fi™ protocol. Inertial data from the gait of 9 people with an average age of 24.8 were collected. The data were used to extract characteristics and arranged as inputs in a Multilayer Perceptron (MLP) to perform the classification of types of step. All individuals collected data under a protocol, which consists of walking 5 meters away. They were also submitted to data collection and evaluated by a professional who classified the type of step. The data were filtered, segmented, normalized and the characteristics were extracted in samples defining the database. To define the RNA configuration and the number of neurons to be used, the K-fold cross-validation method was used. The MLP with the best performance stood out the maximum, minimum and DASDV characteristic for the right foot and maximum, minimum and WL for the left foot, all of which showed an accuracy of 99.22% in the test level for both feet.

Keywords: Gait. Inertial sensors. Wireless communication. Artificial neural network. Wearable.

LISTA DE FIGURAS

Figura 1- Baropodômetros	18
Figura 2- Sistema in-shoe	18
Figura 3- Posição dos sensores	23
Figura 4- Estrutura segmentada do pé	26
Figura 5- Ciclo de marcha	27
Figura 6- Classificação do tipo de pisada	28
Figura 7- Sistemas inerciais comerciais	31
Figura 8- Graus de liberdade em um sistema tri-axial	32
Figura 9- Diagrama de bloco do MPU-6050	36
Figura 10- Módulo inercial- 6050	37
Figura 11- Esquemático de pinos do ESP01	44
Figura 12- IDE Arduino	45
Figura 13- IDE ESPlorer	46
Figura 14- Circuito de carregamento no ESP-01	47
Figura 15- Segmentação por threshold	48
Figura 16- Representação do neurônio genérico	52
Figura 17- Representação da rede neural MLP	54
Figura 18- Exemplificação do k-fold para um k=5 e 10 amostras	56
Figura 19- Fases da metodologia	57
Figura 20- Execução de uma análise de plantigrama	58
Figura 21- Pegada resultante do plantigrama	59
Figura 22- Protocolo de coleta	59
Figura 23- Estrutura básica do boxplot	62
Figura 24- Exemplo de matriz de confusão	62
Figura 25- Fluxo de informação do sistema	63
Figura 26- Esquemático do módulo de aquisição	64
Figura 27- Fluxograma de funcionamento do <i>firmware</i>	65
Figura 28- Ligação entre os módulos e o microcontrolador	66
Figura 29- Posicionamento do sistema no usuário	67
Figura 30- Etapas de pré-processamento	68
Figura 31- Gráficos com os dados de uma coleta do pé esquerdo do acelerômetro 1	68
Figura 32- Segmentação dos dados	69
Figura 33- Erro quadrático médio de treinamento DASDV	72
Figura 34- Boxplot de taxa de acerto do treinamento pé direito	73
Figura 35- Boxplot de taxa de acerto do treinamento pé esquerdo	74
Figura 36- Matriz de confusão para o pé direito	75
Figura 37- Matriz de confusão para o pé esquerdo	75
Figura 38- Eixo X do giroscópio para módulo 1 no pé direito	77
Figura 39- Eixo X do giróscopio para módulo 2 no pé esquerdo	77

LISTA DE QUADROS

Quadro 1- Critérios para classificação de pé com pisada pronada	28
Quadro 2- Critérios para classificação de pé com pisada neutra	28
Quadro 3- Critérios para classificação de pé com pisada supinada.....	29

LISTA DE TABELAS

Tabela 1- Aplicações utilizando sensores na análise de movimento e pisada em situações médicas.....	20
Tabela 2- Trabalhos para comparação de desempenho.....	25
Tabela 3- Comparação entre as tecnologias de sensores inerciais.....	34
Tabela 4- Registradores de <i>Self Test</i>	38
Tabela 5- Modos de seleção de configuração.....	38
Tabela 6- Registrador de endereço.....	39
Tabela 7- Registradores armazenadores de informação de aceleração e velocidade angular.....	39
Tabela 8- Registrador <i>Sleep Mode</i>	40
Tabela 9- Fonte de <i>Clock</i>	40
Tabela 10- Registrador 108.....	40
Tabela 11- Seleção de frequência.....	41
Tabela 12- Comparativo entre microcontroladores de algumas plataformas de prototipagem rápida.....	43
Tabela 13- Melhores resultados do treinamento para análise do pé direito.....	71
Tabela 14- Melhores resultados do treinamento para análise do pé esquerdo.....	71
Tabela 15- Acurácia da etapa de validação para as diferentes características, para os dois pés.....	76
Tabela 16- Comparação de desempenho.....	78

LISTA DE SIGLAS E ACRÔNIMOS

ADC	<i>Analog Digital Converter</i>
AVE	Acidente Vascular Encefálico
BLE	<i>Bluetooth Low Energy</i>
DASDV	<i>Difference Absolute Standard Deviation Value</i>
DMP	<i>Digital Motion Processor</i>
DPS	<i>Degrees per Second</i>
FSR	<i>Full Scale Range</i>
IoT	<i>Internet of Things</i>
LSB	<i>Least Significant Bit</i>
MAV	<i>Mean Absolute Value</i>
MEMS	<i>Micro-Electro Mechanical System</i>
MLP	<i>Multilayer Perceptron</i>
PC	<i>Personal Computer</i>
RMS	<i>Root Mean Square</i>
RNA	Rede Neural Artificial
RTOS	<i>Real Time Operational System</i>
SSF	<i>Sensitivity Scale Factor</i>
SSI	<i>Simple Square Integral</i>
ST	<i>Self-Test</i>
USB	<i>Universal Serial Bus</i>
WL	<i>Waveform Length</i>
ZVU	<i>Zero Velocity Update</i>

LISTA DE SIMBOLOS

a	Aceleração
A	Amplitude do sinal
\mathbf{d}	Vetor de saída desejada
MSE	Erro quadrático médio da RNA
g	Função de ativação
g'	Derivada da função de ativação
I	Potencial de ativação da RNA
k	Constante da mola
j	Quantidade de neurônio na camada
m	Massa
n	Camada
N	Número de amostras
u	Potencial de ativação do neurônio
\mathbf{x}	Vetor do conjunto amostras RNA
x	Deslocamento do eixo x
$\boldsymbol{\omega}$	Vetor de peso do neurônio
\mathbf{w}	Vetor de peso da RNA
θ	Limiar de ativação da RNA
β	
δ	Gradiente do erro local
η	Taxa de aprendizagem
ε	Precisão
\mathbf{y}	Vetor de saída da RNA
σ	Desvio padrão

SUMÁRIO

1 INTRODUÇÃO	14
1.1 OBJETIVOS.....	15
1.2 ESTADO DA ARTE.....	16
2 REFERENCIAL BIBLIOGRÁFICO.....	26
2.1 TIPOS DE PISADA	27
2.2 MÓDULOS INERCIAIS COMERCIAIS	30
2.3 SENSORES INERCIAIS	31
2.3.1 - MPU6050.....	36
2.4 MICROCONTROLADOR	41
2.4.1 ESP01.....	44
2.5 PROCESSAMENTO DE DADOS	47
2.5.1 Rede Neural Artificial	51
2.5.2 Rede <i>Perceptron</i> de Múltiplas Camadas	53
2.5.3 Metodologia	56
3 DESENVOLVIMENTO.....	63
3.1 MÓDULO DE AQUISIÇÃO DE DADOS.....	65
3.2 PROCEDIMENTO DE AQUISIÇÃO DE DADOS	66
3.3 PRÉ-PROCESSAMENTO DOS DADOS	68
3.4 IMPLEMENTAÇÃO DA REDE NEURAL.....	70
4 RESULTADOS	71
5 CONCLUSÃO.....	80
REFERÊNCIAS.....	82

1 INTRODUÇÃO

A reabilitação física é o processo que busca a retomada das capacidades perdidas e/ou prejudicadas de maneira integral dos movimentos responsáveis pela locomoção (THAKUR *et al.*, 2018). Por este motivo é necessário o emprego de ferramentas para observação dessas características de movimento, sendo que, em muitos casos, a avaliação dos parâmetros apresentados pela marcha podem fornecer evidências de problemas que afetam diretamente a mobilidade (PAPI; BO; MCGREGOR, 2018).

A marcha é uma atividade diária que pode fornecer diversos parâmetros que estão fortemente associados ao bem-estar do indivíduo, como a simetria da marcha (MAJUMDER; MONDAL; DEEN, 2019) e a identificação do tipo de pisada (normal ou anormal). Entre os principais componentes da marcha estão os pés, que possuem as funções de absorção de impacto, estabilidade e propulsão (DE COCK *et al.*, 2006) o joelho e quadril são importantes devido aos momentos de força (KIRKWOOD *et al.*, 2007) e os braços fornecem estabilidade/equilíbrio. Em especial a estrutura anatômica do pé é uma das que mais sofre alterações que podem implicar em lesões das juntas dos membros inferiores (GUIMARÃES *et al.*, 2000).

Na reabilitação, a marcha pode refletir algumas inconformidades na estrutura ortopédica dos membros inferiores que podem ser agravados futuramente levando a uma lesão. A análise da marcha pode permitir acompanhar a evolução, a estratégia de tratamento e os parâmetros, como o tamanho da passada, velocidade, tempo de balanço e outros. Esses parâmetros podem ser observados principalmente durante a fase de apoio (DE COCK *et al.*, 2006).

O tipo de pisada (avaliação do apoio ortopédico) pode ser realizado pela técnica de plantigrafia, ou baropodometria. Para analisar detalhes da pressão plantar são utilizados dispositivos eletrônicos conhecidos como plataformas baropodométricas e palmilhas instrumentadas, os quais são em sua maioria baseados em sensores resistivos, piezoressistivos, células de carga, entre outros. Por meio da análise da pressão plantar pode-se obter a classificação dos tipos de pisada de forma automática.

Os dados obtidos de forma estática utilizam plataformas e são mais comuns nos ambientes clínico-hospitalares, em situações dinâmicas se utilizam as palmilhas

instrumentadas, elas permitem a coleta de dados e análise durante a realização das atividades físicas.

Como principais limitações destes sistemas, pode se citar a dificuldade de análises contínuas, interferência do ambiente hospitalar e a necessidade de dispositivos personalizados (em tamanho) para as palmilhas instrumentadas. Outra preocupação é esterilização que evita a contaminação dos objetos e materiais por seres vivos como vírus, bactérias e fungos o que pode expor os pacientes a riscos de alta gravidade.

Paralelamente ao processo de reabilitação, com o advento da Internet das coisas (*Internet of Things*- IoT), qualquer processo de monitoramento contínuo ganha interesse principalmente nos ambientes de cuidado com a saúde (dispositivos *e-health*) e esportivos, onde pode-se além de coletar dados de forma contínua, realizar o monitoramento e análise à distância em especial, sistemas de monitoramento de movimento utilizando sensores inerciais e dispositivos IoT são aplicados em diversas situações tornando uma ferramenta promissora na aquisição e monitoramento dessas atividades. Pode-se explicar que a análise remota do monitoramento desses parâmetros possibilita a avaliação e acompanhamento de deficiências motoras, relacionados a balanço em idosos, acidente vascular encefálico (AVE), esclerose múltipla, Parkinson e outros (CHANG *et al.*, 2016) (WANG *et al.*, 2018).

Esta dissertação busca responder a seguinte proposição: é possível desenvolver um sistema de aquisição eletrônico, baseado exclusivamente em sensores inerciais realizando a coleta de dados de forma dinâmica utilizando uma plataforma IoT, ou seja, proporcionando a análise de dados à distância? E com isso obter-se uma correlação para classificação do tipo de pisada sem o uso de sensores de carga, e sem a necessidade de particularização (tamanho, como no caso das palmilhas instrumentadas).

1.1 OBJETIVOS

Objetivo geral deste trabalho é desenvolver um dispositivo de um disposto para identificação do tipo de pisada, baseado em sensores inerciais e redes neurais artificiais.

Para alcançar o objetivo supracitado, foram listados os seguintes objetivos específicos:

- Realizar uma revisão bibliográfica sobre análise de marcha, tipos de pisada, sensores e sistemas de sensoriamento e técnicas de processamento de dados;
- Desenvolver módulos de aquisição baseados em microcontroladores, sensores inerciais e interface de comunicação sem fio;
- Elaborar uma metodologia experimental para aquisição de dados decorrentes da marcha;
- Implementar sistema para computador que realize o processamento e identificação de tipos de pisada utilizando uma Rede Neural Artificial;
- Analisar e discutir os resultados obtidos.

1.2 ESTADO DA ARTE

A análise de informação provinda do corpo humano, seja por movimento, sinais biológicos e/ou biométricos nem sempre são possíveis pelas suas simples análises, sendo a extração de características inerentes dos dados e posteriormente a realização de análises por meio de ferramentas computacionais, como, o uso de redes neurais.

Desta forma, a extração de características e análise de padrões dos sinais decorrentes da movimentação dos músculos dos membros inferiores, facilitam o entendimento do comportamento da marcha humana, o que proporciona a possibilidade de identificar e classificar peculiaridades. Este tipo de análise permite uma orientação técnica mais adequada o qual reflete diretamente no desenvolvimento da reabilitação ortopédica (QIU *et al.*, 2018).

Para a análise de marcha, normalmente são utilizados sensores de pressão/força para realização da medição de pressão plantar. São dispostos diretamente no solo ou integrados a calçados para obtenção de características de marcha. Os sensores são dependentes da pressão externa e não conseguem fornecer informações relevantes durante a fase de balanço (fase em que não há contato do pé com a superfície).


Os sistemas de análise de pisada geralmente são divididos em sistemas de plataforma e *in-shoe*. Estes usualmente se utilizam de sensores de pressão e de imagens para obtenção das informações.

No mercado atual há vários modelos e fabricantes de baropodômetros (Figura 1) construídos no formato de plataformas ou pistas de marcha tanto utilizados para análises estáticas como dinâmicas. O modelo plataforma é usualmente utilizado em locais fixos, sendo comum em avaliações estáticas, embora alguns permitam a sua utilização para análise dinâmica, em que o paciente realiza o andar passando por cima da plataforma, mas não permite avaliar a resposta da pressão plantar do ciclo completo, sendo necessário obter a informação de um pé por vez devido a centralização da pisada e a plataforma. A tecnologia da pista de marcha permite uma maior facilidade nas análises dinâmicas, pois ao realizar o andar o sistema consegue observar a distribuição da pressão plantar bem como a posição dos pés durante a ação. Estes tipos de equipamentos são usualmente empregados em consultórios e laboratórios.

O EPS da fabricante Kinetec (Figura 1-A) é um baropodômetro que pode ser encontra na versão com sensores resistivos ou sensores capacitivos. O modelo com sensores resistivos possui 2304 sensores dispostos em uma área de 480x480 mm. O modelo com sensores capacitivos possui 4096 sensores dispostos em área de 500x500cm. Os sistemas possuem frequência de aquisição de até 100 Hz e realizam a transmissão de dados para um computador por meio de cabo USB (KINECT TECNOLOGIAS BIOMECÂNICAS, 2019).

O WIN-TRACK da fabricante Medicapteurs (Figura 1- B) apresenta 12.288 sensores resistivos distribuídos em uma área de 150x150 cm. A faixa de operação de cada um é de 0,4 N a 100 N, frequência de aquisição de até 200 Hz e ele realiza a transmissão dos dados para um computador por meio de cabo USB(MEDICAPTEURS, 2019).

Figura 1- Baropodômetros




Fonte: (KINECT TECNOLOGIAS BIOMECÂNICAS, 2019; MEDICAPTEURS, 2019)

Os sistemas *in-shoe* são sistemas de aquisição em formato de palmilha os quais são instalados dentro dos calçados, permitindo análises em ambientes externos e em atividades dinâmicas cotidianas. Este tipo de tecnologia permite uma maior mobilidade e o seu funcionamento baseia-se na medição da pressão plantar entre o pé e a sola do tênis.

O sistema Pedar© (Figura 2- A) possui até 1024 sensores capacitivos, alimentação por bateria de NiMH, comunicação de dados via USB ou *Bluetooth*® e memória *flash* interna de 32 MB para armazenamento de informações (PEDAR SYSTEM, 2019). O sistema F-scan© (Figura 2- B) utiliza 25 sensores resistivos por polegada quadrada, possui frequência de aquisição até 600 Hz, alimentação por bateria e comunicação de dados via USB e Wi-Fi™ (TECKSCAN, 2019).

Figura 2- Sistema in-shoe



Fonte: (PEDAR SYSTEM, 2019; TECKSCAN, 2019)

De modo remoto ao indivíduo que se pretende avaliar, sistemas de aquisição por imagem são capazes de fornecer diversas variáveis referentes a marcha, mas são extremamente caros e necessitam de estrutura com diversas câmeras e computadores capazes de processar todas as informações em conjunto (MAJUMDER; MONDAL; DEEN, 2019).

Uma alternativa aos sistemas de análise de movimento supracitados, é a utilização de sensores inerciais os quais possuem custo comparativamente menor, tamanho reduzido e baixo consumo de energia (BERAVS *et al.*, 2011). Sistemas para análise de marcha baseados nestes sensores podem trazer benefícios para mensurar e estabelecer métricas sobre a saúde do indivíduo (MARTINEZ-MENDEZ; SEKINE; TAMURA, 2011).

Foram selecionados 25 trabalhos que abordam a utilização de sensores e dispositivos, em ambiente de reabilitação ou de avaliação hospitalar que são apresentados na Tabela 1. São apresentados na Tabela 1 a doença ou problema analisado, tipo de sensor, localização de posicionamento do sensor, número de sensores, frequência de amostragem e filtro. Dentre os trabalhos que 72% empregaram sensores inerciais em aplicações voltadas ao estudo de movimento do corpo humano para diferentes objetivos, 20% empregam sensores resistivos de força para obtenção da pressão plantar durante a marcha e 8% empregam câmeras para análise de movimento.

Dos trabalhos selecionados 64% abordam a utilização de sensores ou dispositivos para classificação e análise do comportamento da marcha ou do tipo de pisada em pacientes acometidos de doenças como paralisia cerebral, acidente vascular encefálico, síndrome de Parkinson e outros.

As aplicações utilizam frequências compatíveis com os movimentos analisados respeitando o Teorema de Nyquist, segundo Yang e Kong (2009), a frequência de marcha é de 1,69 Hz, sendo assim é possível realizar a reconstrução do sinal. Para as diversas aplicações é mais recorrente a utilização de 100 Hz como frequência de amostragem empregados em 40% dos trabalhos, isso reforça a falta de um consenso principalmente para aplicações que envolvem análise de marcha.

Tabela 1- Aplicações utilizando sensores na análise de movimento e pisada em situações médicas.

