

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

LUIZ CARLOS GIACOMOSI

**MÉTODO DE TRIANGULAÇÃO APLICADO SOBRE DADOS CAPTURADOS COM
ACELERÔMETRO DE MOVIMENTOS HUMANOS, VISANDO A EXTRAÇÃO DE
NOVAS CARACTERÍSTICAS E O RECONHECIMENTO DE PADRÕES**

CURITIBA

2022

LUIZ CARLOS GIACOMOSSO

**MÉTODO DE TRIANGULAÇÃO APLICADO SOBRE DADOS CAPTURADOS COM
ACELERÔMETRO DE MOVIMENTOS HUMANOS, VISANDO A EXTRAÇÃO DE
NOVAS CARACTERÍSTICAS E O RECONHECIMENTO DE PADRÕES**

**TRIANGULATION METHOD APPLIED ON DATA CAPTURED WITH HUMAN
MOVEMENT ACCELEROMETER, AIMING TO EXTRACT NEW
CHARACTERISTICS AND PATTERN RECOGNITION**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica Federal do Paraná, como requisito parcial à obtenção do título de Doutor em Ciências – Área de Concentração: Engenharia Biomédica.

Orientador: Prof. Dr. Sérgio Francisco Pichorim.

CURITIBA

2022



[4.0 Internacional](https://creativecommons.org/licenses/by-nc-sa/4.0/)

Esta licença permite remixe, adaptação e criação a partir do trabalho, para fins não comerciais, desde que sejam atribuídos créditos ao(s) autor(es) e que licenciem as novas criações sob termos idênticos. Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.



LUIZ CARLOS GIACOMOSI

MÉTODO DE TRIANGULAÇÃO APLICADO SOBRE DADOS CAPTURADOS COM ACELERÔMETRO DE MOVIMENTOS HUMANOS, VISANDO A EXTRAÇÃO DE NOVAS CARACTERÍSTICAS E O RECONHECIMENTO DE PADRÕES.

Trabalho de pesquisa de doutorado apresentado como requisito para obtenção do título de Doutor Em Ciências da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Engenharia Biomédica.

Data de aprovação: 22 de Junho de 2022

Dr. Sergio Francisco Pichorim, Doutorado - Universidade Tecnológica Federal do Paraná
Dr. Andre Eugenio Lazzaretti, Doutorado - Universidade Tecnológica Federal do Paraná
Dr. Jose Jair Alves Mendes Junior, Doutorado - Universidade Tecnológica Federal do Paraná
Dr. Julio Cesar Nievola, Doutorado - Pontifícia Universidade Católica do Paraná (Pucpr)
Dr. Roberto Tadeu Raittz, Doutorado - Universidade Federal do Paraná (Ufpr)

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 22/06/2022.

Dedico esta tese primeiramente a Deus, pois sem Ele nada seria possível.

À minha família pelo incentivo e confiança demonstrada.

À minha esposa e filhos, pelo apoio incondicional, compreensão e motivação.

Ao meu orientador pela disposição em ensinar e paciência dedicada no decorrer do trabalho.

Enfim, a todos que de alguma forma tornaram este caminho mais fácil de ser percorrido.

AGRADECIMENTOS

Agradeço a Deus que me deu coragem de superar todos os desafios e escolhas que fiz em minha vida.

Aos meus pais Dagmar Giacomossi e Osvaldo Giacomossi (in memoriam) pelo incentivo aos estudos e pelo exemplo de vida.

À minha esposa Alessandra B. Giacomossi e aos meus filhos Luiz Carlos Giacomossi Jr e Eduardo Giacomossi pela paciência, colaboração, incentivo e amor.

Ao Professor Dr. Sérgio Francisco Pichorim, pela oportunidade, orientação, dedicação e confiança em mim depositada.

Aos professores Dr. Roberto Tadeu Raittz e Dr. Júlio Cesar Nievola, pelas orientações na banca de qualificação.

Ao professor Dr. Fabio Luiz Pessoa Albini pela ajuda prestada na aquisição de dados nesta pesquisa, estímulo e partilha.

Ao professor Luis Claudio Moreira de Lima, chefe de seção de Inovação e Empreendedorismo do IFPR, pela intermediação na aquisição de uma esteira ergométrica para a aquisição de dados nesta pesquisa, estímulo e partilha.

À aluna Carolina Arenas Okawa de iniciação científica, do Curso Técnico de Informática Integrado ao Ensino Médio do Instituto Federal do Paraná, pela participação no desenvolvimento de um aplicativo para a leitura de dados capturados do acelerômetro interno de um *smartphone* (plataforma android).

Ao Instituto Federal do Paraná na pessoa do Diretor do Campus Curitiba Adriano Willian da Silva, pela compreensão, estímulo e companheirismo.

Aos professores da UTFPR pelo conhecimento compartilhado.

RESUMO

GIACOMOSSI, Luiz Carlos. **Método de triangulação aplicado sobre dados capturados com acelerômetro de movimentos humanos, visando a extração de novas características e o reconhecimento de padrões.** 2022. 142 p. Tese - Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná. Curitiba, 2022.

Esta pesquisa apresenta um método de triangulação, o qual, foi aplicado sobre os sinais elétricos 3D discretizados de movimentos humanos normais do dia a dia e anormais como os tremores, capturados do acelerômetro interno de um *smartphone*, visando o reconhecimento de padrões. A principal contribuição do método proposto, está na elaboração de um algoritmo que utiliza os conceitos Euclidianos e estatística básica na composição de novas características extraídas de sequências de triângulos, as quais, são baseadas em retas (subida, descida e base), perímetro, ângulos, coeficientes angulares das retas (derivada) e contagem dos triângulos. Os novos conceitos, podem ser aplicados na área da engenharia biomédica, tendo em vista, a quantidade de estudos que utilizam movimentos humanos e o sensor acelerômetro, bem como, os ótimos resultados apresentados neste estudo. Foram feitas comparações entre o método proposto e os conhecidos conceitos da FFT (*Fast Fourier Transform*), que converte um sinal no domínio do tempo para o domínio da frequência, bem como, realizadas comparações com características estatísticas no domínio do tempo. Foram elaborados 4 conjuntos de padrões que aplicam a técnica de triangulação e 3 conjuntos de padrões que aplicam as características clássicas da literatura, em 4 experimentos variando a quantidade de movimentos (5 e 9), a quantidade de características (9, 15 e 36) e o tamanho das janelas de dados de entrada (100, 200, 500 e 1000 pontos) na composição dos padrões. Os índices de classificação para cada classe supervisionada (1 a 9), utilizando dois classificadores, *Multilayer Perceptron* (MLP) e *K-Nearest Neighbor* (KNN) para $k=5$, foram utilizados nas avaliações e registrados os valores de acertos individuais e médios por movimento, entre as 9 categorias estudadas. Quanto aos índices médios de acerto, no terceiro experimento (5 movimentos e 36 características), os valores 99,6% e 99,6%, foram resultados alcançados com os conjuntos de características aplicando triangulação (e média) e os conjuntos das características clássicas da literatura, para janelas de 200 e 500 pontos, ambos com o classificador MLP, respectivamente. Resultado favorável a técnica de triangulação devido ao tamanho da janela de entrada ser menor (200 pontos). Utilizando os mesmos 5 movimentos, no terceiro experimento e janelas de 1000 pontos, foi obtida a maior taxa média de 100% de acerto, com os conjuntos de características que aplicam a triangulação (e soma) e 99,9% utilizando os conjuntos de características da literatura, ambos com o classificador MLP. No quarto experimento, utilizando todos os 9 movimentos, foram obtidos os índices médios de 99,5% com as características da literatura e 99,5% com as características da triangulação (e média), neste caso, para janelas de 1000 pontos e classificador KNN. Os resultados obtidos nesta pesquisa são promissores, tendo em vista os elevados índices de acerto obtidos com o método de triangulação, os quais, foram equiparados aos índices obtidos com os conjuntos de características da literatura, bem como, ao realizar a associação de todas as características (triangulação e literatura) em um novo processamento, os índices de acerto na classificação final (categorias de movimentos) melhoraram, comprovando a eficiência do método proposto.

Palavras-chave: Técnica de triangulação, Reconhecimento de padrões, Características no domínio do tempo, Características no domínio da frequência.

ABSTRACT

GIACOMOSSI, Luiz Carlos. **Triangulation method applied to data captured with an accelerometer of human movements, aiming at the extraction of new features and pattern recognition.** 142 p. Thesis - Post-Graduate Program in Electrical Engineering and Computer Science Industrial, Federal Technological University of Parana. Curitiba, 2022.

This research presents a triangulation method, which was applied to the 3D electrical signals discretized from normal everyday human movements and abnormal ones such as tremors, captured from the internal accelerometer of a smartphone, aiming at pattern recognition. The main contribution of the proposed method is in the elaboration of an algorithm that uses Euclidean concepts and basic statistics in the composition of new features extracted from sequences of triangles, which are based on straight lines (ascent, descent and base), perimeter, angles, angular coefficients of the straights (derived) and triangle count. The new concepts can be applied in the area of biomedical engineering, in view of the amount of studies that use human movements and the accelerometer sensor, as well as the excellent results presented in this study. Comparisons were made between the proposed method and the well-known concepts of FFT (Fast Fourier Transform), which converts a signal in the time domain to the frequency domain, as well as comparisons with statistical features in the time domain. Four sets of patterns that apply the triangulation technique and 3 sets of patterns that apply the classic features of the literature were elaborated, in 4 experiments varying the amount of movements (5 and 9), the amount of features (9, 15 and 36) and the size of the input data windows (100, 200, 500 and 1000 points) in the pattern composition. The classification indices for each supervised class (1 to 9), using two classifiers, Multilayer Perceptron (MLP) and K-Nearest Neighbor (KNN) for $k=5$, were used in the evaluations and the values of individual and average hits were recorded by movement, among the 9 categories studied. As for the average hit rates, in the third experiment (5 movements and 36 features), the values 99.6% and 99.6% were results achieved with the sets of features applying triangulation (and average) and the sets of classic features from the literature, for windows of 200 and 500 points, both with the MLP classifier, respectively. Favorable result for the triangulation technique due to the smaller input window size (200 points). Using the same 5 movements, in the third experiment and windows of 1000 points, the highest average rate of 100% hit was obtained, with the feature sets that apply triangulation (and sum) and 99.9% using the feature sets from the literature, both with the MLP classifier. In the fourth experiment, using all 9 movements, the average indices of 99.5% were obtained with the features of the literature and 99.5% with the features of triangulation (and average), in this case, for windows of 1000 points and classifier KNN. The results obtained in this research are promising, in view of the high hit rates obtained with the triangulation method, which were equated to the indices obtained with the sets of features in the literature, as well as, when performing the association of all the features (triangulation and literature) in a new processing, the hit rates in the final classification (categories of movements) improved, proving the efficiency of the proposed method.

Keywords: Triangulation technique, Pattern recognition, Time domain features, Frequency domain features.

LISTA DE FIGURAS

Figura 1 - Mostra um ponto de máximo em azul e um ponto de mínimo em verde, da aceleração de uma janela de pontos correspondentes à atividade andando.....	28
Figura 2 - Sinal da atividade andando demonstrando o cálculo do valor médio.....	29
Figura 3 - Espectro de frequência (transformada rápida de Fourier, FFT) de um sinal e as características extraídas dele.	30
Figura 4 - Modelo de um neurônio artificial	33
Figura 5 - Rede com múltiplas camadas alimentadas adiante (<i>feedforward</i>).....	34
Figura 6 - <i>Smartphone</i> preso à cintura como um sensor de movimentos.....	36
Figura 7 - Visão geral do sistema	37
Figura 8 - Diagrama em blocos de um alarme onde o sinal original é transformado em um novo sinal que sempre excede o original, ou acompanha os picos, seguido de um tempo para chegar a zero	44
Figura 9 - Processo de <i>pipeline</i> de dados usados neste estudo	46
Figura 10 - Método de triangulação proposto	49
Figura 11 - Sequência simulada de duas janelas de pontos de pico e vale selecionados pelo algoritmo de triangulação	50
Figura 12 - Fases da metodologia implementada neste estudo	52
Figura 13 - Sinais do movimento andando na esteira (eixo x em azul, eixo y em marron e eixo z em cinza).....	54
Figura 14 - Sinais do movimento correndo na esteira (eixo x em azul, eixo y em marron e eixo z em cinza).....	54
Figura 15 - Sinais do movimento andando em círculo (eixo x em azul, eixo y em marron e eixo z em cinza).....	55
Figura 16 - Sinais do movimento tremores (eixo x em azul, eixo y em marron e eixo z em cinza)	55
Figura 17 - Sinais do movimento subindo e descendo escada (eixo x em azul, eixo y em marron e eixo z em cinza).....	56
Figura 18 - Sinais do movimento batendo palmas (eixo x em azul, eixo y em marron e eixo z em cinza).....	56
Figura 19 - Sinais do movimento apagando o quadro (eixo x em azul, eixo y em marron e eixo z em cinza).....	57

Figura 20 - Sinais do movimento aceno de tchau (eixo x em azul, eixo y em marron e eixo z em cinza).....	57
Figura 21 - Sinais do movimento penteando o cabelo (eixo x em azul, eixo y em marron e eixo z em cinza).....	58
Figura 22 - Diagrama de blocos mostrando a extração de características para todos os métodos comparados na pesquisa	61
Figura 23 - Resultado da classificação utilizando o conjunto de características TrS composição com o conjunto de características TFDF, para o classificador MLP, apresentados em uma matriz de confusão	89
Figura 24 - Resultado da classificação utilizando o conjunto de características TrS composição com o conjunto de características TFDF, para o classificador KNN, apresentados em uma matriz de confusão	90

LISTA DE FOTOGRAFIAS

Fotografia 1 - <i>Smartphone</i> e <i>software</i> aplicativo utilizado na aquisição dos dados de movimentos humanos.....	53
Fotografia 2 - Aquisição dos dados no antebraço dos voluntários.....	53

LISTA DE GRÁFICOS

Gráfico 1 - Comparação entre os índices médios (5 movimentos) de classificação final obtidos no experimento 1 (9 características), utilizando o classificador MLP	68
Gráfico 2 - Comparação entre os índices médios (5 movimentos) de classificação final obtidos no experimento 1 (9 características), utilizando o classificador KNN	68
Gráfico 3 - Dispersão dos dados utilizando os índices médios obtidos com os conjuntos de características comparados no experimento 1, para o classificador MLP	69
Gráfico 4 - Comparação entre os índices médios (5 movimentos) de classificação final obtidos no experimento 2 (15 características), utilizando o classificador MLP	71
Gráfico 5 - Comparação entre os índices médios (5 movimentos) de classificação final obtidos no experimento 2 (15 características), utilizando o classificador KNN	71
Gráfico 6 - Dispersão dos dados utilizando os índices médios obtidos com os conjuntos de características comparados no experimento 2, para o classificador MLP	75
Gráfico 7 - Comparação entre os índices médios (5 movimentos) de classificação final obtidos no experimento 3 (36 características), utilizando o classificador MLP	77
Gráfico 8 - Comparação entre os índices médios (5 movimentos) de classificação final obtidos no experimento 3 (36 características), utilizando o classificador KNN	77
Gráfico 9 - Dispersão dos dados utilizando os índices médios obtidos com os conjuntos de características comparados no experimento 3, para o classificador MLP	82
Gráfico 10 - Comparação entre os índices médios (9 movimentos) de classificação final obtidos no experimento 4 (36 características), utilizando o classificador MLP	84
Gráfico 11 - Comparação entre os índices médios (9 movimentos) de classificação final obtidos no experimento 4 (36 características), utilizando o classificador KNN	84
Gráfico 12 - Dispersão dos dados utilizando os índices médios obtidos com os conjuntos de características comparados no experimento 4, para o classificador KNN	88
Gráfico 13 - Comparação entre o conjunto de características aplicando a triangulação e a soma e o conjunto de características aplicando a triangulação e a média, para todos os testes. A linha verde marca a igualdade ($y = x$)	92
Gráfico 14 - Comparação entre o conjunto de características aplicando a triangulação e a soma e o conjunto de características aplicando a triangulação e o desvio padrão, para todos os testes. A linha verde marca a igualdade ($y = x$)	93

Gráfico 15 - Comparação entre o conjunto de características aplicando a triangulação e a soma e o conjunto de características aplicando a triangulação e a variância, para todos os testes. A linha verde marca a igualdade ($y = x$)	94
Gráfico 16 - Comparação entre o conjunto de características aplicando a triangulação e a média e o conjunto de características aplicando a triangulação e o desvio padrão, para todos os testes. A linha verde marca a igualdade ($y = x$).....	95
Gráfico 17 - Comparação entre o conjunto de características aplicando a triangulação e a média e o conjunto de características aplicando a triangulação e a variância, para todos os testes. A linha verde marca a igualdade ($y = x$)	96
Gráfico 18 - Comparação entre o conjunto de características aplicando a triangulação e o desvio padrão e o conjunto de características aplicando a triangulação e a variância, para todos os testes. A linha verde marca a igualdade ($y = x$)	97
Gráfico 19 - Mostra os índices médios em percentual de acerto de classificação final para os experimentos com 5 e 9 movimentos, utilizando janelas de dados de entrada de 1000 pontos e o classificador MLP.....	98
Gráfico 20 - Mostra os índices médios em percentual de acerto de classificação final para os experimentos com 5 e 9 movimentos, utilizando janelas de dados de entrada de 1000 pontos e o classificador KNN	98
Gráfico 21 - Comparação entre os conjuntos de característica aplicando a triangulação e a soma (TrS) e o conjunto de características aplicando a triangulação e a média (TrM), utilizando 5 categorias de movimentos e o classificador MLP	100
Gráfico 22 - Comparação entre o conjunto de característica aplicando a triangulação e a soma (TrS) e o conjunto de características aplicando a triangulação e a média (TrM), utilizando 5 categorias de movimentos e o classificador KNN.....	101
Gráfico 23 - Comparação entre o conjunto de característica aplicando a triangulação e a soma (TrS) e o conjunto de características aplicando a triangulação e a média (TrM), utilizando 9 categorias de movimentos e o classificador MLP	102
Gráfico 24 - Comparação entre o conjunto de característica aplicando a triangulação e a soma (TrS) e o conjunto de características aplicando a triangulação e a média (TrM), utilizando 9 categorias de movimentos e o classificador KNN.....	102
Gráfico 25 - Comparação entre os conjuntos de característica aplicando a triangulação e a soma (TrS) e o conjunto de características da literatura no domínio tempo-frequência (TFDF), utilizando 5 categorias de movimentos e o classificador MLP	103

Gráfico 26 - Comparação entre os conjuntos de característica aplicando a triangulação e a soma (TrS) e o conjunto de características da literatura no domínio tempo-frequência (TFDF), utilizando 5 categorias de movimentos e o classificador KNN.....	104
Gráfico 27 - Comparação entre os conjuntos de característica aplicando a triangulação e a soma (TrS) e o conjunto de características da literatura no domínio tempo-frequência (TFDF), utilizando 9 categorias de movimentos e o classificador MLP	105
Gráfico 28 - Comparação entre os conjuntos de característica aplicando a triangulação e a soma (TrS) e o conjunto de características da literatura no domínio tempo-frequência (TFDF), utilizando 9 categorias de movimentos e o classificador KNN.....	105
Gráfico 29 - Comparação entre os conjuntos de característica aplicando a triangulação e a média (TrM) e o conjunto de características da literatura no domínio tempo-frequência (TFDF), utilizando 5 categorias de movimentos e o classificador MLP.....	106
Gráfico 30 - Comparação entre os conjuntos de característica aplicando a triangulação e a média (TrM) e o conjunto de características da literatura no domínio tempo-frequência (TFDF), utilizando 5 categorias de movimentos e o classificador KNN	107
Gráfico 31 - Comparação entre os conjuntos de característica aplicando a triangulação e a média (TrM) e o conjunto de características da literatura no domínio tempo-frequência (TFDF), utilizando 9 categorias de movimentos e o classificador MLP.....	108
Gráfico 32 - Comparação entre os conjuntos de característica aplicando a triangulação e a média (TrM) e o conjunto de características da literatura no domínio tempo-frequência (TFDF), utilizando 9 categorias de movimentos e o classificador KNN	108

LISTA DE QUADROS

Quadro 1 - Conjuntos de características comparados na pesquisa	59
Quadro 2 - Melhores índices de acerto individuais por movimento, comparando os conjuntos de características aplicando a triangulação, com os conjuntos de características da literatura no domínio do tempo e domínio da frequência, utilizando 3 características por eixo no experimento 1	65
Quadro 3 - Melhores índices de acerto individuais por movimento, comparando os conjuntos de características aplicando a triangulação, com os conjuntos de características da literatura no domínio do tempo e domínio da frequência, utilizando 5 características por eixo no experimento 2	72
Quadro 4 - Melhores índices de acerto individuais por movimento, comparando os conjuntos de características aplicando a triangulação, com os conjuntos de características da literatura no domínio tempo- frequência, utilizando 12 características por eixo no experimento 3.....	81
Quadro 5 - Melhores índices de acerto individuais por movimento, comparando os conjuntos de características aplicando a triangulação, com os conjuntos de características da literatura no domínio do tempo-frequência, utilizando 12 características por eixo no experimento 4.....	85
Quadro 6 - Lista de trabalhos da literatura com as características extraídas no domínio do tempo (TDF) e domínio da frequência (FDF), visando o reconhecimento de padrões.....	112
Quadro 7 - Mostra a diferença entre os maiores índices de acerto para os conjuntos de características objetos de estudo, envolvendo 5 e 9 categorias de movimentos, variando o tamanho das janelas de dados de entrada em 100, 200, 500 e 1000 pontos, para padrões compostos de 36 características.....	116

LISTA DE TABELAS

Tabela 1 - Descrição das categorias de movimentos, classes, dados de aquisição e número de padrões gerados para janelas de dados de entrada de 100, 200, 500 e 1000 pontos, correspondentes aos 9 movimentos objetos de estudo.....	64
Tabela 2 - Comparação (em porcentagem) das taxas de acerto por movimento estudado, para o classificador MLP e conjuntos de padrões com 3 características por eixo.....	66
Tabela 3 - Comparação (em porcentagem) das taxas de acerto por movimento estudado, para o classificador KNN para $k = 5$ e conjuntos de padrões com 3 características por eixo.....	67
Tabela 4 - Comparação (em porcentagem) das taxas de acerto por movimento estudado, para o classificador MLP e conjuntos de padrões com 5 características por eixo.....	73
Tabela 5 - Comparação (em porcentagem) das taxas de acerto por movimento estudado, para o classificador KNN para $k = 5$ e conjuntos de padrões com 5 características por eixo.....	74
Tabela 6 - Comparação (em porcentagem) das taxas de acerto por movimento estudado, para o classificador MLP e conjuntos de padrões com 12 características por eixo.....	79
Tabela 7 - Comparação (em porcentagem) das taxas de acerto por movimento estudado, para o classificador KNN para $k = 5$ e conjuntos de padrões com 12 características por eixo.....	80
Tabela 8 - Comparação (em porcentagem) das taxas de acerto individuais por categoria de movimento estudada (A – andando na esteira, B – correndo na esteira, C - tremores, D - palmas, E – aceno de tchau, F – andando em círculo, G – apagando quadro, H – subindo e descendo escada, I – penteando o cabelo), utilizando 9 movimentos, para o classificador MLP e conjuntos de padrões com 36 características.....	86
Tabela 9 - Comparação (em porcentagem) das taxas de acerto individuais por categoria de movimento estudada (A – andando na esteira, B – correndo na esteira, C - tremores, D - palmas, E – aceno de tchau, F – andando em círculo, G – apagando quadro, H – subindo e descendo escada, I – penteando o cabelo), utilizando 9 movimentos, para o classificador KNN	

e conjuntos de padrões com características.....	36
características.....	87
Tabela 10 - Comparação (em porcentagem) das taxas de acerto individuais por categoria de movimento estudada (A – andando na esteira, B – correndo na esteira, C - tremores, D - palmas, E – aceno de tchau, F – andando em círculo, G – apagando quadro, H – subindo e descendo escada, I – penteando o cabelo), utilizando os classificadores MLP e KNN para $k=5$, para conjuntos de padrões com 72 características, os quais, associam as características extraídas pelo método de triangulação com as características clássicas da literatura no domínio	
domínio tempo-frequência.....	91

LISTA DE ABREVIATURAS E SIGLAS

Algo	Algoritmo.
<i>angb</i>	Ângulo de Base.
<i>angd</i>	Ângulo de Descida.
<i>angs</i>	Ângulo de Subida.
ANN	Rede Neural Artificial.
APF	Média dos valores de Pico da Frequência.
AR	Coefficiente Autoregressivo.
<i>at</i>	Área do Triângulo.
ECG	Eletrocardiograma.
EEG	Eletroencefalograma.
EMG	Eletromiograma.
FIS	Sistema de Inferência <i>Fuzzy</i> .
FFT	Transformada Rápida de Fourier.
FDF	Características no Domínio da Frequência.
HAR	Reconhecimento de Atividade Humana.
HG	Histograma de Gradiente
IQR	Intervalo Interquartil.
KNN	<i>K</i> -Vizinhos Próximos.
LDA	Análise Discriminante Linear de Fisher
L-SMA	Média Móvel Simples da Soma da Faixa de Aceleração Linear.
MAV	Valor Médio Absoluto.
MAX	Máximo.
MC-SVM	Polinomial - <i>Multiclass support vector machine polynomial kernel</i> .
MC-SVM	Linear - <i>multiclass support vector machine Linear Kernel</i> .
MIN	Mínimo.
MinMax	Diferença entre mínimo e máximo.
ML	<i>Machine Learning</i> .
MLP	<i>Multi-Layer Perceptron</i> .
NB	<i>Naïve Bayes</i> .
NSSC	Número de alterações da inclinação do sinal.
NZC	Número de cruzamentos do nível zero da amplitude do sinal.

<i>per</i>	Perímetro.
PSD	<i>Power Spectral Density</i> .
<i>rb</i>	Reta de Base.
<i>rd</i>	Reta de Descida.
RF	<i>Random Forest</i>
RMS	Valor Quadrático Médio (<i>Root Mean Square</i>).
<i>rs</i>	Reta de Subida.
SMA	Área de Magnitude do Sinal.
SOR	Soma da Faixa de Aceleração Linear.
SoSD	Soma do Desvio Padrão da aceleração linear.
STD	Desvio Padrão.
SVM	<i>Signal Magnitude Vector</i> .
TDF	Características no Domínio do Tempo.
TrDP	Características aplicando a triangulação e o desvio padrão estatístico.
TrM	Características aplicando a triangulação e a média estatística.
TrS	Características aplicando a triangulação e a soma estatística.
TrV	Características aplicando a triangulação e a variância estatística.
UPDRS	<i>Unified Parkinson's Disease Rating Scale</i> .
WAMP	Amplitude <i>Willison</i> .
WEKA	<i>Waikato Environment for Knowledge Analysis</i> .
WL	Comprimento da forma de onda do sinal.

SUMÁRIO

1	INTRODUÇÃO	21
1.1	Motivação	21
1.2	Justificativa	22
1.3	Objetivos	22
1.3.1	Objetivo geral	22
1.3.2	Objetivos específicos.....	23
1.4	Organização da tese	24
2	FUNDAMENTAÇÃO TEÓRICA	25
2.1	Reconhecimento de padrões	25
2.1.1	Extração de características	25
2.1.2	Características extraídas no domínio do tempo (TDF)	26
2.1.3	Características extraídas no domínio da frequência (FDF)	29
2.2	Aprendizado de máquina	32
2.2.1	Aprendizado supervisionado	32
2.3	Classificadores	32
2.3.1	Redes neurais <i>Multilayer Perceptron</i> (MLP).....	32
2.3.2	<i>K-Nearest Neighbor</i> (KNN)	34
3	ESTADO DA ARTE	36
4	MÉTODO DE DESENVOLVIMENTO DA PESQUISA	48
4.1	Extração de Características	50
4.2	Coleta de dados (fase 1)	52
4.3	Extração de características (fase 2)	58
4.4	Classificação dos dados (fase 3)	62
5	RESULTADOS	63
5.1	Primeiro experimento	64
5.2	Segundo experimento	70
5.3	Terceiro experimento	76
5.4	Quarto experimento	83

5.4.1	Associando os conjuntos de características que aplicam o método de triangulação, com os conjuntos de características no domínio tempo-frequência (para os critérios do experimento 4).....	89
5.5	Comparação entre os quatro conjuntos de características que aplicam o método de triangulação proposto	91
5.6	Número de características	97
5.7	Análise estatística aplicando Bland Altman.....	99
5.7.1	Comparando os conjuntos de características aplicando o método de triangulação TrS e TrM, para o experimento 3 (36 características).....	100
5.7.2	Comparando os conjuntos de características aplicando o método de triangulação TrS e TrM, para o experimento 4 (36 características).....	101
5.7.3	Comparando o conjunto de características aplicando o método de triangulação TrS e o conjunto de características da literatura TFDF, para o experimento 3 (36 características).....	103
5.7.4	Comparando o conjunto de características aplicando o método de triangulação TrS e o conjunto de características da literatura TFDF, para o experimento 4 (36 características).....	104
6	DISCUSSÕES E CONCLUSÕES.....	110
6.1	Discussões.....	110
6.2	Conclusões.....	116
6.3	Estudos futuros.....	122
	REFERÊNCIAS	123
	APÊNDICES – Tabelas com os valores de correlação.....	127
	ANEXO – Parecer consubstanciado do CEP.....	138

1 INTRODUÇÃO

1.1 Motivação

Esta pesquisa apresenta um método de triangulação, o qual, foi aplicado sobre sinais elétricos irregulares em amplitude e frequência, capturados com acelerômetro de movimentos humanos comuns do dia a dia, utilizando um *smartphone* com aplicativo embarcado programado para ler do acelerômetro interno os sinais nos 3 eixos ortogonais (x, y e z), cuja principal contribuição é a extração de novas características visando o reconhecimento de padrões. Alguns exemplos de aplicação podem ser relacionados, tais como: os sistemas de monitoramento de saúde para análises de aquisições de movimentos em ambientes internos ou externos, principalmente para pessoas idosas como prevenção, ou mesmo, detectando uma queda remota usando mensagem SMS para pedido de ajuda, caso esteja imóvel por um determinado tempo (KHAN, LEE, *et al.*, 2010; LEE e CALISLE, 2011; LI, LIN *et al.*, 2014).

Na literatura existem diversos estudos voltados ao reconhecimento de movimentos humanos, servindo de base e motivação para o desenvolvimento da técnica de triangulação proposta (KHAN, LEE, *et al.*, 2010; JAIN e KANHANGAD, 2018; NURHANIM *et al.*, 2017; DIRICAN e AKSOY, 2017; JALAL, QUAID e SIDDUQI, 2019; BAYAT, POMPLUN e TRAN, 2014; BAYAT, BAYAT e GHASEMI, 2017; SARCEVIC, PLETL e KINCSES, 2017; SARCEVIC, KINCSES e PLETL, 2019; ALEMAYOH, LEE e OKAMOTO, 2021).

O método de triangulação a princípio pode ser aplicado sobre qualquer fonte de sinal irregular em amplitude e frequência, no entanto, só foram realizados experimentos com dados de movimentos humanos lidos com *smartphone* (acelerômetro interno), o qual apresenta baixo custo e pode ser facilmente adaptado no corpo humano (braço, cintura, perna) ou mesmo colocado dentro de um bolso da camisa, calça, entre outros (KHAN, LEE, *et al.*, 2010). No entanto, o reconhecimento de padrões utilizando o método proposto, deve ser testado futuramente em outras áreas, tais como: na robótica voltada a aplicações industriais (DALLAIRE, EMOND, *et al.*, 2011), no reconhecimento de fala (ESPINOLA, GOMES, *et al.*, 2021), em análises de controle de tráfego nas grandes metrópoles (ZHOU e KWAN, 2018), no reconhecimento de sinais capturados de abalos sísmicos (GATTI e LOPEZ-CABALLERO, 2019), entre outras.

1.2 Justificativa

O método de triangulação apresenta um algoritmo que emprega os conceitos da geometria Euclidiana e estatística básica na extração de novas características extraídas de um sinal convertido em sequências de triângulos, gerados entre os pontos de pico (máximos) e vales (mínimos), dos quais, são calculadas retas (subida, descida e base), áreas, ângulos, coeficientes angulares das retas (derivada), perímetro e uma contagem dos triângulos na composição dos padrões (GIACOMOSSI, 2011; GIACOMOSSI e PICHORIM, 2022). Os novos conceitos podem ser aplicados na área da engenharia biomédica, tendo em vista, a quantidade de estudos que utilizam movimentos humanos e o sensor acelerômetro (KHAN, LEE, *et al.*, 2010; JAIN e KANHANGAD, 2018; NURHANIM, *et al.*, 2017), bem como, os ótimos resultados apresentados com os conjuntos de características que aplicam a triangulação na classificação de movimentos humanos (movimentos normais do dia a dia ou anormais como os tremores), os quais, foram equiparados com os índices de acerto obtidos para os conjuntos de características clássicos extraídos da literatura no domínio tempo-frequência (PIERLEONI *et al.*, 2014; DIRICAN e AKSOY, 2017; GUO *et al.*, 2018; GAO *et al.*, 2017).

Também foi observado nesta pesquisa que ao associar as características extraídas pelo método de triangulação, com as principais características encontradas na literatura no domínio tempo-frequência (último experimento), os índices médios de acerto na classificação final melhoraram, ou seja, comprovando a relevância e contribuição do método proposto.

Sendo assim, a hipótese inicial desta pesquisa a ser comprovada é: “a técnica de triangulação pode ser utilizada para o reconhecimento de padrões de movimentos humanos do dia a dia, capturados com acelerômetro, como andar, correr, subir e descer escada, entre outros”.

1.3 Objetivos

1.3.1 Objetivo geral

Avaliar um método para a extração de novas características aplicando triangulação sobre dados de movimentos humanos realizados no cotidiano ou movimentos anormais como os tremores patológicos, capturados com acelerômetro nos três eixos ortogonais (x, y e z), visando o reconhecimento de padrões, bem como comparar com outros métodos, os quais, utilizam as principais características da literatura no domínio do tempo-frequência.

1.3.2 Objetivos específicos

Os objetivos específicos são:

- Elaborar um projeto com a descrição detalhada de todos os procedimentos para o Comitê Permanente de Ética em Pesquisa Envolvendo Seres Humanos, para a aquisição de dados de movimentos humanos.
- Criar um programa na plataforma Android, para a aquisição de dados do acelerômetro interno de um *smartphone*.
- Desenvolver um programa na plataforma Matlab para a extração de características e elaboração de padrões supervisionados de acordo com as classes de movimentos de entrada, divididos em 9 categorias de movimentos, tais como: andando na esteira, corrida na esteira, tremores simulados, palmas, acenos de tchau, andando em círculo, apagando quadro, subindo e descendo escada e penteando o cabelo e
- Avaliar o método proposto com o uso da plataforma WEKA e *softwares* classificadores, utilizando como medida os índices de acerto por categoria de dados de entrada.

1.4 Organização da tese

O capítulo 2 apresenta a fundamentação teórica. Os principais conceitos encontrados na literatura, ou seja, o estado da arte, são apresentados no capítulo 3. No capítulo 4 são apresentados o método e experimentos realizados neste estudo. Os resultados encontrados nos experimentos realizados em laboratório não detalhados no capítulo 5, e finalmente, o capítulo 6 apresenta as discussões e conclusões encontradas nesta pesquisa.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção serão apresentados os principais conceitos encontrados em trabalhos publicados na literatura para o desenvolvimento do método proposto nesta pesquisa.

2.1 Reconhecimento de padrões

O reconhecimento de padrões é uma ferramenta importante para facilitar, automatizar e acelerar procedimentos e atividades realizadas em nossa sociedade moderna, como biometria (SARCEVIC; KINCSES; PLETL, 2017), avaliações médicas (CAPELA *et al.*, 2016), entre outras. Um padrão refere-se a qualquer elemento que pode ser definido quantitativamente, mesmo se estiver sujeito a variações, o reconhecimento pode ser feito por diferenciação, classificação ou ambos (SAFI *et al.*, 2015). As características ou descritores são usados para caracterizar um objeto na elaboração de um padrão (BARAN, PARTILA, WILK, 2018). Cada tipo de descritor será mais apropriado para uma aplicação específica, como os valores de pico de tensão resultantes de movimentos anormais que ocorrem em uma crise de epilepsia nas pesquisas de Elevant (1999) e Cuppens *et al.* (2009), bem como, nos distúrbios patológicos relacionados aos tremores de Parkinson no estudo de Bazgir *et al.* (2015), entre outros. Sinais elétricos capturados com acelerômetro nos 3 eixos ortogonais (x, y e z) ou níveis discretizados de tensão de atividades normais do dia a dia são usados para monitorar atividades realizadas por idosos, bem como, avaliações de movimentos realizados por atletas, respectivamente nas pesquisas de Khan *et al.* (2010) e Howe *et al.* (2017).

Na pesquisa de Yang *et al.* (2017), a composição de características são baseadas no reconhecimento da língua chinesa de sinais, sendo as características extraídas da eletromiografia de superfície, acelerômetro e giroscópio. Pode-se mencionar também o reconhecimento de imagens, onde as características mais comuns são os contornos (BARAN, PARTILA, WILK, 2018), contraste no estudo de Cui *et al.* (2018), cor na pesquisa de Seo *et al.* (2018), textura nas pesquisas de Asuroglu *et al.* (2017) ou no reconhecimento de fala as características pitch, duração e intensidade do som em Espinola *et al.* (2021), entre outros.

2.1.1 Extração de características

De acordo com os principais estudos encontrados na literatura, são extraídas características no domínio do tempo (TDF – *Time Domain Feature*) e domínio da frequência (FDF – *Frequency Domain Feature*).

2.1.2 Características extraídas no domínio do tempo (TDF)

As características são extraídas por amostras ou janelas dos sinais 3D discretizados capturados do acelerômetro interno de um *smartphone*. Os sinais de entrada são contínuos no tempo, ou seja, apresentam uma amplitude para cada instante de tempo e são digitalizados pelo sensor acelerômetro a uma taxa de amostragem específica, como exemplo 50 Hz.

As características TDF foram utilizadas no monitoramento *online* de movimentos humanos na pesquisa de Sarcevic, Pletl e Kincses (2017). Foi elaborado um sistema de protótipo capaz de detectar diferentes movimentos do braço e do corpo humano usando sensores sem fio montados no pulso. As unidades sem fio estão equipadas com três sensores tri-axiais, um acelerômetro, um giroscópio e um magnetômetro. Foram extraídas características TDF escolhidas pelo uso de recursos de memória, hardware e quantidade de informação. Dentre as principais características podem ser relacionadas:

a) Característica *Mean Absolute Value* (MAV)

A característica MAV corresponde ao valor médio absoluto calculado de acordo com a equação (2.1):

$$MAV = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (2.1)$$

Onde N corresponde ao número de pontos da janela do sinal de aquisição e x_i os valores da amplitude do sinal de entrada indexados por i .

b) Característica valor máximo (MAX) e mínimo (MIN)

As características valor máximo (MAX) e valor mínimo (MIN), correspondem ao valor mais elevado (pico) da amplitude do sinal de entrada e o valor mais baixo da amplitude (vale), medido na janela de processamento.

c) Característica *Root Mean Square* (RMS)

A característica RMS, em português valor quadrático médio, corresponde a uma medida estatística aplicada sobre a amplitude da janela do sinal de entrada, também designada de valor eficaz. Foi calculada pela equação (2.2):

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (2.2)$$

Também foi calculada a Transformada Rápida de Fourier (FFT) como característica no domínio da frequência (FDF). A classificação final dos dados com o uso de redes neurais MLP e padrões compostos de características TDF, proporcionaram maior eficiência do que os padrões elaborados com características FDF. A maior taxa de classificação obtida em dados

desconhecidos (que não fizeram parte do treinamento) foi de 91,74% usando TDF e 88,51% aplicando FDF.

As características estatísticas extraídas de sinais elétricos capturados com dispositivo sensor acelerômetro nos 3 eixos (x, y e z), foram utilizadas na pesquisa de Jalal, Quaid e Sidduqi (2019), as quais, foram submetidas ao classificador *Random Forest* (RF) para a classificação de algumas atividades humanas do dia a dia, dentre elas:

a) Característica máximo (MAX)

Esta característica está relacionada com os picos de um sinal de aquisição. A equação (2.3) seguinte, expressa o máximo ou pico de cada janela de dados de entrada da aceleração de um sinal capturado com o acelerômetro:

$$MAX(\text{Sinal}) = MAX(a_0 \dots a_n) \quad (2.3)$$

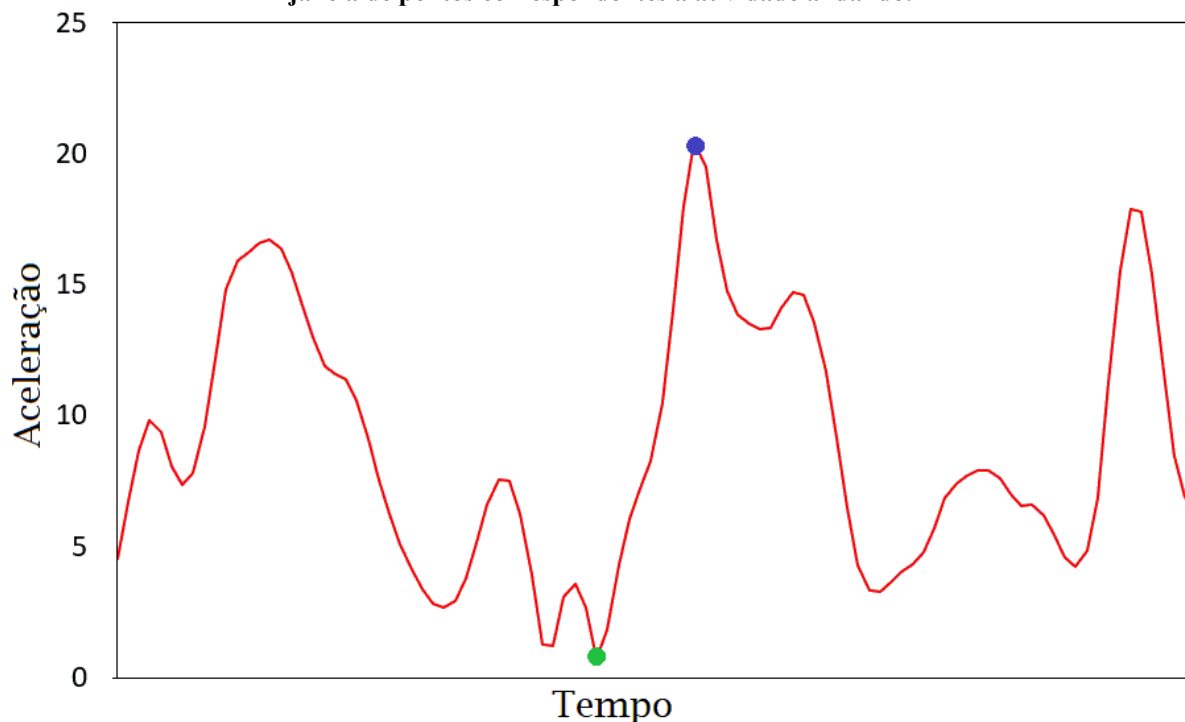
b) Característica mínimo (MIN)

A característica mínimo, representa o valor mais baixo (vale) em uma janela dos dados de aquisição. A equação (2.4) seguinte, expressa o valor mínimo para cada janela da aceleração do sinal capturado com o acelerômetro:

$$MIN(\text{Sinal}) = MIN(a_0 \dots a_n) \quad (2.4)$$

A Figura 1 mostra uma janela de pontos da aceleração do movimento andando. Os pontos de cores verde e azul, correspondem a um valor de mínimo do sinal e máximo na janela, respectivamente.

Figura 1 - Mostra um ponto de máximo em azul e um ponto de mínimo em verde, da aceleração de uma janela de pontos correspondentes à atividade andando.



Fonte: Autorial própria (2022)

c) Característica variância

O parâmetro estatístico ou característica variância é uma medida de dispersão em relação a média. Como os sinais não são regulares ou uniformes em termos de amplitude, a característica variância pode contribuir para a identificação das classes de atividades.

O desvio padrão mede a dispersão dos valores de amplitude de uma janela do sinal em torno da média, de acordo com a equação (2.5):

$$VAR = \frac{1}{N} \sum_{i=1}^N |x_i - \mu|^2 \quad (2.5)$$

Onde N corresponde ao número de pontos da janela do sinal de aquisição, x_i os valores da amplitude do sinal de entrada indexados por i e μ a média dos N pontos.

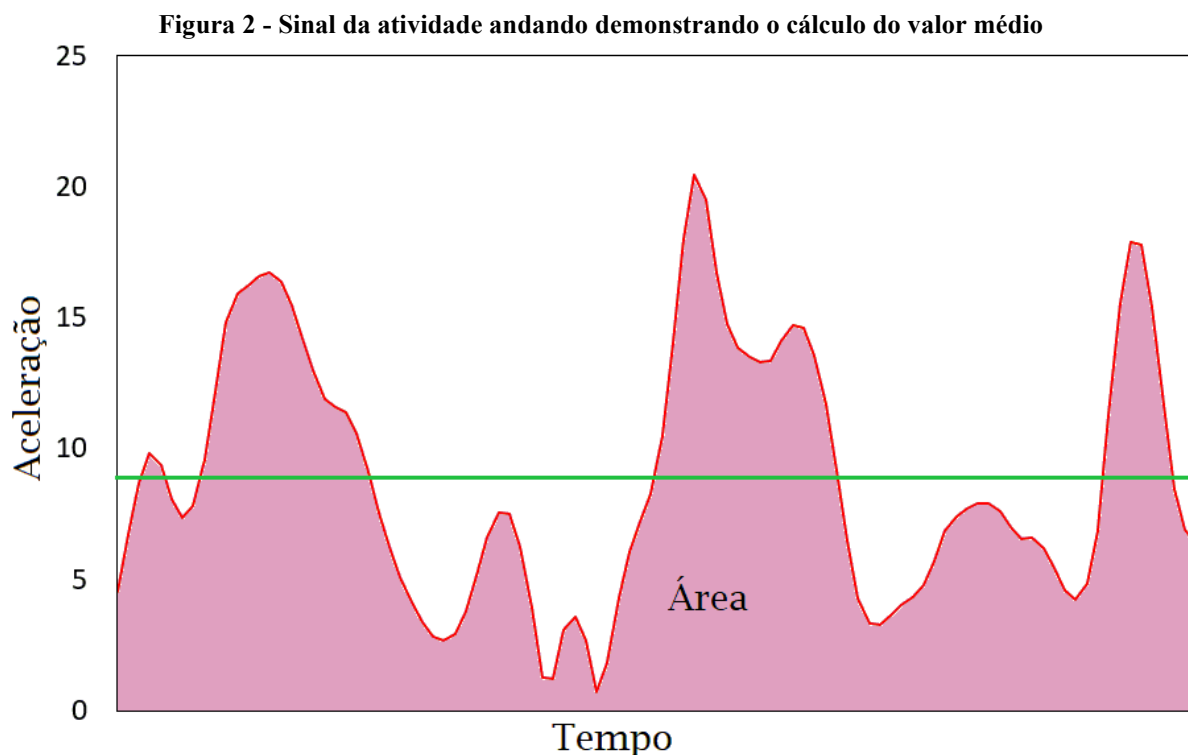
O sistema proposto foi validado e obteve precisão satisfatória de 79,58% com o classificador *Random Forest*. Sendo assim, pode ser aplicado a sistemas de monitoramento de saúde, jogos interativos e para análises de aquisições em ambientes externos e internos.

Na pesquisa de Bayat *et al.* (2017) foram extraídas um total de 6 características estatísticas TDF que incluem a média, STD, MIN, MAX, RMS e valor médio de picos, utilizando os dados capturados por um acelerômetro interno de um *smartphone*. Calcular o valor médio de um sinal periódico qualquer, corresponde obter a média deste sinal durante um

período de tempo, ou seja, calcular o valor médio da amplitude dos sinais de aquisição. Pode ser calculado, conforme mostra a equação (2.6):

$$\text{Valor Médio} = \frac{1}{T} \int_0^T a(t) d(t) \quad (2.6)$$

Onde T corresponde ao período de tempo, a variável a o valor numérico da amplitude do sinal discretizado em um determinado instante t de tempo, dentro do período T de uma janela de dados. A Figura 2 mostra um sinal senoidal periódico com a indicação do valor médio.



Fonte: Autoria própria (2022)

O desvio padrão mede a dispersão dos valores de amplitude de uma janela do sinal em torno da média, de acordo com a equação (2.7).

$$STD = \sqrt{\frac{1}{N} \sum_{i=1}^N |x_i - \mu|^2} \quad (2.7)$$


Onde N corresponde ao número de pontos da janela do sinal de aquisição, x_i os valores da amplitude do sinal de entrada indexados por i e μ a média dos N pontos.

2.1.3 Características extraídas no domínio da frequência (FDF)

A Transformada Rápida de Fourier, um dos principais métodos da literatura que realiza a conversão de um sinal no domínio do tempo para o domínio da frequência

(DIRICAN e AKSOY, 2017). Conceitualmente, a FFT assume que o conjunto de dados é finito em um espectro contínuo igual a um período de um sinal periódico (GUO *et al.*, 2018; GAO *et al.*, 2017). Como os sinais de aquisição nesta pesquisa são aperiódicos, é necessário corrigir possíveis distorções nas bordas das janelas ou segmentos do sinal com a aplicação de funções de janelamento, que atenuam os níveis de tensão nas extremidades das janelas, eliminando assim a existência de altas frequências indesejáveis. No entanto, devido à presença de valores de *offset* pela ação da gravidade, o valor médio de todas as janelas foi calculado e subtraído de todas as posições do vetor, para aplicar uma função de janelamento. Posteriormente, o valor de *offset* foi adicionado aos pontos das janelas para o cálculo da FFT. Para eliminar possíveis distorções nas bordas das amostras, foi utilizada a técnica de janelamento de Hamming (ORFANIDIS, 2010). A Figura 3 ilustra um exemplo de um espectro de frequência gerado na Transformada Rápida de Fourier, ou seja, a conversão de uma janela de pontos no domínio do tempo, para o domínio da frequência.

Figura 3 - Espectro de frequência (transformada rápida de Fourier, FFT) de um sinal e as características extraídas dele.



Fonte: Autoria própria (2022)

Nesta pesquisa, para calcular as características no domínio da frequência (FDF), devem ser obtidos os vetores FFT_f e FFT_p , os quais são baseados na taxa de amostragem de 66 Hz.

- o vetor FFT_f armazena as 64 frequências até 33 Hz e

- o vetor FFT_p os 64 primeiros valores de potência sem a componente DC.

Na sequência são apresentados os cálculos das características extraídas no domínio da frequência (FDF) da Transformada Rápida de Fourier (FFT).

a) Primeira característica – calcula o valor da frequência correspondente ao pico de potência ou ponto indicado pela reta na cor marron na Figura 3. Primeiramente deve-se encontrar o índice (idx) equivalente ao pico de potência ou valor numérico 3 no eixo y da Figura 3, de acordo com a equação 2.8:

$$[\sim, idx] = \max(FFT_p) \quad (2.8)$$

Encontrado o índice, pode-se determinar o valor da frequência, conforme a equação 2.9:

$$Freq = FFT_f(idx) \quad (2.9)$$

b) Segunda característica - a equação 2.10 mostra o cálculo do valor de pico do vetor de frequência da FFT:

$$Valor_pico = \max(FFT_p) \quad (2.10)$$

c) Terceira característica - corresponde a soma de todos os valores de potência do espectro (pontos em azul da Figura 3), ou potência total, conforme a equação 2.11:

$$Pot_total = \sum(FFT_p) \quad (2.11)$$

d) Quarta característica – equivale ao valor da frequência média, de acordo com a equação 2.12

$$Freq_med = \sum(FFT_p * FFT_f) / Pot_total \quad (2.12)$$

e) Quinta característica - cálculo da média de potência, que correspondente a reta em vermelho na Figura 3, conforme a equação 2.13

$$Med_pot = \text{mean}(FFT_p) \quad (2.13)$$

Os sinais capturados dos três eixos (x, y e z) do acelerômetro interno de um *smartphone* divididos em categorias de movimentos humanos (andando na esteira, correndo na esteira, tremor, palmas, aceno de tchau, andando em círculo, apagando o quadro, subindo e descendo escadas e penteando o cabelo) são objetos de estudo nesta tese, onde foram calculadas as 5 características (equações 2.8 a 2.13). Janelas de dados de entrada com 100, 200, 500 e 1000 pontos foram utilizadas na composição dos padrões (GIACOMOSSI, 2011; GIACOMOSSI e PICHORIM, 2022).

2.2 Aprendizado de máquina

2.2.1 Aprendizado supervisionado

Para o reconhecimento de padrões, primeiramente deve ser executada a fase de extração de características para a elaboração dos conjuntos de padrões de acordo com as classes estudadas. Na fase seguinte, deve ser executado o treinamento ou aprendizado de máquina com parte do conjunto de padrões gerados (em torno de 70%), podendo ser supervisionado ou não supervisionado, para a construção de um modelo, o qual será submetido a fase final de classificação utilizando padrões desconhecidos ou que não fizeram parte do treinamento (em torno de 30%). Quando um conjunto de padrões é supervisionado, as classes são pré-definidas. Na sequência, a fase final de classificação dos dados com o uso de classificadores tais como: redes neurais MLP, KNN, SVM, RF, Naive Bayes, entre outros (SAFI *et al.*, 2015; NURHANIM *et al.*, 2017).

Nesta pesquisa foi utilizado o método de validação cruzada *k-fold*, no caso foi adotado *10-fold*. Na validação cruzada *k-fold*, os dados de entrada são divididos em subconjuntos de dados *k* (também chamados de *folds*). Um modelo de aprendizado de máquina (*Machine Learning* - ML) em todos, menos em um (*k-1*) dos conjuntos de dados e, em seguida, efetua a validação do modelo no conjunto de dados que não foi usado para treinamento. Esse processo é repetido *k* vezes, ou seja, 10 vezes com um subconjunto diferente reservado para avaliação (e excluído do treinamento) a cada vez.

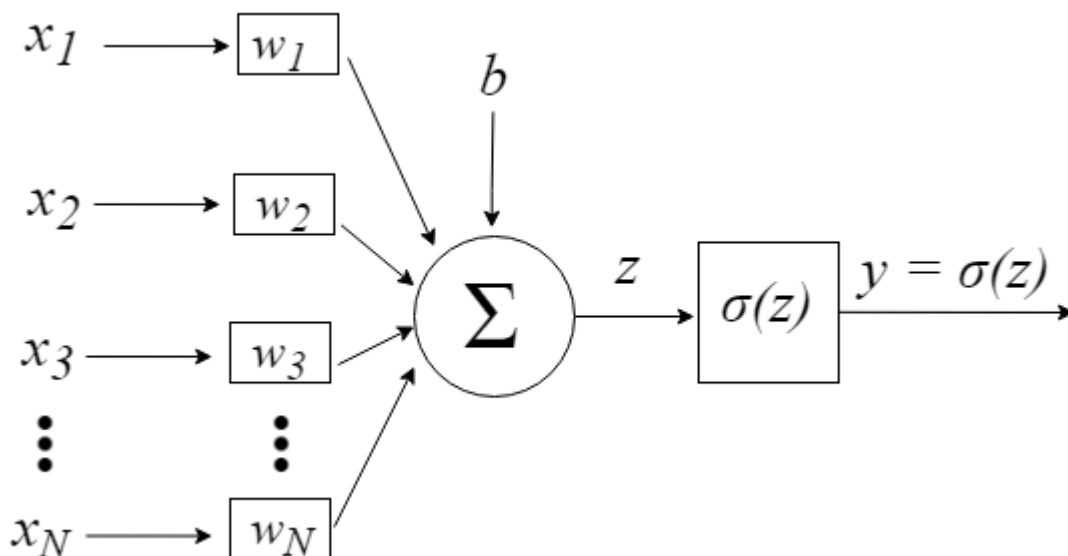
2.3 Classificadores

Nesta pesquisa foram utilizados classificadores aplicando redes neurais *Multilayer Perceptron* (MLP) e *K-Nearest Neighbor* (KNN) para a comparação dos resultados (índices de acerto) entre os métodos objetos de estudo. Também foi realizado o processamento com os classificadores SVM (*Support Vector Machine*) e *Naive Bayes*, no entanto, como apresentaram índices de classificação um pouco abaixo, esses classificadores foram descartados

2.3.1 Redes neurais *Multilayer Perceptron* (MLP)

As redes neurais utilizam neurônios nas camadas de entrada, oculta e saída. A Figura 4 apresenta o modelo de um neurônio artificial:

Figura 4 - Modelo de um neurônio artificial

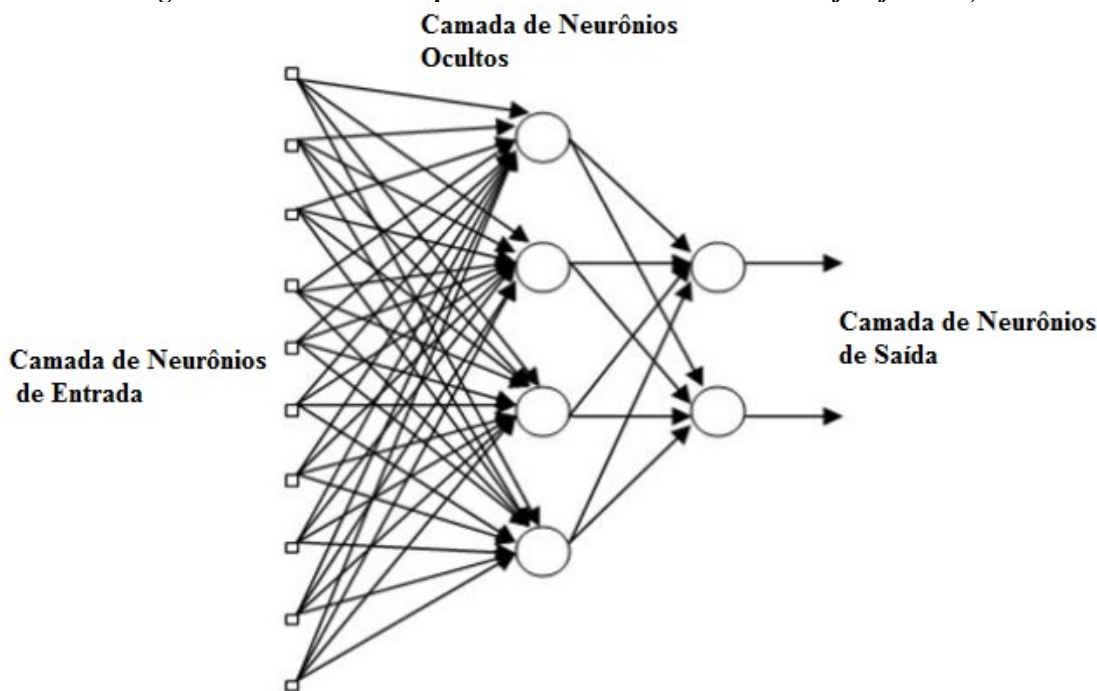


Fonte: Adaptado de Haykin (2001)

Os neurônios que caracterizam um modelo computacional, recebem na camada de entrada os dados de entrada. Nesta pesquisa, correspondem aos valores da amplitude dos sinais discretizados capturados com acelerômetro, divididos em categorias conforme os valores representados na Figura 4 ($x_1, x_2, x_3, \dots, x_N$). Cada valor de entrada é multiplicado por um peso sináptico correspondendo aos valores das variáveis $w_1, w_2, w_3, \dots, w_N$. Sendo assim, a saída z que equivale ao potencial de ativação, pode ser representada pela equação $z = \sum_{i=1}^N x_i w_i + b$. O valor de b fornece um grau de liberdade (*bias*). Na sequência, o valor de z é submetido a uma função matemática de ativação σ (função não linear), a qual limita o valor a um intervalo, produzindo o valor de saída y do neurônio. As funções de ativação mais usadas são a sigmoide, tangente hiperbólica, degrau e softmax.