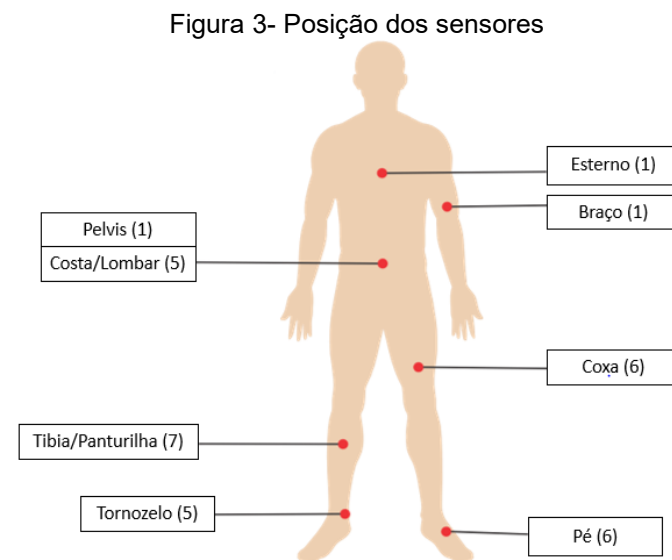
Autor	Doença/ Problema	Sensor/ Dispositivo	Localização do sensor	Número de sensores	Frequência de amostragem	Filtro
(AMENE <i>et al.</i> , 2019)	Paralisia cerebral	Câmera infravermelho	Pé	12	-	-
(BELLUSCIO <i>et al.</i> , 2019)	Síndrome de Down e Prader-Willi	Inercial	Esterno; Tíbia distal; Pélvis	4	128 Hz	Passa-baixa Butterworth de 4ª ordem frequência de corte de 20Hz
(BROWNE; FRANZ, 2019)	Idoso	Inercial	Tornozelo	-	100 Hz	Passa-faixa Butterworth de 4ª ordem frequência de corte 6Hz- 100 Hz
(FENNEMA <i>et al.</i> , 2019)	Ângulo do joelho	Inercial	Coxa; Panturrilha	2	100 Hz	-
(GERBER <i>et al.</i> , 2019)	Paralisia cerebral	Inercial	Tíbia	5	100 Hz	-
(MAHONEY; RHUDY, 2019)	Análise de marcha	Inercial	Tornozelo	1	200 Hz	Passa-baixa Butterworth de 4ª ordem frequência de corte de 4Hz
(MUNDT <i>et al.</i> , 2019)	Tarefas diárias	Inercial	Braço; Costas; Tíbia; Coxa; Pé	13	100 Hz	Filtro de Kalman
(POTLURI <i>et al.</i> , 2019)	Análise de marcha	Inercial/Sensor resistivo de força	Panturrilha; Pé	4 / 64	-	Filtro de Kalman
(PITT; CHOU, 2019)	Controle de balanço da marcha	Inercial	Lombar (L5)	1	128 Hz	Passa-baixa Butterworth de 2ª ordem frequência de corte de 12 Hz

(SÁEZ DE ASTEASU <i>et al.</i> , 2019)	Quantificação de trajetória em idosos hospitalizados	Inercial	Lombar (L3)	1	100 Hz	-
(LEE <i>et al.</i> , 2018)	Análise de marcha / Síndrome de Parkinson	Inercial	Pé	2	100 Hz	Passa-baixa Butterworth de 2ª ordem frequência de corte de 10 Hz
(NGAMSURIYAROJ <i>et al.</i> , 2018)	Análise da marcha e ângulo	Inercial	Coxa; Tíbia	4	10 Hz	-
(PRATEEK <i>et al.</i> , 2018)	Modelagem, detecção e rastreamento do congelamento da marcha	Inercial	Tornozelo	2	1000 Hz	Filtro <i>point-process</i>
(QIU <i>et al.</i> , 2018)	Análise de marcha / AVE	Inercial	Tornozelo	2	100 Hz	-
(ALLSEITS <i>et al.</i> , 2017)	Análise de marcha	Inercial	Tíbia; Coxa	5	50 Hz	-
(JEONG; TRUONG; CHOI, 2017)	Classificação de atividades ambulatoriais	Sensor resistivo de força	Pé	8	50 Hz	
(WATANABE <i>et al.</i> , 2017)	Algoritmo para estimativa de pressão plantar	Inercial	Pélvis; Coxa; Tíbia; Pé	7	100 Hz	Filtro passa-baixa de 4ª ordem frequência de corte de 20 Hz
(DESCHAMPS <i>et al.</i> , 2016)	Diabetes	Plataforma Footscan®	Pé	4096	200 Hz	-

(RAMPP <i>et al.</i> , 2015)	Parâmetros de marcha / Geriatría	Inercial	Pé	2	102,4 Hz	Filtro passa-baixa frequência de corte de 140 Hz
(DESCHAMPS <i>et al.</i> , 2013)	Diabetes	Plataforma de pressão plantar/ Câmeras ao redor	Pé	4096	200 Hz / 100 Hz	-
(BERAVS <i>et al.</i> , 2011)	Exoesqueleto dos membros inferiores	Inercial	Lombar; Coxa; Tíbia; Pé	8	160 Hz	Filtro de Kalman
(MARTINEZ-MENDEZ; SEKINE; TAMURA, 2011)	Detecção de antecipação postural	Inercial	Lombar Tornozelo	2	100 Hz	Passa-baixa Butterworth frequência de corte de 3 Hz
(CROSBIE; BURNS; OUVRIER, 2008)	Charcot-Marie-Toot	Sistema Pedar©	Pé	2	50 Hz	-
(HYO-SEON JEON <i>et al.</i> , 2008)	Parkinson/Análise de marcha	Sistema Pedar©	Pé	2	-	-

Fonte: Autoria própria

A Figura 3 apresenta com base na Tabela 1 os locais de instalação dos sensores nos indivíduos, e em 56% das propostas que utilizam sensores inerciais nos membros inferiores, sendo 36% na região do tornozelo e pé e 24% utilizam sensores de força para análise de marcha por meio da pressão plantar.



Fonte: Autoria própria

Em Rampp *et al.* (2015), foram utilizados sensores em pacientes geriátricos para monitoramento da marcha com ou sem o uso do andador, permitindo atingir benefícios clínicos na distinção do emprego do equipamento. Validou-se o método com sensores inerciais utilizando um padrão ouro e percebeu-se que o sistema inercial é capaz de obter as variáveis de marcha de forma eficaz para ambas as situações.

Em Ngamsuriyaroj *et al.* (2018) sensores inerciais e sensores resistivos de força (FRS) foram empregados para análise de marcha, ângulo do joelho e pressão plantar. A pressão plantar foi obtida realizando a instrumentação de palmilhas com 6 FRS que foram distribuídos cobrindo a área de pressão plantar conforme as fases do movimento. Os ângulos do joelho são provenientes de 4 sensores inerciais dispostos nas regiões do fêmur e da tibia, em que a combinação fornece a angulação do joelho. O software realiza a obtenção, análise e apresentação das características de marcha normal e anormal, sendo possível perceber uma diferença significativa no ângulo mínimo.

Em Qiu *et al.* (2018) um sensor inercial foi utilizado no tornozelo de pacientes que sofreram AVE para auxiliar no diagnóstico e reabilitação em ambiente hospitalar. Ele empregou o algoritmo de fusão multi-sensor para obtenção dos parâmetros de marcha e comunicação sem fio. São obtidos os parâmetros de marcha passo a passo por meio do algoritmo ZVU (*Zero Velocity Update*). A verificação da diferença da marcha normal e abnormal (marcha hemiplégica) é realizada por meio da comparação entre as informações obtidas e gráficos de elevação do pé, evidenciando a assimetria.

Em Prateek *et al* (2018), foram utilizados sensores inerciais na região do osso calcâneo de pacientes com Parkinson. Foram desenvolvidos três módulos que consistem em detectar, rastrear e filtrar as informações de marcha. A partir das informações, este foi comparado com sistemas comerciais para detecção do congelamento de marcha.

Alguns dos trabalhos presentes na Tabela 1 foram selecionados com o objetivo de comparação por utilizarem algoritmos de classificação para movimentos humanos relacionados a marcha para avaliar a qualidade do movimento, auxílio de diagnóstico e acompanhamento. A Tabela 2 traz informações sobre os classificadores empregados, o desempenho obtido e objetivo do estudo. Estes trabalhos possuem diferentes etapas e desafios, mas ainda assim semelhantes aos encontrados neste estudo.

As principais diferenças estão no modo de coleta com a aplicação de sensores de pressão plantar e/ou sensores inerciais para a composição da base dados e possuem diferentes tipos de arquiteturas de classificação de dados de movimento.

Em Jeong, Truong e Choi (2017), empregaram palmilhas instrumentadas de baixo custo e o algoritmo de classificação supervisionada (SVM) e não supervisionadas (KNN) para a classificação de movimentos em ambiente ambulatorial para acompanhamento e avaliação.

Em Potluri *et al* (2019), foram empregados sensores inerciais e palmilhas de pressão plantar para realizar a segmentação das fases de marcha utilizando algoritmos de classificação supervisionada (SVM) e não supervisionadas (K-means).

Em Deschamps *et al* (2016) avaliou a eficácia da pressão plantar na classificação de problemas nos pés de diabéticos os quais empregaram o algoritmo *Belgian Diabetes Foot Plantar Pressure Classification System* o qual utiliza o método de clusterização e realiza um mapeamento semi-autômático para identificar as regiões

de interesse. A empregabilidade deste tipo de sistema pode servi para comunicar, auxiliar no diagnóstico e tomada de decisão da equipe médica.

Em Hyo Seon Jeon *et al* (2008) emprega palmilhas instrumentadas para classificar marcha de Parkinson e normal utilizando algoritmo de classificação SVM utilizando função de base radial (RBF) em que se destacou por classificar os indivíduos saudáveis.

Tabela 2- Trabalhos para comparação de desempenho

Referência	Objetivo	Método	Acurácia
(POTLURI <i>et al.</i> , 2019)	Segmentação da marcha humana	SVM, K-means	94,07%; 84,34%
(JEONG; TRUONG; CHOI, 2017)	Classificação de movimento	SVM; KNN	95,20%; 93,3%
(DESCHAMPS <i>et al.</i> , 2016)	Classificação de pacientes com diabetes usando pressão plantar	BDFP	98,10%
(HYO-SEON JEON <i>et al.</i> , 2008)	Classificação do tipo de marcha em pacientes com Parkinson	SVM	91,73%


Fonte: Autoria propria

2 REFERENCIAL BIBLIOGRÁFICO

A evolução da eletrônica e dos sistemas de comunicação têm permitido o desenvolvimento de dispositivos que auxiliam na análise dos sinais bioelétricos e/ou movimentos, permitindo um monitoramento contínuo para a análise de padrões (SYED *et al.*, 2019). Essa evolução permite o desenvolvimento de dispositivos que podem ser empregados em programas de reabilitação ou auxílio de diagnóstico.

Usualmente a avaliação do programa de reabilitação é orientada por um especialista (fisioterapeuta, ortopedista e entre outros), embora seja esperado que o paciente realize atividades do tratamento de maneira independente, a adesão dos pacientes relatada é baixa, dificultando assim a conclusão sobre a eficácia do tratamento. Há necessidade não só do monitoramento remoto, mas também da obtenção de informações sobre a eficácia do tratamento de reabilitação, no qual os sensores inerciais permitem uma abordagem no monitoramento destas atividades de reabilitação (BAVAN *et al.*, 2019).

Para a avaliação do programa de reabilitação ligados aos membros inferiores os pés possuem grande relevância na movimentação humana, por meio do contato com o solo. O pé é uma estrutura multissegmentada, composta por 26 ossos e músculos, extremamente complexa e que garante a função estática e dinâmica, sendo suas principais funções a estabilidade, propulsão e absorção de impacto (DE COCK *et al.*, 2006) (MAUCH *et al.*, 2009). É usualmente dividido em três segmentos (Figura 4): retropé, mediopé e o antepé.



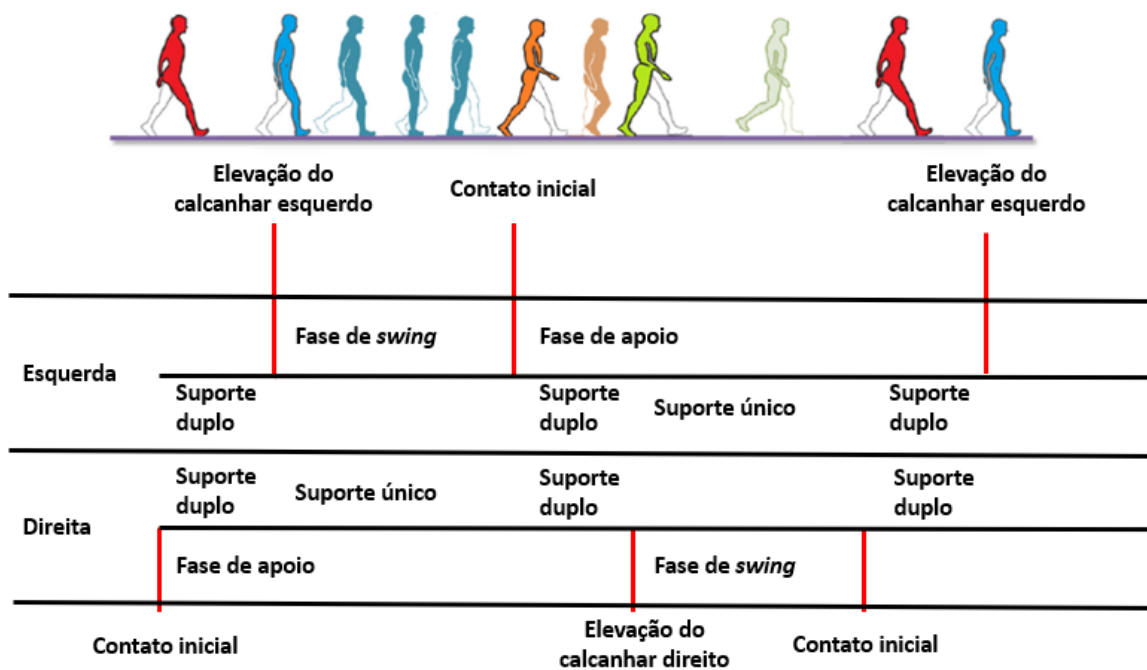
Fonte: Adaptado (MAFFI, 2019)

No sistema esquelético do pé humano o retropé é constituído pelo tálus e o calcâneo, no mediopé estão os ossos do tarso e no antepé os metatarsos e falanges (REMÍGIO, 2016).

2.1 TIPOS DE PISADA

Um ciclo de marcha (Figura 5) é dividido pela fase de apoio que é responsável por 60% do ciclo distribuído em sete fases (contato inicial, resposta à carga, apoio médio, elevação do calcânhar, pré-balanço, início do balanço e término do balanço) e pela fase de balanço (NGAMSURIYAROJ *et al.*, 2018). A fase de apoio se inicia com o contato do calcânhar com o solo até o segmento de pré-balanço e a fase de balanço se inicia quando o pé está sem contato com o solo e inicia o movimento até o início da fase de apoio. A pressão plantar abrange a análise estática e a dinâmica, embora a análise dinâmica seja somente durante a fase de apoio. Os tipos de pisada variam da posição estática para a dinâmica, pois durante o desenvolvimento o comportamento seja agravado o que pode não estar claro em uma avaliação estática.

Figura 5- Ciclo de marcha



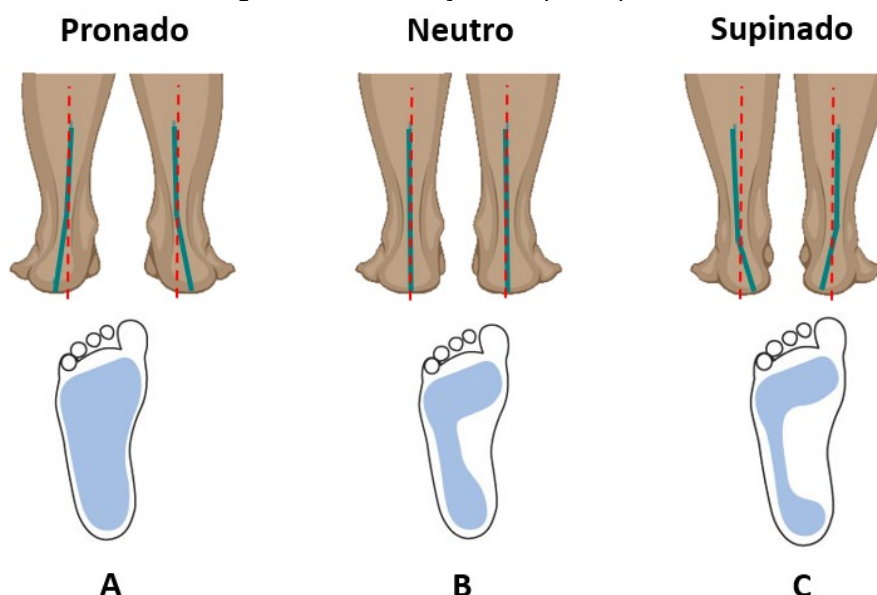
Fonte: Adaptado (CHEN *et al.*, 2016)

Segundo Dahle *et al.* (1991) um pé é classificado como pronado (Figura 6- A) quando atender obrigatoriamente os três critérios (1,2 e 3), e outros dois (4 e 5) eletivos, indicados no quadro 1.

Quadro 1- Critérios para classificação de pé com pisada pronada

1. O calcanhar não deve apresentar uma diferença de 3° da posição perpendicular do solo no sentido lateral para o medial;
2. Deve ter uma protuberância medial na articulação talonavicular;
3. O arco medial longitudinal que é o ângulo entre maléolo medial e o osso navicular e este deve se manter próximo de 90° para ser considerado baixo;
4. O antepé deve ter uma abdução em relação ao retropé; e
5. A rotação interna deve ser extremamente baixa.

Figura 6- Classificação do tipo de pisada



Fonte: Adaptado ("Overpronation:What it is and what can you do about it", 2018)

A classificação da pisada como neutra (Figura 6- B) deve atender obrigatoriamente dois critérios citados no Quadro 2.

Quadro 2- Critérios para classificação de pé com pisada neutra

1. O calcanhar deve estar perpendicular ao solo; e
2. O pé deve apresentar um arco longitudinal medial normal.

A classificação supinada (Figura 6- C) ocorre quando atender obrigatoriamente três critérios (1,2 e 3), sendo outros três (4,5 e 6) eletivos.

Quadro 3- Critérios para classificação de pé com pisada supinada

1. O calcanhar não deve apresentar uma diferença de 3° da posição perpendicular do solo no sentido medial para o lateral;
2. Não deve ter uma protuberância medial na articulação talonavicular. O pé pode ter uma protuberância lateral do tálus até o sínus-tarsi;
3. O arco medial longitudinal que é o ângulo entre maléolo medial e o osso navicular e este deve manter distante de 90° para ser considerado alto;
4. O ante pé deve ter uma adução em relação ao retropé;
5. A perna deve estar excessivamente rotacionada; e
6. A largura do pé na junta mediotársica deve ser reduzida.

A análise de marcha é fortemente associada a condição de saúde, sendo um bom indicativo da saúde podendo ser uma métrica não invasiva e confiável. A marcha varia de acordo com a estrutura musculoesquelética que por sua vez é influenciada pela idade, sexo, altura, peso e outros fatores (MAJUMDER; MONDAL; DEEN, 2019).

A classificação do tipo de pisada obtidos pela realização de Plantigrama ou análise da pressão plantar permite relacionar a doenças. Crianças diagnosticadas com obesidade possuem 2,66 vezes mais chance de possuir pé chato, sendo mais frequente no sexo masculino entre 7 e 8 anos (CHANG *et al.*, 2010). Em diabéticos o comportamento do primeiro metatarso, a atrofia a almofada de gordura, o valgo do antepé e dedo do pé são alguns dos fatores que clinicamente precisam ser constantemente avaliados para evitar uma neuropatia motora. Desta forma, utilizando um tapete para coleta de sinais de pressão plantar e uma técnica de mapeamento total semi-automática, os autores analisaram a hipótese de distinguir grupos de indivíduos com padrões semelhantes de pisada e verificar se grupos específicos de pacientes com diabetes poderiam ser isolados de não-diabéticos (DESCHAMPS *et al.*, 2013). Com a técnica *Belgian Diabetes Foot Plantar Pressure Classification System* foi possível atingir uma taxa de 98,10% para os resultados do estudo de eficácia clínica, sendo um resultado bom e excelente para todos os conjuntos de validação cruzada (DESCHAMPS *et al.*, 2016). A doença de Charcot-Marie-Tooth é frequentemente associada à deformidade do pé cavo em que é provocada pelo desequilíbrio muscular periférico o qual é agravado com a progressão da doença. Os padrões de pressão plantar refletem a cavidade do pé e quanto maior o arco longitudinal medial mais altas são as pressões sob o retropé e o antepé fazendo com

que o pé apresente um comportamento supinado (CROSBIE; BURNS; OUVRIER, 2008). A consequência de uma pisada errada são a hipermobilidade que é quando as articulações passam do limite de alongamento e a possível lesão do tendão ou ligamento.

2.2 MÓDULOS INERCIAIS COMERCIAIS


Sensores inerciais são usualmente utilizados para análise de movimento e são encontrados comercialmente. A quantidade de módulos que podem ser empregados simultaneamente conforme a aplicação do sistema desenvolvido pelo fabricante.

O MTN500 (Figura 7- A) é um sistema sem fio capaz de conectar até 7 módulos com sensores inerciais de 9 eixos (acelerômetro tri-axial, giroscópio tri-axial e magnetômetro tri-axial) simultaneamente. Também é capaz de realizar aquisições de dados em tempo real e utiliza o protocolo de comunicação *Bluetooth Low Energy* (BLE). O sistema também conta com memória interna caso haja perda de dados de transmissão, permite a configuração da taxa de aquisição e outras características (ELIKO, 2019).

O STT-IWS IMU (Figura 7- B) é um sistema sem fio capaz de conectar até 17 módulos com sensores inerciais de 9 eixos, sensor de pressão barométrica, sensor de temperatura e sensor de umidade. O dispositivo consegue atingir uma frequência de aquisição de até 400 Hz e utiliza o protocolo de comunicação Wi-Fi™ (STT SYSTEMS, 2019).

O fabricante *Xsens* (Figura 7- C) apresenta dois modelos de módulos inerciais para a captura de movimento, sendo o *MVN Awiinda* a versão com tiras elásticas para alocação no corpo. É capaz de conectar até 17 módulos sensores inerciais de 9 eixos. Pode alcançar uma frequência de saída de até 60 Hz. Utiliza protocolo de comunicação Wi-Fi™. O *MVN Link* é constituído uma vestimenta de elastano com 17 módulos sensores inerciais de 9 eixos conectados por cabos a uma central e pode atingir uma frequência de saída de até 240 Hz. A central utiliza o protocolo de comunicação Wi-Fi™ (XSENS, 2019).

Figura 7- Sistemas inerciais comerciais
(a) MTN500; (b) STT-IWS; (c) Xsens



Fonte: (ELIKO, 2019; STT SYSTEMS, 2019; XSENS, 2019)

2.3 SENSORES INERCIAIS

Uma das formas de monitoramento de movimentação é realizada por meio da utilização dos sensores inerciais, os quais são baseados em acelerômetros e giroscópios.

O acelerômetro é o dispositivo capaz de medir a aceleração translacional resultado da movimentação de uma massa, um acelerômetro medirá utilizando o seu próprio corpo como referência e os efeitos de forças externas sobre ele (COLLIN *et al.*, 2013). A maioria dos acelerômetros atuais são construídos utilizando a tecnologia MEMS (*Micro-Electro Mechanical System*), que foi desenvolvida pelo setor militar nos anos 70.

Os acelerômetros MEMS são classificados de acordo com a tecnologia do transdutor. Os que utilizam transdutores piezoresistivos nas suas molas alteram as suas propriedades resistivas conforme o movimento, permitindo a dedução da aceleração. Esta classe é muito suscetível a ruídos, temperatura e consome uma quantidade de energia elevada (CALACHE, 2013).