A Figura 5 apresenta a configuração de uma rede neural com multicamadas MLP, ou seja, uma camada de neurônios de entrada, uma camada de neurônios ocultos e uma camada de neurônios de saída. Pode existir mais de uma camada oculta, sendo a segunda camada a entrada para a terceira camada (HAYKIN, 2001).

Figura 5 - Rede com múltiplas camadas alimentadas adiante (*feedforward*)



Fonte: Adaptado de Haykin (2001)

A rede neural deve ser treinada, ou seja, corresponde ao aprendizado de máquina para a elaboração do modelo a ser utilizado na classificação final. Os padrões são rotulados ou supervisionados, ou seja, recebem uma identificação da classe a qual pertencem. Desta forma, a rede aprende a identificar as classes de entrada, procedimento que é denominado de pré-processamento. Sendo assim, na última fase, ou classificação final, os padrões que não participaram da fase de aprendizado, são separados ou classificados de acordo com os rótulos pré-definidos ou classes (SARCEVIC; KINCSES; PLETL, 2017).

2.3.2 *K-Nearest Neighbor* (KNN)

O classificador KNN realiza o aprendizado baseado por analogia. O conjunto de dados de treinamento é formado por vetores n -dimensionais, onde cada elemento do vetor representa um ponto no espaço n -dimensional. O nome KNN vem de *k-Nearest Neighbor* (k -ésimo vizinho mais próximo) e realiza o aprendizado de máquina baseado nas k amostras mais próximas de uma dada instância. Desta forma, são encontrados os k vizinhos mais próximos de uma determinada classe, e não simplesmente o vizinho mais próximo, ou seja, nesta pesquisa foi adotado o valor $k=5$, procurando adequar o tempo de processamento com a precisão na classificação, por este classificador utilizar muito recurso de memória, uma vez que o algoritmo usa todo o conjunto de características para determinar a classe (quanto maior o valor de k , maior o uso de memória) (SARCEVIC, PLETL e KINCSES, 2017; AL-FAIZ,

ALI e MIRY, A. H., 2010). O que determina a proximidade entre os vizinhos é a distância calculada entre os pontos em um espaço Euclidiano (instâncias).

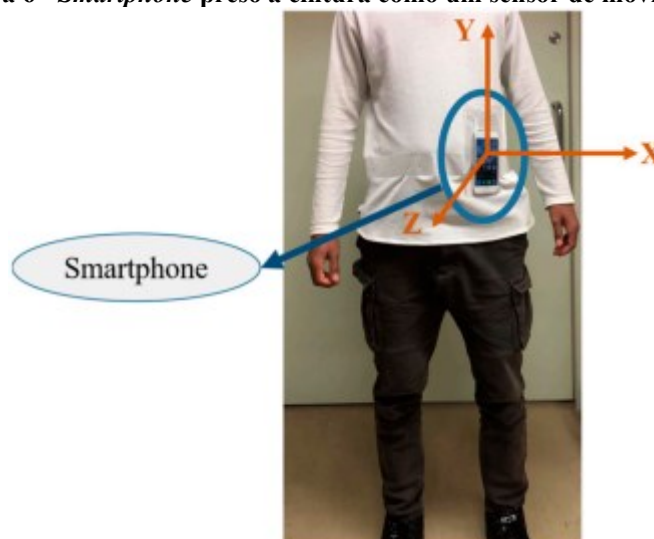
Para determinar a classe de um elemento que não pertença ao conjunto de treinamento, o classificador KNN procura k elementos do conjunto de treinamento que estejam mais próximos deste elemento desconhecido, ou seja, que tenham a menor distância. Estes k elementos são chamados de K-vizinhos mais próximos. Verifica-se quais são as classes desses k vizinhos e a classe mais frequente será atribuída à classe do elemento desconhecido (ASUROGLU *et al.*, 2017; WEBBER e ROJAS, 2021; GIACOMOSSI e PICHORIM, 2022).

3 ESTADO DA ARTE

Nesta seção são apresentados os principais conceitos, técnicas, métodos e características clássicas no domínio do tempo e domínio da frequência utilizadas no reconhecimento de padrões de acordo com a literatura. Algumas destas pesquisas estão relacionadas a seguir:

Na pesquisa de Alemayoh, Lee, e Okamoto (2021) foi utilizado um *smartphone* (*iPhone 7*) como sensor acoplado à cintura do corpo humano, fornecendo um acelerômetro de 3 eixos e dados do giroscópio, empregado como um dispositivo para medir a cinemática de movimentos humanos, no caso, atividades diárias incluindo oito categorias, tais como: caminhar, correr, pular, subir escadas, descer escadas, parado (em pé e sentado), deitar e andar de bicicleta. O objetivo principal é o reconhecimento dessas atividades em tempo real (*online*). Para tratar os dados dos sensores de forma simplificada, foi desenvolvido um *software* aplicativo exclusivo para iOS, mostrado na Figura 6. Ao contrário da maioria dos trabalhos de HAR (Reconhecimento de Atividades Humanas), foi escolhido um ambiente ao ar livre e os voluntários foram solicitados a iniciar e parar a gravação sem instrução de como realizar as atividades.

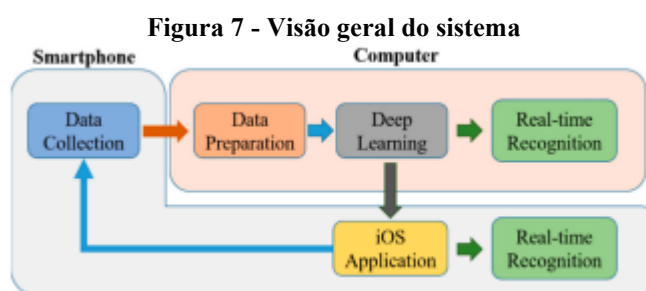
Figura 6 - Smartphone preso à cintura como um sensor de movimentos



Fonte: Adaptado de Alemayoh (2021)

Durante o teste dos modelos treinados em um computador, o aplicativo iOS (embarcado no *smartphone*) transmiti os dados do sensor em tempo real via Wi-Fi para o computador. Como muitas atividades humanas são uma repetição de um único movimento (por exemplo, caminhar é uma repetição de passos), os dados de grandes séries temporais foram divididos em pequenos quadros de dados ou janelas com um determinado intervalo de

tempo. Na fase de treinamento, um tamanho de janela de amostragem muito grande e muito pequeno tem um efeito significativo no desempenho geral do sistema. Se o tamanho for muito grande, um único quadro amostrado pode incluir várias atividades, que serão erroneamente consideradas como uma única atividade. Pelo contrário, uma pequena janela pode resultar em dados insuficientes para a identificação de uma única atividade. A inferência/previsão de atividade em tempo real foi investigada não apenas em um computador, mas também em um *smartphone*, incorporando o modelo ao *software* do aplicativo, conforme mostra a Figura 7.



Fonte: Adaptado de Alemayoh (2021)

Um conjunto de dados individual é representado na forma de imagem em tons de cinza, mapeando os valores máximo e mínimo para 0 e 255. Um módulo *Python* específico foi usado para mapear uma série de dados no tempo.

Os sinais brutos são moldados em uma matriz simples que pode ser considerada como uma imagem virtual. Esta imagem não representa o desenho de nenhum objeto, no entanto, os dados são moldados e representados simulando uma imagem normal. Para extrair características mais profundas, foi calculada a correlação entre os eixos de dados de entrada (3 acelerômetros e 3 giroscópios). Sendo assim, a correlação do eixo temporal e espacial dos sinais do sensor, foram reestruturados em imagens virtuais 2D. Foram extraídas características no domínio do tempo, ou seja, sobre os dados brutos do sensor de série temporal coletados do *smartphone*, bem como no domínio da frequência (Transformada Rápida de Fourier – cada atividade apresenta uma frequência distinta) e transformada Wavelet para a classificação das atividades diárias utilizando classificador por rede neural.

Em Nurwulan e Selamaj (2020) movimentos humanos de atividade diária foram classificados, utilizando dados capturados com *smartphone*, o qual apresenta acelerômetro triaxial integrado, fornecendo uma maneira prática e barata de monitorar, tendo em vista que para uso de longo prazo, sensores de movimento podem ter um custo elevado. Os dados de movimentos humanos correspondem aos sinais capturados do acelerômetro, os quais, foram

analisados e classificados em várias atividades (categorias), aplicando as técnicas de reconhecimento de padrões.

A abordagem comum é extrair as características dos dados de séries temporais e treinar modelos de aprendizado de máquina para classificar cada atividade. A aquisição dos dados foi realizada com o *smartphone* preso à cintura dos voluntários, sendo o conjunto de dados dividido nas categorias: caminhar, subir escadas, descer escadas, sentar, levantar e deitar. Os dados foram pré-processados utilizando janela sobreposta. Na fase de extração de características para a elaboração de padrões de acordo com as classes de movimentos, dois modos foram aplicados, ou seja, características no domínio do tempo e domínio da frequência, bem como a composição dos dois modos, em outro conjunto de padrões. O domínio do tempo refere-se à variação da amplitude do sinal no tempo. Já o domínio da frequência é mais robusto, como exemplo, a Transformada Rápida de Fourier (FFT).

Neste estudo as características calculadas foram: média, desvio padrão, desvio médio absoluto, máximo, mínimo, área de magnitude do sinal (SMA), energia, intervalo interquartil e entropia espectral em ambos os modos (domínio do tempo e da frequência). Na fase de classificação, foi comparado *Random Forest* (RF) com outros classificadores: rede neural artificial (RNA), *k*-vizinhos mais próximos (KNN), análise discriminante linear de Fisher (LDA), *Naïve Bayes* (NB) e máquina de vetor de suporte (SVM).

Utilizou-se o ambiente WEKA (*Waikato Environment for Knowledge Analysis*) para fazer as análises de aprendizado de máquina. Foi aplicado um classificador que utiliza os princípios de redes neurais *Multilayer Perceptron* (MLP), que consiste em pelo menos três camadas de nós: uma camada de entrada, uma camada oculta e uma camada de saída. A camada oculta e a camada de saída utilizam uma função de ativação não linear. A rede MLP usa *backpropagation* para treinamento, uma poderosa técnica de aprendizado supervisionado que pode distinguir dados que não são linearmente separáveis.

O classificador KNN (*k-Nearest Neighbors*) possui dois parâmetros: o número de vizinhos (*k*) e a medida de similaridade usada para encontrar os vizinhos mais próximos. A distância Euclidiana é a medida mais amplamente usada para determinar os vizinhos, embora existam outras opções. Em relação ao parâmetro *k* (número de vizinhos), várias alternativas para determinar o valor mais adequado podem ser empregadas, sendo que, uma delas é avaliar o algoritmo KNN no conjunto de validação, adotando diferentes valores para *k* e o valor de *k* que alcançar a melhor precisão, será escolhido para classificar todas as instâncias de teste. Uma primeira diferença em relação a outros classificadores, tais como árvore de decisão e MLP, é que, no KNN, a etapa de treinamento é caracterizada apenas pelo armazenamento das

instâncias. A rigor, não há treinamento. Logo, a função que será usada para a tomada de decisão é definida pelos k -vizinhos mais próximos. A classificação dos dados é feita determinando a similaridade entre o conjunto de treinamento e a nova observação que é atribuída à classe com maior número de votos. A semelhança é decidida pela menor distância euclidiana.

O classificador LDA é um método supervisionado de redução de dimensionalidade linear que usa combinações lineares para extrair características de menor dimensão. O classificador NB é um método supervisionado simples com a suposição de independência condicional das características, embora tenha apresentado ótimos resultados em aplicações médicas, estudos anteriores constataram resultados não favoráveis para sinais de “marcha” a partir de dados de acelerômetros.

O classificador SVM é um método de aprendizado de máquina supervisionado discriminativo, que coloca um hiperplano de decisão no espaço de padrões para a classificação dos dados em diferentes classes. A diferença com o LDA, é que o SVM seleciona o hiperplano com distância de margem máxima.

O classificador *Random Forest* (RF) é um método de aprendizado para classificação utilizando regressão e outras tarefas que operam construindo uma infinidade de árvores de decisão no tempo de treinamento. Para tarefas de classificação, a saída da floresta aleatória é a classe selecionada pela maioria das árvores. Para tarefas de regressão, a previsão média ou média das árvores individuais é retornada. Cada árvore do RF pode selecionar apenas um subconjunto aleatório de características que possibilita aumentar a variação entre as árvores do modelo. Assim, a classificação resultará em maior precisão considerando a baixa correlação entre as árvores. Embora a RF possa render ótimos resultados nos índices de acerto na classificação final, o grande número de árvores pode tornar o algoritmo muito lento e ineficaz para previsões em tempo real.

Neste estudo, não foi avaliado apenas a precisão ou índices de classificação, mas também foi considerado o tempo gasto para construir os modelos de aprendizado de máquina. Foram utilizadas características no domínio do tempo e da frequência para avaliar qual modo apresenta melhor resultado na classificação de dados de aceleração. A FFT foi usada para produzir as características no domínio da frequência.

Com base nos resultados, o classificador RF superou os outros classificadores em todas as categorias de dados, combinando as características no domínio de tempo e frequência obtendo os índices de acerto mais elevados. No entanto, o tempo gasto para construir o modelo, foi o segundo mais longo depois da RNA. Na avaliação dos resultados utilizando

somente características no domínio do tempo, apenas a RNA e a RF alcançaram o índice de acerto de 84%. Utilizando somente características no domínio da frequência, a ANN (*Artificial Neural network*), LDA, SVM e RF obtiveram índice de acerto de 85% e a combinação de características no domínio do tempo e da frequência apresentaram a maior precisão para todos os classificadores, exceto o NB.

As características distância total percorrida, aceleração e distância em alta velocidade são medidas biométricas monitoradas em atletas com o uso do dispositivo acelerômetro na pesquisa de Howe *et al.* (2017). Este procedimento pode auxiliar na prescrição do treinamento. Os acelerômetros fornecem informações que podem auxiliar os praticantes na preparação física e no monitoramento de atletas em esportes coletivos baseados em colisões, superando a tecnologia GPS.

Os sinais capturados do acelerômetro e do sensor do giroscópio integrados de um *smartphone*, são utilizados para realizar o reconhecimento de atividades realizadas pelo usuário no dia a dia no estudo de Jain e Kanhangad (2018). Os sinais fornecem informações da aceleração linear triaxial e velocidade angular, e destes são extraídas características no domínio do tempo e da frequência.

O histograma de gradiente (HG) e descritor de Fourier (FD) foram utilizados como métodos para a extração de características. Na classificação das categorias de movimentos, foram utilizados os classificadores SVM e KNN. Dois conjuntos de dados da literatura foram comparados, sendo que nos dois casos o método proposto foi superior, obtendo uma precisão média de classificação de atividade de 97,12% como o melhor resultado.

Os sinais dos sensores inerciais (acelerômetro, giroscópio e magnetômetro) do *smartphone* adaptado na cintura de voluntários, foram usados na pesquisa de Nurhanim *et al.* (2017) para classificar atividades de movimentos humanos tais como: andar, sentar, ficar em pé, deitar, subir e descer escadas, usando o método de reconhecimento de padrões. Diversas características foram extraídas no domínio do tempo e domínio da frequência.

Características no domínio do tempo extraídas dos dados de entrada, tais como: área de magnitude do sinal (SMA), valor mínimo (MIN) e valor máximo (MAX) de uma janela de pontos, desvio padrão (STD), medida da energia do sinal (soma dos quadrados da amplitude de sinal divididos pelo número de valores). Dentre as características no domínio da frequência foram calculadas: distorção do sinal (*skewness*), entropia (*entropy*), coeficiente autorregressivo, índice da componente de frequência de maior magnitude, média ponderada da frequência, frequência média, coeficiente de correlação, ângulo entre dois vetores de pontos do sinal.

Foi utilizado uma janela de 2,56 segundos de tempo, para a extração das características das atividades. Para avaliar o desempenho da classificação, o conjunto de dados foi dividido aleatoriamente por 70% para o conjunto de dados de treinamento e 30% restantes do conjunto de dados para a realização de testes. Os resultados mostram que o método proposto utilizando o classificador *Support Vector Machine* (MC-SVM-Polynomial - *Multiclass support vector machine polynomial kernel*) produziu o melhor resultado com 98,57% em comparação com MC-SVM-Linear (*multiclass support vector machine Linear Kernel*) com 97,04%, baseando-se nos índices de classificação corretos.

A contagem de passos utilizando dados capturados com acelerômetro de um *smartphone* (android) foi realizada no estudo de Dirican e Aksoy, (2017). O método realiza um pré-processamento com um algoritmo baseado na FFT (Transformada Rápida de Fourier) aplicada sobre os dados de aquisição para os eixos x, y e z. O algoritmo detecta e conta os passos comparando os dados processados com a aplicação da FFT a limiares pré-definidos.

Como na conversão dos dados através da FFT, são gerados números complexos, ou seja, uma parte real e outra imaginária, o algoritmo prevê limites distintos para as duas partes, desta forma, inicialmente realizando uma comparação com o máximo real, caso esteja dentro do limiar estabelecido, será testada a parte imaginária. Neste caso, admite valores positivos ou negativos, ou seja, quando a perna está em movimento para frente ou para trás respectivamente, sendo assim, somente será incrementado o contador de passos caso as duas condições, parte real e imaginária, estiverem dentro dos limites estabelecidos (valor máximo da parte real dentro do limiar e parte imaginária com valor positivo). Os limiares foram determinados antes dos experimentos, sendo assim, foram analisados os movimentos de usuários ao sentar, ficar de pé e caminhar; com o *smartphone* colocado em um suporte frontal da calça na posição vertical.

O reconhecimento de padrões de movimentos humanos envolvendo atividades do dia a dia como sentar, ficar em pé, deitar, cair, correr e caminhar, estão presentes no estudo de Li *et al.* (2013). Neste artigo, foram extraídas características no domínio do tempo e no domínio da frequência de cada janela da aceleração triaxial (sensor acelerômetro). As características no domínio do tempo incluem:

- Valor médio dos dados de aceleração sobre uma janela;
- Correlação entre os eixos (x, y), (y, z), (z, x);
- Valor RMS ou eficaz;
- Desvio médio absoluto;

- Desvio Padrão e
- Variância.

No domínio da frequência são calculadas as características:

- A característica Energia da amostra do sinal, que é calculada como a soma dos quadrados da amplitude do sinal (por amostra);
- *Fast Fourier Transform* (FFT).

Também foram calculadas as características Área da Magnitude do Sinal (SMA) e Vetor Magnitude do Sinal (SVM). A característica SMA foi calculada segundo a equação (3.1):

$$SMA = \frac{1}{t} \left(\int_0^t |x(t)| dt + \int_0^t |y(t)| dt + \int_0^t |z(t)| dt \right) \quad (3.1)$$

onde $x(t)$, $y(t)$ e $z(t)$, correspondem aos componentes da amplitude da amostra do sinal para os eixos x, y e z. A característica SMA, pode ser usada para determinar se o movimento humano é dinâmico ou estático durante um período de tempo. A equação (3.2) seguinte mostra o cálculo para a característica SVM:

$$SVM = \sqrt{x_i^2 + y_i^2 + z_i^2} \quad (3.2)$$

onde x_i , y_i e z_i , são os limites de amplitude para as amostras x, y e z. A característica SVM, pode ser usada para detectar uma queda durante um período de tempo.

No estudo de Dias (2009, p. 40), os parâmetros aceleração, velocidade ou variações de distâncias são as características utilizadas na quantificação de movimentos 3D em crises epiléticas, animação por computador, robótica, entre outras. Na quantificação de movimentos 3D em crises epiléticas, por meio de análises gráficas, determinam-se as variações de parâmetros como distância percorrida, velocidade ou aceleração dos movimentos. As variações ou movimentos de posicionamento são baseados em vários pontos de marcação (marcadores) estabelecidos no corpo, que serão associados a câmeras de vídeo que capturam os sinais de reflexão infravermelho em tais marcadores, para o processamento usando os recursos de computação e obtenção dos parâmetros ou características desejadas, tais como: distâncias Euclidianas que determinam os deslocamentos, volume, aceleração, entre outros. Nestes casos, por exemplo, também podem ser analisados os *frames* de imagens individualizadas ou vídeos para auxiliar na classificação de um tipo de crise.

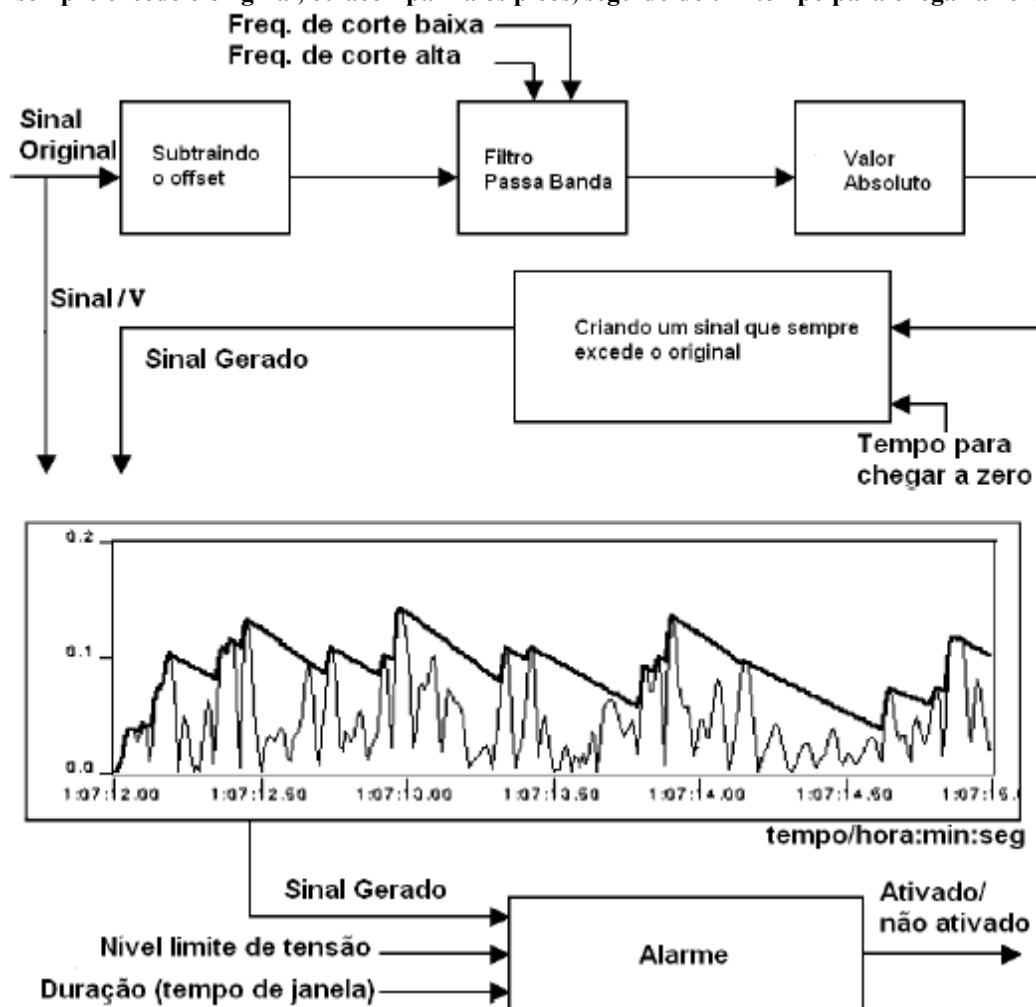
A detecção de padrões de uma caminhada realizada por diferentes indivíduos, utilizando um *smartphone* para a captura de dados do acelerômetro interno, corresponde a

pesquisa de Bayat *et al.* (2017). São utilizados os sinais dos eixos x, y e z, onde cada série temporal (dos diferentes eixos) pode ser considerada como uma combinação de dois componentes de aceleração: a aceleração gravitacional e a aceleração corporal. Foi utilizado um filtro digital, o qual separa a gravidade e a aceleração do corpo. A componente contínua (DC) resultante do filtro passa-baixa obtém-se a aceleração gravitacional e subtraindo esta componente do sinal original é assumido como a aceleração resultante do movimento do corpo.

De acordo com o comportamento dos sinais da atividade de caminhada (sinal com variantes positivas e negativas), passou a ser utilizado as características desvio padrão (STD) e o valor RMS. O valor Min-Max é proposto como outra característica, onde o valor mínimo de cada componente da janela (amostra do sinal de entrada) é subtraído do seu valor máximo, bem como a média ou o número médio de valores de pico local em cada janela, e a sua variação nas três direções dos movimentos. A variação pode fornecer uma boa estimativa da distribuição dos picos locais ao longo do eixo x, y e z. Além disso, foi medido a correlação entre os 3 eixos. Sendo assim, nesta pesquisa, foram utilizadas 6 características que incluem a média, desvio padrão (STD), o valor mínimo (MIN), o valor máximo (MAX), o valor RMS, valor médio de picos e sua variação estatística. Essas características foram escolhidas para serem aplicadas nas janelas ou amostras das séries temporais (eixos x, y e z). Além disso, foram aplicadas as correlações para os 3 eixos. Utilizou-se validação cruzada *10-fold* e vários classificadores, no entanto, o melhor resultado foi obtido com o classificador baseado em regras *Decision Table* (DT) ou Tabelas de Decisão com índice de acerto de 98,45%.

A conversão de um sinal de entrada em um novo sinal é realizada na pesquisa de Elevant (1999) e fundamenta um dos principais conceitos utilizados nesta tese com a redução do sinal de entrada em pontos de mínimo e máximo (GIACOMOSSI, 2011; GIACOMOSSI e PICHORIM, 2022). O estudo de Elevant (1999) utilizou um conceito similar, no caso, as janelas de sinais de aquisição de crises epiléticas são convertidas em um novo sinal seguindo o sinal original (somente alguns pontos de máximo), com decaimento linear mais lento na descida para chegar a zero após um tempo especificado. Desta forma, um alarme é acionado com base em parâmetros como: frequência de corte alta e baixa, tempo para o sinal criado atingir zero, nível de tensão limite e duração (janela de tempo). A Figura 8 mostra o diagrama em blocos apresentando todos os passos para a elaboração do novo sinal.

Figura 8 - Diagrama em blocos de um alarme onde o sinal original é transformado em um novo sinal que sempre excede o original, ou acompanha os picos, seguido de um tempo para chegar a zero



Fonte: Adaptado de Elevant (1999, p. 15)

O monitoramento dos tremores da doença de Parkinson com o uso de um *smartphone* foi objeto de estudo na pesquisa de Bazgir *et al.* (2015). As duas principais características analisadas para a detecção dos tremores foram a frequência (frequência fundamental) e a intensidade do tremor. Os valores da aceleração capturados com dispositivo acelerômetro, resultaram em uma taxa de acerto de 91% de precisão com o uso de um classificador por rede neural. A frequência fundamental também foi utilizada na detecção dos tremores de mão no estudo de Pierleoni, *et al.* 2014. A classificação do tipo de tremor tem correlação com a UPDRS (*Unified Parkinson's Disease Rating Scale*). Os resultados da correlação com a UPDRS calculada pelo algoritmo proposto, são fiéis à avaliação feita com os neurologistas. O algoritmo tem 100% de sensibilidade e especificidade considerando uma amostra de 12 pacientes.

As acelerações mínimas e máximas de diversas atividades diárias são comparadas com movimentos de quedas simuladas em Lee e Carlisle (2011), com o objetivo de detecção de quedas por meio de acelerômetros e tecnologia de telefonia móvel.

Este estudo é útil principalmente para pessoas idosas que vivem sozinhas, pois o método pode notificar um sistema remoto usando mensagem SMS e detectar uma emergência quando um sujeito permanece parado após a queda.

O objetivo é diminuir o risco de queda e aumentar a confiança dos idosos com o uso do telefone celular, diminuindo o medo de cair, estimulando a prática de atividade física, o que levará a uma melhora da qualidade de vida. As configurações de limiares individuais com base nas atividades da vida diária resultam em alta sensibilidade e especificidade da detecção de quedas por acelerômetros.

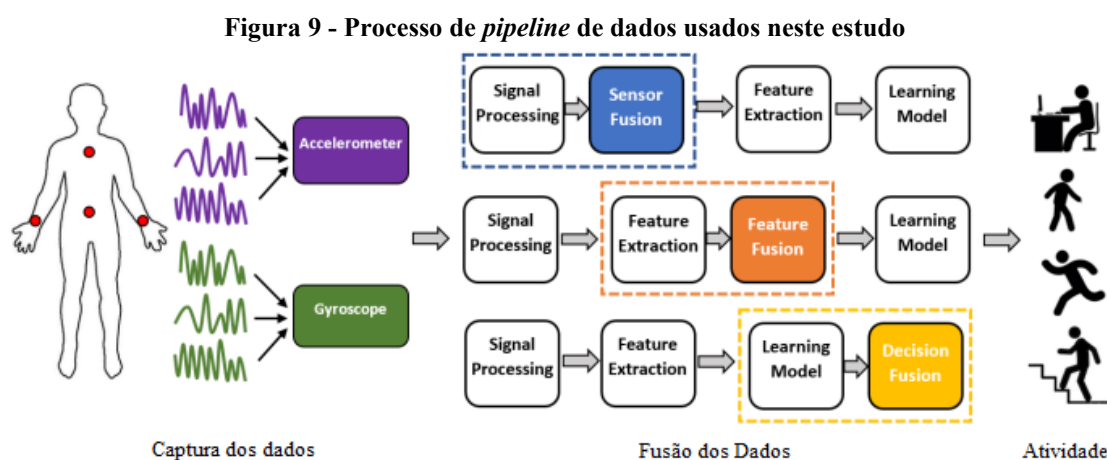
De acordo com Khan *et al.* (2010), a mobilidade é um bom indicador do estado de saúde, portanto, nesta pesquisa foram armazenados dados de atividades diárias com pacientes idosos utilizando o acelerômetro, o qual pode ser utilizado para o monitoramento de atividades de longo prazo, com o objetivo de avaliar o estado de saúde de pacientes idosos.

Neste estudo foram validadas sete atividades: repouso (deitado/sentado/em pé), caminhada, subir escadas, descer escadas, correr, andar de bicicleta e aspirar. Os sinais foram capturados a partir de cinco posições do corpo: bolso traseiro da calça, bolso interno da jaqueta no peito, bolso frontal esquerdo da calça e bolso frontal direito da calça. Foram utilizadas as características área de magnitude do sinal (SMA), entropia espectral e coeficientes autorregressivos (AR). A classificação final foi realizada por uma rede neural artificial (RNA) com uma precisão média de reconhecimento de 94%.

Um método de reconhecimento de padrões de movimentos humanos mistos, baseado na fusão de várias características extraídas de múltiplas fontes, foi desenvolvido no estudo de Song *et al.* (2020). Foi realizado o controle híbrido inteligente de um exoesqueleto, visando o reconhecimento rápido da etapa de marcha do usuário. Para descrever os movimentos dos membros inferiores, foi proposto um sistema de análise de marcha que combina o sensor inercial e o sensor de pressão para realizar o sincronismo das informações de movimento da coxa, panturrilha e pé. Foram extraídas 141 características de multiplas-fontes baseadas na média, variância, valor máximo (MAX), coeficiente de correlação, série de Fourier, Área de Magnitude do Sinal (SMA) e entropia de energia Wavelet. A classificação dos movimentos foi baseada em uma rede neural multi-camada. Nos experimentos realizados no modo de movimentos mistos, a melhor taxa de acerto obtida foi 97,4%.

Três níveis de composição de dados foram utilizados na pesquisa de Webber e Rojas (2021), com o objetivo de determinar o nível ideal para dados de atividades humanas capturados com vários sensores, neste estudo, o acelerômetro e o giroscópio. Todos os três níveis foram analisados usando quatro técnicas. As técnicas de fusão a nível de sensor foram escolhidas para ver o impacto de um sensor no outro. O giroscópio e o acelerômetro têm suas desvantagens, ou seja, o giroscópio é extremamente vulnerável a desvios (oscilações) a longo prazo, enquanto o acelerômetro é sensível a solavancos bruscos (impactos), mas não oscila ao longo do tempo. A fusão de dados a nível de sensor nos permite mesclar as melhores partes de cada sensor. A fusão a nível de características serve para identificar a correlação entre as mesmas, permitindo que os classificadores extraiam as características mais fortes, facilitando a separação ou classificação das categorias de movimentos.

Foram extraídas características estatísticas a partir de janelas ou amostras dos dados de entrada, nos diversos níveis, tais como: média, mediana, desvio padrão (STD), mínimo (MIN), máximo (MAX), a diferença entre o máximo e o mínimo (MinMax) e a diferença entre o quartil superior e o quartil inferior (*Inter-Quartile Range* - IQR).



Na Figura 9 em primeiro lugar, a atividade humana é capturada usando sensores de acelerômetro e giroscópio, sendo os dados registrados como séries temporais. Em segundo lugar, os dados coletados são fundidos em três níveis diferentes separadamente: fusão a nível do sensor (em azul), fusão a nível de características (em laranja) e fusão a nível de decisão (em amarelo). Finalmente, uma atividade humana é reconhecida na última etapa

A fusão em nível de decisão permite que classificadores de desempenho inferior mesquem seus resultados para produzir um classificador com melhor desempenho. Os classificadores *Support Vector Machine* (SVM), *K-Nearest Neighbours* (KNN), *Linear*

Discriminant Analysis (LDA) e *Decision Tree Classifier* (DTC) foram escolhidos com base na simplicidade de implementação e uso estendido na literatura na classificação de movimentos humanos (HAR). O objetivo neste estudo, é identificar o nível de fusão mais adequado para melhorar a precisão dos sistemas de reconhecimento de atividade humana. Em termos de precisão, o nível de decisão na média obteve o melhor desempenho, no entanto, o tempo de processamento necessários para treinar e fazer as classificações para os dois classificadores de maior desempenho, reduziram a eficácia do nível de decisão para uso em sistemas HAR em dispositivos móveis.

Os trabalhos correlatos encontrados na literatura abordados nesta pesquisa, apresentam conceitos em comum, entre os quais, a classificação de movimentos humanos diários, utilizando dados capturados com acelerômetro, além de utilizar o dispositivo *smartphone*, que apresenta um acelerômetro interno, facilitando e simplificando o tratamento dos sinais lidos nos 3 eixos ortogonais.

Para a classificação de movimentos humanos, de um modo geral, são extraídas características no domínio do tempo e domínio da frequência, visando o reconhecimento de padrões. São utilizadas características no domínio do tempo ou cálculos estatísticos como área, mínimo, máximo, desvio padrão, variância, média, valor RMS, SMA, entre outras. Assim como, no domínio da frequência, são utilizadas características extraídas da FFT (valor de frequência correspondente ao pico de potência da FFT, valor de tensão de pico do vetor de frequência da FFT, potência total, frequência média e potência média), características como distorção do sinal, entropia, AR (coeficiente autoregressivo), correlação entre os sinais (x, y e z), características extraídas da transformada de Wavelet, entre outras. Estes são os métodos tradicionais encontradas nos trabalhos relatados, dos quais, algumas das principais características (clássicas) encontradas na literatura, serão comparadas com uma abordagem baseada em novas características extraídas simultaneamente nos domínios do tempo e frequência.

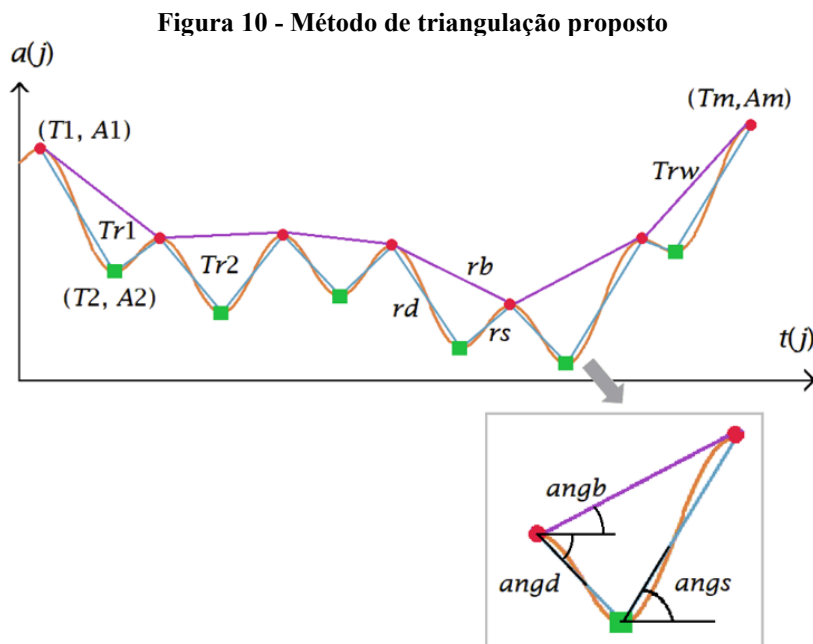
A principal contribuição desta pesquisa, corresponde a extração de novas características, as quais, são calculadas com um algoritmo que aplica os princípios Euclidianos e estatística básica, visando o reconhecimento de padrões. O método proposto converte os sinais de entrada em um novo sinal, gerando sequências de triângulos entre os pontos de máximos e mínimos, ou picos e vales, e destes, são calculadas retas (subida, descida e base), ângulos, áreas, coeficientes angulares (derivadas das retas), perímetro e contagem dos triângulos. Na sequência, em métodos, é apresentada a descrição da técnica de triangulação e os cálculos das referidas características.

4 MÉTODO DE DESENVOLVIMENTO DA PESQUISA

A técnica proposta aplica conceitos estatísticos e geométricos na extração de características de qualquer sinal irregular em amplitude e período irregular. Tal técnica pode ser descrita passo a passo começando com a obtenção de todos os pontos de pico e vale (coordenadas t, a) do sinal original, considerando uma janela ou segmento de tamanho fixo de uma variável contínua discretizada no tempo. A variável a corresponde ao valor numérico de amplitude e a variável t ao valor numérico do tempo, indexados pela variável j , para cada ponto de pico e vale encontrado na janela. A Figura 10 ilustra o processo de construção de triângulos conectando pontos de picos e vales de um sinal genérico em uma janela de n pontos, começando com um ponto de pico ($T1, A1$), porém, este início pode ser um ponto de pico ou um vale, dependendo da sequência do sinal de entrada ao selecionar uma próxima janela (GIACOMOSSO e PICHORIM, 2022).

Sendo assim, o algoritmo de pesquisa dos pontos de picos e vales pode ser descrito como:

- Em uma inclinação descendente do sinal $a_{(j+1)}$ é menor que $a_{(j)}$, então j é repetidamente acrescido em 1 até $a_{(j+1)} \geq a_{(j)}$. Neste ponto j , um vale é detectado e armazenado no vetor $A(i)$ com a sua posição no tempo $T(i)$, e
- Em uma inclinação ascendente do sinal, $a_{(j+1)}$ é maior que $a_{(j)}$, então j é incrementado em 1 até $a_{(j+1)} \leq a_{(j)}$. Neste ponto j , um pico é detectado e armazenado no vetor $A(i)$ com a sua a posição no tempo $T(i)$. A variável i indexa os m pontos de pico e vale encontrados na janela. A Figura 10, ilustra o processo de seleção dos picos e vales de uma amostra genérica de n pontos.



Fonte: Autoria própria (2022)

Os vetores unidimensionais $T(i)$ e $A(i)$, são usados para o cálculo das linhas retas entre todos os pontos de picos e vales selecionados encontrados na janela (linhas ascendentes e descendentes), bem como as linhas retas entre dois picos quando a amostra de sinal inicia em um ponto de pico (linhas de base), ou dois vales quando a janela inicia em um ponto de vale. O sinal de entrada (em marrom), apresenta os pontos de pico (em vermelho) e vale (em verde) por janela. Uma sequência de triângulos w ($Tr1$ a Trw) é gerada calculando as distâncias entre os pontos de pico e vale, gerando as retas rs, rd , bem como as distâncias dos pontos consecutivos de pico rb . Cada triângulo é avaliado pelos lados, áreas e ângulos ($angs$, $angb$ e $angd$).

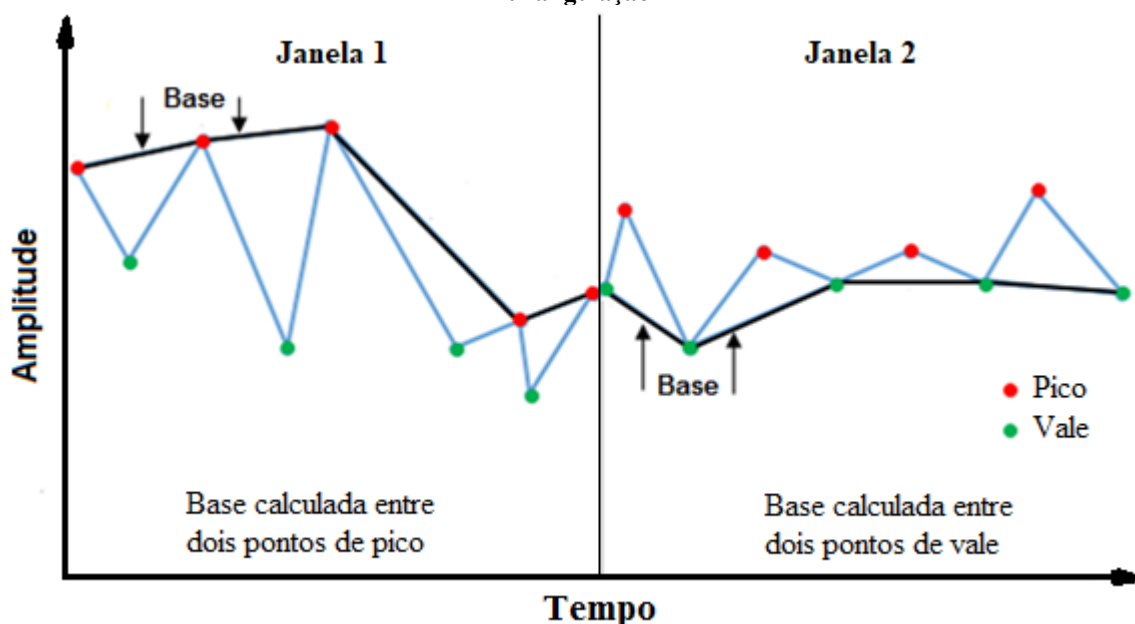
Desta forma, a janela de sinal é transformada em uma sequência de triângulos com a aplicação dos princípios Euclidianos. Os pontos são armazenados nos vetores $T(i)$ e $A(i)$ indexados com a variável i variando de $i=1$ até m , onde m é o número de picos e vales encontrados na janela.

A quantidade de pontos de picos e vales variam devido à irregularidade dos dados de entrada. Sendo assim, uma sequência de triângulos ($Tr1$ até Trw) será gerada, onde o índice k corresponde ao número de triângulos obtidos em uma janela, o qual varia de 1 até w .

A Figura 11 mostra o que foi descrito anteriormente, com relação a inversão de cálculo das bases dos triângulos gerados em uma janela selecionada, sempre com o mesmo número de pontos (tamanho fixo para o cálculo de todos os padrões). Foi simulada uma sequência de duas janelas de pontos de pico e vale selecionados pelo algoritmo de triangulação, extraídos do sinal original de uma categoria de dados de entrada qualquer, bem

como as linhas retas calculadas. Sendo assim, uma inclinação descendente ocorre quando o cálculo das linhas retas tem os dois primeiros pontos com valores decrescentes (janela 1) ou uma inclinação ascendente (janela 2) quando os dois primeiros pontos apresentam valores crescentes, ou seja, as linhas retas da base calculadas entre dois picos ou dois vales respectivamente.

Figura 11 - Sequência simulada de duas janelas de pontos de pico e vale selecionados pelo algoritmo de triangulação



Fonte: Autoria própria (2022)

4.1 Extração de Características

Deste ponto, começa o processo de extração de características, que é baseado na média dos lados, ângulos de subida, ângulos de descida, perímetros e áreas de todos os triângulos em uma janela. Os comprimentos das linhas rs , rd e rb , os lados de cada triângulo k , são calculados, respectivamente, por

$$rs(k) = \sqrt{(T_{2k+1} - T_{2k})^2 + (A_{2k+1} - A_{2k})^2} \quad (4.1)$$

$$rd(k) = \sqrt{(T_{2k} - T_{2k-1})^2 + (A_{2k} - A_{2k-1})^2} \quad (4.2)$$

$$rb(k) = \sqrt{(T_{2k+1} - T_{2k-1})^2 + (A_{2k+1} - A_{2k-1})^2} \quad (4.3)$$

A partir dos triângulos, as áreas (at), perímetros (per), ângulos de subida ($angs$), ângulos de descida ($angd$), ângulos de base ($angb$), derivada da subida ($devs$), derivada da descida ($devd$) e derivada da base ($devb$), são calculados, respectivamente, por

$$at(k) = \frac{1}{2} \begin{bmatrix} T_{2k-1} & A_{2k-1} & 1 \\ T_{2k} & A_{2k} & 1 \\ T_{2k+1} & A_{2k+1} & 1 \end{bmatrix} \quad (4.4)$$

$$per(k) = rs(k) + rd(k) + rb(k) \quad (4.5)$$

$$angs(k) = \arctan \left(\frac{A_{2k+1} - A_{2k}}{T_{2k+1} - T_{2k}} \right) \quad (4.6)$$

$$angd(k) = \arctan \left(\frac{A_{2k} - A_{2k-1}}{T_{2k} - T_{2k-1}} \right) \quad (4.7)$$

$$angb(k) = \arctan \left(\frac{A_{2k+1} - A_{2k-1}}{T_{2k+1} - T_{2k-1}} \right) \quad (4.8)$$

$$devs(k) = \left(\frac{A_{2k+1} - A_{2k}}{T_{2k+1} - T_{2k}} \right) \quad (4.9)$$

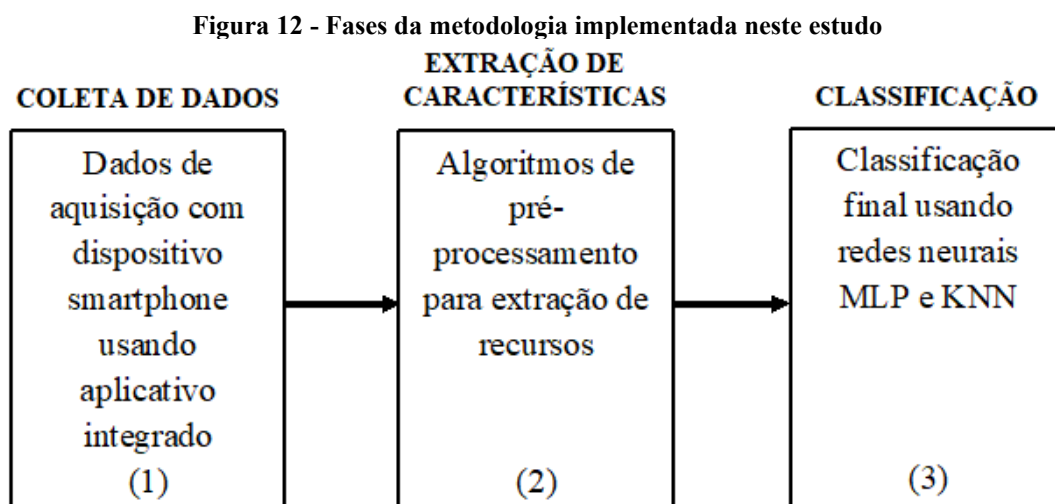
$$devd(k) = \left(\frac{A_{2k} - A_{2k-1}}{T_{2k} - T_{2k-1}} \right) \quad (4.10)$$

$$devb(k) = \left(\frac{A_{2k+1} - A_{2k-1}}{T_{2k+1} - T_{2k-1}} \right) \quad (4.11)$$

Observando as equações acima, todas as características dos triângulos são obtidas usando as variáveis de amplitude e tempo (A e T). Em outras palavras, essas características se comportam como pertencentes aos domínios do tempo e da frequência.

Na próxima etapa, um cálculo estatístico deve ser aplicado aos vetores $rs(k)$, $rd(k)$, $rb(k)$, $at(k)$, $per(k)$, $angs(k)$, $angd(k)$, $angb(k)$, $devs(k)$, $devd(k)$ e $devb(k)$, como soma, média, desvio padrão, variância, etc. Os valores estatísticos calculados nos 11 vetores (C_1 to C_{11} repectivamente) são atribuídos para um novo vetor característica, incluindo uma 12ª característica, contador de triângulos, para a composição de um padrão extraído do sinal de entrada (eixo x) do sensor do acelerômetro. O procedimento anterior é repetido com o eixo y para criar as características C_{13} a C_{24} e as características C_{25} a C_{36} para o eixo z.

Para validação da técnica proposta, foi aplicada uma metodologia, a qual, foi dividida em três fases, conforme mostra a Figura 12. 1) aquisição do sinal do movimento humano; 2) extração de características por triangulação e extração de características encontradas na literatura no domínio do tempo e no domínio da frequência; e 3) classificação e teste (GIACOMOSSI e PICHORIM, 2022).



Fonte: Autoria própria (2022)


4.2 Coleta de dados (fase 1)

Para a realização dos experimentos e a aquisição dos dados nesta pesquisa, foi aprovado um projeto com a descrição detalhada de todos os procedimentos para o comitê permanente de ética em pesquisa envolvendo seres humanos da Universidade de Maringá, Estado do Paraná, Brasil, protocolo número 1717907 (em Anexo). Na fase 1 foram coletados dados de movimentos humanos de 24 voluntários normais (12 homens e 12 mulheres), com idades entre 18 e 45 anos, nas categorias de andando na esteira, corrida na esteira, tremores simulados, palmas, acenos de tchau, andando em círculo, apagando quadro, subindo e descendo escada e penteando o cabelo, nos três eixos ortogonais (x, y e z) e registrados em arquivos de texto separados. Os dados foram capturados por meio de uma taxa de amostragem de 15,15 ms (66 Hz) (GIACOMOSSI, 2011), com um único sensor acelerômetro interno de um *smartphone Android*, fabricante LG, modelo D-805, colocado no antebraço dos voluntários e fixado com um suporte. Somente o movimento penteando o cabelo teve a captura dos dados interrompida no período de isolamento das pessoas, devido a pandemia do

SARS-COV-2. As acelerações foram lidas nas três direções ortogonais. Todos os sinais de entrada são convertidos em valores absolutos.

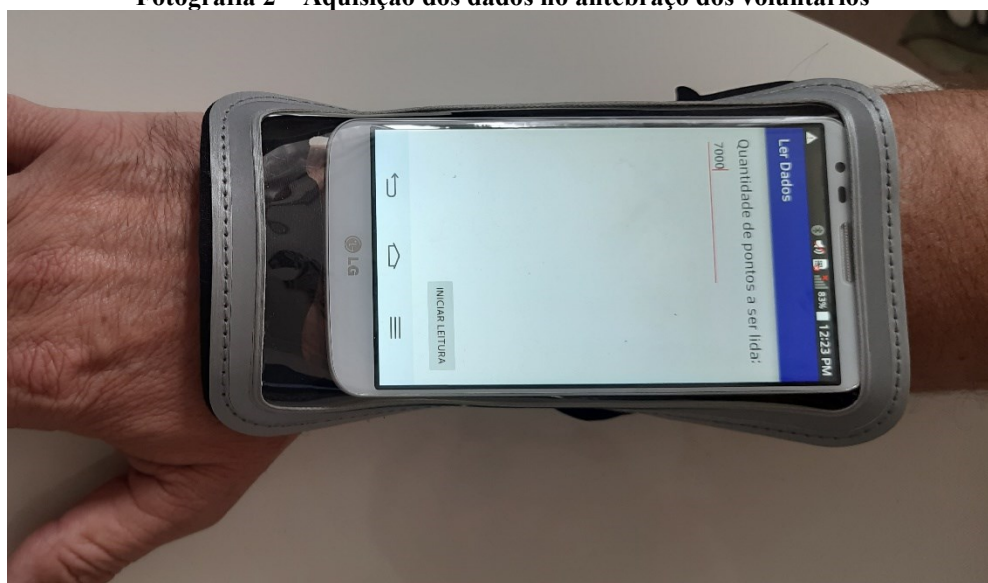
A Fotografia 1 apresenta o *layout* do *software* embarcado e a Fotografia 2, o local do corpo onde foi posicionado o *smartphone* para obtenção dos dados de movimentos humanos. Os exemplos dos sinais (3 eixos do acelerômetro) provenientes das atividades humanas objetos de estudo são apresentados da Figura 13 até a Figura 21.

Fotografia 1 - Smartphone e software aplicativo utilizado na aquisição dos dados de movimentos humanos



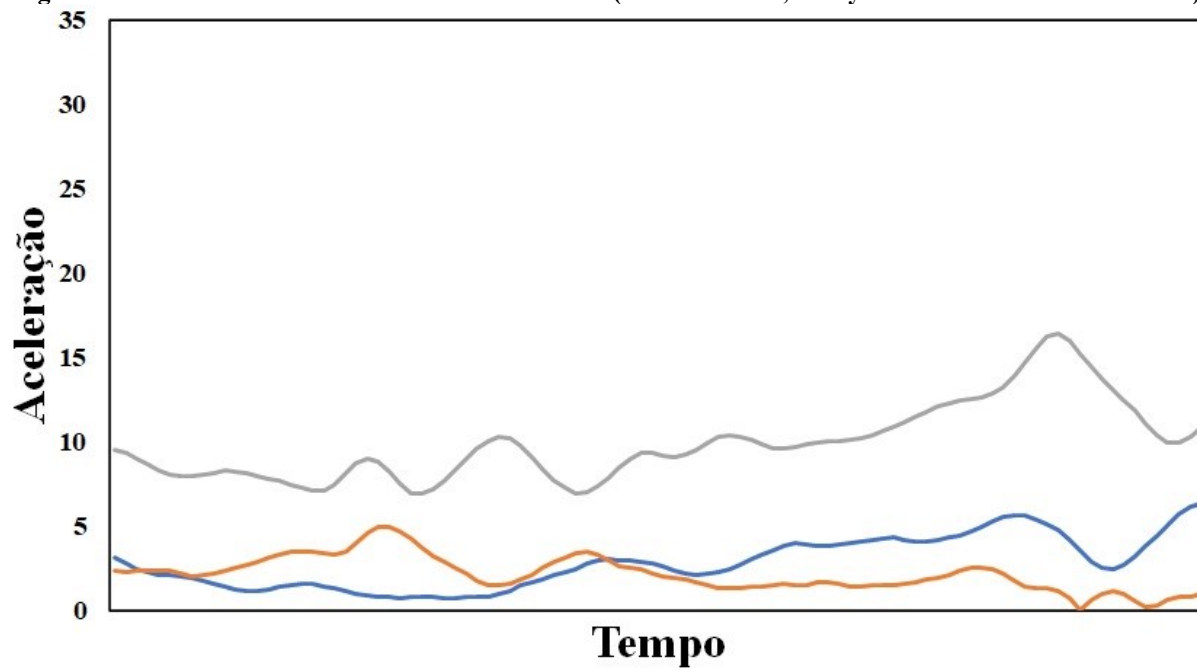
Fonte: Autoria própria (2022)

Fotografia 2 – Aquisição dos dados no antebraço dos voluntários



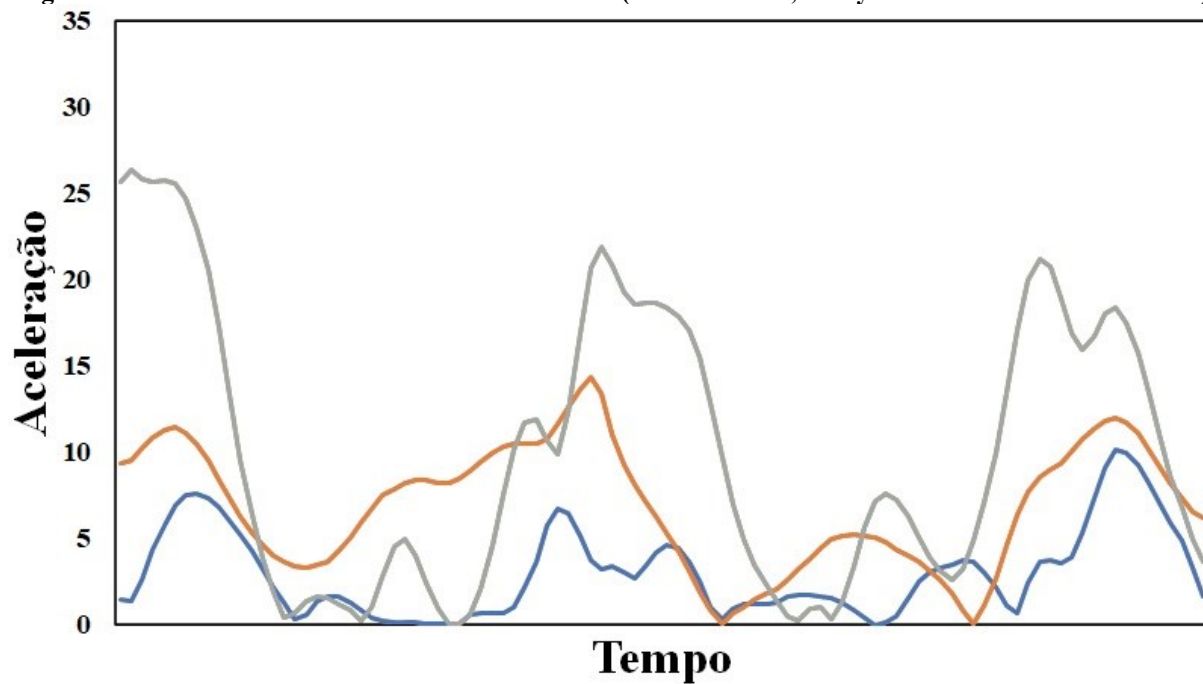
Fonte: Autoria própria (2022)

Figura 13 - Sinais do movimento andando na esteira (eixo x em azul, eixo y em marron e eixo z em cinza)



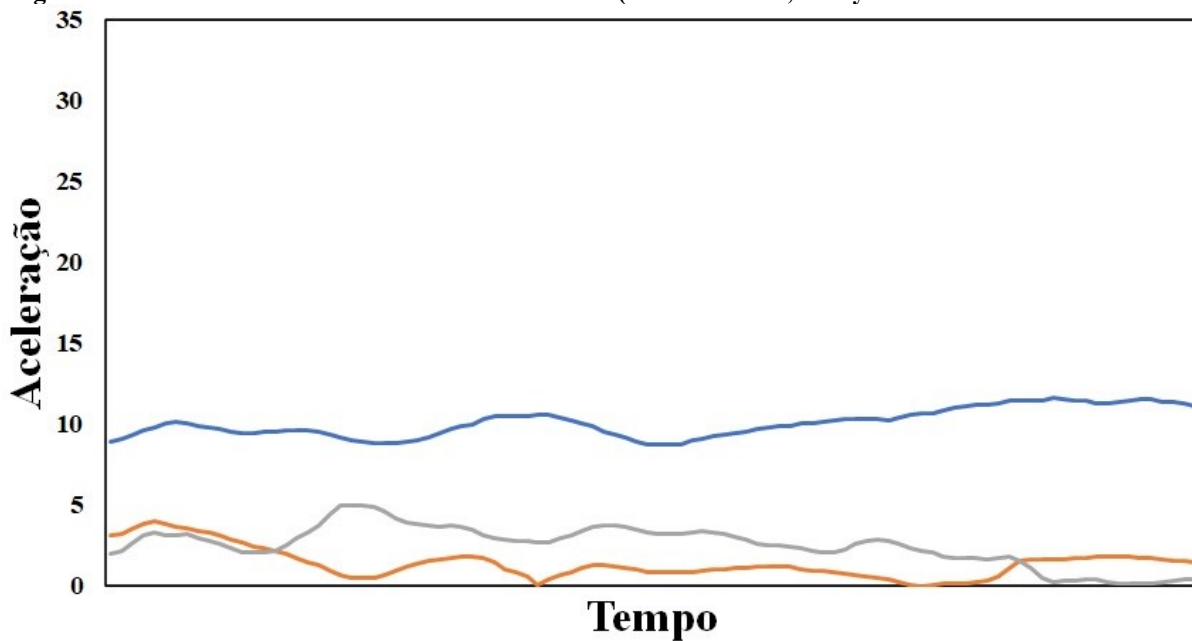
Fonte: Autoria própria (2022)