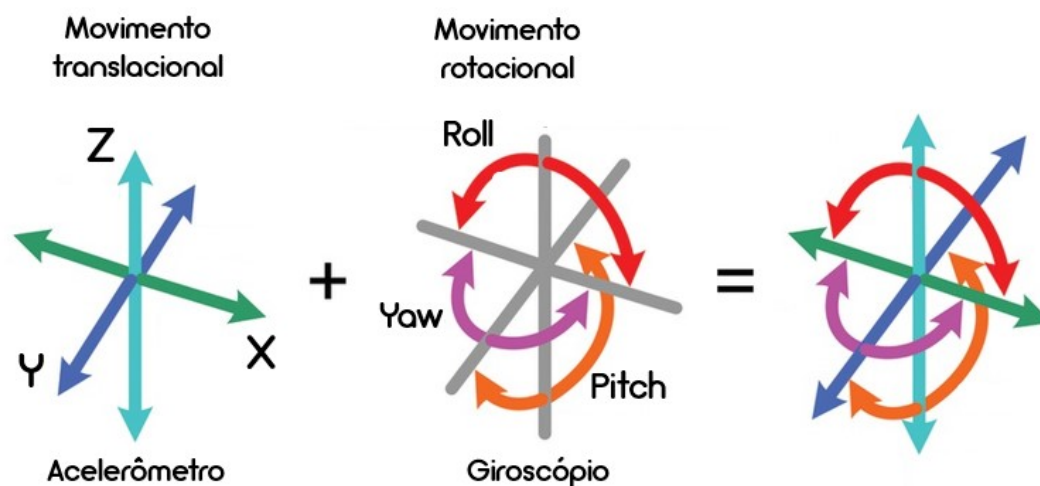
Nos acelerômetros que utilizam transdutores capacitivos, a massa fica entre duas placas paralelas, o qual varia a posição conforme o movimento alterando a capacitância. Esta classe de sensor permite uma maior sensibilidade e faixa de operação (CALACHE, 2013).

O giroscópio é um dispositivo capaz de medir a orientação angular e a variação causada pela movimentação do espaço inercial. O giroscópio MEMS também se utiliza do sistema de massa suspensa por mola em que a medição é dada pela

variação de capacitância, mas quando ocorre uma rotação da massa, tem a sua em estrutura de vibração baseada no fenômeno de forças de Coriolis (LYNCH; MARCHUK; ELWIN, 2015). Os efeitos expressos por estas são proporcionais a taxa de rotação. Fisicamente os sensores de capacitância são configurados para exprimir um valor zero, se o desvio é resultado de uma aceleração linear do giroscópio. Isso garante que apenas a velocidade angular seja mensurada.

O monitoramento de sistemas de navegação inercial é baseado na utilização de sensores acelerômetros tri-axiais (X, Y e Z) e sensores giroscópios tri-axiais (*Roll*, *Pitch*, *Yaw*) (Figura 8), para o rastreamento da posição e da orientação de um corpo rígido sem utilizar referências externas.

Figura 8- Graus de liberdade em um sistema tri-axial



Fonte: Adaptado (NELSON, 2019)

Os sensores inerciais são largamente empregados em diversas áreas como a aeronáutica (DUDAK *et al.*, 2016), automotiva (FARINELLI, 2019), telefonia (SPRAGER; JURIC, 2015) e biomédica (SPRAGER; JURIC, 2015). Em especial, apresenta-se promissora para utilização em programas de reabilitação (BORA; KUMAR; DUTTA, 2019). As vantagens apresentadas por esses sistemas são o seu tamanho reduzido, seu baixo custo e a possibilidade de fornecer informações completas sobre a marcha humana (MAJUMDER; MONDAL; DEEN, 2019). A integração de sistemas MEMS com opções de comunicação sem fio de baixo consumo permite obter informações dos movimento do cotidiano (andar, correr, pular e etc) de uma pessoa, para uma avaliação contínua e monitoramento de diversas variáveis biofísicas para uma análise mais completa (BORA; KUMAR; DUTTA, 2019).

A aplicação pode ser estática ou dinâmica, podendo ser empregados os sensores inerciais de 6 eixos (CUTTI *et al.*, 2006), como o exemplo de modelos comerciais G-Walk e Eliko utilizados para análise de movimento.

Diversas tecnologias de sensores inerciais estão disponíveis no mercado como é apresentado na Tabela 3. Um comparativo entre as tecnologias de sensores digitais e analógicos e as características. A faixa de operação do acelerômetro e do giroscópio podem ser configurados em quase todos os modelos apresentados e os seus intervalos de configuração são semelhantes, sendo a faixa de frequência de operação diversificada conforme a indicação de aplicação do fabricante. A densidade de ruído é decorrente da tecnologia e a blindagem utilizada pelo fabricante.

O MPU-6050 será apresentado devido a sua disponibilidade no mercado, o seu custo atrativo comparado aos outros modelos e o formato de módulo, o que facilita a utilização em diversas aplicações.

Tabela 3- Comparação entre as tecnologias de sensores inerciais

Sensor (com saída digital)	Eixos	Faixa de operação acelerômetro (g) ¹	Sensibilidade acelerômetro (LSB/g) ²	Faixa de operação Giroscópio (dps) ³	Sensibilidade giroscópio (LSB/dps)	Faixa de frequência (Hz)	Sensibilidade (%)	Densidade de ruído ($\mu\text{g}/\sqrt{\text{Hz}}$)	Resolução (bits)
MPU 6050	6	±2 ±4 ±8 ±16	16.384 8.192 4.096 2.048	±250 ±500 ±1.000 ±2.000	131 65,5 32,8 16,4	500	±2	400	16
MPU 9250	6	±2 ±4 ±8 ±16	16.384 8.192 4.096 2.048	±250 ±500 ±1.000 ±2.000	131 65,5 32,8 16,4	500	±2	300	16
ICM20649	6	±4 ±8 ±16 ±30	8.192 4.096 2.048 1.024	±500 ±1.000 ±2.000 ±4.000	65,5 32,8 16,4 8,2	5,7-197	±2	285	16
ICM30670	6	±2 ±4 ±8 ±16	16.384 8.192 4.096 2.048	±250 ±500 ±1.000 ±2.000	131 65,5 32,8 16,4	154	±2	220	16
BMI 160	6	±2 ±4 ±8 ±16	16.384 8.192 4.096 2.048	±125 ±250 ±500 ±1.000 ±2.000	262,4 131,2 65,6 32,8 16,4	5,06- 684	±1	180	16
BMI270	6	±2 ±16	16.384 2.048	±125 ±2.000	262,1 16,4	5-684	±4	160	16

LSM6DSOXTR	6	±2 ±4 ±8 ±16	16.384 8.192 4.096 2.048	±125 ±250 ±500 ±1.000 ±2.000	228 114 57 28 14	4,2-1441,8	-	70	-
MMA8452	3	±2 ±4 ±8	1024 512 256	-	-	0,78-400	-	99	12
MMA7455L	3	±2 ±4 ±8	64 32 16	-	-	62,5-125	±5%	-	8
Sensor (com saída analógica)	Eixos	Faixa de operação acelerômetro (g) ¹	Sensibilidade (mV/g)			Faixa de frequência (Hz)	Sensibilidade (%)	Densidade de ruído (µg/√Hz)	Saída
MMA7361	3	±1,5 ±6,0	800 206	-		400	±5	300	Analógica
ADXL335	3	±3,0	2400	-	-	1600	±1	150	Analógica

Fonte: (BOSCH SENSORTEC, 2018, 2019; INVENSENSE, 2016a, 2016b, 2016c, 2016d; NXP SEMICONDUCTORS, 2009, 2011, 2016; ONE TECHNOLOGY WAY, 2009; STMICROELECTRONICS, 2019)

¹ g = Força gravitacional

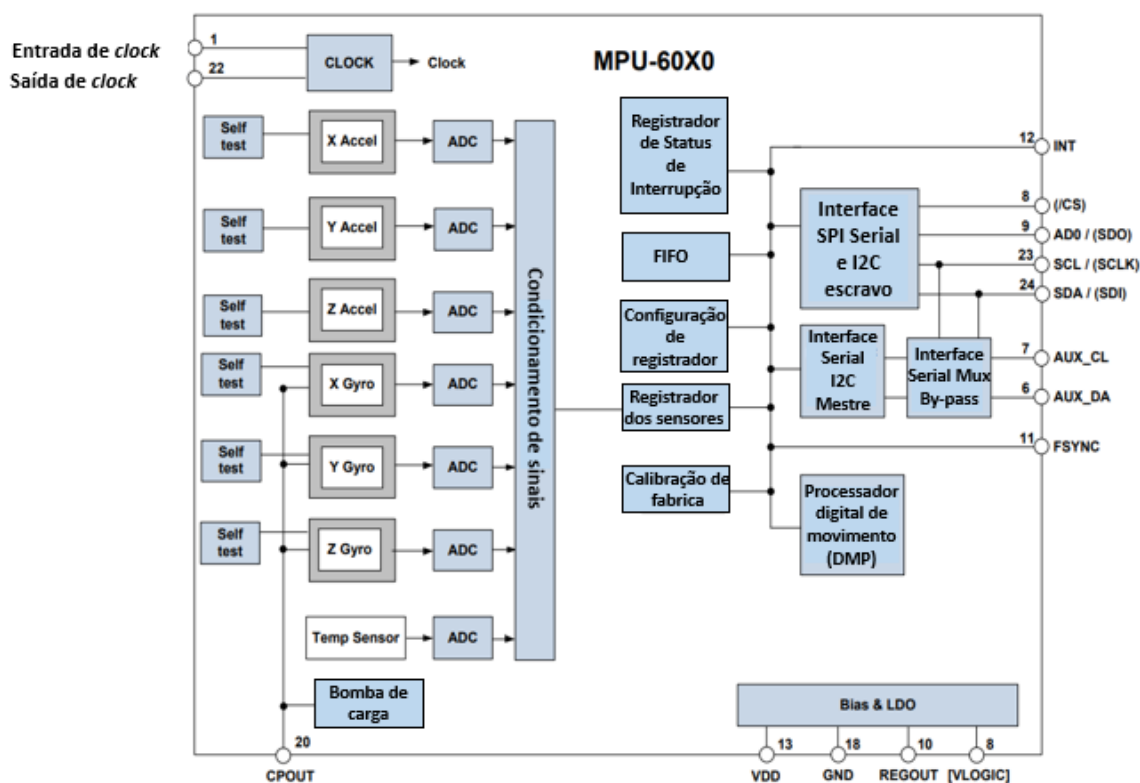
² LSB = *Least Significant Bit per g* (Bit menos significante por g)

³ dps = *Degrees per second* (Graus por segundo)

2.3.1 - MPU6050

O MPU-6050 é um dos módulos inerciais largamente disseminados, e pode ser encontrado facilmente no mercado, além de ser mais acessível que outros modelos. É fabricado pela InvenSense®, sendo um microcontrolador que possui giroscópio tri-axial, acelerômetro tri-axial, sensor de temperatura, processador digital de movimento, condicionamento de sinal, calibração, interface de comunicação I²C tanto primária quanto auxiliar, sistema de *clock* e registradores de configuração e operação. Sua arquitetura é apresentada na Figura 9.

Figura 9- Diagrama de bloco do MPU-6050



Fonte- (INVENSENSE, 2016d, p. 60)

O dispositivo possui 7 conversores AD de 16 bits para a digitalização das saídas do acelerômetro, giroscópio e temperatura, permitindo ajustar a faixa de operação para uma maior precisão para análise de movimentos rápidos ou lentos. A comunicação é feita por uma I²C dedicada com frequência de 400 kHz (INVENSENSE, 2016d). Ele também permite a sua utilização para a captura e reconhecimento de movimentos corporais.

O Processador Digital de Movimento (DMP) descarrega as informações processadas pelo algoritmo de movimento. Ele realiza a aquisição e o processamento


por meio do acelerômetro, giroscópio. O resultado pode ser lido requisitando as informações do registrador do DMP ou carregá-lo no registrador do FIFO. O DMP também pode ser utilizado para a geração de interrupção por meio do acesso ao pino externo do MPU (INVENSENSE, 2016d).

O *Self-test* (ST) é uma função disponível que permite a realização de teste tanto da parte mecânica quanto elétrica (INVENSENSE, 2013).

Para utilização, o MPU-6050 é vendido em um módulo para prototipagem rápida que permite que projetos sejam desenvolvidos com maior velocidade e segurança. Entre diversos fabricantes deste tipo de módulo, um deles é apresentado na Figura 10, o qual contém 8 pinos de interface, sendo eles:

- VCC- Pino de alimentação;
- GND- Pino de terra;
- SCL- Pino *Serial Clock*. Conecta-se ao pino SCL do microcontrolador;
- SDA- Pino *Serial Data*. Conecta-se ao pino SDA do microcontrolador;
- XDA- Pino auxiliar de *Serial Data*. Pino utilizado conectar outra interface I₂C habilitando o pino SDA ao MPU-6050;
- XCL- Pino auxiliar de *Serial Clock*. Pino utilizado conectar outra interface I₂C habilitando o pino SCL ao MPU-6050;
- AD0- Pino do bit menos significativo do endereço do I₂C; e
- INT- Pino de saída de interrupção digital.

Figura 10- Módulo inercial- 6050



Fonte: ("Tutorial", 2014)

Segundo o mapa de registradores do MPU-6050, estão disponíveis 82 registradores que podem ser divididos em configuração e operação do *hardware*. Destes 17 registradores foram elencados devido à realização de testes,

endereçamento, modo de energia, frequência de operação, alteração de parâmetros de aquisição e armazenamento de dados.

Os registradores responsáveis pela configuração da faixa de fundo de escala do acelerômetro e do giroscópio são o 27 e o 28, respectivamente, como apresentados na Tabela 4. O terceiro e o quarto bit são reservados para a realização da seleção (INVENSENSE, 2013).

Tabela 4- Registradores de *Self Test*

Registrador (HEX)	Registrador (DEC)	bit 7	bit 6	bit 5	bit 4	bit 3	bit 2	bit 1	bit 0
1B	27	XG_S	YG_S	ZG_S	FS_SEL [1:0] ³		-	-	-
1C	28	XA_S	YA_S	ZA_S	FS_SEL [1:0]		-	-	-

Fonte: (INVENSENSE, 2013)

¹ xG_ST- É o bit que quando setado realiza o auto teste para o eixo do giroscópio referente;

² xA_ST- É o bit que quando setado realiza o autoteste para o eixo do acelerômetro referente;

³ 2-bit não sinalizado para seleção da faixa de fundo de escala.

Os valores de faixa de fundo de escala e a sensibilidade do fator de escala (SSF) do acelerômetro e do giroscópio para da alteração nos registradores são apresentados na Tabela 5.

Tabela 5- Modos de seleção de configuração.

FS_SEL	Acelerômetro		Giroscópio	
	Fundo de escala (g)	Sensibilidade do fator de escala (LSB/g)	Fundo de escala (dps)	Sensibilidade do fator de escala (LSB/dps)
0	±2	16.384	±250	131
1	±4	8.192	±500	65,5
2	±8	4.096	±1.000	32,8
3	±16	2.048	±2.000	16,4

Fonte: (INVENSENSE, 2013)

A comunicação pode ser realizada por meio do protocolo SPI ou I²C. O módulo sempre atua no modo escravo, em que o endereço do módulo é (0x68) e o Bit Menos Significativo (LSB) do endereço I²C pode ser setado por meio do pino AD0, de modo que quando o pino está em nível lógico alto o endereço do módulo altera-se para (0x69). O registrador 117 (Tabela 6) é utilizado para identificar o dispositivo, em que o bit 0 não é alterado a não ser pelo pino AD0.

Tabela 6- Registrador de endereço

Registrador (HEX)	Registrador (Decimal)	Bit							
		7	6	5	4	3	2	1	0
75	117	Endereço							AD0

Fonte: (INVENSENSE, 2013)

As leituras das informações são realizadas pelos registradores do 59 ao 72 (Tabela 7) em que cada par de byte são responsáveis por um eixo do acelerômetro, giroscópio e do sensor de temperatura.

Tabela 7- Registradores armazenadores de informação de aceleração e velocidade angular

Registrador (HEX)	Registrador (Decimal)	Bit							
		7	6	5	4	3	2	1	0
3B	59	³ ACCEL_XOUT[15:8]							
3C	60	⁴ ACCEL_XOUT[7:0]							
3D	61	³ ACCEL_YOUT[15:8]							
3E	62	⁴ ACCEL_YOUT[7:0]							
3F	63	³ ACCEL_ZOUT[15:8]							
40	64	⁴ ACCEL_ZOUT[7:0]							
41	65	⁵ TEMP_OUT[15:8]							
42	66	⁶ TEMP_OUT[7:0]							
43	67	¹ GYRO_XOUT[15:8]							
44	68	² GYRO_XOUT[7:0]							
45	69	¹ GYRO_YOUT[15:8]							
46	70	² GYRO_YOUT[7:0]							
47	71	¹ GYRO_ZOUT[15:8]							
48	72	² GYRO_ZOUT[7:0]							

Fonte:(INVENSENSE, 2013)

- ¹ GYRO_xOUT[15:8]- É o byte mais significativo do eixo x do giroscópio; em que x={X,Y,Z};
² GYRO_xOUT[7:0]- É o byte menos significativo do eixo x do giroscópio; em que x={X,Y,Z};
³ ACCEL_xOUT[15:8]- É o byte mais significativo do eixo x do acelerômetro; em que x={X,Y,Z};
⁴ ACCEL_xOUT[7:0]- É o byte menos significativo do eixo x do acelerômetro; em que x={X,Y,Z};
⁵ TEMP_OUT[15:8]- É o byte mais significativo da medição de Temperatura; e
⁶ TEMP_OUT[7:0]- É o byte menos significativo da medição de Temperatura.

O registro 107 (Tabela 8) permite a configuração de modo de alimentação, fonte de *clock*, resetar o dispositivo completamente e desabilitar o sensor de temperatura. Quando o bit 7 se encontra em nível lógico alto, todos os seus registradores retornam aos valores padrões de fábrica. Quando o bit 6 está em nível lógico alto o MPU-6050 entra no *Sleep mode*. O bit 5, quando se encontra o nível lógico alto, e o *Sleep mode* se encontra desabilitado, o MPU-6050 realizará o ciclo entre despertar e voltar ao *sleep mode* para a coleta de uma amostra de dado no

intervalo determinado pelo registrador 108. O bit 3 é responsável por habilitar e desabilitar o sensor de temperatura. Os bits 2 a 0 são responsáveis pela seleção da fonte de *clock* apresentado na Tabela 9, quando é escolhido o modo de operação com *clock* interno, usando o oscilador, ou o externo. É possível utilizar o módulo em baixo consumo de energia com o giroscópio desabilitado.

Tabela 8- Registrador *Sleep Mode*

Registrador (HEX)	Registrador (Decimal)	Bit							
		7	6	5	4	3	2	1	0
6B	107	Resetar dispositivo	<i>Sleep mode</i>	<i>Cycle</i>	-	Sensor de temperatura	Seleção de <i>clock</i>		

Fonte: (INVENSENSE, 2013)

Tabela 9- Fonte de *Clock*

Seleção de <i>clock</i>	Bits 2-1-0	Fonte de <i>clock</i>
0	000	Oscilador interno de 8MHz
1	001	PLL ¹ com o eixo X do giroscópio
2	010	PLL com o eixo Y do giroscópio
3	011	PLL com o eixo Z do giroscópio
4	100	PLL com o <i>clock</i> externo de 32.768kHz
5	101	PLL com o <i>clock</i> externo de 19.2MHz
6	110	Reservado
7	111	Para o <i>clock</i> e mantém o contador de tempo resettato

Fonte: (INVENSENSE, 2013)

O registrador 108 (Tabela 10) permite a seleção da frequência (Tabela 11) para despertar do módulo no modo de baixo consumo somente para acelerômetro, e também permite estabelecer se o usuário deseja que algum eixo fique em *stand-by*, sendo o bit 5 a 3 referente ao acelerômetro X ao Z, respectivamente, e do bit 2 a 0 do giroscópio.

Tabela 10- Registrador 108

Registrador (HEX)	Registrador (Decimal)	Bit							
		7	6	5	4	3	2	1	0
6C	108	Seleção de frequência			<i>Stand-by</i> acelerômetro			<i>Stand-by</i> giroscópio	

Fonte: (INVENSENSE, 2013)

Tabela 11- Seleção de frequência

Seleção de frequência	Bits 7-6	Frequência
0	00	1,25 Hz
1	01	5,00 Hz
2	10	20 Hz
3	11	40 Hz

Fonte: (INVENSENSE, 2013)

As informações do módulo consistem em 16 bits sinalizados. Logo os valores da aceleração no eixo em g ($9,81 \text{ m/s}^2$) são dados pela Equação 2, e os valores da velocidade angular no eixo em graus por segundo, são dados pela Equação 3.

$$\text{Aceleração} = \frac{\text{Dado acelerômetro}}{\text{SSF Acelerômetro}} \quad (2)$$

$$\text{Velocidade angular} = \frac{\text{Dado giroscópio}}{\text{SSF Giroscópio}} \quad (3)$$

Em que SSF é a Sensibilidade do Fator de Escala, tanto para o acelerômetro quanto para o giroscópio.