Figura 14 - Sinais do movimento correndo na esteira (eixo x em azul, eixo y em marron e eixo z em cinza)




Fonte: Autoria própria (2022)

Figura 15 - Sinais do movimento andando em círculo (eixo x em azul, eixo y em marron e eixo z em cinza)



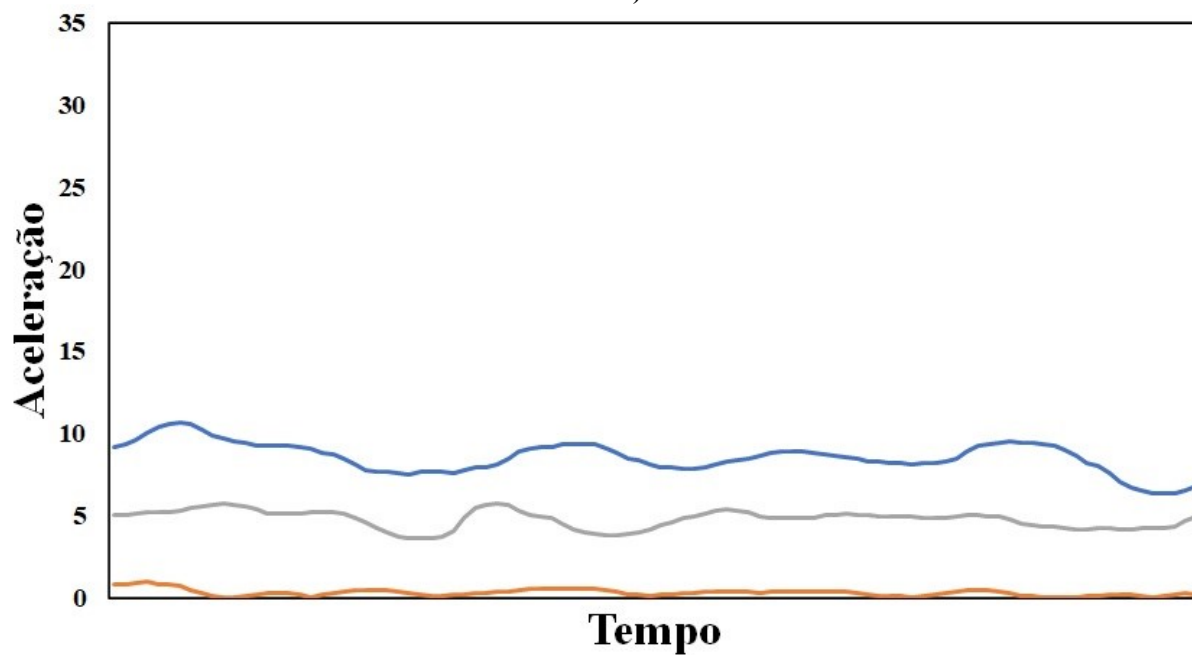
Fonte: Autoria própria (2022)

Figura 16 - Sinais do movimento tremores (eixo x em azul, eixo y em marron e eixo z em cinza)



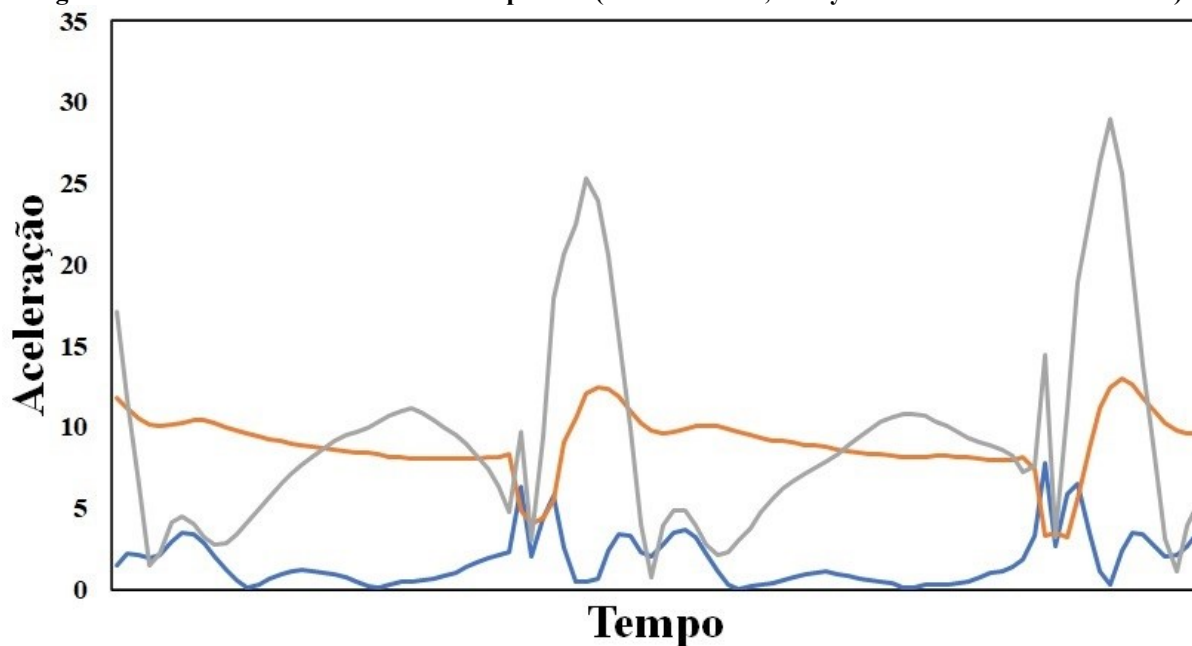
Fonte: Autoria própria (2022)

Figura 17 - Sinais do movimento subindo e descendo escada (eixo x em azul, eixo y em marron e eixo z em cinza)




Fonte: Autoria própria (2022)

Figura 18 - Sinais do movimento batendo palmas (eixo x em azul, eixo y em marron e eixo z em cinza)




Fonte: Autoria própria (2022)

Figura 19 - Sinais do movimento apagando o quadro (eixo x em azul, eixo y em marron e eixo z em cinza)



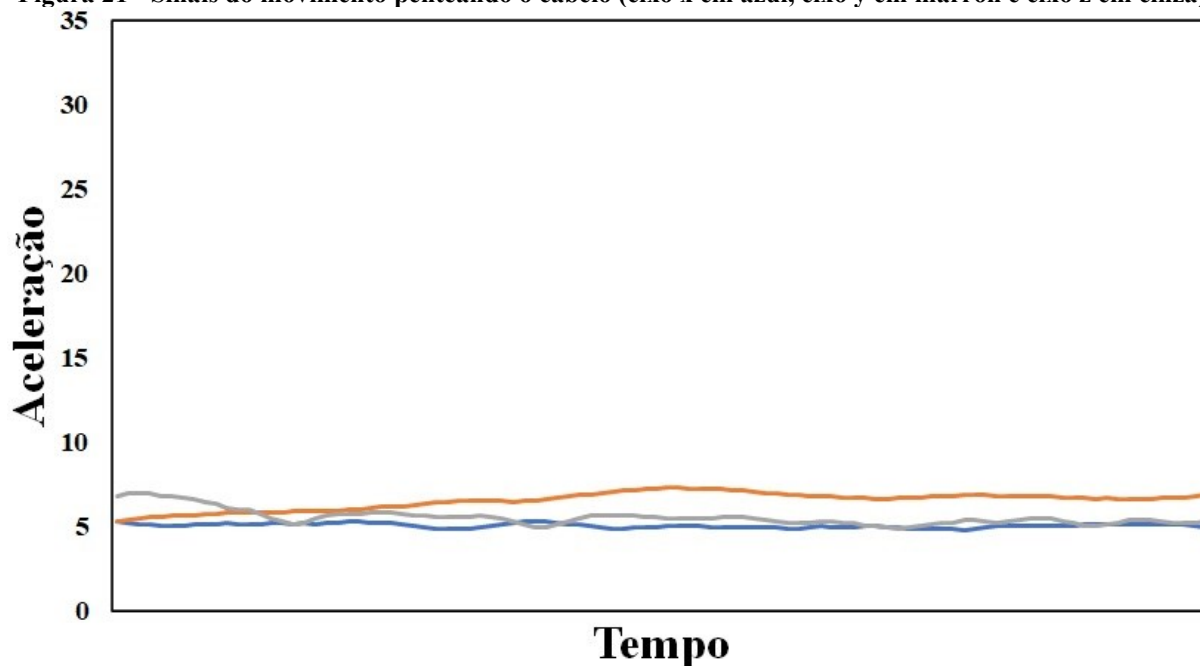
Fonte: Autoria própria (2022)

Figura 20 - Sinais do movimento aceno de tchau (eixo x em azul, eixo y em marron e eixo z em cinza)



Fonte: Autoria própria (2022)

Figura 21 - Sinais do movimento penteando o cabelo (eixo x em azul, eixo y em marron e eixo z em cinza)



Fonte: Autoria própria (2022)

4.3 Extração de características (fase 2)

Na fase 2 (Figura 12) realizou-se o pré-processamento dos dados para extração de características e composição de padrões, divididos por categorias ou classes de movimentos de entrada. Efetuou-se uma comparação entre o método proposto e os conhecidos conceitos de FFT (*Fast Fourier Transform*), que converte um sinal do domínio do tempo para o domínio da frequência, bem como a comparação com características estatísticas no domínio do tempo. Por fim, elaborou-se uma comparação entre o método proposto e um conjunto de padrões composto por todas as características calculadas no domínio do tempo e no domínio da frequência.

O Quadro 1 apresenta os conjuntos de características comparados nesta pesquisa, com a quantidade de características calculadas por padrão, bem como, as nomenclaturas simplificadas (abreviações) utilizadas na continuidade da tese:

Quadro 1 - Conjuntos de características comparados na pesquisa

Conjuntos de características	Quantidade de Características	Abreviação
1. Triangulação aplicando a soma estatística	C_1 a C_{36}	TrS
2. Triangulação aplicando a média estatística	C_{37} a C_{72}	TrM
3. Triangulação aplicando o desvio padrão estatístico	C_{73} a C_{108}	TrDP
4. Triangulação aplicando a variância estatística	C_{109} a C_{144}	TrV
5. Domínio do Tempo	C_{145} a C_{165}	TDF
6. Domínio da Frequência	C_{166} a C_{180}	FDF
7. Domínio do Tempo e Frequência	C_{145} a C_{180}	TFDF

Fonte: Autoria própria (2022)

A especificação das características calculadas, as quais, são repetidas para cada eixo de aquisição do acelerômetro (x, y e z), são as seguintes:

- Para o método de triangulação, conjuntos de características 1, 2, 3 e 4 (Quadro 1), foram calculadas 12 características por eixo (totalizando 36 características), ou seja, C_1 a C_{36} para o conjunto TrS, C_{37} a C_{72} para o conjunto TrM, C_{73} a C_{108} para o conjunto TrDP, C_{109} a C_{144} para o conjunto TrV: lado ascendente, lado descendente, lado da base, área, perímetro, ângulo de subida, ângulo de descida, ângulo de base, derivada de subida, derivada de descida, derivada de base e contador de triangulos;
- No domínio do tempo (TDF), conjunto de características 5 (Quadro 1), foram calculadas 7 características por eixo (totalizando 21 características). Correspondem as características C_{145} a C_{165} , ou valores estatísticos aplicados sobre as janelas de dados de entrada (Figura 22): média, área, variância, desvio padrão, valor RMS, valor máximo e valor mínimo e
- No domínio da frequência (FDF), conjunto de características 6 (Quadro 1), foram calculadas 5 características por eixo (totalizando 15 características). Correspondem as características C_{166} a C_{180} , onde foram aplicados os conceitos da Transformada Rápida de Fourier sobre as janelas de dados de entrada (Figura 22): valor da frequência correspondente ao pico de potência, valor de tensão de pico do vetor de frequência da FFT, potência total, valores estatísticos como a frequência média e a potência média. Conceitualmente, o FFT assume que o conjunto de dados é finito sobre um espectro contínuo igual a um período de um sinal periódico (GUO, *et al.*, 2018; GAO, *et al.*, 2017; KARANTONIS, *et al.*, 2006). Como os sinais de aquisição nesta pesquisa não são periódicos, é necessário corrigir possíveis distorções nas bordas das janelas ou segmentos do sinal com a aplicação de funções de janelamento.

Sendo assim, a técnica de janelamento de Hamming foi utilizada (BAZGIR, *et al.*, 2015; PIERLEONI, *et al.*, 2014), e

- A composição dos conjuntos de características 5 e 6 (Quadro 1), para formar o conjunto de características 7 no domínio do tempo-frequência (TFDF), correspondendo a sequência C_{145} a C_{180} (36 características), ou seja, a junção das características calculadas no domínio do tempo (TDF), com características calculadas no domínio da frequência (FDF), totalizando 12 características por eixo.

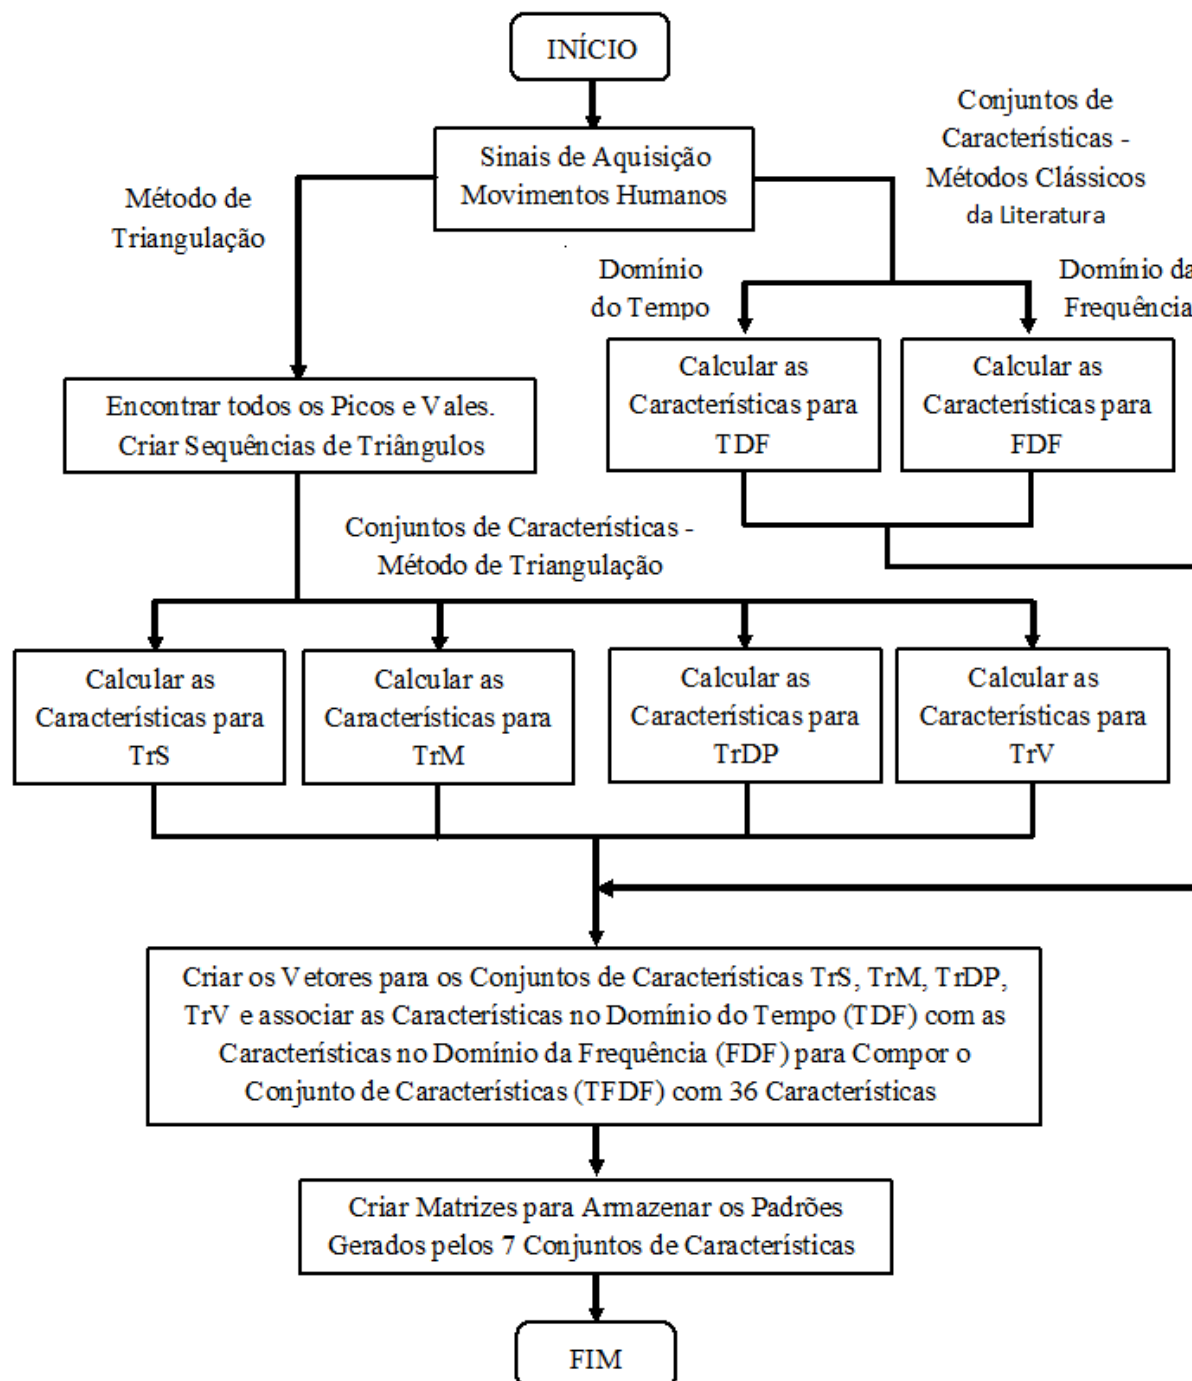
Para a seleção de características foram calculadas as matrizes de correlação apresentadas nos Apêndices, com os valores de correlação de Pearson das características para os conjuntos de padrões gerados pelo método de triangulação aplicando a soma (TrS), triangulação aplicando a média (TrM), triangulação aplicando o desvio padrão (TrDP), triangulação aplicando a variância (TrV) e os conjuntos de características clássicas da literatura no domínio tempo-frequência (TFDF). Para todos os conjuntos foram calculadas 12 características por eixo (x, y e z), totalizando 36 características por padrão e janelas de dados de entrada de 1000 pontos. Esses valores refletem a contribuição de tais características na classificação final, ou seja, quanto mais próximos de 1 ou -1, indicam forte correlação linear e próximos de 0 (zero), indicam ausência de correlação linear.

Foram adotados os seguintes critérios para as seguintes faixas de correlações absolutas: fraco (w) quando for igual ou inferior a 0,30, moderado (m) quando estiver entre 0,31 e 0,69, forte (s) quando for igual ou superior a 0,70. A matriz de correlação para as categorias de movimentos, foi calculada separadamente para cada classe. Sendo assim, para cada coluna os dados de pré-processamento ou conjuntos de padrões para as 5 classes nos experimentos 1, 2, 3, e 9 classes no quarto experimento, foram transformados somente em duas classes supervisionadas. Portanto, um valor numérico para a classe desejada e outro valor para o restante dos padrões. As tabelas com os valores de correlação, para os conjuntos de características que aplicam a triangulação (TrS, TrM, TRDP e TrV), bem como os conjuntos de características clássicas da literatura (TFDF), foram colocadas como apêndices.

O diagrama de blocos mostrado na Figura 22, foi codificado na plataforma Matlab (versão R2017a) e corresponde ao pré-processamento dos dados de aquisição para a elaboração dos padrões. A Figura 22, mostra o fluxograma aplicando a extração de características pelo método de triangulação, conjuntos de características TrS, TrM, TrDP e TrV, bem como, a extração de características clássicas da literatura nos domínios do tempo e domínio da frequência, conjuntos de características TDF e FDF, respectivamente, bem como a

composição das características TDF e FDF, formando o conjunto de características no domínio tempo-frequência TFDF.

Figura 22 - Diagrama de blocos mostrando a extração de características para todos os métodos comparados na pesquisa



Fonte: Autoria própria (2022)

Os procedimentos mostrados no diagrama de blocos da Figura 22, são repetidos (*looping*) até o final dos sinais de entrada, para as 9 categorias de movimentos estudadas, utilizando janelas com 100, 200, 500 e 1000 pontos, bem como, são criadas matrizes para

armazenar os padrões gerados para todos os conjuntos de características (métodos comparados), variando a quantidade de características 3, 5 e 12 por eixo (totalizando 9, 15 e 36 características).

4.4 Classificação dos dados (fase 3)

A fase 3 (Figura 12) corresponde a classificação final dos dados gerados na fase de pré-processamento (fase 2), ou seja, os padrões supervisionados de acordo com as classes de movimentos estudadas. Inicialmente foram processados os padrões gerados para os movimentos andando na esteira, corrida na esteira, tremor simulado, palmas e acenos de tchau, os quais, foram submetidos a dois classificadores: MLP (*Multilayer Perceptron*) e KNN (*k-Nearest Neighbour*) para $k=5$. Os resultados correspondentes às taxas de acerto (separados por categoria) foram registrados a partir da matriz de confusão com o uso do software WEKA (*Waikato Environment for Knowledge Analysis*), versão V. 3.8.1 (código aberto), conforme as Tabelas 2, 3, 4, 5, 6 e 7. Outros classificadores foram utilizados, como SVM (*Support Vector Machine*) e *Naive Bayes*, no entanto, os melhores resultados foram obtidos com MLP e KNN.

Posteriormente, foi realizado um último processamento com 9 movimentos, ou seja, andando na esteira, corrida na esteira, tremores simulados, palmas, acenos de tchau, andando em círculo, apagando quadro, subindo e descendo escada, penteando o cabelo e os índices de classificação final se encontram nas Tabelas 8 e 9.

5 RESULTADOS

Para demonstrar as fases de desenvolvimento do método de triangulação proposto, foram elaborados 4 conjuntos de características aplicando a triangulação, TrS, TrM, TrDP e TrV (Figura 22), os quais, foram comparados com os principais métodos encontrados na literatura no domínio do tempo e domínio da frequência, TDF e FDF (Figura 22), utilizando como medida os índices de classificação final individuais e médios, por categoria de movimento. A comparação será apenas no valor % maior na taxa, não sendo realizada a análise de significância estatística.

Inicialmente foi realizado o pré-processado dos dados de entrada em 3 experimentos, correspondendo a fase 2 (Figura 12) de extração de características, utilizando somente cinco categorias de movimentos ou atividades de entrada: andando na esteira, corrida na esteira, tremores simulados, palmas e acenos de tchau. Posteriormente, foram utilizados a totalidade dos movimentos de aquisição (9 categorias de movimentos), em um quarto experimento, acrescentando os movimentos: andando em círculo, apagando o quadro, subindo e descendo escada e penteando o cabelo. Nos 3 primeiros experimentos, variou-se o número de características por eixo de aquisição do acelerômetro (x, y e z), em 3 por eixo (experimento 1), 5 por eixo (experimento 2) e 12 por eixo (experimento 3), totalizando 9, 15 e 36 características, bem como, foi variado o tamanho das janelas de dados de entrada em 100, 200, 500 e 1000 pontos. No quarto experimento, foi aumentado a quantidade de movimentos ou atividades a serem classificadas para 9 categorias (todas as classes capturadas), utilizando padrões formados com 36 características, calculados a partir de janelas de dados de entrada com 100, 200, 500 e 1000 pontos.

Os mesmos critérios foram adotados para os métodos de comparação, ou seja, para os conjuntos de características TDF (domínio do tempo) e FDF (domínio da frequência), variando a quantidade de movimentos (categorias), quantidade de características e tamanhos das janelas de dados de entrada.

Dois classificadores foram usados na classificação final de todos os conjuntos de características comparados nesta pesquisa, os quais, apresentaram os melhores resultados, ambos configurados para validação cruzada 10-fold (BAYAT *et al.*, 2017): Rede neural MLP (*Multilayer Perceptron*) e *k*-vizinhos mais próximos (KNN) para $k = 5$. Também realizou-se o processamento com os classificadores SVM (*Support Vector Machine*) e *Naive Bayes*, no entanto, como apresentaram índices de classificação um pouco abaixo, esses resultados foram descartados. A Tabela 1 apresenta os códigos padronizados para as classes, as descrições das

categorias de movimentos estudados, incluindo o número de pontos digitalizados (discretizados), bem como, o número de padrões supervisionados gerados para cada janela de dados de entrada:

Tabela 1 – Descrição das categorias de movimentos, classes, dados de aquisição e número de padrões gerados para janelas de dados de entrada de 100, 200, 500 e 1000 pontos, correspondentes aos 9 movimentos objetos de estudo

Classe	Categoria de Movimento	Número de pontos	Número de padrões gerados para janelas			
			100 pontos	200 pontos	500 pontos	1000 pontos
A	Andando na esteira	160000	1600	800	320	160
B	Correndo na esteira	147000	1470	735	294	147
C	Tremores	120000	1200	600	240	120
D	Palmas	120000	1200	600	240	120
E	Aceno de tchau	122000	1220	610	244	122
F	Andando em círculo	105000	1050	525	210	105
G	Apagando quadro	105000	1050	525	210	105
H	Subindo e descendo escada	105000	1050	525	210	105
I	Penteando o cabelo	7000	70	35	14	7
	Total	991000	9910	4955	1982	991

Fonte: Autoria própria (2020)

5.1 Primeiro experimento

Os métodos que aplicam a triangulação TrS, TrM, TrDP e TrV, bem como, os métodos de comparação que aplicam os conceitos clássicos da literatura no domínio do tempo (TDF) e domínio da frequência (FDF), foram processados utilizando 5 categorias de movimentos (andando na esteira, corrida na esteira, tremores simulados, palmas e acenos de tchau), formando conjuntos de características compostos por 3 características por eixo (as características foram repetidas para os sinais dos 3 eixos), totalizando 9 características por padrão, utilizando janelas de dados de entrada com 100, 200, 500 e 1000 pontos.

Na sequência é apresentada a descrição das características calculadas para os quatro conjuntos de características aplicando o método de triangulação, bem como os conjuntos de características da literatura TDF e FDF, no primeiro experimento:

- Características extraídas aplicando a triangulação: lado ascendente, lado descendente e lado da base dos triângulos;
- Características calculadas para os conjuntos TDF: área; mínimo e máximo e
- Características calculadas para os conjuntos FDF: valor de frequência correspondente ao pico de potência FFT, valor da tensão de pico e potência total no vetor de frequência.

O Quadro 2 apresenta uma análise comparativa dos resultados obtidos no experimento 1, a partir dos maiores índices de acerto individuais por categoria de movimentos, dos conjuntos de padrões (calculados com 3 características por eixo) aplicando o método de triangulação (TrS, TrM, TrDP e TrV), bem como, os conjuntos de características da literatura calculadas no domínio do tempo (TDF) e frequência (FDF), conforme registrado nas Tabelas 2 e 3.

Quadro 2 – Melhores índices de acerto individuais por movimento, comparando os conjuntos de características aplicando a triangulação, com os conjuntos de características da literatura no domínio do tempo e domínio da frequência, utilizando 3 características por eixo no experimento 1

Categoria de movimentos	Triangulação				Literatura			
	Conj. de caract.	Taxa de acerto (%)	Tam. da Janela (pontos)	Classificador	Conj. de caract.	Taxa de acerto (%)	Tam. da Janela (pontos)	Classificador
Andando na Esteira	TrS	99,7	500	KNN	TDF	98,6	100	MLP
	TrS	100	1000	MLP e KNN	TDF	99,4	1000	MLP
Correndo na Esteira	TrS	97,8	200	KNN	TDF	97,3	200	MLP
	TrM	97,3	200	MLP	TDF	99,3	1000	MLP
Tremores	TrDP	99,2	500	MLP e KNN	TDF	100	100	KNN
	TrS TrM e TrDP	100	1000	KNN	FDF	100	500	KNN
Palmas	TrM	98	200	KNN	TDF	100	100	MLP e KNN
	TrS e TrM	100	1000	KNN	FDF	100	1000	KNN
Aceno de Tchou	TrM	99,9	100	KNN	TDF	100	100	KNN
	TrM	100	200	KNN	FDF	100	500	MLP e KNN

Fonte: Autoria própria (2020)

As Tabelas 2 e 3 mostram os índices individuais de classificação final, por categoria de movimento estudadas no experimento 1, para o classificador MLP e KNN para $k = 5$, respectivamente:

Tabela 2 - Comparação (em porcentagem) das taxas de acerto por movimento estudado, para o classificador MLP e conjuntos de padrões com 3 características por eixo

Janela	Algo.	Andando	Correndo	Tremores	Palmas	Tchau
100 pontos	TrS	95,9	89,0	86,9	87,8	98,5
	TrM	94,4	83,6	91,8	89,9	99,8
	TrDP	86,9	87,2	94,7	91,3	87,0
	TrV	80,3	86,1	88,3	90,2	79,2
	TDF	98,6	97,2	99,6	100,0	99,8
	FDF	97,1	94,8	98,6	98,7	99,1
200 pontos	TrS	96,6	97,0	91,7	97,2	99,7
	TrM	93,8	97,3	96,0	97,2	99,8
	TrDP	90,1	91,7	97,3	94,3	89,7
	TrV	82,5	89,8	93,3	92,3	81,0
	TDF	98,5	97,3	100,0	100,0	100,0
	FDF	97,9	95,8	99,0	99,5	99,8
500 pontos	TrS	98,4	96,3	94,6	97,5	99,6
	TrM	96,6	87,8	96,7	96,7	100,0
	TrDP	90,3	95,6	99,2	97,9	89,3
	TrV	85,0	94,6	93,3	97,1	75,8
	TDF	96,9	97,3	98,8	100,0	99,6
	FDF	96,9	95,6	97,9	100,0	100,0
1000 pontos	TrS	100,0	97,3	100,0	99,2	100,0
	TrM	98,1	95,2	100,0	98,3	100,0
	TrDP	88,1	96,6	100,0	99,2	89,3
	TrV	85,0	97,3	96,7	93,3	82,8
	TDF	99,4	99,3	100,0	100,0	99,2
	FDF	97,5	98,6	99,2	98,3	100,0

Fonte: Autoria própria.


Tabela 3 - Comparação (em porcentagem) das taxas de acerto por movimento estudado, para o classificador KNN para $k = 5$ e conjuntos de padrões com 3 características por eixo

Janela	Algo.	Andando	Correndo	Tremores	Palmas	Tchau
100 pontos	TrS	96,3	89,9	94,6	91,7	99,2
	TrM	95,1	85,2	95,8	93,4	99,9
	TrDP	86,9	85,8	97,8	96,9	93,8
	TrV	84,0	80,3	96,8	95,3	92,7
	TDF	97,9	96,7	100,0	100,0	100,0
	FDF	96,6	92,8	99,6	99,4	99,5
200 pontos	TrS	96,8	97,8	95,5	97,8	99,7
	TrM	93,6	97,1	96,8	98,0	100,0
	TrDP	93,3	90,5	96,8	96,8	93,6
	TrV	92,5	87,5	97,5	96,7	93,4
	TDF	97,6	96,7	100,0	99,8	100,0
	FDF	98,3	95,5	99,0	100,0	99,8
500 pontos	TrS	99,7	93,5	95,4	95,8	99,6
	TrM	98,8	85,0	97,1	96,3	100,0
	TrDP	94,4	92,2	98,8	97,1	90,6
	TrV	93,4	89,8	99,2	97,1	91,0
	TDF	95,0	96,9	100,0	99,6	100,0
	FDF	98,4	91,5	100,0	100,0	100,0
1000 pontos	TrS	100,0	93,9	97,5	100,0	100,0
	TrM	98,1	88,4	98,3	100,0	100,0
	TrDP	93,8	93,2	97,5	95,0	86,9
	TrV	91,9	89,1	96,7	95,8	82,8
	TDF	92,5	98,0	100,0	97,5	100,0
	FDF	96,3	89,8	97,5	100,0	100,0

Fonte: Autoria própria (2022)


Os Gráficos 1 e 2 mostram a classificação final utilizando os classificadores MLP e KNN para para $k=5$, respectivamente, onde são comparados os índices médios calculados para as 5 categorias de movimentos utilizadas no experimento 1 (9 características por padrão), variando o tamanho das janelas de dados de entrada em 100, 200, 500 e 1000 pontos, envolvendo os conjuntos de características elaborados para o método de triangulação TrS, TrM, TrDP e TrV, bem como, os conjuntos de características aplicando os conceitos clássicos da literatura no domínio do tempo (TDF) e frequência (FDF).

Gráfico 1 – Comparação entre os índices médios (5 movimentos) de classificação final obtidos no experimento 1 (9 características), utilizando o classificador MLP



Fonte: Autoria própria (2022)

Gráfico 2 - Comparação entre os índices médios (5 movimentos) de classificação final obtidos no experimento 1 (9 características), utilizando o classificador KNN

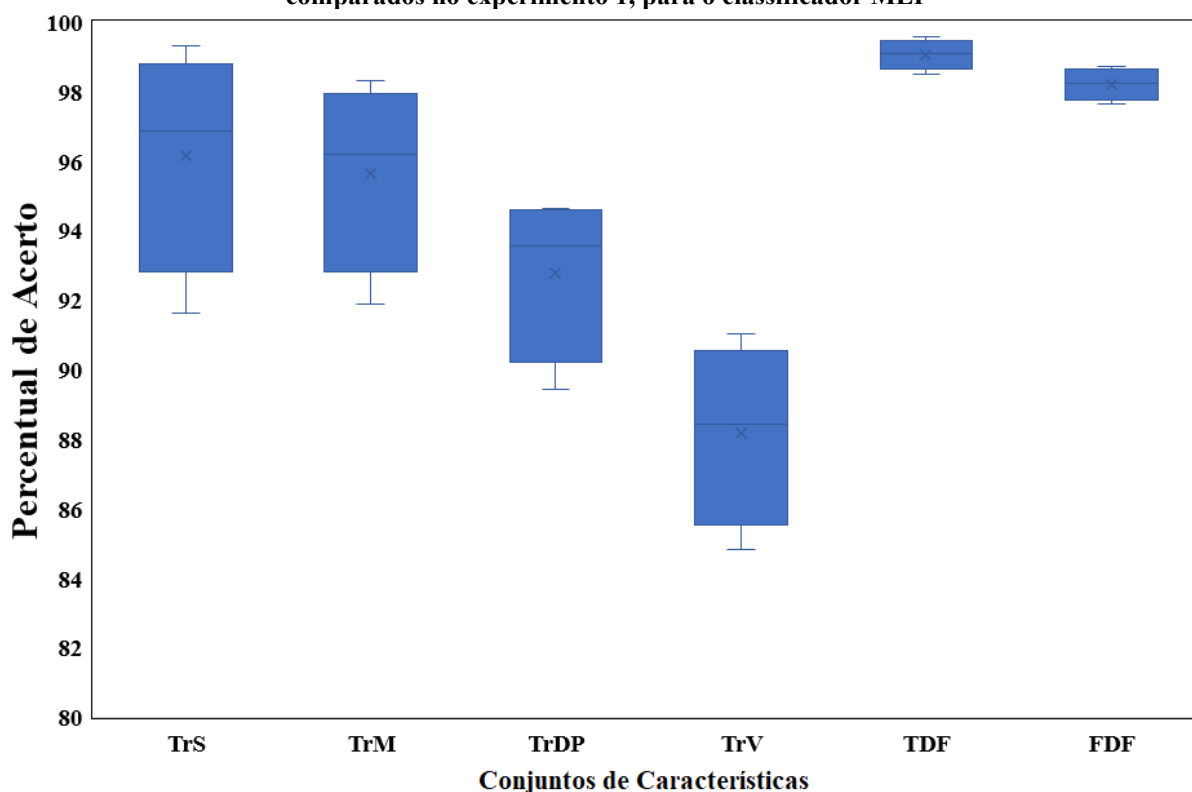


Fonte: Autoria própria (2022)

Comparando o valor das taxas média obtida na classificação final para as 5 categorias de movimentos humanos com padrões compostos por 3 características por eixo, os índices obtidos com os conjuntos de características que aplicam a triangulação (TrS, TrM, TrDP e TrV) foram inferiores em relação aos conjuntos de característica da literatura TDF e FDF para janelas de 100, 200, 500 e 1000 pontos, embora tenha havido uma melhora significativa nos índices de acerto para janelas com 200, 500 e 1000 pontos, conforme os Gráficos 1 e 2. No experimento 1 o maior índice de 99,6% foi obtido com o conjunto de características TDF e 99,3% com o conjunto TrS, ambos para o classificador MLP e janelas de 1000 pontos, conforme o Gráfico 1.

O Gráfico 3 na sequência, mostra uma análise da dispersão dos dados, utilizando os melhores resultados (índices médios entre as 5 categorias de movimentos) para os conjuntos de características comparados no experimento 1, os quais, foram obtidos com o classificador MLP, para janela de dados de entrada com 100, 200, 500 e 1000 pontos.

Gráfico 3 – Dispersão dos dados utilizando os índices médios obtidos com os conjuntos de características comparados no experimento 1, para o classificador MLP



Fonte: Autoria própria (2022)

Analisando os resultados mostrados no Gráfico 3, observar-se uma maior dispersão dos índices médios (para as 5 categorias de movimentos) obtidos no primeiro experimento, para os quatro conjuntos que aplicam a técnica de triangulação, conjuntos TrS, TrM, TrDP e

TrV, em relação aos conjuntos que empregam os conceitos clássicos da literatura TDF e FDF. No entanto, comparando o melhor resultado com o índice de acerto de 99,3% obtido com o conjunto de características TrS (triangulação aplicando a soma estatística) e o maior índice de 99,6% (Gráficos 1 e 3) obtido com o conjunto de características TDF (características da literatura no domínio do tempo), a diferença de 0,3% é relativamente pequena entre os dois conjuntos de características, considerando os pontos de limite superior no Gráfico 3. Entretanto, considerando os limites inferiores 91,6% e 99% (Gráficos 1 e 3), para os mesmos conjuntos de características TrS e TDF, a diferença 7,6% foi mais significativa, favorável para os conjuntos de características da literatura.


Na sequência foi realizado um segundo experimento, mantendo as mesmas 5 categorias de movimentos, com padrões compostos de 15 características (5 características por eixo), com o objetivo de verificar o comportamento dos conjuntos de características que aplicam a triangulação, comparados com os conjuntos de características da literatura.

5.2 Segundo experimento

No segundo experimento foram utilizados os mesmos movimentos (primeiro experimento): andando na esteira, corrida na esteira, tremores simulados, palmas e acenos de tchau. Visando o aperfeiçoamento do método de triangulação, duas novas características foram calculadas para TrS, TrM, TrDP e TrV, todas baseadas nos lados dos triângulos, ou seja, as características área e perímetro dos triângulos, para formar padrões com 5 características por eixo: lado ascendente, lado descendente, lado base, área e perímetro. Além disso, duas novas características, média e variância, foram calculadas para o domínio do tempo (TDF), formando 5 características por eixo: área, mínimo, máximo, média e variância. Assim como, duas novas características foram calculadas para os conjuntos de características FDF, frequência média e a potência média, formando padrões com 5 características por eixo: valor de frequência correspondente ao pico de potência da FFT, valor de tensão de pico do vetor de frequência FFT, potência total, frequência média e potência média.


Para todos os conjuntos de características que aplicam a triangulação (TrS, TrM, TrDP e TrV), bem como, os conjuntos de características clássicas no domínio do tempo (TDF) e domínio da frequência (FDF), foram calculados padrões compostos de 15 características, variando o tamanho das janelas de dados de entrada em 100, 200, 500 e 1000 pontos (repetindo o procedimento realizado no primeiro experimento). Os Gráficos 4 e 5 apresentam os valores dos índices médios de classificação final (5 movimentos), utilizando os classificadores MLP e KNN para $k=5$, respectivamente.

Gráfico 4 - Comparação entre os índices médios (5 movimentos) de classificação final obtidos no experimento 2 (15 características), utilizando o classificador MLP



Fonte: Autoria própria (2022)

Gráfico 5 - Comparação entre os índices médios (5 movimentos) de classificação final obtidos no experimento 2 (15 características), utilizando o classificador KNN



Fonte: Autoria própria (2022)

O Quadro 3 apresenta uma análise comparativa dos resultados obtidos no experimento 2, a partir dos maiores índices de acerto individuais por movimentos (5 categorias de movimentos) obtidos com os conjuntos de padrões (calculados com 5 características por eixo) aplicando o método de triangulação (TrS, TrM, TrDP e TrV), bem como, os conjuntos de padrões calculados a partir das características TDF e FDF (características da literatura), conforme registrado nas Tabelas 4 e 5.

Quadro 3 - Melhores índices de acerto individuais por movimento, comparando os conjuntos de características aplicando a triangulação, com os conjuntos de características da literatura no domínio do tempo e domínio da frequência, utilizando 5 características por eixo no experimento 2

Categoria de movimentos	Triangulação				Literatura			
	Conj. de caract.	Taxa de acerto (%)	Tam. da Janela (pontos)	Classificador	Conj. de caract.	Taxa de acerto (%)	Tam. da Janela (pontos)	Classificador
Andando na Esteira	TrS	99,4	500	MLP	FDF	99,7	500	KNN
	TrS e TRM	100	1000	MLP e KNN	FDF	100	1000	MLP e KNN
Correndo na Esteira	TrS	98,4	200	KNN	FDF	97,6	200	MLP
	TrDP e TrV	100	1000	MLP	TDF	100	1000	MLP
Tremores	TrDP	100	200	MLP e KNN	TDF	100	100	KNN
Palmas	TrS	99,6	500	MLP	TDF	100	100	KNN
	TrS e TrM	100	1000	KNN	FDF	100	100	KNN
Aceno de Tchou	TrS	100	100	KNN	TDF	100	100	KNN

Fonte: Autoria própria (2020)

As Tabelas 4 e 5 mostram os índices individuais de classificação final, por categoria de movimento estudadas no experimento 2, para o classificador MLP e KNN para $k = 5$, respectivamente:

Tabela 4 - Comparação (em porcentagem) das taxas de acerto por movimento estudado, para o classificador MLP e conjuntos de padrões com 5 características por eixo

Janela	Algo.	Andando	Correndo	Tremores	Palmas	Tchau
100 pontos	TrS	97,1	92,2	97,2	93,0	99,8
	TrM	95,4	89,9	94,8	91,8	99,8
	TrDP	95,8	93,0	99,5	95,5	98,4
	TrV	93,4	91,0	98,9	93,8	99,3
	TDF	98,8	97,5	99,7	99,8	99,8
	FDF	98,1	96,3	99,9	99,9	99,7
200 pontos	TrS	98,1	97,7	99,7	99,2	100,0
	TrM	93,9	98,1	97,8	99,0	100,0
	TrDP	98,8	95,5	100,0	97,8	99,3
	TrV	97,3	94,6	99,5	97,5	99,3
	TDF	98,5	97,3	100,0	100,0	100,0
	FDF	98,6	97,6	100,0	99,8	99,8
500 pontos	TrS	99,4	97,6	100,0	99,6	100,0
	TrM	99,1	94,9	97,9	96,7	100,0
	TrDP	98,4	96,9	100,0	99,2	100,0
	TrV	98,4	96,9	100,0	99,2	100,0
	TDF	98,1	98,3	98,8	100,0	100,0
	FDF	99,4	97,3	100,0	100,0	100,0
1000 pontos	TrS	100,0	98,6	100,0	99,2	100,0
	TrM	100,0	98,6	100,0	99,2	100,0
	TrDP	99,4	100,0	100,0	100,0	100,0
	TrV	99,4	100,0	100,0	100,0	100,0
	TDF	99,4	100,0	100,0	100,0	100,0
	FDF	100,0	99,4	100,0	100,0	100,0

Fonte: Autoria própria (2022)

Tabela 5 - Comparação (em porcentagem) das taxas de acerto por movimento estudado, para o classificador KNN para $k = 5$ e conjuntos de padrões com 5 características por eixo


Janela	Algo.	Andando	Correndo	Tremores	Palmas	Tchau
100 pontos	TrS	97,3	92,0	97,8	93,3	100,0
	TrM	96,0	88,6	97,2	92,6	99,9
	TrDP	95,3	90,0	99,4	98,0	99,2
	TrV	92,4	85,5	99,5	94,3	98,8
	TDF	98,1	97,6	100,0	100,0	100,0
	FDF	98,3	95,2	99,8	100,0	99,6
200 pontos	TrS	97,6	98,4	98,3	99,0	100,0
	TrM	94,8	97,0	98,0	98,0	100,0
	TrDP	98,5	94,7	100,0	98,7	99,3
	TrV	97,9	93,2	99,8	98,2	99,8
	TDF	97,6	97,4	100,0	100,0	100,0
	FDF	99,1	94,6	100,0	98,8	100,0
500 pontos	TrS	99,1	93,5	97,5	97,5	100,0
	TrM	98,1	89,8	97,9	98,3	100,0
	TrDP	99,1	95,6	100,0	99,2	98,8
	TrV	99,1	94,9	100,0	99,2	100,0
	TDF	95,9	98,0	100,0	100,0	100,0
	FDF	99,7	95,9	100,0	100,0	100,0
1000 pontos	TrS	100,0	95,2	100,0	100,0	100,0
	TrM	100,0	95,2	100,0	100,0	100,0
	TrDP	97,5	97,3	100,0	99,2	96,7
	TrV	99,4	97,3	100,0	99,2	99,2
	TDF	95,0	99,3	100,0	97,5	100,0
	FDF	100,0	91,8	98,3	100,0	100,0

Fonte: Autoria própria (2022)

Comparando os valores dos índices médios entre as 5 categorias de movimentos estudadas para os conjuntos de padrões com 5 características por eixo, para janelas de 500 pontos, foram obtidas as taxas de 99,3% e 99,3% com TrS e FDF, e classificador MLP, respectivamente. No entanto, a maior taxa 99,9% foi obtida com TrDP, TrV, TDF e FDF, para janelas de 1000 pontos e classificador MLP, conforme o Gráfico 4.

O Gráfico 6 na sequência, mostra uma análise da dispersão dos dados, utilizando os melhores resultados (índices médios entre as 5 categorias de movimentos) para os conjuntos de características comparados no experimento 2, os quais, foram obtidos com o classificador MLP, para janela de dados de entrada com 100, 200, 500 e 1000 pontos.

Gráfico 6 - Dispersão dos dados utilizando os índices médios obtidos com os conjuntos de características comparados no experimento 2, para o classificador MLP



Fonte: Autoria própria (2022)

Analisando os resultados mostrados no Gráfico 6, observar-se uma maior dispersão dos índices médios (para as 5 categorias e movimentos) obtidos no segundo experimento, para os quatro conjuntos de características que aplicam a técnica de triangulação, conjuntos TrS, TrM, TrDP e TrV, em relação aos conjuntos que empregam os conceitos clássicos da literatura TDF e FDF.

No entanto, comparando o melhor resultado com o índice de acerto de 99,9%, obtido com os conjuntos de características TrDP (triangulação aplicando o desvio padrão estatístico) e TrV (triangulação aplicando a variância) e o maior índice de 99,9% (Gráficos 4 e 6), obtido com os conjuntos de características TDF (características da literatura no domínio do tempo) e FDF (características da literatura no domínio da frequência), os resultados são idênticos para os quatro conjuntos de características, considerando os pontos de limite superior no Gráfico 6.

Analisando os limites inferiores, 96,4% (TrDP) e 95,3% (TrV) para os conjuntos que aplicam a triangulação (Gráficos 4 e 6), bem como, 99% (TDF) e 98,8% (FDF) para os conjuntos da literatura, a diferença entre os dois valores menores ($98,8 - 95,3 = 3,5\%$) é significativa, com vantagem para a literatura, no entanto, a dispersão dos dados entre os conjuntos de características comparados no segundo experimento, diminuiu em relação ao primeiro experimento, de 7,6% para 3,5%.

Na sequência foi realizado um terceiro experimento utilizando 36 características por padrão (12 características por eixo), com o objetivo de verificar o comportamento dos conjuntos de características que aplicam a triangulação, comparados com os conjuntos de características da literatura.

5.3 Terceiro experimento

No terceiro experimento foram utilizados os mesmos movimentos (primeiro e segundo experimento): andando na esteira, corrida na esteira, tremores simulados, palmas e acenos de tchau. Visando o aperfeiçoamento do método de triangulação, 7 novas características foram calculadas para TrS, TrM, TrDP e TrV, todas baseadas nos lados dos triângulos, ou seja, as características ângulo de subida, ângulo de descida, ângulo de base, derivada de subida, derivada de descida, derivada de base e contador de triângulos, para formar padrões com 12 características por eixo: lado ascendente, lado descendente, lado base, área, perímetro, ângulo de subida, ângulo de descida, ângulo de base, derivada de subida, derivada de descida, derivada de base e contador de triângulos.


Além disso, duas novas características, desvio padrão e valor RMS, foram calculadas para o domínio do tempo (TDF), formando 7 características por eixo: área, mínimo, máximo, média, variância, desvio padrão e valor RMS.

No entanto, para os conjuntos de características FDF, foram mantidas as mesmas 5 características por eixo: valor de frequência correspondente ao pico de potência da FFT, valor de tensão de pico do vetor de frequência FFT, potência total, frequência média e potência média. Sendo assim, para formar conjuntos com 12 características extraídas da literatura, foram associados os conjuntos TDF e FDF para compor um novo conjunto de características TFDF no domínio tempo-frequência, com as seguintes características: área, mínimo, máximo, média, variância, desvio padrão, valor RMS, valor de frequência correspondente ao pico de potência da FFT, valor de tensão de pico do vetor de frequência FFT, potência total, frequência média e potência média.

Para todos os conjuntos de características que aplicam a triangulação (TrS, TrM, TrDP e TrV), bem como, o novo conjunto de características clássicas no domínio do tempo-frequência (TFDF), foram calculados padrões compostos com 36 características, variando o tamanho das janelas de dados de entrada em 100, 200, 500 e 1000 pontos.


Os Gráficos 7 e 8 apresentam os valores dos índices médios de classificação final (5 movimentos) obtidos no experimento 3, utilizando os classificadores MLP e KNN para $k=5$, respectivamente:

Gráfico 7 - Comparação entre os índices médios (5 movimentos) de classificação final obtidos no experimento 3 (36 características), utilizando o classificador MLP



Fonte: Autoria própria (2022)

Gráfico 8 - Comparação entre os índices médios (5 movimentos) de classificação final obtidos no experimento 3 (36 características), utilizando o classificador KNN



Fonte: Autoria própria (2022)

Comparando os valores dos índices médios entre as 5 classes de movimentos estudadas para os conjuntos de padrões com 12 características por eixo, o índice de acerto de 99,6% foi obtido com TrM (triangulação aplicando a média estatística) e 99,4% obtido com

TFDF (literatura no domínio tempo-frequência), para janelas de 200 pontos, com o classificador MLP. Taxas de acerto semelhantes foram obtidas com uma janela de 500 pontos, 99,6% com TrS (triangulação aplicando a soma estatística) e 99,6% com TFDF, ambos com o classificador MLP, conforme o Gráfico 7. Porém, embora as médias obtidas para os 3 conjuntos de características TrS, TrM e TFDF sejam aproximadamente iguais, houve uma pequena vantagem para o método de triangulação com o conjunto de características TrM, devido ao fato de ter obtido o resultado com uma janela de pontos de entrada menor (200 pontos).

No entanto, a maior taxa de acerto 100% foi obtida com o conjunto de características TrS, enquanto o conjunto de características da literatura TFDF (domínio tempo-frequência) obteve o índice de acerto de 99,9%, para janelas de 1000 pontos e classificador MLP, conforme o Gráfico 7.

As Tabelas 6 e 7 mostram os índices individuais de classificação final, por categoria de movimento estudadas no experimento 3, para o classificador MLP e KNN para $k = 5$, respectivamente.

Tabela 6 - Comparação (em porcentagem) das taxas de acerto por movimento estudado, para o classificador MLP e conjuntos de padrões com 12 características por eixo

Janela	Algo.	Andando	Correndo	Tremores	Palmas	Tchau
100 pontos	TrS	98,6	97,7	100,0	99,7	100,0
	TrM	98,3	97,3	99,9	99,5	99,9
	TrDP	96,8	96,6	100,0	99,4	99,5
	TrV	95,0	93,8	99,3	99,3	99,7
	TFDF	99,2	98,4	100,0	100,0	99,9
200 pontos	TrS	98,9	99,0	100,0	100,0	100,0
	TrM	98,9	99,5	100,0	100,0	99,8
	TrDP	97,9	96,5	100,0	99,8	99,5
	TrV	96,6	97,3	99,7	99,8	99,2
	TFDF	99,1	98,1	100,0	100,0	100,0
500 pontos	TrS	99,4	98,6	100,0	100,0	100,0
	TrM	98,8	98,3	100,0	100,0	100,0
	TrDP	97,2	96,6	100,0	99,6	99,2
	TrV	96,6	93,2	100,0	100,0	99,6
	TFDF	99,7	98,3	100,0	100,0	100,0
1000 pontos	TrS	100,0	100,0	100,0	100,0	100,0
	TrM	99,4	100,0	100,0	100,0	100,0
	TrDP	96,3	95,2	100,0	100,0	99,2
	TrV	98,8	93,2	100,0	100,0	99,2
	TFDF	100,0	99,3	100,0	100,0	100,0

Fonte: Autoria própria (2022)

Tabela 7 - Comparação (em porcentagem) das taxas de acerto por movimento estudado, para o classificador KNN para $k = 5$ e conjuntos de padrões com 12 características por eixo

Janela	Algo.	Andando	Correndo	Tremores	Palmas	Tchau
100 pontos	TrS	98,7	95,3	100,0	98,0	100,0
	TrM	98,1	95,0	99,8	97,9	100,0
	TrDP	98,4	91,6	99,7	99,6	99,0
	TrV	96,4	79,3	99,7	92,6	98,0
	TFDF	99,6	97,6	100,0	100,0	100,0
200 pontos	TrS	99,4	98,2	100,0	99,8	100,0
	TrM	98,6	98,4	99,7	99,8	100,0
	TrDP	98,6	93,5	100,0	99,8	99,2
	TrV	97,8	92,9	100,0	99,2	99,3
	TFDF	99,5	97,8	100,0	100,0	100,0
500 pontos	TrS	99,7	97,3	100,0	100,0	100,0
	TrM	100,0	97,6	100,0	99,6	100,0
	TrDP	99,4	93,5	100,0	100,0	99,2
	TrV	100,0	82,3	99,6	98,8	98,8
	TFDF	99,4	96,9	100,0	100,0	100,0
1000 pontos	TrS	100,0	96,6	100,0	100,0	100,0
	TrM	100,0	97,3	100,0	100,0	100,0
	TrDP	99,4	95,9	100,0	100,0	99,2
	TrV	100,0	81,6	98,3	100,0	99,2
	TFDF	100,0	99,3	100,0	99,2	100,0

Fonte: Autoria própria (2022)

O Quadro 4 apresenta uma análise comparativa dos resultados obtidos no experimento 3, a partir dos maiores índices de acerto individuais por movimentos (5 categorias de movimentos), dos conjuntos de padrões calculados com 12 características por eixo aplicando o método de triangulação (TrS, TrM, TrDP e TrV), bem como, os conjuntos de padrões calculados a partir das características TDF e FDF (características da literatura), conforme registrado nas Tabelas 6 e 7.


Quadro 4 - Melhores índices de acerto individuais por movimento, comparando os conjuntos de características aplicando a triangulação, com os conjuntos de características da literatura no domínio tempo-frequência, utilizando 12 características por eixo no experimento 3

Categoria de movimentos	Triangulação				Literatura			
	Conj. de caract.	Taxa de acerto (%)	Tam. da Janela (pontos)	Classificador	Conj. de caract.	Taxa de acerto (%)	Tam. da Janela (pontos)	Classificador
Andando na Esteira	TrM e TrV	100	500	KNN	TFDF	99,7	500	MLP
Correndo na Esteira	TrM	99,5	200	MLP	TFDF	98,1	200	MLP
	TrS e TrM	100	1000	MLP	TFDF	99,3	1000	MLP e KNN
Tremores	TrS e TrDP	100	100	MLP	TFDF	100	100	MLP e KNN
Palmas	TrS e TrM	100	200	MLP	TFDF	100	100	MLP e KNN
Aceno de Tchou	TrS e TrM	100	100	KNN	TFDF	100	100	KNN

Fonte: Autoria própria (2020)

O Gráfico 9 na sequência, mostra uma análise da dispersão dos dados utilizando os melhores resultados (índices médios entre as 5 categorias de movimentos) para os conjuntos de características comparados no experimento 3, os quais, foram obtidos com o classificador MLP, para janela de dados de entrada com 100, 200, 500 e 1000 pontos.

Gráfico 9 - Dispersão dos dados utilizando os índices médios obtidos com os conjuntos de características comparados no experimento 3, para o classificador MLP



Fonte: Autoria própria (2022)

Analisando os resultados mostrados no Gráfico 9, observar-se uma maior dispersão dos índices médios (para as 5 categorias e movimentos) obtidos no terceiro experimento, para os quatro conjuntos de características que aplicam a técnica de triangulação, conjuntos TrS, TrM, TrDP e TrV, em relação ao conjunto de características que utilizam os conceitos clássicos da literatura no domínio do tempo-frequência (TFDF).

No entanto, comparando o melhor resultado com o índice de acerto de 100%, obtido com o conjunto de característica TrS (triangulação aplicando a soma estatística) e o maior índice de 99,9% (Gráfico 7 e 9), obtido com os conjuntos de características TFDF (características da literatura no domínio tempo-frequência), os valores numéricos são muito próximos nos pontos de limite superior (Gráficos 7 e 9), com uma vantagem de 0,1% para o método de triangulação.

Analisando os limites inferiores, 99,2% para TrS e 99,4% para TFDF (Gráficos 7 e 9), os índices de acerto também são muito próximos, com uma diferença pequena de 0,2% de vantagem para as características da literatura.

Desta forma, pode-se concluir que no terceiro experimento, utilizando 5 categorias de movimentos e todas as 36 características extraídas para os conjuntos de características comparados, o método de triangulação apresentou resultados positivos, principalmente para os dois conjuntos de características TrS e TrM, com valores numéricos equivalentes aos

índices obtidos com o conjunto clássico da literatura TFDF (características no domínio tempo-frequência).

Na sequência foi realizado um quarto experimento, variando a quantidade de categorias de movimentos, ou seja, utilizando as 9 categorias de movimentos de aquisição, com padrões compostos de 36 características (12 características por eixo), com o objetivo de verificar o comportamento dos conjuntos de características que aplicam a triangulação, comparados com os conjuntos de características da literatura.