O MPU-6050 possui os três sistemas vibratórios MEMS independentes, e o resultado da tensão é proporcional ao da variação angular. Para o acelerômetro são utilizadas três massas de prova para cada eixo. O resultado da tensão é proporcional a taxa de variação. Quando o sensor é posto em uma superfície reta, será medido 0g no eixo X e Y e 1g no eixo Z (INVENSENSE, 2016d). Logo, se o sensor for posto em uma posição diferente, a sua representação será dada como um *offset* do sinal para os eixos conforme sua posição.

Estão disponíveis 24 bytes para a obtenção de dados referentes aos sensores externos. Os dados são armazenados nos registradores de 73 a 96. É possível a utilização das interfaces auxiliares I²C classificadas de 0 a 4. A taxa de amostragem definida por registrador referente a interface. Os dados referentes a configuração das interfaces auxiliares estão nos registradores de 37 a 43 (INVENSENSE, 2013).

2.4 MICROCONTROLADOR

Para tratar os dados dos sensores, dispositivos microcontroladores são necessários para receber, processar e transmitir essas informações por meio das suas funcionalidades, ou seja, permite com que as informações obtidas do meio físico pelo sensor sejam traduzidas para o meio digital.

Os microcontroladores são mecanismos inteligentes dotados de capacidade de processamento, armazenamento, entradas e saídas analógico/digitais e interface de comunicação, que possibilitam a aplicação em diferentes situações.

Diversas aplicações têm sido desenvolvidas utilizando estes dispositivos voltadas a movimentação de braços robóticos (PAKALAPATI *et al.*, 2017), Internet das Coisas (SRIVASTAVA; BAJAJ; RANA, 2018), *Smart home* (HAMDAN *et al.*, 2019), *Healthcare* (REIS *et al.*, 2015) e outros. Na Tabela 11 é apresentado um comparativo com alguns dos principais dispositivos de prototipagem atualmente disponíveis no mercado, em que é possível observar as características, interfaces de comunicação e a relação de custo comparado ao Arduíno UNO.

No caso de aplicações que envolvam sistemas vestíveis é desejável que o microcontrolador possua interface de comunicação sem fio, baixo consumo de energia, tamanho reduzido e deve ser economicamente agradável para que o equipamento permita um melhor conforto ao usuário, autonomia e maior liberdade de movimento.

Na Tabela 12 são apresentados diversos modelos de plataformas de prototipagem rápida que são dotadas de sistemas microcontrolados encontrados no mercado. São avaliados comparativamente pelo processador, resolução do conversor analógico/digital, interfaces de comunicação, armazenamento de dados, preço, entradas e saídas tanto digitais quanto analógicas. O melhor microcontrolador é definido de maneira relativa, pois o objetivo dessas plataformas é se adaptarem e oferecem as ferramentas necessárias para os mais diversos tipos de aplicação, por isso é possível avaliar pelo processamento de dados, pelo modo construtivo ou por número de entradas e saídas. O preço deve ser economicamente viável para a aplicação, mas na Tabela 12 o preço é comparado ao preço do Arduino uno um dos microcontroladores mais populares encontrados comercialmente.

O ESP01 será apresentado de maneira detalhada devido as suas características construtivas e sua disponibilidade de ferramentas úteis a aplicação, como interfaces de comunicação como I²C e Wi-Fi, custo mais baixo comparado aos outros avaliados no mercado, tamanho (25 x 14 x 1mm) e peso reduzidos em torno de 7 gramas.

Tabela 12- Comparativo entre microcontroladores de algumas plataformas de prototipagem rápida

Plataforma	Processador	Resolução ADC	Interface de comunicação	Memória Flash	Memória RAM	Memória ROM	GPI/O	Entrada analógica	Preço relativo (base 2019) ¹
Arduino uno	ATmega328	10 bits	Serial; SPI; I ² C; UART	32 kB	2 kB	1 kB	14	6	1 x
Arduino Mega	ATmega2560	10 bits	Serial; SPI; I ² C; UART	256 kB	8 kB	4 kB	54	16	1,73 x
ESP-01	Tensilica L106	12 bits	Serial; SPI; I ² C; UART; Wi-Fi	512 kB	50 kB	-	4	0	0,44 x
ESP32s	Xtensa LX6	12 bits	Serial; SPI; I ² C; Wi-Fi; Bluetooth; UART	16 MB	520 kB	448 kB	32	16	1,27 x
BeagleBone Black Wireless	Octavo Systems OSD3358	12 bits	Serial; Bluetooth; Wireless; USB; I ² C; CAN; UART; SPI	4 GB	512 MB	-	65	7	14,57 x
BeagleBone Green Wireless	AM3358	12 bits	Serial; Bluetooth; Wireless; USB; I ² C; CAN; UART; SPI	4 GB	512 MB	-	92	8	7,83 x
Raspberry Pi 3 A+	Broadcom BCM2837B0	-	Serial; Bluetooth; Wireless; USB; I ² C; UART; SPI	32 GB	512 MB	-	40	0	4,01 x
Raspberry Pi Zero W	Broadcom BCM2835	-	Serial; Bluetooth; Wireless	32 GB	512 MB	-	40		2 x

Fonte: Autoria própria


¹ Preço relativo do dispositivo comercial, em relação ao preço sugerido do Arduino UNO, estimado em DEZ/2019;

2.4.1 ESP01

O ESP01 dentre os dispositivos detalhados na Tabela 12 é um módulo de prototipagem eletrônica rápida desenvolvido pela Ai-Thinker. Contém um microcontrolador ESP8266EX o qual integra um processador Tensilica L106 de 32 bits, com *clock* de 160 MHz e conversor AD com resolução de 10 bits.

Essa plataforma possui suporte RTOS (*Real Time Operational System*), interface de comunicação SPI, I²C, Serial e Wi-Fi® 802.11 b/g/n embutido, memória SRAM e memória ROM (ESPRESSIV, 2019). A plataforma permite a conexão com outros protocolos de comunicação não nativos como o *Bluetooth*. O módulo é possui 8 pinos. Na Figura 11 são apresentados as entradas e os esquemáticos, sendo VCC a alimentação realizada em 3,3V; o GND que é o terra (0V); GPIOx que são as entrada e saída digitais; RXD que é a comunicação serial de recebimento de dados; TXD que é a comunicação serial de transmissão de dados; CH-PD que é a habilitação do chip em que é ativo em nível lógico alto; e RESET que permite externamente o reset, ativo em nível lógico baixo.

Figura 11- Esquemático de pinos do ESP01



Fonte: (SEO *et al.*, 2017)

O ESP8266 pode ser programado utilizando a linguagem LUA, Micropython e a linguagem de programação para Arduino, que é equivalente a um C/C++ com modificações. A linguagem LUA foi desenvolvida na PUC-Rio e é reconhecida eficiente, leve e poderosa, sendo possível as programações orientadas a objetos,

funcional, orientados a dados e descrição de dados. Já a Micropython é uma linguagem desenvolvida para tornar a linguagem Python 3, que permite utilizar um subconjunto de biblioteca, sendo otimizada para microcontroladores e arquiteturas com baixo recurso. Essa linguagem possui *prompt* interativo, números com precisão arbitrária, listas, *closures*, tratamento de exceções e outros. A linguagem de programação em Arduino tem uma estrutura simples e de fácil aprendizagem.

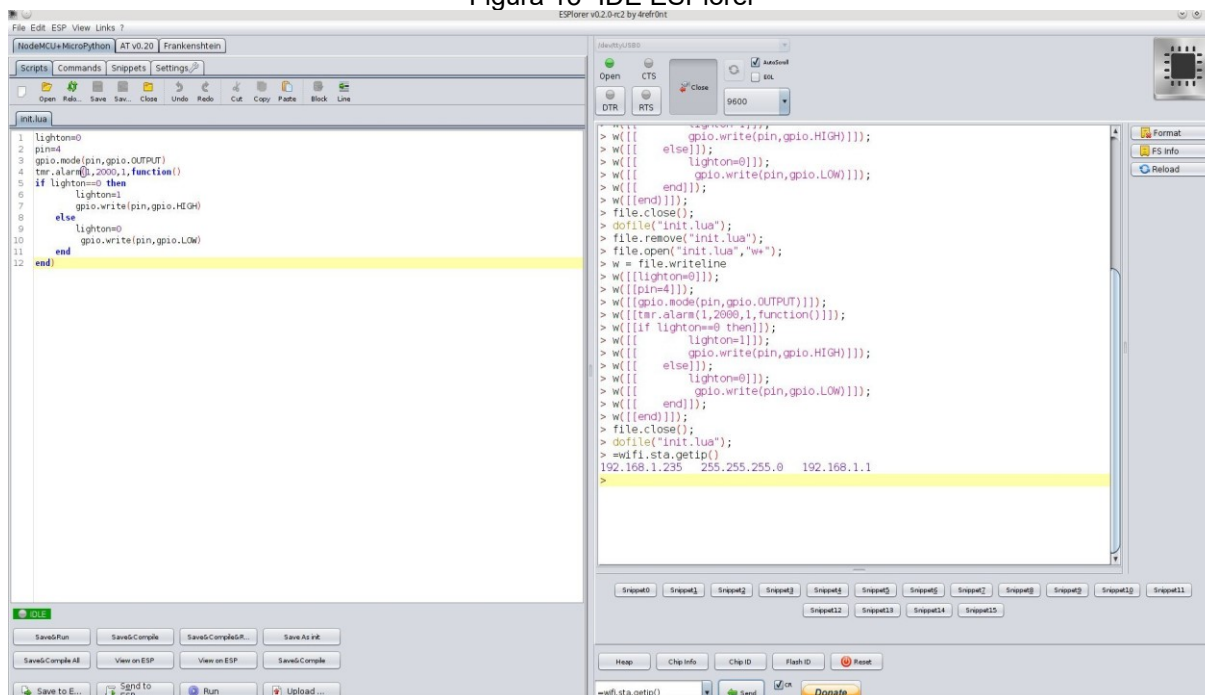
Para realizar o modo de programação o ESP01 permite a utilização de dois ambientes que são a interface IDE (*Integrated Development Environment*), do Arduino e o ESPlorer. O IDE Arduino, em sua versão 1.8.3, apresentado na Figura 12, permite programar diversos modelos de microcontroladores, entre eles toda a família Arduino e muitos dispositivos da família ESP.



Fonte: (“Carregando código de quadro e Arduino IDE”, [s.d.]

O ESPlorer, apresentado na Figura 13, e a IDE permitem programar em duas linguagens: o Micropython e o LUA além de carregar as informações nos microcontroladores ESP.

Figura 13- IDE ESPlorer




Fonte:(SUHANKO, [s.d.]

O carregamento do código pode ser realizado utilizando a IDE do Arduino e um Arduino UNO. O Arduino UNO é alimentado em 5 V e a alimentação do ESP-01 é realizada em 3,3V, sendo necessário que todos os níveis de tensão sejam respeitados. Por este motivo é empregado um divisor de tensão. O procedimento para o carregamento é que o GPIO0 deve estar em nível lógico baixo a ser acionado por um *push button*, o pino Reset deve estar em nível lógico baixo a ser acionado por um *push button*, o pino TX do Arduino é conectado ao TX do ESP-01. O RX do Arduino é conectado ao divisor de tensão e em seguida conectado ao RX do ESP-01. O pino do chip *enable* deverá estar em nível lógico baixo.

Para realizar o carregamento pode ser necessário manter pressionado o botão *Flash* (GPIO0) e pressionar o botão *reset*. A partir disso o LED indicativo irá piscar de modo a informar que o firmware está sendo transferido para a placa (STEVAN JR; FARINELLI, 2019). O circuito é exemplificado na Figura 14.

Figura 14- Circuito de carregamento no ESP-01



Fonte: (STEVAN JR; FARINELLI, 2019)

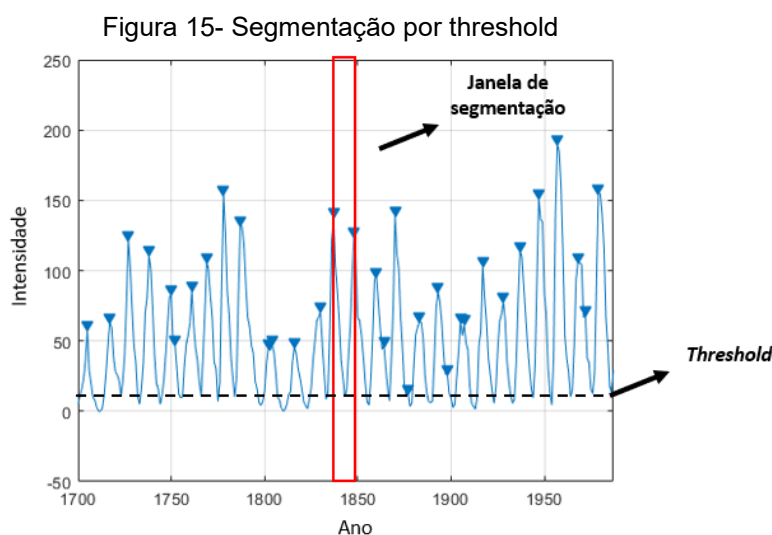
2.5 PROCESSAMENTO DE DADOS

Após a digitalização das informações de movimento, os dados necessitam passar por etapas para preparar o sinal a ser avaliado pelo classificador. Sendo assim, é necessária a realização da segmentação para separar as diversas amostras contidas em cada coleta, a normalização para delimitar os limites de operação e, após, a obtenção de características do sinal precisa ser matematicamente extraída para que quando apresentado ao classificador ele seja capaz de identificar os padrões de cada classe. Abaixo descreveremos tais processos:

a) Segmentação

A segmentação é uma das etapas do pré-processamento do sinal de sensores Inerciais, essencial para identificação e separação de porções do sinal relativo à cada evento dinâmico. Nesta etapa, o sinal bruto é dividido em pequenos segmentos em função do tempo para que possam ser extraídas características baseadas em análises matemáticas que permitam o seu uso em sistemas de classificação de dados. Existem diversas técnicas de segmentação de sinais. Entre as mais usais, citam-se dois métodos: 1) a comparação do sinal por meio um valor de limiar (*threshold*) e através dele, detectar os picos ou vales do sinal e segmentá-lo (SHI; SHI; WANG, 2012).; e 2) detectar a alteração do sinal e segmentá-lo em determinado período de tempo.

A Figura 15 ilustra a técnica de identificação de picos por *Threshold* (Figura 15) nos dados dos sensores inerciais em conjunto com os detectores de auto correlação dos picos e velocidade de mínimo local.



Fonte: Adaptado (“Peak Analysis- MATLAB & Simulink Example”, [s.d.]

Cada detector avalia conforme a ultrapassagem do sinal por um determinado valor capturando uma janela de dados entre um número de pontos detectados. A auto correlação de pico é utilizado para ações periódicas, logo a auto correlação também será periódica e é contado os picos em uma janela de tempo e quando está acima do *threshold* o ponto é marcado. O mínimo local de velocidade utiliza a integral da magnitude da aceleração para aproximar a velocidade do sinal demarcando os pontos de transição (SHI; SHI; WANG, 2012).

Foi empregado a técnica *threshold* com o detector de mínimo local de velocidade e o nível do *threshold* foi alterado para cada indivíduo devido a velocidade de marcha que interfere nas magnitudes do sinal.

b) Normalização

A normalização é uma etapa necessária para que os dados sejam delimitados por um espaço amostral podendo propiciar a obtenção de uma melhor taxa de acerto e eficiência em algoritmos de classificação (AL SHALABI; SHAABAN, 2006). Os sinais de cada amostra são normalizados aplicando-se uma transformação linear e permitindo que os valores permaneçam entre um intervalo definido de $[0, 1]$. Os valores são obtidos por meio da Equação 4.

$$A_{norm} = \frac{A_i - A_{min}}{A_{max} - A_{min}} \quad (4)$$

Em que: A_{norm} é a amplitude normalizada; A_{min} é a amplitude mínima; e A_{max} é a amplitude máxima.

O Z-score é outra técnica de normalização e é representada pela Equação 5 (JAIN; NANDAKUMAR; ROSS, 2005).

$$A_{norm} = \frac{A_i - \bar{A}}{\sigma} \quad (5)$$

Em que: \bar{A} é a média geométrica da amplitude do sinal; i refere ao índice; e σ é o desvio padrão.

c) Características de um sinal

Sinais aquisitados de sensores inerciais possuem uma natureza de difícil interpretação visual. Por este motivo, após a segmentação do sinal, aplicam-se operações matemáticas, de modo que se possam obter métricas capazes de permitir a análise do comportamento do sinal (ANWARY; YU; VASSALLO, 2018). O processo de operar matematicamente o sinal de diferentes formas, denomina-se de extração de características.

Dentre as dezenas de características possíveis, foram escolhidas para serem utilizadas neste estudo, as mais citadas em trabalhos corretos, que são:

- - Diferença absoluta do valor de desvio padrão (DASDV);
- - Máximo e Mínimo;
- - Valor Médio Absoluto (MAV);
- - Média quadrática (RMS);
- - Integral quadrada simples (SSI); e
- - Comprimento de onda (WL).

A DASDV (*Difference Absolute Standard Deviation Value*) representa a diferença absoluta do valor do desvio padrão do sinal (PHINYOMARK; PHUKPATTARANONT; LIMSAKUL, 2012). É calculada por meio da Equação 6.

$$DASDV = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (A_{i+1} - A_i)} \quad (6)$$

Em que: A_i é a amplitude do sinal; i é o índice; e N é o número de amostras.

O valor de Máximo (max) apresenta a maior amplitude do sinal coletado; e o valor de Mínimo (min) a menor amplitude obtida.

A Valor Médio Absoluto (MAV- *Mean Absolute Value*) está relacionado ao disparo do sinal e é calculado por meio Equação 7 (HUDGINS; PARKER; SCOTT, 1993).

$$MAV = \frac{1}{N} \sum_{i=1}^N |A_i| \quad (7)$$

A raiz quadrada média (RMS- *Root Mean Square*) é uma característica relacionada com a força, contração muscular e a potência do sinal. Ela é obtida por meio da Equação 8 (PHINYOMARK; PHUKPATTARANONT; LIMSAKUL, 2012).

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N A_i^2} \quad (8)$$

A Integral Quadrada Simples (*Simple Square Integral*) é utilizado para analisar a potência do sinal, sendo calculado por meio da soma dos quadrados das amplitudes do sinal (Equação 9) (PHINYOMARK; PHUKPATTARANONT; LIMSAKUL, 2012).

$$SSI = \sum_{i=1}^N A_i^2 \quad (9)$$

O comprimento de onda (WL- *Wavelength*) é utilizado para analisar a complexidade do sinal e é representado pelo comprimento cumulativo ao longo do tempo (HUDGINS; PARKER; SCOTT, 1993). É possível observar a medida de amplitude a frequência e a duração do sinal. A característica é obtida por meio da Equação 10.

$$WL = \sum_{i=1}^{N-1} |A_{i+1} - A_i| \quad (10)$$

2.5.1 Rede Neural Artificial

Com a realização do processamento dos dados é necessário empregar ferramentas capazes de analisar o agrupamento e a correlação entre as variáveis obtidas, as quais podem não ser visíveis utilizando análise de dados tradicionais. De tal maneira, pode ser útil usar ferramentas de inteligência computacional que são capazes de reconhecer padrões estabelecidos pelas características dos sinais advindos do sensoriamento inercial.


Uma dessas ferramenta é a Rede Neural Artificial (RNA) que tem capacidade de realizar previsão de séries temporais, reconhecimento e classificação de padrões (SYED *et al.*, 2019). Com isso, pode ser empregada na identificação do tipo de pisada usando sensores inerciais durante a marcha.

As redes neurais artificiais são inspiradas no funcionamento do sistema nervoso dos organismos superiores, nos quais ocorre no processo de geração e propagação dos pulsos elétricos pela membrana celular dos neurônios biológicos (HAYKIN, 2001). O seu funcionamento se dá com base nos estímulos recebidos do ambiente, sendo essas informações captadas pelos receptores, entregues a rede neural e fornecem a saída de informação (HAYKIN, 2001).

Em 1943 foi proposto o modelo matemático de um neurônio artificial por Mcculloch e Pitts (1943) e, em 1949 foi proposta a regra de aprendizagem de Hebb, em que o cérebro permite a adaptação para aprendizagem, ou seja, se um neurônio é estimulado repetidas vezes a ponto de que está, se desenvolva e estimule os seus vizinhos.

O neurônio genérico (Figura 16) é representado por múltiplas entradas (x_i), que representam os estímulos dados ao neurônio, os pesos (w_j) ponderam os níveis de representatividade das sinapses conforme a sua relevância, limiar de ativação (θ) que forma o nível *offset* ao sinal também deve ser ponderado. O combinador linear é responsável pela soma dos produtos das entradas com os pesos sinápticos e o limiar de ativação para a obtenção do potencial de ativação (u). A função de ativação (g) é necessária a fim de estabelecer valores funcionais e não linearidade, gerando assim a saída (y) referente ao estímulo na entrada.

Figura 16- Representação do neurônio genérico.



Fonte: Autoria própria

A representação matemática do neurônio artificial generalizado é dada pela Equação 11 e 12.

$$u = \sum X.W - \theta.w_0 \quad (11)$$

$$y = g(u) \quad (12)$$

Em que: X é o vetor de sinais de entrada; W é o vetor de pesos sinápticos; e θ é o limiar de ativação.

As funções de ativação podem ser divididas em parcialmente diferenciáveis e totalmente diferenciáveis. As parcialmente diferenciáveis possuem pontos em que a primeira derivada é inexistente. Entre as principais estão a função degrau, a degrau bipolar e a rampa simétrica. As totalmente diferenciáveis possuem as primeiras derivadas conhecidas em todos os pontos em que estão a logística, a tangente hiperbólica e a gaussiana.

A função logística (Equação 13) permite que os resultados sejam expressos em valores no intervalo de [0,1] (HAYKIN, 2001).

$$g(u) = \frac{1}{1 + e^{-\beta u}} \quad (13)$$

Em que β é a constante de inclinação.

A função tangente hiperbólica (Equação 14), diferentemente da função logística, permite que os valores sejam expressos no intervalo de [-1,1] (HAYKIN, 2001).

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

As redes neurais mais comuns são a *perceptron* de múltiplas camadas, redes de função de base radial e máquinas de vetor de suporte (SVM).

A *Perceptron* de múltiplas camadas (MLP) é característica por possuir uma ou mais camadas ocultas em que a função dos neurônios presentes é interferir na entrada e na saída tornando a rede capaz de extrair estatísticas de ordem superior essencialmente quando se possui um tamanho elevado número de entradas (HAYKIN, 2001). A função de base radial busca obter um espaço multidimensional para o melhor ajuste do treinamento, sendo construído em três camadas com objetivos diferentes em que um conecta a rede ao ambiente, outra aplica uma transformação não-linear e a camada de saída linear fornece a resposta da rede ao padrão de ativação (HAYKIN, 2001). A SVM possui aprendizagem supervisionada e busca obter hiperplanos a fim de separar as amostras otimizando os limites de generalização (HAYKIN, 2001).


A MLP vai ser abordada devido a capacidade de classificação de dados e fácil aplicabilidade.

2.5.2 Rede *Perceptron* de Múltiplas Camadas

A Rede *Perceptron* de Múltiplas Camadas (MLP) é a evolução da rede *Perceptron* desenvolvida em 1950 por Frank Rosenblatt. A MLP é caracterizada pela utilização de pelo menos uma camada escondida de neurônios. Possui uma diversa gama de aplicações como aproximação de funções, reconhecimento de padrão, identificação e controle de processo, previsões de séries temporais e otimização de sistemas (HAYKIN, 2001).

A MLP (Figura 17) é uma arquitetura *feedforward*, em que o fluxo de informações possui somente um sentido, ou seja, da camada de entrada para a camada de saída. A partir de 1986 por meio da publicação do livro *Parallel Distributed Processing*, em que foi explicitado o algoritmo de aprendizagem conhecido como *backpropagation* e a sua implementação no processo de treinamento nessas redes, o MLP se tornou uma ferramenta difundida (HAYKIN, 2001).

Figura 17- Representação da rede neural MLP



Fonte: Adaptado (SILVA; SPATTI; FLAUZINO, 2010)

O treinamento ocorre de maneira supervisionada, ou seja, é necessário informar para a rede qual a classe que o conjunto de entradas pertence (SYED *et al.*, 2019). Esta etapa possui dois passos, *forward* e *backward*, em que ambos constituem o método gradiente ótimo, e as suas derivadas são calculadas por meio da retropropagação do erro.

Silva, Spatti e Flauzino (2010) descrevem o procedimento de treinamento de uma MLP, o qual se inicia o processo obtendo-se o conjunto de amostras (\mathbf{X}), associados as amostras aos conjuntos de saídas desejadas (\mathbf{d}). Inicializando-se os pesos sinápticos (\mathbf{W}) de valores aleatórios pequenos. Antes de começar é preciso estabelecer a taxa de aprendizagem (η) e a precisão (ϵ). O passo *forward* é constituído pelo vetor de entradas ponderadas (\mathbf{I}) pela Equação 15 e as saídas dos neurônios (\mathbf{Y}) pela Equação 16.

$$\mathbf{I}_j^n = \mathbf{x} \cdot \mathbf{W}_{ji}^{nT} \quad (15)$$

$$\mathbf{Y}_j^n = g(\mathbf{I}_j^n) \quad (16)$$

Em que n é a camada; e j é o neurônio da camada n .

Os pesos sinápticos são ajustados no passo *backward* em que o gradiente local do erro para a camada de saída é dado pela Equação 17.

$$\delta_j^n = (\mathbf{d}_j - \mathbf{Y}_j^n) \cdot g'(\mathbf{I}_j^n) \cdot \mathbf{Y}_i^{n-1} \quad (17)$$

Os pesos da camada de saída são dados pela Equação 18.

$$\mathbf{W}_{ji}^n = \mathbf{W}_{ji}^n + \eta \cdot \delta_j^n \cdot \mathbf{Y}_i^{n-1} \quad (18)$$

Diferentemente da camada de saída, os ajustes dos pesos das camadas intermediárias são realizados por meio de estimativas do erro produzidos pela camada posterior previamente ajustado, em que o gradiente do erro local é dado pela Equação 19, até que os ajustes sejam realizados para todas as camadas intermediárias:

$$\delta_j^{n-1} = \left(\sum_{k=1}^m \delta_k^n \cdot \mathbf{W}_{kj}^n \right) \cdot g'(\mathbf{I}_j^{n-1}) \quad (19)$$

em que m é o neurônio da camada n .

Os pesos das camadas intermediárias são dados pela Equação 20:

$$\mathbf{W}_{ji}^{n-1} = \mathbf{W}_{ji}^{n-1} + \eta \cdot \delta_j^{n-1} \cdot \mathbf{Y}_i^{n-2} \quad (20)$$

A medição do desempenho global do algoritmo pode ser realizada por meio da avaliação do erro quadrático médio (Equação 21).

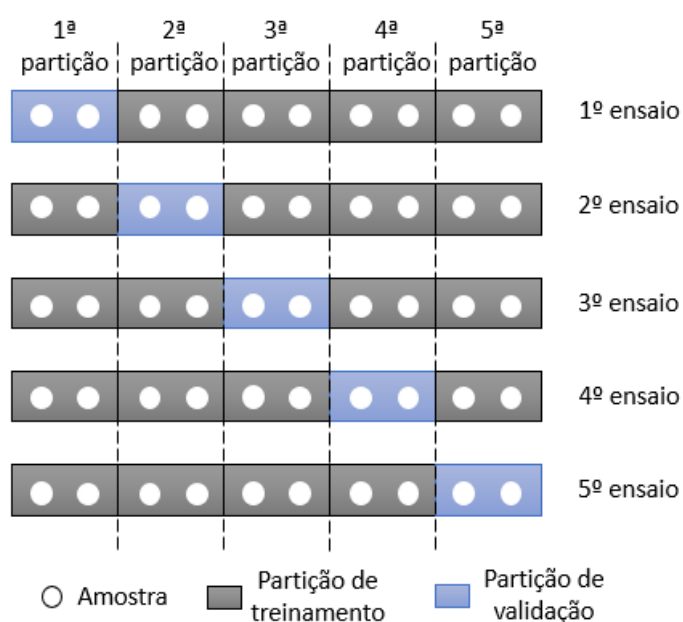
$$e_m = \frac{1}{N} \sum_{k=1}^N \left(\frac{1}{2} \sum_{j=1}^m (\mathbf{d}_j - \mathbf{Y}_j^n)^2 \right) \quad (21)$$

Os critérios de parada utilizados são o *early stopping* (Equação 22) é adotado o quando o algoritmo converge o módulo do erro quadrático médio para um ponto de mínimo local (ZUR *et al.*, 2009), quando a precisão estipulada é atingida ou quando a quantidade máxima de interações é atingida. Este valor deve ser ajustado para que a capacidade de generalização não seja afetada

$$|MSE^{atual} - MSE^{anterior}| \leq \varepsilon \quad (22)$$

A validação cruzada é uma técnica para a seleção de topologias candidatas e para evitar o sobre-treinamento. São separados subconjuntos de treinamento e validação. A Figura 18 ilustra o funcionamento do *K-Fold* com 10 amostras com $K=5$ o qual realiza a divisão do conjunto de entradas em $k-1$ subconjuntos para treinamento e um subconjunto para validação. O objetivo é que todas as partições atuem como subconjunto de validação (SILVA; SPATTI; FLAUZINO, 2010).

Figura 18- Exemplificação do k-fold para um $k=5$ e 10 amostras

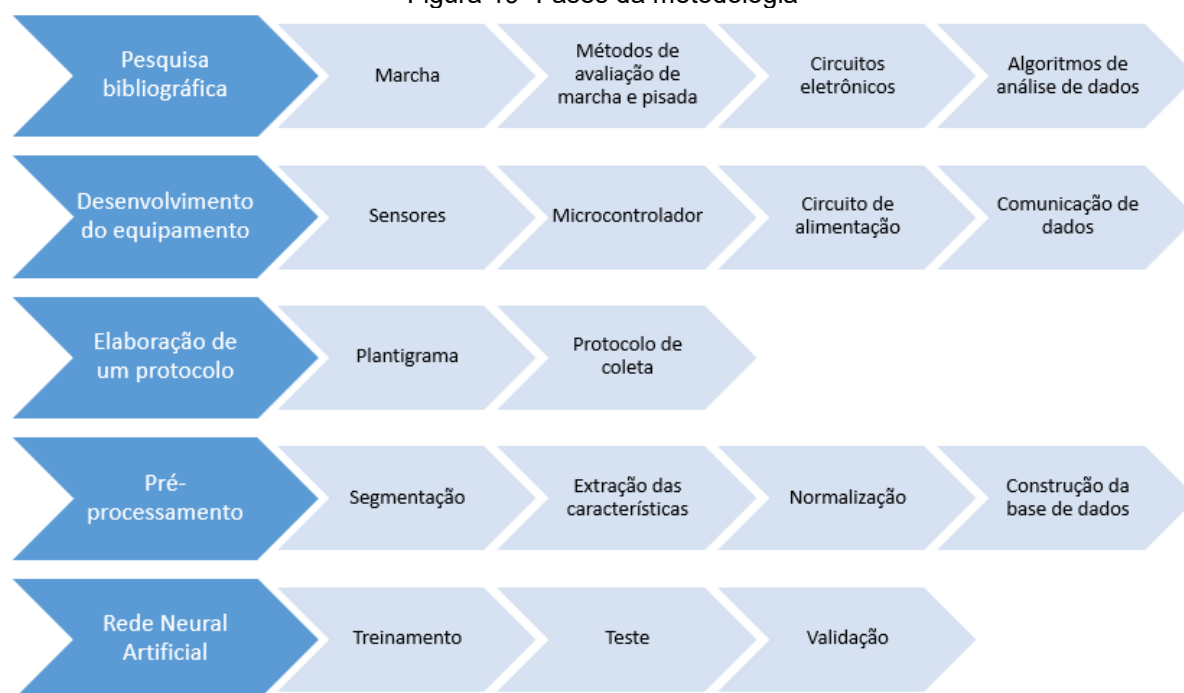


Fonte: Autoria própria

2.5.3 Metodologia

Metodologicamente este trabalho foi dividido em 6 fases: pesquisa bibliográfica, desenvolvimento do equipamento, elaboração de um protocolo experimental de coleta, pré-processamento dos dados, construção de uma base de dados e o processamento dos dados por meio da utilização de classificador baseado em RNA como apresentado na Figura 19.

Figura 19- Fases da metodologia



Fonte: Autoria própria

a) Metodologia de pesquisa bibliográfica

Foi realizada uma pesquisa sobre a marcha, reabilitação, equipamentos eletrônicos e algoritmos para análise de dados nas bases de dados do IEEE e *Science Direct*. Os trabalhos foram filtrados pelo local de publicação (jornais e revistas), organizados de maneira cronológica decrescente e por utilização de palavras chaves. Foi observado como as doenças afetam a marcha e como as características desse movimento são úteis para avaliação de desempenho durante a reabilitação, como os tipos de pisada afetam a condição de saúde (doenças e lesões), equipamentos eletrônicos utilizados na análise do tipo de pisada e movimento, além de algoritmos para classificação e análise de dados.

b) Metodologia de desenvolvimento

Para a construção de um dispositivo é necessário estabelecer as etapas que cumpram os objetivos e respeitem os requisitos que são a fácil instalação, não atrapalhe o movimento, possua uma pequena massa (em torno de 200 gramas), alimentação própria e comunicação sem fio. Por este motivo o desenvolvimento foi dividido em 6 fases, que são:

- i. Determinar o tipo de sensor;

- ii. Determinar o modelo de sensor;
- iii. Definição do microcontrolador para aquisição e comunicação dos dados;
- iv. Sistema de alimentação do circuito;
- v. Estabelecimento da comunicação dos dados; e
- vi. Reconstrução dos dados.

c) Metodologia experimental

Para a construção da base de dados utilizando o módulo para obtenção dos valores da movimentação humana é necessário definir uma metodologia experimental para a coleta de dados, organização das informações e a validação do sistema.

Para a validação foi realizado o método clássico de cinesiologia da planta do pé denominado de Plantigrafia (Figura 20). Consiste em revestir a sola do pé com algum pó/tinta e analisar as marcas que as solas dos pés imprimem em uma superfície ou tapete para este fim. Em nosso caso, utilizamos pó de gipsita, formada por sulfato (sal) de cálcio, oxigênio e enxofre, também conhecido como pó de giz de lousa escolar. Foi utilizado como superfície de avaliação, um tapete de EVA de cor preto, de 2 metros de comprimento.

Figura 20- Execução de uma análise de plantigrama




Fonte: Autoria própria

De acordo com o formato do desenho do pé (Figura 21) é possível estimar o tipo de pisada segundo o parecer do profissional de saúde (educador físico) sobre o

tipo de pisada do indivíduo obtido em avaliação dinâmica como apresentado na Figura 20.


Figura 21- Pegada resultante do plantigrama



Fonte: Autoria própria

O protocolo de coleta (Figura 22) dos dados proposto foi baseado no plantigrafia, de forma a ser realizado em um ambiente controlado devido a padronização do procedimento de coleta. Inicia-se com o indivíduo parado sobre uma linha com os pés paralelos e assim que é dado o sinal de início da coleta, o indivíduo deverá entrar em movimento e realizar o caminhar pelo trajeto de 5 metros em velocidade normal.

Figura 22- Protocolo de coleta



Fonte: Autoria própria

Com isso definir as regiões de instalação do sistema compatíveis com a análise deste estudo. Foi determinado que os módulos serão instalados na região da panturrilha para acompanhar o movimento translacional da marcha e na região do osso calcâneo devido a função da articulação do tornozelo.

A operação do sistema durante a coleta é definida por 7 fases que são:

- Instalação do dispositivo no usuário;
- Conexão da central com o PC;
- Realização da configuração do tempo de coleta e das informações de coleta;

- Realização da coleta;
- Organização dos dados;
- Filtragem; e
- Salvamento dos dados.

d) Metodologia de pré-processamento de dados e formação de base de dados

Após a coleta é necessário preparar os dados para serem processadas pela rede neural. O pré-processamento tem por objetivo condicionar o sinal e delimitar em um intervalo específico para um melhor desempenho, sendo dividido em 3 fases que são:

- Segmentação dos dados;
- Normalização; e
- Extração das características.

Foi aplicada a técnica de identificação de picos por *threshold* de maneira adaptada, pois é realizada a identificação dos vales que se caracterizam por um pico invertido. O comportamento do movimento que é cíclico, permite afirmar que o fim de uma amostra é o início de outra. Sendo assim os vales abaixo de um limiar denotam os pontos que devem ser segmentados em todos os eixos e esses valores são alocados em matrizes até que outro limiar seja detectado e inicie a próxima amostra.

A normalização é realizada em dois estágios, tanto antes como depois da extração das características. Primeiramente é realizada uma transformação linear (Equação 4) e, após, o método z-score (Equação 5), a fim de delimitar em um intervalo compatível com o da função de ativação empregado pela rede neural.

Foram calculadas as características DASDV, máximo, mínimo, MAV, RMS, SSI e WL como apresentados pelas suas respectivas equações anteriormente para todos os eixos do acelerômetro e giroscópio.

A população analisada durante o estudo para construção da base de dados foi composta por 7 indivíduos do sexo masculino e 2 indivíduos do sexo feminino, com uma média de idade de 24,8. A coleta de dados foi acompanhada por um educador físico a fim de fornecer o tipo de pisada de cada indivíduo. Esses constituem a base de dados utilizada neste estudo.

A aplicação dos equipamentos a fim de coletar dados no público englobado pelo estudo foi submetida à aprovação ao Comitê de Ética em Pesquisa (CEP), obtendo parecer favorável. O Certificado de Apresentação para Apreciação Ética (CAAE) sob o número 66548217.6.0000.0105.

e) Metodologia da RNA

Após a construção da base de dados foi definido uma metodologia de verificação com base na identificação e interpretação do uso de classificador para a identificação do tipo de pisada, baseado em 3 passos:

- Definir os critérios;
- Executar a RNA; e
- Avaliar os resultados obtidos.

A arquitetura utilizada foi a MLP que é umas das arquiteturas mais conhecidas e permite a classificação de padrões. O k-fold é definido com 5 participações tendo como objetivo evitar o sobre-treinamento e testar possíveis topologias. São analisados o número de camada, neurônios e a taxa de acerto de teste para a obtenção da melhor topologia para cada característica.


Os critérios da RNA foram estabelecidos utilizando a taxa de aprendizagem em 0,01, o critério de parada é a quantidade máxima de 10.000 interações, precisão do erro do quadrático médio de 10^{-6} e o valor máximo de 100 neurônios e no máximo de 1 camadas escondidas.

f) Metodologia de análise dos resultados.

Para analisar os dados, utilizaram-se duas ferramentas: Boxplot e Matriz de confusão.

O *boxplot* (Figura 23) é uma ferramenta que permite a visualização a distribuição dos dados apresentando a localização, dispersão, assimetria por meio da média e mediana e identificação de valores extremos, sendo uma ferramenta gráfica robusta (HUBERT; VANDERVIJREN, 2008). Ele é constituído por uma caixa em formato retangular para representar o horizonte de distribuição, quartis que são divisões apresentadas dentro da caixa, a média representada por uma cruz, a haste ou T representam os limites inferior e superior e os valores atípicos (*outliers*) que são valores fora do horizonte (NETO *et al.*, 2017).

Figura 23- Estrutura básica do boxplot



Fonte: (NETO *et al.*, 2017)

A matriz de confusão (Figura 24) permite analisar de qual forma foram classificadas as amostras identificando também quando ocorre um falso positivo em qual classe ele foi alocado. A matriz associa os as categorias (linhas) com os resultados (colunas) apresentando a assertividade do classificador do obtido com o esperado (HELOU; NOVAES, 2005).

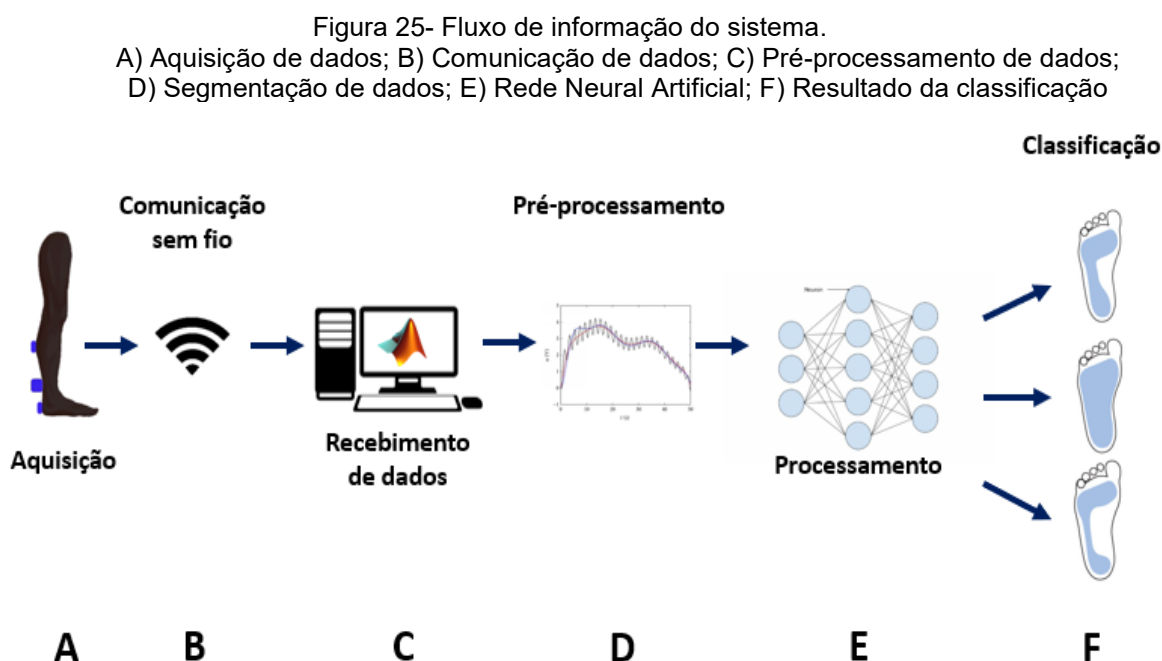
Figura 24- Exemplo de matriz de confusão

		Obtido	
		Positivo	Negativo
Esperado	Positivo	Verdadeiro positivo	Falso negativo
	Negativo	Falso positivo	Verdadeiro negativo

Fonte: Autoria própria

3 DESENVOLVIMENTO

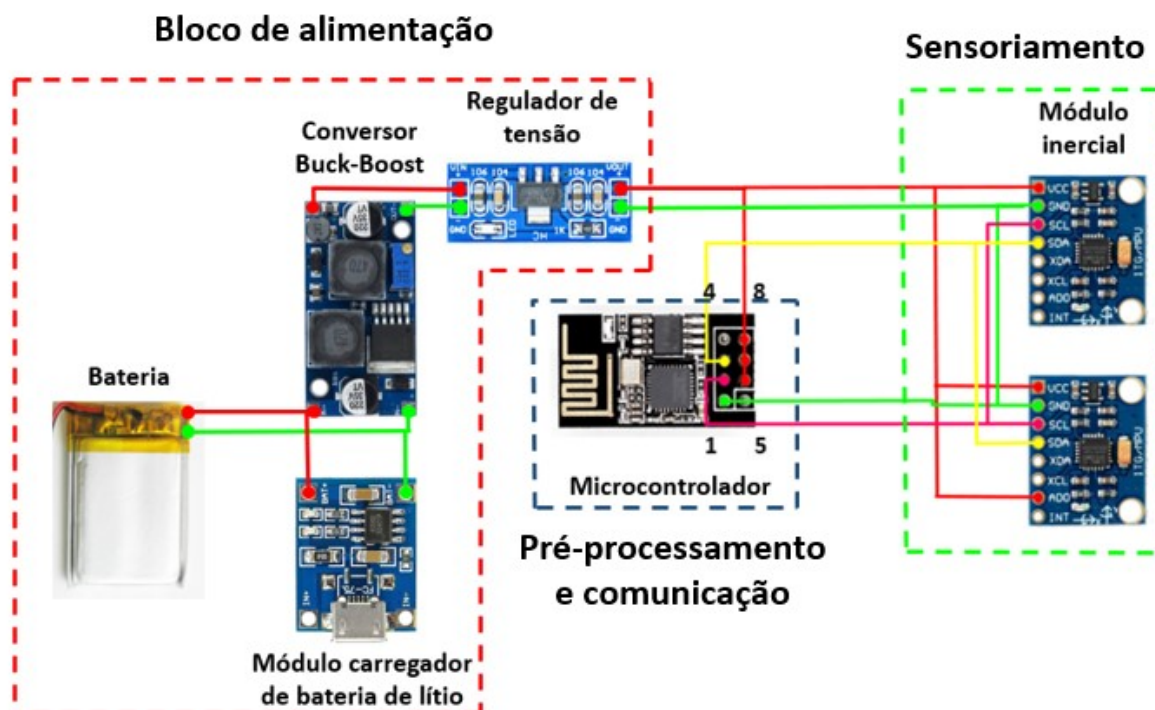
Este trabalho possui diversas etapas de desenvolvimento como: *Hardware* para aquisição, *software* para pré-processamento, processamento, identificação dos sinais e armazenamento de dados. O fluxo de informações é apresentado na Figura 23 a fim de ilustrar a sequência das etapas do desenvolvimento.