5.4 Quarto experimento

A partir deste ponto, foi realizado um quarto experimento utilizando as nove categorias de movimentos capturados com o *smartphone* nesta pesquisa: andando na esteira, corrida na esteira, tremores, palmas, acenos de tchau, andando em círculo, apagando quadro, subindo e descendo escada e penteando o cabelo.

De acordo com o que foi observado com a variação do número de características (3, 5 e 12 por eixo), neste quarto experimento, somente foram utilizados padrões formados por 36 características (12 por eixo), para os conjuntos de características que aplicam o método de triangulação TrS, TrM, TrDP, TrV e características no domínio tempo-frequência TFDF. Também foram mantidas a variação do tamanho das janelas de dados de entrada em 100, 200, 500 e 1000 pontos, no cálculo dos padrões para as 9 categorias de movimentos de aquisição.

Os Gráficos 10 e 11 apresentam os valores dos índices médios de classificação final, para as 9 categorias de movimentos obtidos no experimento 4, utilizando os classificadores MLP e KNN para $k=5$, respectivamente.

Comparando os valores dos índices médios de acerto entre as 9 categorias de movimentos estudadas para os conjuntos de padrões com 36 características (12 por eixo), os maiores valores 99,5% e 99,5% foram obtidos com o conjunto de características aplicando a triangulação e a soma (TrS) e o conjunto de características da literatura no domínio tempo-frequência (TFDF), para janelas de 1000 pontos e classificador KNN, respectivamente, ou seja, reforçando a validação do método proposto no quarto experimento.

Gráfico 10 - Comparação entre os índices médios (9 movimentos) de classificação final obtidos no experimento 4 (36 características), utilizando o classificador MLP





Gráfico 11 - Comparação entre os índices médios (9 movimentos) de classificação final obtidos no experimento 4 (36 características), utilizando o classificador KNN



O Quadro 5 apresenta uma análise comparativa dos resultados obtidos no experimento 4, a partir dos maiores índices de acerto individuais por movimentos (9 categorias de movimentos), dos conjuntos de padrões calculados com 12 características por eixo (36 características), aplicando o método de triangulação (TrS, TrM, TrDP e TrV), bem

como, os conjuntos de padrões calculados no domínio tempo-frequência TFDF (características da literatura), conforme registrado nas Tabelas 8 e 9.

Quadro 5 - Melhores índices de acerto individuais por movimento, comparando os conjuntos de características aplicando a triangulação, com os conjuntos de características da literatura no domínio do tempo-frequência, utilizando 12 características por eixo no experimento 4

Categoria de movimentos	Triangulação				Literatura			
	Conj. de caract.	Taxa de acerto (%)	Tam. da Janela (pontos)	Classificador	Conj. de caract.	Taxa de acerto (%)	Tam. da Janela (pontos)	Classificador
Andando na Esteira	TrS e TrM	100	500	KNN	TFDF	100	500	MLP e KNN
Correndo na Esteira	TrS	97,7	100	MLP	TFDF	98	100	MLP
	TrS, TrM e TrDP	100	1000	KNN	TFDF	100	1000	MLP
Tremores	TrS, TrM e TrDP	100	100	KNN	TFDF	100	100	MLP e KNN
Palmas	TrDP	99,8	100	MLP	TFDF	100	100	MLP
	TrM e TrDP	100	200	KNN	TFDF	100	100	KNN
Aceno de Tchou	TrS	100	100	KNN	TFDF	100	100	KNN
Andando em Círculo	TrM	98,1	1000	KNN	TFDF	99,5	500	KNN
Apagando o Quadro	TrM e TrDP	100	500	MLP	TFDF	100	100	KNN
Subindo e Descendo Escada	TrDP	96,7	500	MLP	TFDF	97,3	200	MLP
	TrS, TrM e TrV	97,1	1000	KNN	TFDF	97,2	1000	KNN
Penteando o Cabelo	TrS e TrM	100	200	KNN	TFDF	100	100	MLP e KNN

Fonte: Autoria própria (2022)

Os resultados dos índices individuais de acerto por movimento das 9 categorias de movimentos, para o experimento 4, são apresentados nas Tabelas 8 e 9.

Tabela 8 - Comparação (em porcentagem) das taxas de acerto individuais por categoria de movimento estudada (A – andando na esteira, B – correndo na esteira, C - tremores, D - palmas, E – aceno de tchau, F – andando em círculo, G – apagando quadro, H – subindo e descendo escada e I – penteando o cabelo), utilizando 9 movimentos, para o classificador MLP e conjuntos de padrões com 36 características

Jan.	Conj.	A	B	C	D	E	F	G	H	I
	Car.									
100	TrS	97,4	97,7	100,0	99,7	99,90	84,2	95,4	85,0	94,3
	TrM	96,5	97,4	99,9	99,5	99,90	82,3	95,4	83,3	94,3
	TrDP	93,9	97,1	99,8	99,8	99,40	81,9	91,3	83,0	75,7
	TrV	89,0	96,1	99,3	99,4	98,90	72,4	84,6	81,7	78,6
	TFDF	99,3	98,0	100,0	99,9	99,90	96,2	99,9	95,4	100,0
200	TrS	98,1	97,8	100,0	99,8	100,00	89,0	98,5	88,6	100,0
	TrM	97,8	98,1	100,0	99,8	100,00	90,3	98,7	87,8	97,1
	TrDP	97,3	97,3	99,8	99,7	99,70	89,0	97,1	88,6	94,3
	TrV	93,6	97,0	99,8	99,8	99,70	83,6	92,0	88,8	91,4
	TFDF	99,1	98,4	100,0	100,0	100,00	96,6	100,0	97,3	100,0
500	TrS	99,4	98,0	100,0	100,0	100,00	90,0	99,5	96,2	100,0
	TrM	98,4	98,0	100,0	100,0	100,00	91,9	100,0	94,8	100,0
	TrDP	98,4	97,6	100,0	100,0	99,20	91,9	100,0	96,7	100,0
	TrV	96,3	98,0	100,0	100,0	99,20	90,5	97,6	95,7	100,0
	TFDF	100,0	99,3	100,0	100,0	99,60	98,6	100,0	93,8	100,0
1000	TrS	100,0	100,0	100,0	100,0	100,00	90,5	100,0	96,2	85,7
	TrM	100,0	99,3	100,0	100,0	100,00	92,4	100,0	95,2	85,7
	TrDP	99,4	100,0	100,0	100,0	98,40	90,5	100,0	94,3	100,0
	TrV	98,1	100,0	100,0	100,0	99,20	89,5	99,0	94,3	100,0
	TFDF	100,0	100,0	100,0	100,0	100,00	97,1	100,0	93,3	100,0

Fonte: Autoria própria (2022)


Tabela 9 - Comparação (em porcentagem) das taxas de acerto individuais por categoria de movimento estudada (A – andando na esteira, B – correndo na esteira, C - tremores, D - palmas, E – aceno de tchau, F – andando em círculo, G – apagando quadro, H – subindo e descendo escada e I – penteando o cabelo), utilizando 9 movimentos, para o classificador KNN e conjuntos de padrões com 36 características

Jan.	Conj.	A	B	C	D	E	F	G	H	I
	Car.									
100 pts	TrS	97,6	97,3	100,00	98,8	100,0	83,8	94,5	83,1	78,6
	TrM	97,7	97,2	100,00	99,5	99,8	85,1	96,0	84,5	87,1
	TrDP	88,6	94,4	100,00	99,5	99,2	81,9	86,2	82,7	74,3
	TrV	81,5	87,8	99,40	97,5	98,3	77,2	77,9	79,4	64,3
	TFDF	99,2	97,5	100,00	100,0	100,0	97,1	100,0	91,4	100,0
200 pts	TrS	98,8	97,6	100,00	99,8	100,0	91,8	97,3	87,6	100,0
	TrM	99,1	98,0	100,00	100,0	100,0	93,5	98,3	90,5	100,0
	TrDP	94,6	96,3	100,00	100,0	99,5	89,5	96,8	90,1	88,6
	TrV	91,1	93,5	100,00	99,0	99,5	88,0	92,6	89,9	91,4
	TFDF	99,5	98,0	100,00	100,0	100,0	97,5	100,0	95,6	100,0
500 pts	TrS	100,0	97,6	100,00	100,0	100,0	94,8	99,0	93,8	100,0
	TrM	100,0	98,0	100,00	100,0	100,0	96,7	99,0	93,3	100,0
	TrDP	99,1	97,6	100,00	100,0	98,4	94,8	99,5	95,7	92,9
	TrV	98,4	94,2	100,00	100,0	98,8	94,3	97,1	94,3	92,9
	TFDF	100,0	98,0	100,00	100,0	100,0	99,5	100,0	93,8	100,0
1000 pts	TrS	100,0	100,0	100,00	100,0	100,0	97,1	100,0	97,1	100,0
	TrM	100,0	100,0	100,00	100,0	100,0	98,1	100,0	97,1	100,0
	TrDP	99,4	100,0	99,20	100,0	98,4	96,2	100,0	96,2	100,0
	TrV	98,8	98,6	98,30	100,0	98,4	95,2	100,0	97,1	100,0
	TFDF	100,0	99,3	100,00	100,0	100,0	99,0	100,0	97,2	100,0

Fonte: Autoria própria (2022)

No experimento 4 os índices médios de classificação obtidos para os conjuntos de características que aplicam a triangulação, foram mais baixos para janelas de dados de entrada com 100 pontos, comparados com os conjuntos de características da literatura. Por este motivo, no Gráfico 12, foi realizada uma análise da dispersão dos dados utilizando os melhores resultados (índices médios entre as 9 categorias de movimentos), os quais, foram obtidos com o classificador KNN, para janela de dados de entrada de 200, 500 e 1000 pontos, para todos os conjuntos de características comparados no experimento 4, com o objetivo de verificar nestas condições, o comportamento dos métodos utilizados nesta pesquisa.

Gráfico 12 - Dispersão dos dados utilizando os índices médios obtidos com os conjuntos de características comparados no experimento 4, para o classificador KNN



Fonte: Autoria própria (2022)

Analisando os resultados mostrados no Gráfico 12, observa-se uma maior dispersão dos índices médios (para as 9 categorias de movimentos) obtidos no quarto experimento, para os quatro conjuntos de características que aplicam a técnica de triangulação, conjuntos TrS, TrM, TrDP e TrV, em relação ao conjunto de características que aplicam os conceitos clássicos da literatura no domínio tempo-frequência (TFDF). Verificando o limite superior e comparando o maior índice médio de acerto de 99,5% (Gráficos 11 e 12) obtidos com os dois conjuntos de características, TrM (triangulação aplicando a média estatística) e TFDF (domínio tempo-frequência), os valores arredondados para uma casa decimal foram iguais.

No entanto, observando os limites inferiores (Gráficos 11 e 12), os menores índices de 97,7% obtidos com o conjunto de características TrM e 99% para o conjunto de características TFDF, apresentam uma diferença de 1,3%, ou seja, uma pequena vantagem para a literatura.

5.4.1 Associando os conjuntos de características que aplicam o método de triangulação, com os conjuntos de características no domínio tempo-frequência (para os critérios do experimento 4)

Foi realizado um último processamento utilizando as 9 categorias de movimentos capturados com o *smartphone*, para janelas de dados de entrada de 1000 pontos, formando dois novos conjuntos com 72 características, ou seja, fazendo a associação das 36 características extraídas pelos métodos que aplicam a técnica de triangulação com melhores resultados (de acordo com os experimentos anteriores), com as 36 características clássicas da literatura calculadas no domínio tempo-frequência. Sendo assim, foram compostos os seguintes conjuntos de características:

- Conjunto composto de 72 características, associando o conjunto de características TrS com o conjunto de características TFDF e
- Conjunto composto de 72 características, associando o conjunto de características TrM com o conjunto de características TFDF.

Os resultados obtidos neste processamento, utilizando os classificadores MLP e KNN para $k=5$, são mostrados na Tabela 10. As Figuras 23 e 24, mostram dois exemplos de matrizes de confusão com os resultados obtidos para os classificadores MLP e KNN, respectivamente, utilizando os conjuntos de características TrS composição com TFDF:

Figura 23 – Resultado da classificação utilizando o conjunto de características TrS composição com o conjunto de características TFDF, para o classificador MLP, apresentados em uma matriz de confusão

```

=== Confusion Matrix ===
  a  b  c  d  e  f  g  h  i  <-- classified as
160  0  0  0  0  0  0  0  0 |  a = 1
  0 147  0  0  0  0  0  0  0 |  b = 2
  0  0 120  0  0  0  0  0  0 |  c = 3
  0  0  0 120  0  0  0  0  0 |  d = 4
  0  0  0  0 122  0  0  0  0 |  e = 5
  0  0  0  0  0 99  2  3  1 |  f = 6
  0  0  0  0  0  0 105  0  0 |  g = 7
  0  0  0  0  0  2  0 103  0 |  h = 8
  0  0  0  0  0  0  0  0  7 |  i = 9

```

Fonte: Autoria própria (2022)

Na Figura 23 pode-se observar que a classe F (código das classes na Tabela 1), correspondente ao movimento andando em círculo, obteve 99 padrões (94,3% de índice de acerto) classificados corretamente, sendo que, 2 padrões foram confundidos com a classe G (apagando o quadro), 3 padrões foram confundidos com a classe H (subindo e descendo escada) e um padrão foi confundido com a classe I (penteadando o cabelo). Também pode-se

observar que a classe H (subindo e descendo escada) obteve 103 padrões (98,1% de índice de acerto) classificados corretamente e somente 2 padrões foram confundidos com a classe F (andando em círculo). Para as outras classes de movimentos (A, B, C, D, E, G e I), todos os padrões foram classificados corretamente com 100% de índice de acerto.

Figura 24 - Resultado da classificação utilizando o conjunto de características TrS composição com o conjunto de características TFDF, para o classificador KNN, apresentados em uma matriz de confusão

```

=== Confusion Matrix ===
  a  b  c  d  e  f  g  h  i  <-- classified as
160  0  0  0  0  0  0  0  0 |  a = 1
  0 147  0  0  0  0  0  0  0 |  b = 2
  0  0 120  0  0  0  0  0  0 |  c = 3
  0  0  0 120  0  0  0  0  0 |  d = 4
  0  0  0  0 122  0  0  0  0 |  e = 5
  0  0  0  0  0 103  0  2  0 |  f = 6
  0  0  0  0  0  0 105  0  0 |  g = 7
  0  0  0  0  0  2  0 103  0 |  h = 8
  0  0  0  0  0  0  0  0  7 |  i = 9

```

Fonte: Autoria própria (2022)

Na Figura 24 pode-se observar que a classe F, correspondente ao movimento andando em círculo, obteve 103 padrões (98,1% de índice de acerto) classificados corretamente, sendo que, 2 padrões foram confundidos com a classe H (subindo e descendo escada). Também pode-se observar que a classe H (subindo e descendo escada) obteve 103 padrões (98,1% de índice de acerto) classificados corretamente e somente 2 padrões foram confundidos com a classe F (andando em círculo). Para as outras classes de movimentos (A, B, C, D, E, G e I), todos os padrões foram classificados corretamente com 100% de índice de acerto.

Tabela 10 - Comparação (em porcentagem) das taxas de acerto individuais por categoria de movimento estudada (A – andando na esteira, B – correndo na esteira, C - tremores, D - palmas, E – aceno de tchau, F – andando em círculo, G – apagando quadro, H – subindo e descendo escada e I – penteando o cabelo), utilizando os classificadores MLP e KNN para $k=5$, para conjuntos de padrões com 72 características, os quais, associam as características extraídas pelo método de triangulação com as características clássicas da literatura no domínio tempo-frequência

Classif.	Conj. Car.	A	B	C	D	E	F	G	H	I	Média
MLP	TrS + TFDF	100,0	100,0	100,0	100,0	100,0	94,3	100,0	98,1	100,0	99,2
	TrM + TFDF	100,0	100,0	100,0	100,0	100,0	93,3	100,0	99,0	100,0	99,1
	TrS + TFDF	100,0	100,0	100,0	100,0	100,0	98,1	100,0	98,1	100,0	99,6
	TrM + TFDF	100,0	100,0	100,0	100,0	100,0	98,1	100,0	98,1	100,0	99,6

Fonte: Autoria própria (2022)

Os resultados dos índices médios de acerto 98,9% e 99,5%, foram obtidos com os classificadores MLP e KNN para $k=5$, respectivamente, para o conjunto de características da literatura no domínio tempo-frequência (TFDF), conforme os Gráficos 10 e 11 (experimento 4).

Comparando com os novos conjuntos de características, conforme a Tabela 10, foi obtido o índice de acerto de 99,2% com a associação dos conjuntos de características TrS e TFDF e para a associação dos conjuntos de características TrM e TFDF, obteve-se o índice de acerto de 99,1%, ambos utilizando o classificador MLP. Sendo assim, para o classificador MLP, houve uma melhora de 0,3% no índice de acerto, com a associação TrS e TFDF (72 características). No caso do classificador KNN, os resultados obtidos foram iguais com índice de acerto de 99,6% para os dois novos conjuntos de características, TrS composição com TFDF e TrM composição com TFDF, melhorando o índice de acerto em 0,1%.


Pode-se concluir que os conjuntos de características que aplicam a triangulação TrS e TrM contribuíram positivamente na composição dos novos padrões associados com as características da literatura no domínio tempo-frequência (TFDF), tendo em vista que, para os casos testados, houve melhora dos índices de acerto na classificação final.

5.5 Comparação entre os quatro conjuntos de características que aplicam o método de triangulação proposto

O Gráfico 13 mostra o desempenho comparativo entre o conjunto de características que aplica a triangulação e a soma (TrS) e o conjunto de características que aplica a

triangulação e a média estatística (TrM). Conforme pode ser visto no Gráfico 13, para todos os 32 testes realizados neste estudo, o conjunto de características TrS foi melhor em 19 testes (53%), ou seja, obteve as maiores taxas de acerto (pontos abaixo da linha verde). O conjunto de características TrM, entretanto, foi melhor em 10 testes (pontos acima da linha verde). Em três situações, os pontos estão sobre a linha verde, então esses conjuntos de características (TrS e TrM) são equivalentes.


Gráfico 13 - Comparação entre o conjunto de características aplicando a triangulação e a soma e o conjunto de características aplicando a triangulação e a média, para todos os testes. A linha verde marca a igualdade ($y = x$)



Fonte: Autoria própria (2022)

O Gráfico 14 mostra o desempenho comparativo entre o conjunto de características que aplica a triangulação e a soma (TrS) e o conjunto de características que aplica a triangulação e o desvio padrão estatístico (TrDP). São plotados os índices médios obtidos em todos os 32 testes realizados neste estudo, sendo que, o conjunto de características TrS foi melhor em 26 testes (77%), ou seja, obteve as maiores taxas de acerto (pontos abaixo da linha verde). O conjunto de características TrDP, neste caso, foi melhor em 6 testes (pontos acima da linha verde).


Gráfico 14 - Comparação entre o conjunto de características aplicando a triangulação e a soma e o conjunto de características aplicando a triangulação e o desvio padrão, para todos os testes. A linha verde marca a igualdade ($y = x$)



Fonte: Autoria própria (2022)

O Gráfico 15 mostra o desempenho comparativo entre o conjunto de características que aplica a triangulação e a soma (TrS) e o conjunto de característica que aplica a triangulação e a variância estatística (TrV). São plotados os índices médios obtidos em todos os 32 testes realizados neste estudo, o conjunto de características TrS foi melhor em 29 testes (89%), ou seja, obteve as maiores taxas de acerto (pontos abaixo da linha verde). O conjunto de características TrV, neste caso, foi melhor em dois testes (pontos acima da linha verde) e em 1 teste os valores são praticamente iguais (em cima da linha verde), mostrando que esses conjuntos de características (TrS e TrV) são equivalentes.


Gráfico 15 - Comparação entre o conjunto de características aplicando a triangulação e a soma e o conjunto de características aplicando a triangulação e a variância, para todos os testes. A linha verde marca a igualdade ($y = x$)



Fonte: Autoria própria (2022)

O Gráfico 16 mostra o desempenho comparativo entre o conjunto de características aplicando a triangulação e a média (TrM) e o conjunto de características aplicando a triangulação e o desvio padrão (TrDP). São plotados os índices médios obtidos em todos os 32 testes realizados nesta pesquisa, o conjunto de características TrM foi melhor em 23 testes (61%), ou seja, obteve as maiores taxas de acerto (pontos abaixo da linha verde). O conjunto de características TrDP, neste caso, foi melhor em 9 testes (pontos acima da linha verde).


Gráfico 16 - Comparação entre o conjunto de características aplicando a triangulação e a média e o conjunto de características aplicando a triangulação e o desvio padrão, para todos os testes. A linha verde marca a igualdade ($y = x$)



Fonte: Autoria própria (2022)

O Gráfico 17 mostra o desempenho comparativo entre o conjunto de características aplicando a triangulação e a média (TrM) e o conjunto de características aplicando a triangulação e a variância (TrV). São plotados os índices médios obtidos em todos os 32 testes realizados nesta pesquisa, o conjunto de características TrM foi melhor em 25 testes (76%), ou seja, obteve as maiores taxas de acerto (pontos abaixo da linha verde). O conjunto de características TrV, neste caso, foi melhor em 6 testes (pontos acima da linha verde) e em 1 teste os valores são praticamente iguais (em cima da linha verde), evidenciando que esses métodos são equivalentes.


Gráfico 17 - Comparação entre o conjunto de características aplicando a triangulação e a média e o conjunto de características aplicando a triangulação e a variância, para todos os testes. A linha verde marca a igualdade ($y = x$)



Fonte: Autoria própria (2022)

O Gráfico 18 mostra o desempenho comparativo entre o conjunto de características aplicando a triangulação e o desvio padrão (TrDP) e o conjunto de características aplicando a triangulação e a variância (TrV). São plotados os índices médios obtidos em todos os 32 testes realizados nesta pesquisa, o conjunto de características TrDP foi melhor em 27 testes (89%), ou seja, obteve as maiores taxas de acerto (pontos abaixo da linha verde). O conjunto de características TrV, neste caso, foi melhor em três testes (pontos acima da linha verde) e em 2 teste os valores são iguais (em cima da linha verde), mostrando que esses conjuntos de características (TrDP e TrV) são equivalentes.

Gráfico 18 - Comparação entre o conjunto de características aplicando a triangulação e o desvio padrão e o conjunto de características aplicando a triangulação e a variância, para todos os testes. A linha verde marca a igualdade ($y = x$)




Fonte: Autoria própria (2022)

5.6 Número de características


Foi realizada uma comparação entre todos os conjuntos de características estudados nesta pesquisa, conforme mostrado nos Gráficos 19 e 20, para os classificadores MLP e KNN para $k=5$, em termos da análise do número de características, incluindo os quatro experimentos, para janelas de dados de entrada de 1000 pontos. Os gráficos mostram os melhores índices de acerto médios para os experimentos 1, 2 e 3 utilizando 5 movimentos, variando a quantidade de características em 9, 15 e 36, para os conjuntos de características que aplicam a triangulação (TrS, TrM, TrDP, TrV), bem como, os conjuntos de características no domínio do tempo (TDF) e domínio da frequência (FDF). Também estão inclusos nos Gráficos 19 e 20 os índices médios de acerto apresentados no experimento 4, utilizando 9 categorias de movimentos, envolvendo os conjuntos de características que aplicam o método de triangulação (TrS, TrM, TrDP, TrV) e o conjunto de características da literatura no domínio tempo-frequência (TFDF).

Gráfico 19 - Mostra os índices médios em percentual de acerto de classificação final para os experimentos com 5 e 9 movimentos, utilizando janelas de dados de entrada de 1000 pontos e o classificador MLP



Fonte: Autoria própria (2022)

Gráfico 20 - Mostra os índices médios em percentual de acerto de classificação final para os experimentos com 5 e 9 movimentos, utilizando janelas de dados de entrada de 1000 pontos e o classificador KNN



Fonte: Autoria própria (2022)

Os Gráficos 19 e 20 mostram um aumento dos índices de acerto para os conjuntos de características que aplicam o método de triangulação (TrS, TrM, TrDP e TrV), bem como, para os conjuntos de características da literatura no domínio do tempo (TDF) e domínio da frequência (FDF), na medida em que foi aumentando o número de características por padrão, inicialmente utilizando 9 características (experimento 1), depois 15 características

(experimento 2) e por fim, utilizando 36 características (experimento 3), onde o maior valor de 100% de taxa de acerto foi obtido utilizando o método de triangulação para o conjunto de características TrS, com padrões compostos de 36 características, janelas de dados de entrada 1000 pontos e classificador MLP, nestes casos, utilizando 5 categorias de movimentos. No quarto experimento, utilizando as 9 categorias de movimentos, os índices de acerto para todos os conjuntos de características que aplicam a triangulação (TrS, TrM, TrDP e TrV), assim como, os conjuntos de características da literatura no domínio tempo-frequência (TFDF), foram ligeiramente mais baixos. O principal motivo foi o aumento da quantidade de categorias de movimentos na classificação final, onde foi obtido o índice de acerto 99,5% para os dois conjuntos de características TFDF (literatura no domínio tempo-frequência) e TrM (triangulação aplicando a média estatística), utilizando janelas de dados de entrada de 1000 pontos e classificador KNN.

Sendo assim, na maioria dos casos, os resultados obtidos nos Gráficos 19 e 20 validam o método de triangulação proposto, tendo em vista o equilíbrio entre os índices de acerto alcançados para os conjuntos de características comparados nesta pesquisa, especialmente para os conjuntos que aplicam a triangulação TrS e TrM e os conjuntos de características no domínio do tempo-frequência TFDF, considerando a análise realizada com padrões gerados utilizando janelas de dados de entrada com 1000 pontos.

5.7 Análise estatística aplicando Bland Altman


A medição de variáveis sempre implica em algum grau de erro. Quando dois métodos são comparados, esta imprecisão pode refletir em conclusões erradas. Então, uma alternativa interessante é avaliar o grau de concordância. Muitos estudos dão o coeficiente de correlação entre os resultados de dois métodos de medição como um indicador de concordância. No entanto, a correlação estuda a relação entre uma variável e outra, não as diferenças, conforme a abordagem proposta por Bland Altman. Sendo assim, a análise do gráfico de Bland Altman é uma maneira simples de avaliar a concordância entre dois métodos ou instrumentos diferentes que devem medir a mesma quantidade. Geralmente são utilizados os limites de 95% de concordância, ou $\pm 1,96$ desvio padrão (s) da diferença (GIAVARINA, 2015). Foram utilizados os índices médios de classificação final nas comparações entre os conjuntos de características que aplicam a triangulação com melhores resultados TrS (aplicando a soma estatística), TrM (aplicando a média estatística) e os conjuntos de características da literatura no domínio tempo-frequência TFDF, em análises gráficas separadas para o experimento 3 (5 categorias de movimentos) e o experimento 4 (9 categorias

de movimentos), em todos os casos, com padrões compostos de 36 características, como também, gráficos gerados para os classificadores MLP e KNN.

5.7.1 Comparando os conjuntos de características aplicando o método de triangulação TrS e TrM, para o experimento 3 (36 características)


Nos Gráficos 21 e 22 utilizando os classificadores MLP e KNN para $k=5$, respectivamente, os quatro pontos ficaram dentro do intervalo que compreende o valor da média $+1,96s$ e a média $-1,96s$, resultado da diferença entre os pontos do conjunto de características aplicando a triangulação e a soma (TrS) e o conjunto de características aplicando a triangulação e a média (TrM), para 5 categorias de movimentos. Neste caso, os dois conjuntos de características, TrS e TrM, apresentaram concordância com 100% dos valores avaliados pelo método de Bland Altman.

Gráfico 21 - Comparação entre os conjuntos de característica aplicando a triangulação e a soma (TrS) e o conjunto de características aplicando a triangulação e a média (TrM), utilizando 5 categorias de movimentos e o classificador MLP



Fonte: Autoria própria (2022)

Gráfico 22 - Comparação entre o conjunto de característica aplicando a triangulação e a soma (TrS) e o conjunto de características aplicando a triangulação e a média (TrM), utilizando 5 categorias de movimentos e o classificador KNN




Fonte: Autoria própria (2022)

5.7.2 Comparando os conjuntos de características aplicando o método de triangulação TrS e TrM, para o experimento 4 (36 características)


Nos Gráficos 23 e 24 utilizando os classificadores MLP e KNN para $k=5$, respectivamente, os quatro pontos ficaram dentro do intervalo que compreende o valor da média + 1,96s e a média -1,96s, resultado da diferença entre os pontos do conjunto de características aplicando a triangulação e a soma (TrS) e o conjunto de características aplicando a triangulação e a média (TrM), de acordo com o experimento 4 (36 características), para 9 categorias de movimentos. Neste caso, os dois conjuntos de características, TrS e TrM, apresentaram concordância com 100% dos valores avaliados pelo método de Bland Altman.