Fonte: Autoria própria

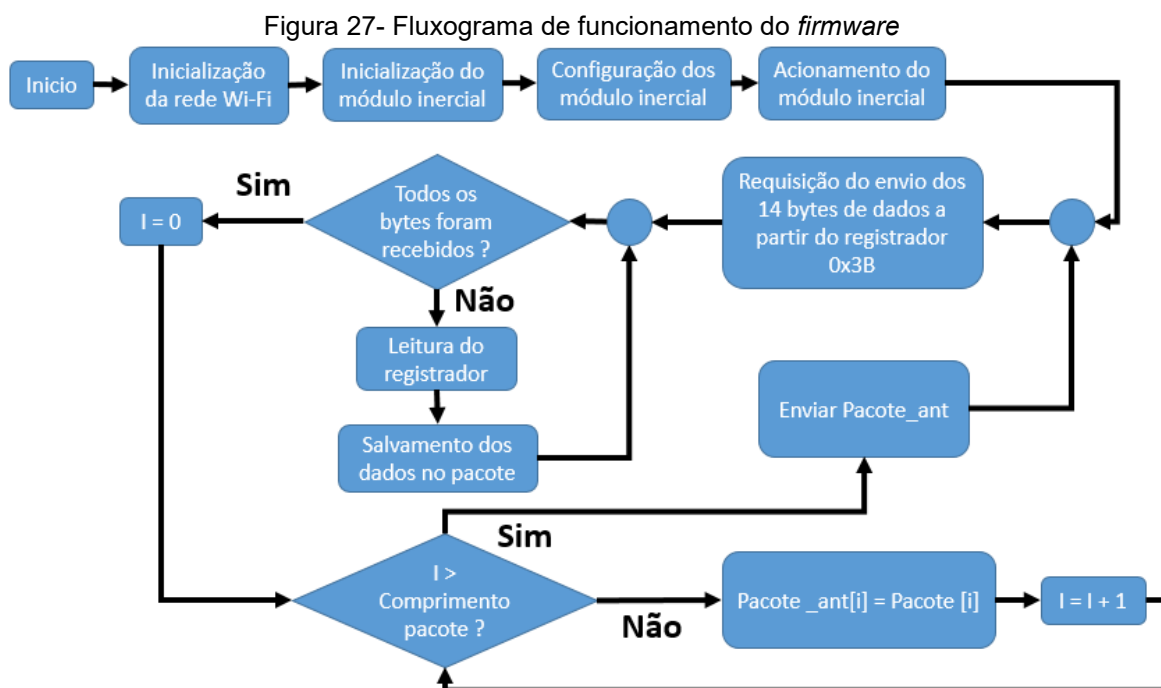
Primeiramente foi desenvolvido o *hardware* apresentado pela Figura 24, em que podemos dividir em alimentação e aquisição de dados. A alimentação tanto dos sensores quanto do microcontrolador é realizado na tensão de 3,3 V. Foi utilizado para a alimentação bateria de íon-lítio de 3,7 V, um conversor Buck-Boost para elevação da tensão, um regulador de tensão AMS1117 para estabelecer a faixa de tensão adequada para a operação dos elementos, além de realizar o isolamento do indivíduo da rede de alimentação elétrica.

Figura 26- Esquemático do modulo de aquisição



Fonte: Autoria própria

O *firmware* inicia a comunicação sem fio configurando o dispositivo como *Access Point*, estabelece o endereço de IP, *gateway*, a máscara de rede, o nome da rede, senha e define a porta para envio das informações. Os módulos inerciais são iniciados definindo as saídas digitais utilizadas no protocolo I²C, e assim inicia a transmissão no endereço desejado. Após a inicialização e estabelecimento da comunicação I²C são alterados os registradores de configuração do giroscópio e do acelerômetro. São requisitadas pelo microcontrolador 14 bytes iniciando pelo registrador 0x3B, sendo tais bytes referentes ao sensor de temperatura desconsiderados. Cada par de byte pertence a um eixo do acelerômetro e do giroscópio e são alocados em um pacote e, assim, que esse pacote tiver o comprimento esperado, os dados são enviados via Wi-Fi para um computador. O fluxo de informações é apresentado pela Figura 25.



Fonte: Autoria própria

Uma requisição de dados é realizada a uma frequência de 100 Hz, e o comprimento do pacote é de 10 aquisições, sendo transmitido um pacote via protocolo Wi-Fi™ para o computador conectado à rede. Os dados são recebidos pelo computador, passados para etapa de filtragem para atenuação dos ruídos e a etapa de armazenados em arquivo MATLAB (.mat) no próprio dispositivo. Os arquivos são identificados pelo nome do indivíduo, número do teste e perna que o equipamento está disposto.

Após a coleta das informações os dados são pré-processados e têm as características extraídas de cada amostra obtida. Isso permite que as informações estejam elegíveis para entradas da RNA para identificação e classificação de padrões.


No algoritmo da RNA os dados são particionados em três conjuntos: treinamento, validação e teste. Após o treinamento e validação da rede é empregado o teste, o qual utiliza o conjunto de entradas nunca apresentada antes e comparada com as saídas desejadas permitindo assim contabilizar os acertos.

3.1 MÓDULO DE AQUISIÇÃO DE DADOS

Foi construído um sistema (Figura 26) modular para cada perna, em que consiste na central responsável pela alimentação dos sensores, recebimento e envio

de informação, enquanto são empregados dois módulos sensores por perna para a captação dos dados.

Figura 28- Ligação entre os módulos e o microcontrolador



Fonte: Autoria própria

O microcontrolador escolhido é o modelo ESP8266 no formato ESP-01 por possuir uma dimensão reduzida, comunicação sem fio e interface de comunicação I²C.

O sensor utilizado foi o MPU6050, o qual permite a obtenção dos valores do acelerômetro e do giroscópio utilizando o protocolo de comunicação I²C para a transmissão das grandezas analisadas. São obtidos 12 bytes referentes aos três eixos do acelerômetro e do giroscópio. Os módulos inerciais possuem por padrão o endereço (0x68), logo é necessário utilizar o pino AD0 em nível lógico alto que permite alterar o bit menos significativo do endereço alterando para (0x69). O fabricante fornece os registradores responsáveis pela configuração das informações do módulo como o fundo de escala e Sensibilidade do fator de escala, tanto para o acelerômetro quanto para o giroscópio.


3.2 PROCEDIMENTO DE AQUISIÇÃO DE DADOS

O dispositivo é composto por três componentes, sendo a central e dois módulos sensores instalados na perna do indivíduo, como apresentado na Figura 27. Os módulos sensores são instalados na fase posterior do osso calcâneo e no músculo gastrocnêmio. A central é instalada entre os dois módulos sensores na região do tendão calcâneo. A má instalação é considerada quando os dispositivos não são instalados nas regiões definidas. Os módulos sensores devem estar alinhados paralelamente ao solo, pois quanto mais alterar a posição dos eixos mais será alterado

a resposta. Os sensores utilizam os seus próprios corpos como referência, o que altera a análise das informações.

Para este protótipo, algumas das limitações estiveram relacionadas à coleta de dado dos dispositivos instalados nas duas pernas, em função do sincronismo e conexão com computador. Assim, para simplificação, cada conjunto de sensores deve se conectar a um computador fazendo com que atualmente sejam necessários dois computadores para realizarem as aquisições de ambas as pernas e a configuração dos sensores que pode não ser suficiente para a aquisição de outros tipos de movimento com uma maior frequência.

Figura 29- Posicionamento do sistema no usuário



Fonte: Autoria própria

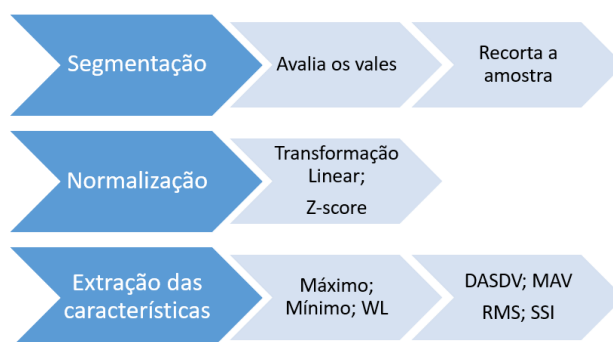
No início de cada coleta foi obtido a identificação e as informações sobre o indivíduo.

Foram realizadas 214 aquisições de dados totalizando 2140 segundos de informação caminhando em linha reta e utilizando o dispositivo com 9 indivíduos, construindo-se assim a base de dados total com 642 amostras para cada pé a serem classificados de forma separada neste estudo. Cada aquisição é composta por 10 segundos de caminhada o qual é estratificada para obtenção das amostras obtendo um tamanho específico de acordo com o ciclo de marcha. O profissional de saúde identificou 5 pisadas pronadas, 7 pisadas supinada e 6 pisadas neutras.

3.3 PRÉ-PROCESSAMENTO DOS DADOS

Os indivíduos forneceram informações sobre a marcha, mas o comprimento da passada de cada um é diferente bem como a velocidade e as propriedades anatômicas. Por isso, foram utilizadas 3 fases para realizar o pré-processamento das informações, como apresentado na Figura 30.

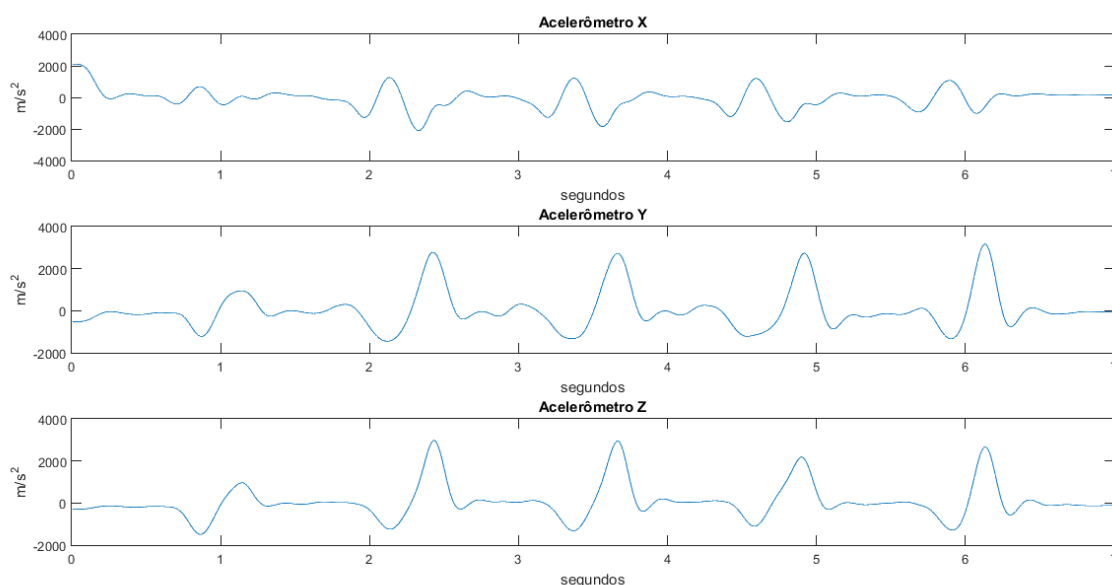
Figura 30- Etapas de pré-processamento



Fonte: Autoria própria

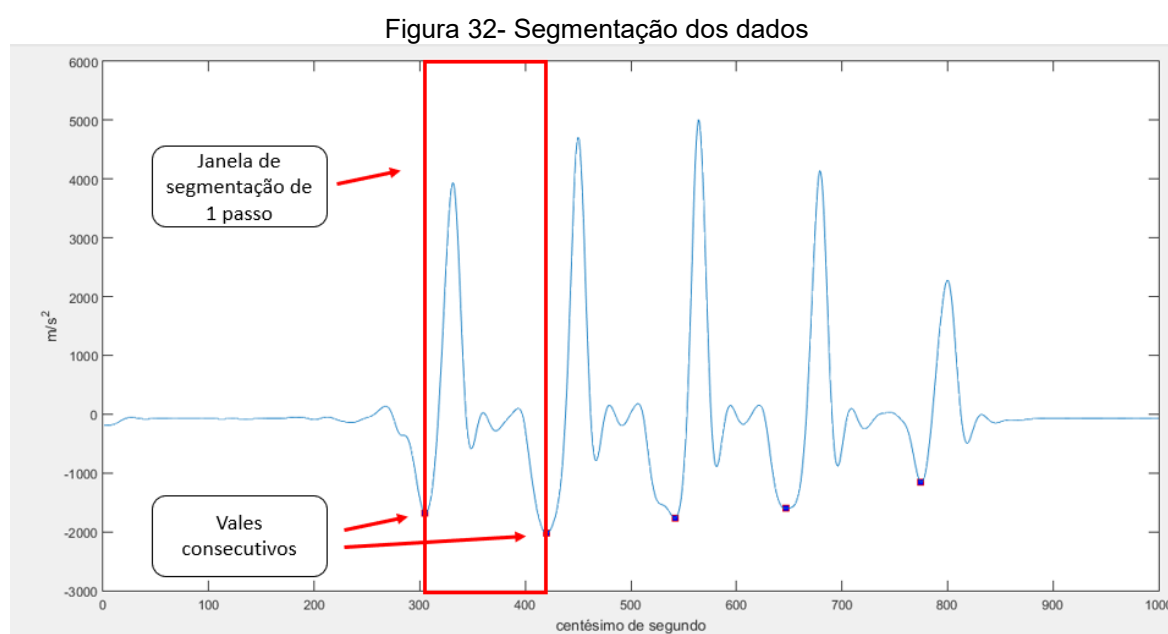
Todos os eixos dos sensores necessitam ser pré-processados, que consiste na segmentação das informações, ou seja, dividir as pisadas dos indivíduos. Na Figura 29 são apresentadas as informações de um dos quatro sensores mostrando a variação da grandeza dos eixos do acelerômetro durante a realização do movimento.

Figura 31- Gráficos com os dados de uma coleta do pé esquerdo do acelerômetro 1.



Fonte: Autoria própria

Para a segmentação dos dados, foi utilizado como base o eixo z do sensor disposto no calcâneo. Foram identificados os vales do movimento característico da marcha. Notou-se que ele denota o movimento transversal da marcha, em que o pico negativo representa o início da passada e o fim é denotado pelo próximo ciclo da passada. Assim, o tempo entre dois vales consecutivos delimitam a duração de cada passo para compor uma amostra, conforme ilustrado e destacado na Figura 32.



Fonte: Autoria própria

Cada passada apresenta diferentes intervalos de tempo, sendo alocados em vetores contendo os dados brutos. Após a segmentação, foi aplicada a etapa de extração de características, a fim de se obter informações relacionadas as amostras.

Após a segmentação realizou-se a normalização aplicando a Equação 4, a fim de permitir que os dados estejam dentro de um intervalo que propicie uma melhor taxa de acerto. Foram escolhidas as características de domínio no tempo devido a rápida e fácil implementação, são largamente utilizadas nas áreas de pesquisa e não necessita realizar transformações. Em seguida, foram extraídas as características: DASDV, máximo, mínimo, MAV, RMS, SSI e WL. Após, os dados foram novamente normalizados pelo método z-score e submetidos ao classificador baseado em RNA do tipo MLP.

3.4 IMPLEMENTAÇÃO DA REDE NEURAL

A aplicação da RNA é dividida em 3 etapas que são: treinamento, validação e teste. O algoritmo foi utilizado no *software* MATLAB R2018b, devido a facilidade de implementação e compatibilidade com os arquivos da base de dados. O treinamento é iniciado com a geração de pesos sinápticos aleatoriamente positivos. O ajuste dos pesos é realizado utilizando a regra de Delta generalizada, com o *backpropagation* do erro. As funções de ativação utilizadas foram a logística e a tangente hiperbólica apresentadas nas Equações 13 e 14, respectivamente. O número de neurônios é alterado por um passo de 5, com no máximo 100 por camada escondida e no máximo 2 camadas escondidas.

A base de dados permite ser reestruturada para avaliar os sinais proveniente de cada eixo de cada sensor, mas o conjunto amostral utilizado é composto pelos sinais de 2 sensores inerciais com os sinais dos 12 eixos para cada perna, formando assim duas bases de dados que serão avaliadas separadamente. Os conjuntos são divididos em 80% para treinamento e validação, enquanto 20% é separado para ser utilizado para teste. Foi utilizado a técnica *earlystopping*, que consiste na interrupção do algoritmo de treinamento mesmo que a precisão e o número máximo de interações não sejam alcançados denotando assim um ponto mínimo do erro quadrático médio.

O algoritmo ao testar as topologias candidatas salva os melhores resultados em relação a topologia, número de neurônios, erro de treinamento e a taxa de acerto. A taxa de acerto é o poder de generalização da mesma.

Com isso são obtidas as informações salvas e gerados gráficos boxplot e matrizes de confusão para todas as características permitindo analisar graficamente variáveis estatísticas e também avaliar o comportamento de classificação do conjunto de validação.

4 RESULTADOS

Foi proposto um sistema vestível capaz de classificar o tipo de pisada com base na utilização de sensores inerciais. Para isso foi desenvolvido o circuito de aquisição de dados inerciais, bem como os *softwares* capazes de receber, pré-processar e classificar as informações.

Foram realizados 15 treinamentos por característica utilizando o classificador neural. A base de dados compostas por 642 amostras e 12 eixos para cada característica, sendo devidamente rotuladas. Para a etapa de treinamento e validação foram utilizadas 80% das amostras e os demais 20% foram separadas aleatoriamente para serem utilizadas para teste.

Dos 15 treinamentos selecionados, a melhor atuação para cada uma das características é apresentada na Tabela 13 e 14. As taxas de acertos obtidas, os erros quadráticos médios (E_{qm}) alcançados durante o teste, as topologias e os totais de interações para o pé direito e esquerdo, também são mostrados.

Tabela 13- Melhores resultados do treinamento para análise do pé direito

	Taxa de acerto (%)	Interação	Neurônios na camada escondida	E_{qm}
DASDV	99,22	7334	80	0,16
Máximo	99,22	8189	15	0,10
Mínimo	99,22	6485	20	0,06
MAV	82,95	7209	65	0,26
RMS	96,12	6908	90	0,15
SSI	58,91	468	15	0,60
WL	98,45	5419	45	0,06

Fonte: Autoria própria

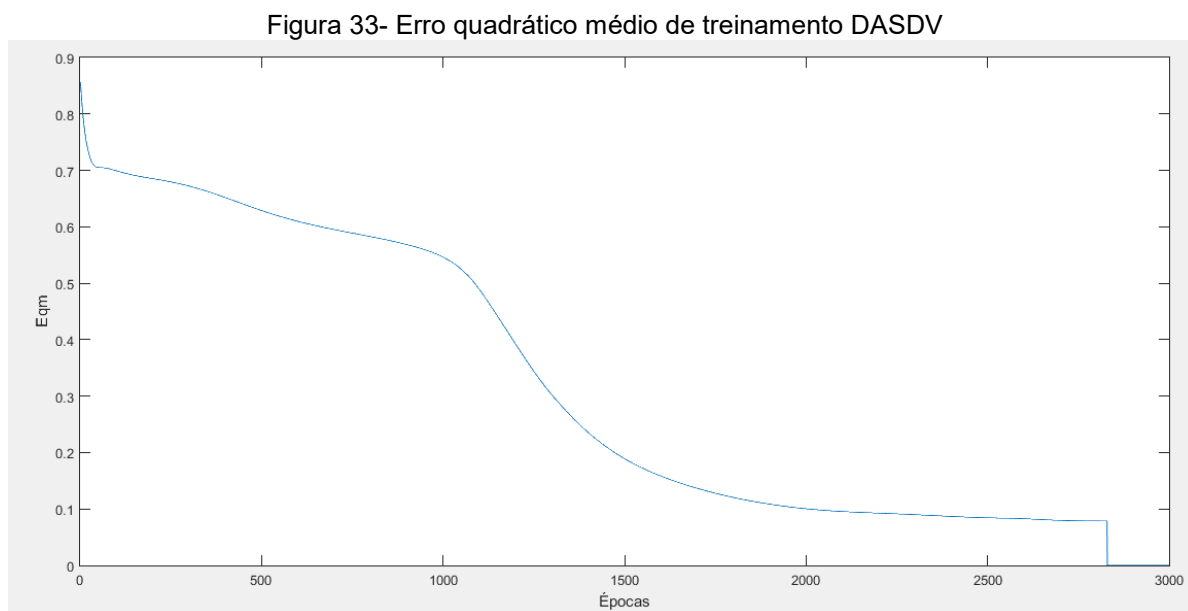
Tabela 14- Melhores resultados do treinamento para análise do pé esquerdo

	Taxa de acerto (%)	Interação	Neurônios na camada escondida	E_{qm}
DASDV	99,22	9712	35	0,04
MAX	99,22	8513	25	0,04
MIN	99,22	6050	20	0,14
MAV	91,47	6571	80	0,13
RMS	98,45	8635	40	0,06
SSI	65,89	313	15	0,54
WL	99,22	7575	70	0,03

Fonte: Autoria própria

O erro quadrático médio do conjunto de treinamento obtido por meio do método do gradiente ótimo permite observar o avanço do treinamento até atingir o regime estacionário como por exemplo o apresentado na Figura 33 da característica

DASDV o qual decresceu até atingir o critério de parada e não precisou utilizar o limite de interações definidos para o treinamento.




Fonte: Autoria própria

É possível observar que o algoritmo convergiu o resultado na interação 2.829. Após esse momento, o erro médio quadrático apresentado na validação começa a ascender e não foi necessário a utilização máxima de interações (10.000).

Para uma primeira análise dos dados, utiliza-se a ferramenta gráfica *boxplot*. Na Figura 34, pode-se verificar que as características que não apresentaram variação com relação a taxa de acerto do treinamento foram a máxima, mínima e WL. A característica DASDV teve uma distribuição simétrica, ou seja, a mediana é igual a média e não possuindo nenhum *outlier*. A característica MAV teve uma distribuição assimétrica em que a média foi inferior a mediana, mas com baixa variação e sem a presença de *outlier*. A característica RMS também possui uma distribuição assimétrica com média superior, mas com pouca baixa variação possuindo uma amostra *outlier* que está acima do limite máximo. A característica SSI possui distribuição assimétrica com média superior a mediana sem a presença de *outlier*.

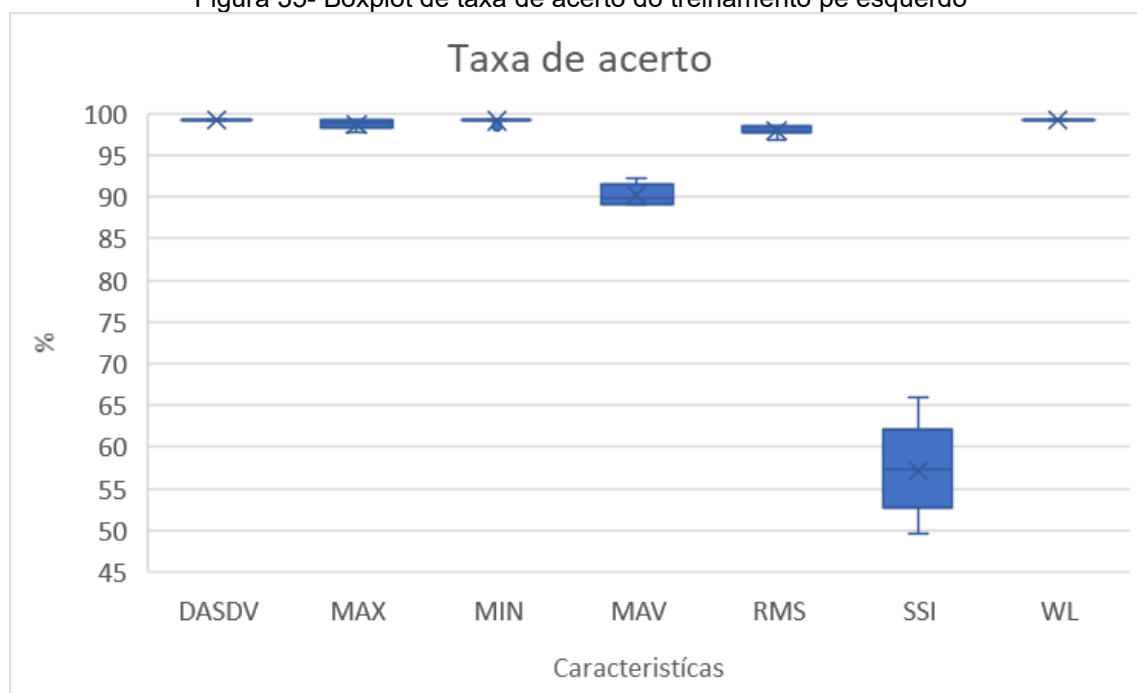
Figura 34- Boxplot de taxa de acerto do treinamento pé direito



Fonte: Autoria própria

O *boxplot* da Figura 33 apresenta as características que não possuem variação com relação a taxa de acerto do treinamento foram a DASDV e WL. A característica MAV teve uma distribuição assimétrica, ou seja, a mediana é inferior à média e não possui nenhum *outlier*. A característica máxima teve uma distribuição assimétrica em que a média foi inferior a mediana, mas com baixa variação e sem a presença de *outlier*. A característica RMS também possui pouca variação sem *outlier*. A característica SSI possui distribuição assimétrica com média inferior a mediana sem a presença de *outlier*. A característica mínima possui a média fora dos limites e possui um *outlier* resultado de uma amostra diferente das demais.

Figura 35- Boxplot de taxa de acerto do treinamento pé esquerdo



Fonte: Autoria própria

A Figura 36 traz as matrizes de cada característica para o pé direito em que a sensibilidade é a quantidade de amostras que foram classificadas de maneira correta, ou seja, a relação entre os verdadeiros positivos comparado aos falsos negativos enquanto a especificidade é a relação entre os verdadeiros positivos comparando aos falsos positivos. Como pode se observar as características DASDV e máximo atingiram o maior desempenho possuindo um único falso negativo, enquanto a característica SSI teve o pior desempenho, pois as amostras foram classificadas como pisada supinada de maneira errônea.

A Figura 37 traz as matrizes de cada característica do pé esquerdo as características DASDV, máximo, mínimo e WL atingiram o maior desempenho possuindo uma única amostra classificada de maneira errada. Assim como o pé direito a pior característica foi o SSI teve o pior desempenho, pois as amostras foram classificadas em classes distintas principalmente como pronado de maneira errônea.

Figura 36- Matriz de confusão para o pé direito

DASDV Direita					Máximo Direita						
		Obtida			Sensibilidade			Obtida			Sensibilidade
		S	N	P		S	N	P	Sensibilidade		
Desejada	S	44	0	0	100%	Desejada	S	44	0	0	100%
	N	0	57	0	100%		N	1	56	0	98,25%
	P	0	1	27	96,43%		P	0	0	28	100%
Especificidade		100%	98,28%	100%		Especificidade		97,78%	100%	100%	

MAV Direita					Mínimo Direita						
		Obtida			Sensibilidade			Obtida			Sensibilidade
		S	N	P		S	N	P	Sensibilidade		
Desejada	S	38	6	0	86,36%	Desejada	S	44	0	0	100,00%
	N	9	45	3	78,95%		N	1	56	0	98,25%
	P	0	5	23	82,14%		P	0	0	28	100%
Especificidade		80,85%	80,36%	88,46%		Especificidade		97,78%	100%	100%	

RMS Direita					SSI Direita						
		Obtida			Sensibilidade			Obtida			Sensibilidade
		S	N	P		S	N	P	Sensibilidade		
Desejada	S	44	0	0	100%	Desejada	S	27	14	3	61,36%
	N	0	54	3	94,74%		N	16	38	3	66,67%
	P	0	1	27	96,43%		P	13	4	11	39,29%
Especificidade		100%	98,18%	90%		Especificidade		48,21%	67,86%	64,71%	

WL Direita					
		Obtida			Sensibilidade
		S	N	P	
Desejada	S	42	0	2	95,45%
	N	0	57	0	100%
	P	0	0	28	100%
Especificidade		100%	100%	93,33%	

Fonte: Autoria própria

Figura 37- Matriz de confusão para o pé esquerdo

DASDV Esquerda					RMS Esquerda						
		Obtida			Sensibilidade			Obtida			Sensibilidade
		S	N	P		S	N	P	Sensibilidade		
Desejada	S	40	0	0	100%	Desejada	S	39	1	0	97,50%
	N	0	25	0	100%		N	0	24	1	96%
	P	1	0	63	98,44%		P	0	0	64	100%
Especificidade		97,56%	100%	100%		Especificidade		100%	96%	98,46%	

MAV Esquerda					WL Esquerda						
		Obtida			Sensibilidade			Obtida			Sensibilidade
		S	N	P		S	N	P	Sensibilidade		
Desejada	S	32	2	6	80%	Desejada	S	40	0	0	100%
	N	1	23	1	92%		N	1	24	0	96%
	P	0	0	64	100%		P	0	0	64	100%
Especificidade		96,97%	92%	90,14%		Especificidade		97,56%	100%	100%	

Máximo Esquerda					SSI Esquerda						
		Obtida			Sensibilidade			Obtida			Sensibilidade
		S	N	P		S	N	P	Sensibilidade		
Desejada	S	39	1	0	97,50%	Desejada	S	25	0	15	62,50%
	N	0	25	0	100%		N	4	2	19	8,0%
	P	0	0	64	100%		P	6	0	58	90,63%
Especificidade		100%	96,15%	100%		Especificidade		71,43%	100%	63,04%	

Mínimo Esquerda					
		Obtida			Sensibilidade
		S	N	P	
Desejada	S	39	0	1	97,50%
	N	0	25	0	100%
	P	0	0	64	100%
Especificidade		100%	100%	98,46%	

Fonte: Autoria própria

Na Tabela 15 é apresentado a acurácia do conjunto amostral de teste obtidos pelas características os quais representam a assertividade da classificação. A perna esquerda apresenta maior assertividade na classificação, atingindo melhores taxas quando se comparado a perna direita.

Tabela 15- Acurácia da etapa de validação para as diferentes características, para os dois pés.

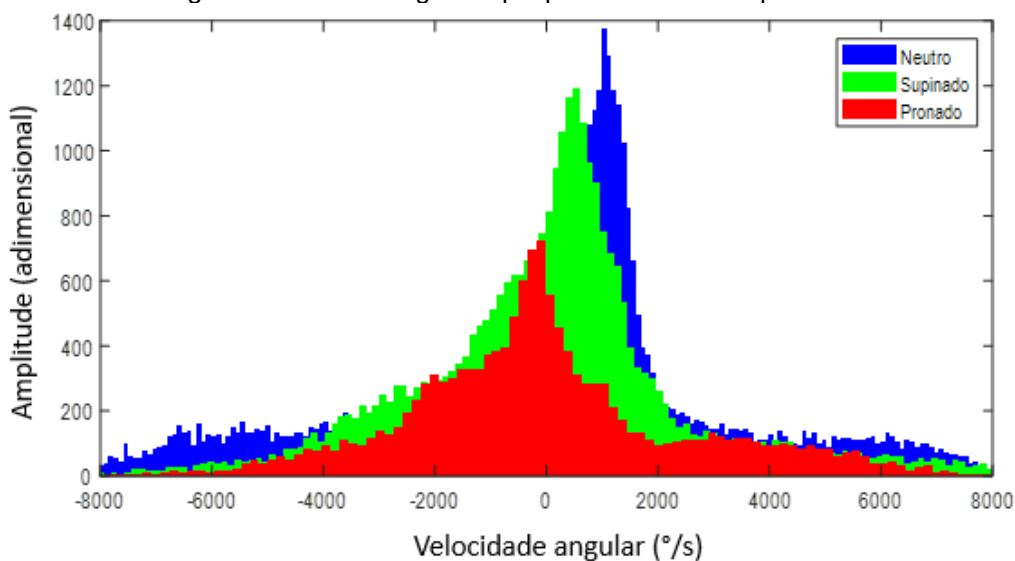
<i>Característica</i>	Pé direito	Pé esquerdo
DASDV	99,22%	99,22%
Máximo	99,22%	99,22%
Mínimo	99,22%	99,22%
MAV	82,17%	92,25%
RMS	96,90%	98,45%
SSI	58,91%	65,89%
WL	98,45%	99,22%

Fonte: Autoria própria

A escolha da topologia ideal para a classificação do tipo de pisada se dará pela acurácia, em que as melhores topologias são das pelas características DASDV, máxima e mínima, que atingiram 99,22% de acerto para o pé direito. Para o pé direito as características foram DASDV, máximo, mínimo e WL que atingiram 99,22%. A topologia é dada pela utilização de 12 neurônios na camada de entrada, nas camadas escondidas conforme apresentado nas Tabelas 12 e 13 para cada característica e 3 neurônios na camada de saída que serviram para a indicação da classe em que a amostra pertence.

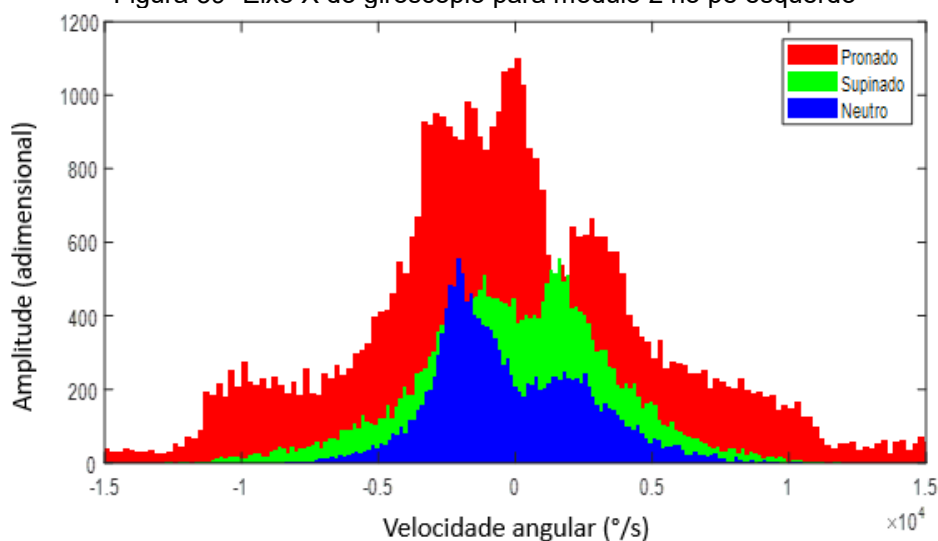
O histograma ajustado a uma função de densidade normal permite uma distribuição de probabilidade para a série de dados de um evento variável no tempo tendo por objetivo avaliar a frequência de ocorrência da magnitude do fenômeno. Nas Figuras 38 e 39 é possível observar diferentes distribuições para cada categoria de classificação e com isso notar a separabilidade entre os dados para cada grupo.

Figura 38- Eixo X do giroscópio para módulo 1 no pé direito



Fonte: Autoria própria

Figura 39- Eixo X do giroscópio para módulo 2 no pé esquerdo



Fonte: Autoria própria

Ao analisar a classificação dos tipos de pisada para cada pé a partir dos dados provenientes dos sensores, e segundo os resultados apresentados pelas análises, observa-se que os resultados obtidos pela RNA demonstram a capacidade necessária para tal aplicação.

De modo a realizar uma comparação de resultados com os trabalhos mais próximos encontrados na literatura, foram separados para comparação 4 de 25 trabalhos que foram apresentados na revisão bibliográfica e que tinham por objetivo contextualizar as técnicas de sensoriamento ou construção de dispositivos com aplicação em ambiente de reabilitação ou hospitalar e empregaram técnicas para

classificação de movimentos ou auxílio de diagnóstico. Em especial, os trabalhos apresentados na Tabela 16 são caracterizados por empregar técnicas de classificação e resultados obtidos por meio de dados coletados em condições reais.

Tabela 16- Comparação de desempenho

Referência	Objetivo	Método	Acurácia
Este trabalho	Classificar o tipo de pisada	MLP	99,22%
(POTLURI <i>et al.</i> , 2019)	Segmentação da marcha humana	SVM, K-means	94,07%; 84,34%
(JEONG; TRUONG; CHOI, 2017)	Classificação de movimento	SVM; KNN	95,20%; 93,3%
(DESCHAMPS <i>et al.</i> , 2016)	Classificação de pacientes com diabetes usando pressão plantar	BDFP	98,10%
(HYO-SEON JEON <i>et al.</i> , 2008)	Classificação do tipo de marcha em pacientes com Parkinson	SVM	91,73%

Fonte: Autoria propria

As semelhanças entre os trabalhos e o estudo como apresentados na Tabela 16 foram a utilização de dispositivos para coleta de dados decorrentes da marcha, a utilização de arquiteturas de classificação de dados e os objetivos que não se concentram em avaliar a marcha em si, mas sim em ambientes que a marcha é um meio de obtenção de parâmetros de avaliação. As principais diferenças se enquadram nos métodos expostos, como o tipo de sensor empregado para a coleta dos dados em que esse estudo empregou somente sensores inerciais enquanto os demais empregaram sensores de pressão plantar e as arquiteturas de classificação de dados em que os demais trabalhos utilizaram métodos de clusterização enquanto este estudo empregou o uso da MLP.

Percebe-se pelos resultados apresentados, é possível a utilização somente de sensores inerciais para a avaliação de tipo de pisada sem a avaliação de pressão plantar.

Com base nos valores de acurácia obtidos pelo estudo comparados as taxas de acerto dos trabalhos contidos na Tabela 16 é possível verificar que a taxa de acerto

deste estudo alcançou um valor superior aos demais. O dispositivo também permite uma fácil instalação, não atrapalha o movimento durante sua utilização e permite a coleta de dados sem fio e utilização do sistema de bateria oferecendo maior liberdade. Outro ganho é a não necessidade de personalização, pois o dispositivo é adaptável para diferentes tipos de pessoas.

5 CONCLUSÃO

Este trabalho teve como objetivo o desenvolvimento de um sistema utilizando sensores inerciais para a classificação do tipo de pisada, para aplicação em ambientes externo aos ambientes clínicos laboratoriais para acompanhamento e auxilia na identificação do tipo de pisada.

O módulo central recebe os sinais dos sensores e realiza o empacotamento e o envio ao computador através de uma comunicação Wi-Fi™, a uma taxa de 100 Hz, em que não houve nenhuma perda de pacote, se mostrando suficiente para a análise de movimento e a reconstrução do sinal.

Alguns benefícios apresentados são a alimentação por baterias de 3,7V, que permitem a portabilidade do protótipo, não é necessário a personalização como acontece as palmilhas (tamanhos diferentes), os sensores não sofrem deterioramento decorrente da movimentação como sensores de pressão, fácil instalação e não é descartável podendo assim ser um substituto dos sistemas *in-shoe* para este fim.

A metodologia experimental proposta permitiu que todos os indivíduos que participaram do estudo seguissem rigorosamente as diretrizes que resultou na padronização da coleta. O processo foi acompanhado pelo profissional de saúde capacitado que foi responsável por avaliar cada um dos voluntários, possibilitando a obtenção das saídas desejadas para aplicação na RNA.

Com a coleta dos dados por meio do dispositivo, do *software* para recebimento, organização dos dados, filtragem e salvamento dos dados e com a aplicação da metodologia experimental foi possível realizar a etapa de pré-processamento das características para entrada dos dados na RNA. O desenvolvimento foi baseado na escolha da MLP como arquitetura para classificar os tipos de pisada, em que os resultados apresentados pela validação cruzada para a escolha da melhor topologia e a melhor acurácia para cada característica analisada, em que se destacaram diversas para ambos os pés atingindo 99,22%.

Por meio da análise dos sinais obtidos de sensores inerciais e da taxa de acertos apresentadas na utilização do classificador, conclui-se que o sistema desenvolvido fornece informações capazes de identificar o tipo de pisada, com base nas informações de movimento da marcha.

Desta forma, este sistema pode substituir sistemas de palmilhas e / ou plataformas que tenham como objetivo principal a identificação do tipo de pisada, trazendo como benefício o custo inferior de fabricação, bem como a facilidade de instalação para análise tanto em laboratório quanto em ambiente aberto.

Para trabalhos futuros, sugere-se utilizar outras ferramentas de inteligência computacional para classificação, como o de clusterização e a validação do sistema utilizando um sistema comercial para correlação com a pressão plantar e comparar com os resultados obtidos aqui.

REFERÊNCIAS

- AL SHALABI, L.; SHAABAN, Z. Normalization as a preprocessing engine for data mining and the approach of preference matrix. *In: INTERNATIONAL CONFERENCE ON DEPENDABILITY OF COMPUTER SYSTEMS, 2006, Proceedings [...]*, Szklarska Poreba: IEEE, maio 2006. Disponível em: <https://ieeexplore.ieee.org/document/4024051>. Acesso em: 18 mar. 2020
- AMENE, J. *et al.* Kinematic foot types in youth with pes planovalgus secondary to cerebral palsy. **Gait & Posture**, v. 68, p. 430-436, fev. 2019.
- ANWARY, A. R.; YU, H.; VASSALLO, M. Optimal Foot Location for Placing Wearable IMU Sensors and Automatic Feature Extraction for Gait Analysis. **IEEE Sensors Journal**, v. 18, n. 6, p. 2555-2567, 15 mar. 2018.
- BAVAN, L. *et al.* Adherence monitoring of rehabilitation exercise with inertial sensors: A clinical validation study. **Gait & Posture**, v. 70, p. 211-217, maio 2019.
- BERAVS, T. *et al.* **Development and validation of a wearable inertial measurement system for use with lower limb exoskeletons**. 2011 11th IEEE-RAS International Conference on Humanoid Robots. **Anais...** In: 2011 11TH IEEE-RAS INTERNATIONAL CONFERENCE ON HUMANOID ROBOTS (HUMANOIDS 2011). Bled, Slovenia: IEEE, out. 2011 Disponível em: <http://ieeexplore.ieee.org/document/6100914>. Acesso em: 26 out. 2018
- BORA, D. J.; KUMAR, N.; DUTTA, R. Implementation of wireless MEMS sensor network for detection of gait events. **IET Wireless Sensor Systems**, v. 9, n. 1, p. 48-52, 1 fev. 2019.
- BOSCH SENSORTEC. **BMI160 Small, low power inertial measurement unit**, 2018. Disponível em: <https://www.bosch-sensortec.com/media/boschsensortec/downloads/datasheets/bst-bmi160-ds000.pdf>. Acesso em: 17 mar. 2020
- BOSCH SENSORTEC. **BMI270 6-axis, smart, low-power inertial measurement unit for high-performance applications**, 2019. Disponível em: <https://www.bosch-sensortec.com/media/boschsensortec/downloads/datasheets/bst-bmi270-ds000-2.pdf>. Acesso em: 17 mar. 2020
- CALACHE, D. C. Caracterização de um Acelerômetro Baseado em Sistemas Microeletromecânicos. p. 90, 2013.
- CARREGANDO código de quadro e Arduino IDE. Disponível em: <https://support.office.com/pt-br/article/carregando-c%C3%B3digo-de-quadro-e-arduino-ide-a9723765-1314-49e0-a69b-bb5c3e1f628d>. Acesso em: 15 dez. 2018.
- CHANG, H.-C. *et al.* A Wearable Inertial Measurement System With Complementary Filter for Gait Analysis of Patients With Stroke or Parkinson's Disease. **IEEE Access**, v. 4, p. 8442-8453, 2016.

CHANG, J.-H. *et al.* Prevalence of flexible flatfoot in Taiwanese school-aged children in relation to obesity, gender, and age. **European Journal of Pediatrics**, v. 169, n. 4, p. 447-452, abr. 2010.

CHEN, S. *et al.* Toward Pervasive Gait Analysis With Wearable Sensors: A Systematic Review. **IEEE Journal of Biomedical and Health Informatics**, v. 20, n. 6, p. 1521-1537, nov. 2016.

COLLIN, J. *et al.* Inertial Sensors and Their Applications. In: BHATTACHARYYA, S. S. *et al.* (Eds.). . **Handbook of Signal Processing Systems**. New York, NY: Springer New York, 2013. p. 69-96.

CROSBIE, J.; BURNS, J.; OUVRIER, R. A. Pressure characteristics in painful pes cavus feet resulting from Charcot-Marie-Tooth disease. **Gait & Posture**, v. 28, n. 4, p. 545-551, nov. 2008.

CUTTI, A. G. *et al.* A simple test to assess the static and dynamic accuracy of an inertial sensors system for human movement analysis. 2006 International Conference of the IEEE Engineering in Medicine and Biology Society. In: CONFERENCE PROCEEDINGS. ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY. **Anais...** New York, NY: IEEE, ago. 2006Disponível em: <http://ieeexplore.ieee.org/document/4463153/>>. Acesso em: 10 dez. 2018

DAHLE, L. K. *et al.* Visual Assessment of Foot Type and Relationship of Foot Type to Lower Extremity Injury. **Journal of Orthopaedic & Sports Physical Therapy**, v. 14, n. 2, p. 70-74, ago. 1991.

DE COCK, A. *et al.* A functional foot type classification with cluster analysis based on plantar pressure distribution during jogging. **Gait & Posture**, v. 23, n. 3, p. 339-347, abr. 2006.

DESCHAMPS, K. *et al.* Classification of Forefoot Plantar Pressure Distribution in Persons with Diabetes: A Novel Perspective for the Mechanical Management of Diabetic Foot? **PLoS ONE**, v. 8, n. 11, p. e79924, 22 nov. 2013.

DESCHAMPS, K. *et al.* Efficacy measures associated to a plantar pressure based classification system in diabetic foot medicine. **Gait & Posture**, v. 49, p. 168-175, set. 2016.

DUDAK, P. *et al.* **Application of inertial sensors for detecting movements of the human body**. 2016 17th International Conference on Mechatronics- Mechatronika (ME). **Anais...**Praga, República Checa: dez. 2016

ELIKO. **MTN500**, 2019. Disponível em: <https://www.eliko.ee/products/inertial-motion-capture-system>. Acesso em: 17 ago. 2019

ESPRESSIV. **ESP8266EX Datasheet**, 2019. Disponível em: https://www.espressif.com/sites/default/files/documentation/0a-esp8266ex_datasheet_en.pdf. Acesso em: 26 set. 2019

FARINELLI, A. **Sistema de aquisição e classificação de dados para reconhecimento da presença das mãos do motorista no volante por redes neurais artificiais**. Ponta Grossa: Universidade Tecnológica Federal do Paraná, 22 fev. 2019.

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, abr. 2000.

HAMDAN, O. *et al.* **IoT-Based Interactive Dual Mode Smart Home Automation**. 2019 IEEE International Conference on Consumer Electronics (ICCE). **Anais...** In: 2019 IEEE INTERNATIONAL CONFERENCE ON CONSUMER ELECTRONICS (ICCE). Las Vegas, NV, USA: IEEE, jan. 2019 Disponível em: <https://ieeexplore.ieee.org/document/8661935>. Acesso em: 28 out. 2018

HAYKIN, S. **Sinais e sistemas**. Porto Alegre: Bookman, 2001.

HELOU, L. F.; NOVAES, B. C. Utilização da matriz de confusão na indicação de aparelho de amplificação sonora individual. **Distúrbios da Comunicação**, v. 17, n. 2, 2005.

HUBERT, M.; VANDERVIEREN, E. An adjusted boxplot for skewed distributions. **Computational Statistics & Data Analysis**, v. 52, n. 12, p. 5186-5201, ago. 2008.

HUDGINS, B.; PARKER, P.; SCOTT, R. N. A new strategy for multifunction myoelectric control. **IEEE Transactions on Biomedical Engineering**, v. 40, n. 1, p. 82-94, jan. 1993.

HYO-SEON JEON *et al.* **Classification of Parkinson gait and normal gait using Spatial-Temporal Image of Plantar pressure**. 2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. **Anais...** In: 2008 30TH ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY. Vancouver, BC: IEEE, ago. 2008 Disponível em: <http://ieeexplore.ieee.org/document/4650255>. Acesso em: 28 jan. 2020

INVENSENSE. **MPU-6000 and MPU-6050 Register Map and Descriptions Revision 4.2**, 19 ago. 2013. Disponível em: <https://www.invensense.com/wp-content/uploads/2015/02/MPU-6000-Register-Map1.pdf>. Acesso em: 28 out. 2019

INVENSENSE. **MPU-9250 Product Specification Revision 1.1**, 2016a. Disponível em: <https://invensense.tdk.com/wp-content/uploads/2015/02/PS-MPU-9250A-01-v1.1.pdf>. Acesso em: 17 mar. 2020

INVENSENSE. **ICM-30670 World's First Dual Interface Optical Image Stabilization (OIS) and 6-axis Motion Tracking Solution**, 2016b. Disponível em: <https://invensense.tdk.com/wp-content/uploads/2015/12/DS-000129-ICM-30670-TYP-v1.0-3.pdf>. Acesso em: 17 mar. 2020

INVENSENSE. **ICM-20649 World's First Wide-Range 6-Axis MEMS MotionTracking™ Device for Sports and High Impact Applications**, 2016c.

Disponível em: <https://invensense.tdk.com/wp-content/uploads/2016/06/DS-000192-ICM-20649-v1.0.pdf>. Acesso em: 17 mar. 2020

INVENSENSE. **MPU-6000 and MPU-6050 Product Specification Revision 3.4**, jun. 2016d. Disponível em: <https://www.invensense.com/wp-content/uploads/2015/02/MPU-6000-Datasheet1.pdf>. Acesso em: 26 set. 2019

JAIN, A.; NANDAKUMAR, K.; ROSS, A. Score normalization in multimodal biometric systems. **Pattern Recognition**, v. 38, n. 12, p. 2270-2285, dez. 2005.

JEONG, G.-M.; TRUONG, P. H.; CHOI, S.-I. Classification of Three Types of Walking Activities Regarding Stairs Using Plantar Pressure Sensors. **IEEE Sensors Journal**, v. 17, n. 9, p. 2638-2639, 1 maio 2017.

KINECT TECNOLOGIAS BIOMECÂNICAS. **Baropôdometro EPS**, 2019. Disponível em: <https://kinetec.com.br/new/project/baropodometro-eps/>. Acesso em: 17 ago. 2019

KIRKWOOD, R. N. *et al.* Análise biomecânica das articulações do quadril e joelho durante a marcha em participantes idosos. **Acta Ortopédica Brasileira**, v. 15, n. 5, p. 267-271, 2007.

LYNCH, K.; MARCHUK, N.; ELWIN, M. **Embedded computing and mechatronics with the PIC32 microcontroller**. Waltham, MA: Newnes is an imprint of Elsevier, 2015.

MAFFI, S. **Fraturas do médiopéClínica e cirurgia do pé e tornozelo**, 2019. Disponível em: <https://clinicaecirurgiadope.com.br/artigos/24?artigo=36>. Acesso em: 17 out. 2019

MAJUMDER, S.; MONDAL, T.; DEEN, M. J. A Simple, Low-Cost and Efficient Gait Analyzer for Wearable Healthcare Applications. **IEEE Sensors Journal**, v. 19, n. 6, p. 2320-2329, 15 mar. 2019.

MARTINEZ-MENDEZ, R.; SEKINE, M.; TAMURA, T. Detection of anticipatory postural adjustments prior to gait initiation using inertial wearable sensors. **Journal of NeuroEngineering and Rehabilitation**, v. 8, n. 1, p. 17, 2011.

MAUCH, M. *et al.* A new approach to children's footwear based on foot type classification. **Ergonomics**, v. 52, n. 8, p. 999-1008, ago. 2009.

MEDICAPTEURS. **WIN-TRACK**, 2019. Disponível em: <https://www.medicapteurs.com/produits/wintrack-2/>. Acesso em: 17 ago. 2019

NELSON, B. **Inertial measurement sensors improve efficiency, safety in farm equipmentOEM Off High Way**, 28 out. 2019. Disponível em: <https://www.oemoffhighway.com/electronics/sensors/article/10979955/inertial-measurement-sensors-improve-safety-in-ag-equipment>. Acesso em: 28 out. 2019

NETO, J. V. *et al.* Boxplot: um recurso gráfico para a análise e interpretação de dados quantitativos. **Revista Odontológica do Brasil Central**, v. 26, n. 76, 3 abr. 2017.

NGAMSURIYAROJ, S. *et al.* **Walking Gait Measurement and Analysis via Knee Angle Movement and Foot Plantar Pressures**. 2018 15th International Joint Conference on Computer Science and Software Engineering (JCSSE). **Anais...** In: 2018 15TH INTERNATIONAL JOINT CONFERENCE ON COMPUTER SCIENCE AND SOFTWARE ENGINEERING (JCSSE). Nakhonpathom: IEEE, jul. 2018Disponível em: <<https://ieeexplore.ieee.org/document/8457175/>>. Acesso em: 26 out. 2018

NXP SEMICONDUCTORS. **MMA7455L- $\pm 2g/\pm 4g/\pm 8g$ Three Axis Low-g Digital Output Accelerometer**, 2009. Disponível em: <<https://www.nxp.com/docs/en/data-sheet/MMA7455L.pdf>>. Acesso em: 17 mar. 2020

NXP SEMICONDUCTORS. **MMA7361LC- $\pm 1.5g$, $\pm 6g$ Three Axis Low-g Micromachined Accelerometer**, 2011. Disponível em: <<https://www.nxp.com/docs/en/data-sheet/MMA7361LC.pdf>>. Acesso em: 17 mar. 2020

NXP SEMICONDUCTORS. **MMA8452Q 3-axis, 12-bit/8-bit digital accelerometer**, 2016. Disponível em: <<https://www.nxp.com/docs/en/data-sheet/MMA8452Q.pdf>>. Acesso em: 17 mar. 2020

ONE TECHNOLOGY WAY. **ADXL- Small, Low Power, 3-Axis ± 3 g Accelerometer**, 2009. Disponível em: <<https://www.sparkfun.com/datasheets/Components/SMD/adxl335.pdf>>

Overpronation:What it is and what can you do about it. The X Brace, 6 fev. 2018. Disponível em: <<https://www.thexbrace.com/blogs/news/overpronation-what-it-is-and-what-can-you-do-about-it>>. Acesso em: 17 out. 2019

PAKALAPATI, S. S. *et al.* **A prosthetic hand control interface using ESP8266 Wi-Fi module and Android application**. 2017 International Conference on Innovations in Information, Embedded and Communication Systems (ICIIECS). **Anais...** In: 2017 4TH INTERNATIONAL CONFERENCE ON INNOVATIONS IN INFORMATION, EMBEDDED AND COMMUNICATION SYSTEMS (ICIIECS). Coimbatore: IEEE, mar. 2017Disponível em: <<http://ieeexplore.ieee.org/document/8275978/>>. Acesso em: 28 out. 2018

PAPI, E.; BO, Y. N.; MCGREGOR, A. H. A flexible wearable sensor for knee flexion assessment during gait. **Gait & Posture**, v. 62, p. 480-483, maio 2018.

Peak Analysis- MATLAB & Simulink Example. Disponível em: <<https://www.mathworks.com/help/signal/examples/peak-analysis.html>>. Acesso em: 16 dez. 2019.

PEDAR SYSTEM. **The pedar® system: The quality in-shoe dynamic pressure measuring system**, 2019. Disponível em: <<https://www.novelusa.com/index.php?fuseaction=systems.pedar>>. Acesso em: 17 ago. 2019

PHINYOMARK, A.; PHUKPATTARANONT, P.; LIMSAKUL, C. Feature reduction and selection for EMG signal classification. **Expert Systems with Applications**, v. 39, n. 8, p. 7420-7431, jun. 2012.

POTLURI, S. *et al.* **Machine Learning based Human Gait Segmentation with Wearable Sensor Platform**. 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). **Anais...** In: 2019 41ST ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE & BIOLOGY SOCIETY (EMBC). Berlin, Germany: IEEE, jul. 2019Disponível em: <<https://ieeexplore.ieee.org/document/8857509/>>. Acesso em: 28 jan. 2020

QIU, S. *et al.* Using Body-Worn Sensors for Preliminary Rehabilitation Assessment in Stroke Victims With Gait Impairment. **IEEE Access**, v. 6, p. 31249-31258, 2018.

REIS, L. P. *et al.* Invited Paper: Multimodal Interface for an Intelligent Wheelchair. In: FERRIER, J.-L. *et al.* (Eds.). **Informatics in Control, Automation and Robotics**. Cham: Springer International Publishing, 2015. v. 325p. 1-34.

REMÍGIO, D. **Interface para Equipamento de Análise da Marcha Humana utilizando Sapatos Instrumentados**. Coimbra: Universidade de Coimbra, jan. 2016.

SEO, C. AT ONLINESHOUTERCHRISTINE WRITES FOR PEOPLE WHO SEEK FOR KNOWLEDGE ABOUT *et al.* **Top 5 Ways to Wire up ESP8266 Module to your Arduino Uno BoardOnline Shouter**, 22 set. 2017. Disponível em: <<http://onlineshouter.com/top-5-ways-wire-esp8266-module-arduino-uno-board/>>. Acesso em: 28 out. 2018

SHI, Y.; SHI, Y.; WANG, X. **Inertial Body-Worn Sensor Data Segmentation by Boosting Threshold-Based Detectors**. 2012 16th International Symposium on Wearable Computers. **Anais...** In: 2012 16TH ANNUAL INTERNATIONAL SYMPOSIUM ON WEARABLE COMPUTERS (ISWC). Newcastle, United Kingdom: IEEE, jun. 2012Disponível em: <<http://ieeexplore.ieee.org/document/6246155/>>. Acesso em: 15 dez. 2019

SILVA, I.; SPATTI, D.; FLAUZINO, R. **Redes neurais artificiais para engenharia e ciências aplicadas**. São Paulo: Artliber Editora Ltda, 2010.

SPRAGER, S.; JURIC, M. Inertial Sensor-Based Gait Recognition: A Review. **Sensors**, v. 15, n. 9, p. 22089-22127, 2 set. 2015.

SRIVASTAVA, P.; BAJAJ, M.; RANA, A. S. **IOT based controlling of hybrid energy system using ESP8266**. 2018 IEEMA Engineer Infinite Conference (eTechNxT). **Anais...** In: 2018 IEEMA ENGINEER INFINITE CONFERENCE (ETECHNXT). New Delhi: IEEE, mar. 2018Disponível em: <<https://ieeexplore.ieee.org/document/8385294/>>. Acesso em: 28 out. 2018

STEVAN JR, S.; FARINELLI, F. **Domótica: automação residencial e casas inteligentes com Arduino e ESP8266**. [s.l.] Érica, 2019.

STMICROELECTRONICS. **LSM6DSOX- iNEMO inertial module: always-on 3D accelerometer and 3D gyroscope**, 2019. Disponível em: <<https://www.st.com/resource/en/datasheet/lsm6dsox.pdf>>. Acesso em: 17 mar. 2020

STT SYSTEMS. **STT-IWS IMU**, 2019. Disponível em: <<https://www.stt-systems.com/motion-analysis/inertial-motion-capture/stt-iws/>>. Acesso em: 17 ago. 2019

SUHANKO, D. **ESPlorer IDE • Do bit Ao ByteDo bit Ao Byte**, [s.d.]. Disponível em: <<https://www.dobitaobyte.com.br/dns-no-raspberry-acessar-dispositivos-da-rede-pelo-nome/esplorer/>>. Acesso em: 17 dez. 2018

SYED, L. *et al.* Smart healthcare framework for ambient assisted living using IoMT and big data analytics techniques. **Future Generation Computer Systems**, v. 101, p. 136-151, dez. 2019.

TECKSCAN. **F-scan System**, 2019. Disponível em: <<https://www.tekscan.com/products-solutions/systems/f-scan-system>>. Acesso em: 17 ago. 2019

THAKUR, C. *et al.* Soft Wearable Augmented Walking Suit With Pneumatic Gel Muscles and Stance Phase Detection System to Assist Gait. **IEEE Robotics and Automation Letters**, v. 3, n. 4, p. 4257-4264, out. 2018.

Tutorial: Acelerômetro MPU6050 com Arduino. Disponível em: <<https://www.filipeflop.com/blog/tutorial-acelerometro-mpu6050-arduino/>>. Acesso em: 28 out. 2018.

WANG, L. *et al.* Estimation of Step Length and Gait Asymmetry Using Wearable Inertial Sensors. **IEEE Sensors Journal**, v. 18, n. 9, p. 3844-3851, 1 maio 2018.

XSENS. **MVN Link**, 2019. Disponível em: <<https://www.xsens.com/products/xsens-mvn-analyze>>. Acesso em: 17 ago. 2019

YANG, S.; KONG, L. **Research on Characteristic Extraction of Human Gait**. 2009 3rd International Conference on Bioinformatics and Biomedical Engineering. **Anais...** In: 2009 3RD INTERNATIONAL CONFERENCE ON BIOINFORMATICS AND BIOMEDICAL ENGINEERING (ICBBE). Beijing, China: IEEE, jun. 2009. Disponível em: <<http://ieeexplore.ieee.org/document/5163328/>>. Acesso em: 26 out. 2018

ZUR, R. M. *et al.* Noise injection for training artificial neural networks: A comparison with weight decay and early stopping. **Medical Physics**, v. 36, n. 10, p. 4810-4818, 2009.