Gráfico 23 - Comparação entre o conjunto de característica aplicando a triangulação e a soma (TrS) e o conjunto de características aplicando a triangulação e a média (TrM), utilizando 9 categorias de movimentos e o classificador MLP



Fonte: Autoria própria (2022)

Gráfico 24 - Comparação entre o conjunto de característica aplicando a triangulação e a soma (TrS) e o conjunto de características aplicando a triangulação e a média (TrM), utilizando 9 categorias de movimentos e o classificador KNN

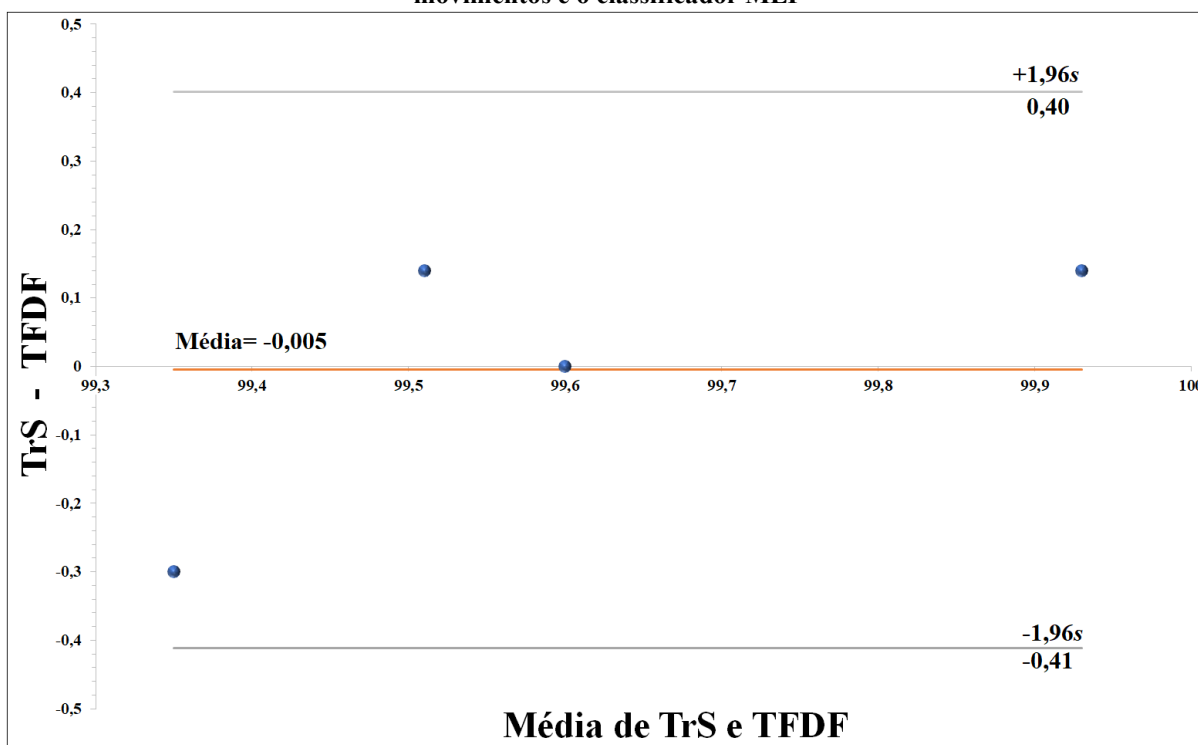


Fonte: Autoria própria (2022)

5.7.3 Comparando o conjunto de características aplicando o método de triangulação TrS e o conjunto de características da literatura TFDF, para o experimento 3 (36 características)


Nos Gráficos 25 e 26 utilizando os classificadores MLP e KNN para $k=5$, respectivamente, os quatro pontos ficaram dentro do intervalo que compreende o valor da média $+1,96s$ e a média $-1,96s$, resultado da diferença entre os pontos do conjunto de características aplicando a triangulação e a soma (TrS) e o conjunto de características clássicas da literatura no domínio tempo-frequência (TFDF), para 5 categorias de movimentos. Neste caso, os dois conjuntos de características, TrS e TFDF, apresentaram concordância com 100% dos valores avaliados pelo método de Bland Altman.

Gráfico 25 - Comparação entre os conjuntos de característica aplicando a triangulação e a soma (TrS) e o conjunto de características da literatura no domínio tempo-frequência (TFDF), utilizando 5 categorias de movimentos e o classificador MLP



Fonte: Autoria própria (2022)

Gráfico 26 - Comparação entre os conjuntos de característica aplicando a triangulação e a soma (TrS) e o conjunto de características da literatura no domínio tempo-frequência (TFDF), utilizando 5 categorias de movimentos e o classificador KNN




Fonte: Autoria própria (2022)

5.7.4 Comparando o conjunto de características aplicando o método de triangulação TrS e o conjunto de características da literatura TFDF, para o experimento 4 (36 características)

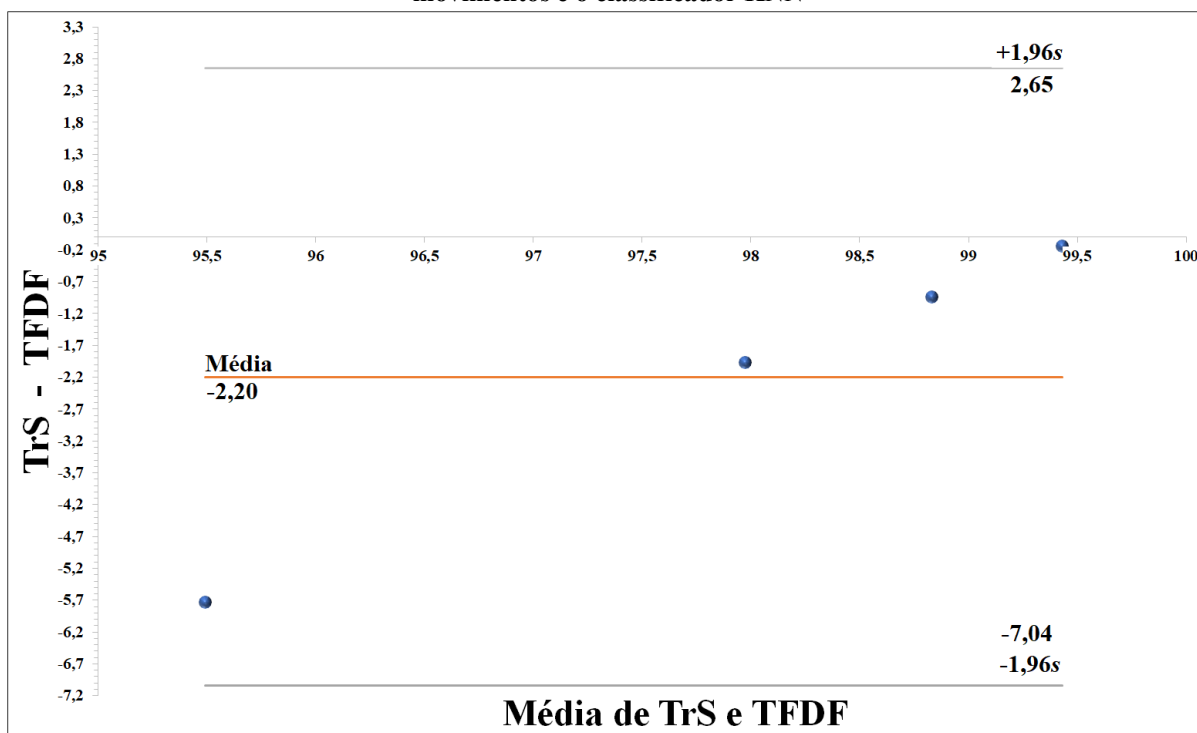
Nos Gráficos 27 e 28 utilizando os classificadores MLP e KNN para $k=5$, respectivamente, os quatro pontos ficaram dentro do intervalo que compreende o valor da média $+ 1,96s$ e a média $-1,96s$, resultado da diferença entre os pontos do conjunto de características aplicando a triangulação e a soma (TrS) e o conjunto de características clássicas da literatura no domínio tempo-frequência (TFDF), para 9 categorias de movimentos. Neste caso, os dois conjuntos de características, TrS e TFDF, apresentaram concordância com 100% dos valores avaliados pelo método de Bland Altman.

Gráfico 27 - Comparação entre os conjuntos de característica aplicando a triangulação e a soma (TrS) e o conjunto de características da literatura no domínio tempo-frequência (TFDF), utilizando 9 categorias de movimentos e o classificador MLP



Fonte: Autoria própria (2022)

Gráfico 28 - Comparação entre os conjuntos de característica aplicando a triangulação e a soma (TrS) e o conjunto de características da literatura no domínio tempo-frequência (TFDF), utilizando 9 categorias de movimentos e o classificador KNN




Fonte: Autoria própria (2022)

5.7.5 Comparando o conjunto de características aplicando o método de triangulação TrM e o conjunto de características da literatura TFDF, para o experimento 3 (36 características)


Nos Gráficos 29 e 30 utilizando os classificadores MLP e KNN para $k=5$, respectivamente, os quatro pontos ficaram dentro do intervalo que compreende o valor da média $+1,96s$ e a média $-1,96s$, resultado da diferença entre os pontos do conjunto de características aplicando a triangulação e a média (TrM) e o conjunto de características clássicas da literatura no domínio tempo-frequência (TFDF), para 5 categorias de movimentos. Neste caso, os dois conjuntos de características, TrM e TFDF, apresentaram concordância com 100% dos valores avaliados pelo método de Bland Altman.

Gráfico 29 - Comparação entre os conjuntos de característica aplicando a triangulação e a média (TrM) e o conjunto de características da literatura no domínio tempo-frequência (TFDF), utilizando 5 categorias de movimentos e o classificador MLP



Fonte: Autoria própria (2022)

Gráfico 30 - Comparação entre os conjuntos de característica aplicando a triangulação e a média (TrM) e o conjunto de características da literatura no domínio tempo-frequência (TFDF), utilizando 5 categorias de movimentos e o classificador KNN




Fonte: Autoria própria (2022)

5.7.6 Comparando o conjunto de características aplicando o método de triangulação TrM e o conjunto de características da literatura TFDF, para o experimento 4 (36 características)


Nos Gráficos 31 e 32 utilizando os classificadores MLP e KNN para $k=5$, respectivamente, os quatro pontos ficaram dentro do intervalo que compreende o valor da média $+ 1,96s$ e a média $-1,96s$, resultado da diferença entre os pontos do conjunto de características aplicando a triangulação e a média (TrM) e o conjunto de características clássicas da literatura no domínio tempo-frequência (TFDF), para 9 categorias de movimentos. Neste caso, os dois conjuntos de características, TrM e TFDF, apresentaram concordância com 100% dos valores avaliados pelo método de Bland Altman.

Gráfico 31 - Comparação entre os conjuntos de característica aplicando a triangulação e a média (TrM) e o conjunto de características da literatura no domínio tempo-frequência (TFDF), utilizando 9 categorias de movimentos e o classificador MLP



Fonte: Autoria própria (2022)

Gráfico 32 - Comparação entre os conjuntos de característica aplicando a triangulação e a média (TrM) e o conjunto de características da literatura no domínio tempo-frequência (TFDF), utilizando 9 categorias de movimentos e o classificador KNN



Fonte: Autoria própria (2022)

A análise realizada nos Gráficos 21 a 32 foi positiva, validando os conjuntos de características que aplicam o método de triangulação, no caso, os dois conjuntos com melhores resultados nesta pesquisa TrS e TrM, comparados com os conjuntos de características clássicas da literatura no domínio tempo-frequência TFDF, tendo em vista que, em todos os casos analisados os quatro pontos plotados ficaram dentro do viés, ou seja, entre as diferenças médias e o intervalo de concordância de 95% das diferenças calculadas entre dois conjuntos de características aplicando o método de Bland Altman, onde os percentuais de concordância obtidos alcançaram o índice máximo de 100%.

No próximo capítulo são apresentadas as principais conclusões e discussões sobre os resultados apresentados nesta pesquisa.

6 DISCUSSÕES E CONCLUSÕES

6.1 Discussões

As características encontradas em diversos estudos na literatura para o reconhecimento de padrões de movimentos humanos, são extraídas no domínio do tempo (*Time Domain Feature* - TDF) e/ou frequência (*Frequency Domain Feature* - FDF). O Quadro 6 apresenta as principais características utilizadas nos artigos referenciados nesta pesquisa, com os respectivos percentuais de acerto na classificação final, bem como as categorias de dados estudados. Os estudos também serviram de base para a escolha das características e a elaboração dos conjuntos de padrões TDF e FDF, os quais, foram extraídos das categorias de movimentos humanos capturadas nesta pesquisa, para realizar a comparação com o método de triangulação proposto, ou seja, os conjuntos de características TrS, TrM, TrDP e TrV. Todas as comparações foram baseadas nos índices percentuais individuais de acerto por movimento, bem como, os índices médios entre as categorias nos 4 experimentos realizados neste estudo.

Como o método de triangulação converte os sinais de entrada capturados de movimentos humanos em um novo sinal baseado em uma sequência de triângulos calculados entre os pontos de máximos (picos) e mínimos (vales), ou coordenadas (a, t) , onde a corresponde a amplitude e t ao tempo, a técnica tem a vantagem de extrair novas características a partir do cálculo de retas, ângulos, áreas, coeficiente angular das retas (derivada) e total de triângulos, que são simultaneamente parâmetros nos domínios do tempo e da frequência.

Quanto às categorias de movimentos andando na esteira e correndo na esteira, foram diferenciadas pela intensidade, velocidades 5 km/h e 8 km/h, e por serem executadas de modo similar (orientação nos planos ortogonais, x, y e z) em comparação com as outras categorias de movimentos utilizadas nesta pesquisa, na classificação final, apresentaram de um modo geral índices de acerto um pouco mais baixos. Neste caso, foi observado uma pequena vantagem do método de triangulação proposto, em relação aos métodos de comparação na classificação do movimento andando na esteira, utilizando somente 5 movimentos (andando na esteira, correndo na esteira, tremores, palmas e aceno de tchau), no primeiro experimento, com padrões compostos por 9 características, o método de triangulação aplicando a soma (TrS) obteve a taxa de acerto de 99,7% (Quadro 2 e Tabela 3) para janelas de 500 pontos com o classificador KNN, e 100% para janelas de 1000 pontos com os classificadores MLP e KNN, conforme a Tabelas 2, Tabela 3 e Quadro 2. Para o mesmo caso, o método que aplica

as características no domínio do tempo (TDF) obteve 98,6% (Quadro 2 e Tabela 2) para janelas de 100 pontos, com o classificador MLP, assim como, TDF obteve 99,4% para janelas de 1000 pontos, utilizando o mesmo classificador. Quanto ao movimento correndo na esteira, utilizando as mesmas 5 categorias de movimentos, no segundo experimento, para padrões formados com 15 características e janelas de 1000 pontos de dados de entrada, foi obtida a taxa de 100 % de acerto com o conjunto de características aplicando a triangulação e o desvio padrão (TrDP), o conjunto de características aplicando a triangulação e a variância (TrV) e o conjunto de características da literatura no domínio do tempo (TDF), em todos os casos, utilizando o classificador MLP (Quadro 3 e Tabela 4). Esses resultados são importantes, tendo em vista que, os movimentos andando e correndo têm diversas aplicações para o dia a dia das pessoas, como o monitoramento *online* de movimentos humanos utilizando *smartphone* (ALEMAYOH, LEE e OKAMOTO, 2021), monitoramento *online* de movimentos humanos usando sensores sem fio montados no pulso (SARCEVIC, KINCSES e PLETL, 2019), uso de dispositivos internos do *smartphone* (acelerômetro, giroscópio e magnetômetro) adaptado na cintura de voluntários para classificar atividades de movimentos humanos (NURHANIM *et al.*, 2017), monitoramento de atividades diárias com idosos (KHAN, *et al.*, 2010), monitoramento e gerenciamento de indivíduos, ou seja, identificação e classificação da atividade dos trabalhadores da construção civil usando acelerômetros e giroscópios embutidos em *smartphones* (ZHANG, *et al.*, 2018), contagem de passos (DIRICAN e AKSOY, 2017), monitoramento de atletas (HOWE, *et al.*, 2017), entre outros.

O método de triangulação aplicando a variância (TrV) obteve o menor índice médio de acerto de 84,8% (Gráfico 1), no primeiro experimento, utilizando 5 categorias de movimentos e padrões formados com 9 características, para janelas de 100 pontos, com o classificador MLP e o índice médio de acerto de 84,8% (Gráfico 11) com o mesmo conjunto de características (TrV), considerando o quarto experimento, utilizando 9 categorias de movimentos (andando na esteira, correndo na esteira, tremor, palmas, aceno de tchau, andando em círculo, apagando quadro, subindo e descendo escada e penteando o cabelo) e padrões com 36 características, utilizando o classificador KNN. Observando o menor índice médio 97,6% (Gráfico 2), utilizando 5 movimentos, com o conjunto de características da literatura no domínio da frequência (FDF) e 98,4% (Gráfico 11) obtido com o conjunto de características da literatura no domínio tempo-frequência (TFDF), utilizando 9 movimentos, ambos com classificador KNN e janelas de 100 pontos, ficou evidenciada uma desvantagem do método de triangulação para janelas de dados de 100 pontos em relação aos índices médios, comparado com os conjuntos que aplicam as características clássicas da literatura.

Quadro 6 - Lista de trabalhos da literatura com as características extraídas no domínio do tempo (TDF) e domínio da frequência (FDF), visando o reconhecimento de padrões

Artigos	Extração de Características		Dados Estudados	Taxa de Acerto (%)
	TDF	FDF		
Alemayoh, Lee e Okamoto (2021)		Correlação, FFT e Wavelet	Reconhecimento de atividades <i>online</i>	
Bayat, Pomplun e Tran (2017)	Media eixo, MinMax, STD e RMS	APF dos 3 eixos, variancia de APF e Correlação entre os eixos y e z.	Reconhecimento de atividade humana com <i>Smartphone</i> .	98,5
Bazgir <i>et al.</i> (2015)		Freq. fund. e PSD	Tremores de Parkinson	91
Dirican e Aksoy (2017)		FFT	Contador de passos	87,5 caminhando e 41,7 correndo
Giacomossi e Pichorim (2022)	Area, mín, máx, média, variância, desvio padrão e RMS	FFT	Reconhecimento de atividades diárias com <i>Smartphone</i>	99,9
Howe <i>et al.</i> (2017)	Distância total percorrida, aceleração e distância em alta velocidade		Quantificando diferenças importantes no movimento do atleta	Limite de confiança ± 90
Jain e Kanhangad (2018)	Aceleração linear triaxial e velocidade angular	HG e descritor de Fourier (FD)	Reconhecimento de atividades diárias com <i>Smartphone</i>	97,1
Khan <i>et al.</i> (2010)	AR and SMA		<i>Activity of the elderly</i>	94
Nurhanim <i>et al.</i> (2017)	SMA, Mín, Máx, STD, Energia do sinal	Distorção do sinal, Entropia, AR, Média ponderada da Freq., Frequência média e Correlação	Reconhecimento de atividades diárias com <i>Smartphone</i>	98,6
Nurwulan e Selamaj (2020)	Média, STD, desvio médio absoluto, Max, Min, SMA e IQR.	Entropia espectral	Reconhecimento de atividades diárias com <i>Smartphone</i>	85
Pierleoni <i>et al.</i> (2014)		Freq. fund. e PSD	Tremores de Parkinson	100
Sarcevic, Kincses, e Pletl (2019)	MAV, WAMP, NZC, NSSC, MAX, MIN, RMS and WL		Reconhecimento de atividades <i>online</i>	90
Song <i>et al.</i> (2007)	Distancia e tempo		Método de estimativa de velocidade com Acelerações do corpo humano	Acima de 99
Song <i>et al.</i> (2020)	Média, Variância, MAX, SMA e.	Coef. de Correlação, entropia de energia Wavelet e FFT	Reconhecimento de atividades humanas mistas	97,4
Zhang <i>et al.</i> (2018)	Média, STD, IRQ e covariância	Distorção do sinal	Reconhecimento de atividade humana com <i>Smartphone</i>	Taxa de acerto 89,9 e previsão de acerto 94,9

Fonte: Autoria própria (2022)

Mesmo considerando os menores índices alcançados nesta pesquisa, em torno de 85%, no Quadro 6, pode-se observar que algumas taxas de acerto são similares, como no estudo Nurwulan e Selamaj (2020), que obteve um índice médio de 85% de acerto no reconhecimento de atividades diárias com *smartphone*, em Dirican e Aksoy (2017) foi obtido um índice de 87,5% de acerto para o movimento caminhando e 41,7% para o movimento correndo, no estudo de Sarcevic, Kincses, e Pletl (2019) com 90% de índice de acerto no reconhecimento de movimentos *online*, em Zhang *et al.* (2018) uma taxa de 89,9% no reconhecimento de atividades humanas com *smartphone*. No entanto, apesar de tais estudos apresentarem escopo similar, com o objetivo de reconhecer atividades humanas do dia a dia utilizando dados capturados com o acelerômetro interno de um *smartphone*, devido às diferenças na composição dos padrões, métodos aplicados, bem como na quantidade e seleção das categorias de movimentos (bases de dados distintas), não é possível fazer uma comparação direta ou indicar superioridade do método proposto.

As matrizes de correlação apresentadas nos Apêndices mostram os valores de correlação das características para os conjuntos de padrões gerados nos experimentos 1, 2 e 3 utilizando 5 movimentos, bem como, no quarto experimentos com 9 movimentos, para os conjuntos de características que aplicam a triangulação e a soma (TrS), triangulação aplicando a média (TrM), triangulação aplicando o desvio padrão (TrDP), triangulação aplicando a variância (TrV) e os conjuntos das características clássicas da literatura no domínio tempo-frequência (TFDF), os quais, apresentam 12 características por eixo (x, y e z), totalizando 36 características por padrão e janelas de dados de entrada de 1000 pontos. Esses valores refletem a força de tais características na classificação final das categorias de movimentos estudados. Deste modo, os valores de correlação contribuíram para a seleção das principais características na composição dos conjuntos de padrões comparados neste estudo. É importante observar, que cada característica apresenta um valor de correlação diferenciado de acordo com os conjuntos de características (TrS, TrM, TrDP, TrV e TFDF), o plano de execução do movimento (eixos x, y e z) e as categorias de movimentos de dados de entrada.

De acordo com o primeiro experimento, utilizando 5 categorias de movimentos, com padrões compostos de 9 características, os maiores índices médios de acerto para as 5 categorias de movimentos foram obtidos com os conjuntos de características da literatura no domínio do tempo (TDF), com índice de acerto de 99%, utilizando o classificador MLP (Gráfico 1) e para o conjunto de características que aplica a soma estatística (TrS), um índice de acerto de 94,3%, com classificador KNN, de acordo com o Gráfico 2, ambos para janelas de 100 pontos. Aumentando o tamanho da janela de dados de entrada para 200 pontos e

utilizando os mesmos 5 movimentos, ocorreu um aumento significativo no índice de acerto para o conjunto de características TrS, obtendo 97,5% com o classificador KNN (Gráfico 2) e para o conjunto de características TDF, com o classificador MLP, o índice aumentou para 99,2% (Gráfico 1). No entanto, para janelas de dados de entrada de 1000 pontos, no mesmo experimento, o conjunto de características TDF obteve o índice de acerto 99,6% (Gráfico 1) e o conjunto de características TrS um índice um pouco abaixo de 99,3% (Gráfico 1), utilizando o classificador MLP, respectivamente.

Aumentando o número de características calculadas de 9 para 15 por padrão, no experimento 2, para janelas de 1000 pontos e os mesmos 5 movimentos, os conjuntos de características aplicando a triangulação e o desvio padrão (TrDP) e o conjunto de características aplicando a triangulação e a variância (TrV), obtiveram o índice de acerto de 99,9% (Gráfico 4), com o classificador MLP, respectivamente, assim como, o conjunto de características da literatura no domínio da frequência (TDF) obteve o mesmo índice de acerto de 99,9%, com o classificador MLP (Gráfico 4). Ou seja, pode-se observar que, no segundo experimento, utilizando 5 categorias de movimentos, os índices médios de acerto alcançados foram bem elevados (próximos de 100%) para os conjuntos de características que aplicam a triangulação TrDP e TRV, assim como, para o conjunto de características da literatura TDF.

No terceiro experimento, aumentando o número de características calculadas de 15 para 36 por padrão, para os mesmos 5 movimentos e janelas de dados de entrada de 1000 pontos, o conjunto de características aplicando a triangulação e a soma (TrS) obteve a maior taxa de 100% de acerto (Gráfico 7) e o conjunto de características da literatura no domínio tempo-frequência (TFDF) a taxa de 99,9% (Gráfico 7), desta forma, comprovando o equilíbrio entre o método de triangulação e os métodos que aplicam as características clássicas da literatura.

O Quadro 7 mostra as diferenças entre as maiores taxas médias obtidas para os conjuntos de características que aplicam a triangulação e os conjuntos de características da literatura, compostos de 36 características, variando a quantidade de movimentos (5 e 9 categorias de movimentos) e o tamanho das janelas de dados de entrada em 100, 200, 500 e 1000 pontos. Analisando o Quadro 7 para 5 categorias de movimentos, no terceiro experimento, o conjunto de características aplicando a triangulação e a soma estatística (TrS) obteve o índice de acerto médio de 99,2% (Gráfico 7), comparado com os conjuntos da literatura no domínio tempo-frequência (TFDF) com índice de acerto médio de 99,5% (Gráfico 7), ambos com classificador MLP, apresentando uma diferença de 0,3% para janelas de dados de 100 pontos, com uma pequena vantagem para a literatura.

No entanto, para janelas de dados de entrada com 200 pontos e as mesmas 5 categorias de movimentos, o conjunto de características que aplica a triangulação e a média (TrM) obteve o índice de acerto médio de 99,6% (Gráfico 7) com classificador MLP e o conjunto de características TFDF obteve o índice de acerto médio de 99,5% (Gráfico 8) com o classificador KNN, apresentando uma pequena vantagem de 0,1% para a triangulação. Para janelas de dados de entrada com 500 pontos, mantendo as 5 categorias de movimentos, os dois conjuntos de características TrS e TFDF alcançaram o mesmo índice de acerto médio de 99,6% (Gráfico 7), com o classificador MLP. Comprovando o equilíbrio entre métodos comparados TrS e TFDF.

Ainda no terceiro experimento, para janelas de dados de entrada de 1000 pontos, o conjunto de características aplicando a triangulação e a soma (TrS) obteve o maior índice médio de acerto de 100% (Gráfico 7), ou seja, 100% de acerto para todas as 5 categorias de movimentos, enquanto o conjunto de características da literatura no domínio tempo-frequência TFDF, obteve o índice médio de 99,9% de acerto (Gráfico 7), com uma pequena vantagem para a triangulação.

No quarto experimento utilizando todas as 9 categorias de movimentos, para janelas de dados de entrada de 100 pontos ocorreu uma diferença de 3,9% entre os maiores índices de acerto obtidos com o conjunto de características que aplica a triangulação e a soma (TrS), o qual, obteve o índice médio de acerto de 94,8% (Gráfico 10), comparado com o conjunto da literatura TFDF, que obteve o índice médio de acerto de 98,7% (Gráfico 10), neste caso, apresentando uma vantagem significativa para a literatura.

No entanto, é importante observar que, para o mesmo tamanho de janela de dados de entrada de 100 pontos e levando em consideração os índices individuais de acerto no quarto experimento, os movimentos correndo na esteira (TrS com índice de acerto de 97,7% e TFDF com índice de acerto de 98%), tremores (TrS, TrM e TrDP com índice de acerto de 100% e TFDF com índice de acerto de 100%), palmas (TrDP com índice de acerto de 99,8% e TFDF com índice de acerto de 100%) e aceno de tchau (TrS com índice de acerto de 100% e TFDF com índice de acerto de 100%), apresentaram resultados com índices de acerto muito similares, de acordo com o Quadro 5.

Continuando a análise dos dados apresentados no Quadro 7, no quarto experimento, para janelas de 200, 500 e 1000 pontos, utilizando todas as 9 categorias de movimentos, os conjuntos de características que aplicam a triangulação (TrS e TrM) e os conjuntos de características da literatura no domínio tempo-frequência (TFDF) apresentaram índices médios de classificação muito próximos, onde a maior diferença percentual de 1,3% foi obtida

entre o conjunto de características da literatura TFDF com índice médio de acerto de 99% (Gráfico 11), e o conjunto de características que aplica a triangulação TrM com índice médio de acerto de 97,7% (Gráfico 11), ambos com o classificador KNN e janelas de dados de entrada de 200 pontos. Para os mesmos conjuntos de características TrM e TFDF, a diferença cai para 0,7%, para janelas de dados de entrada de 500 pontos, com índices médios de 98,6% e 99,3%, respectivamente, ambos com o classificador KNN (Gráfico 11). No entanto, para janelas de 1000 pontos, o conjunto de características que aplica a triangulação e a média estatística (TrM) e o conjunto de características da literatura no domínio tempo-frequência (TFDF), obtiveram resultados equiparados com índices de acerto iguais em 99,5%, conforme o Gráfico 11.

O Quadro 7 mostra as diferenças entre as maiores taxas médias obtidas para os métodos que empregam a triangulação e os métodos da literatura (TFDF), variando a quantidade de movimentos (5 e 9) e o tamanho das janelas (100, 200, 500 e 1000 pontos):

Quadro 7 - Mostra a diferença entre os maiores índices de acerto para os conjuntos de características objetos de estudo, envolvendo 5 e 9 categorias de movimentos, variando o tamanho das janelas de dados de entrada em 100, 200, 500 e 1000 pontos, para padrões compostos de 36 características

Quant. Mov.	Janela	Conj. de Caract. e Classificador	Diferença (%)	Vantagem
5	100 pontos	TFDF (MLP) e TrS (MLP)	$99,5 - 99,2 = 0,3$	Literatura
	200 pontos	TrM (MLP) e TFDF (KNN)	$99,6 - 99,5 = 0,1$	Triângulos
	500 pontos	TFDF (MLP) e TrS (MLP)	$99,6 - 99,6 = 0$	Iguais
	1000 pontos	TrS (MLP) e TFDF (MLP)	$100 - 99,9 = 0,1$	Triângulos
9	100 pontos	TFDF (MLP) e TrS (MLP)	$98,7 - 94,8 = 3,9$	Literatura
	200 pontos	TFDF (KNN) e TrM (KNN)	$99 - 97,7 = 1,3$	Literatura
	500 pontos	TFDF (KNN) e TrM (KNN)	$99,3 - 98,6 = 0,7$	Literatura
	1000 pontos	TFDF (KNN) e TrM (KNN)	$99,5 - 99,5 = 0$	Iguais

Fonte: Autoria própria (2022)

No próximo tópico estão apresentadas as principais conclusões desta pesquisa.

6.2 Conclusões

Nesta pesquisa foram utilizados sinais 3D (eixos x, y e z) capturados do acelerômetro interno de um *smartphone* de movimentos humanos, divididos em categorias (andando na esteira, correndo na esteira, tremores, palmas, aceno de tchau, andando em círculo, apagando quadro, subindo e descendo escada e penteando o cabelo), 9 movimentos no total, sendo que, foram utilizados 5 movimentos (andando na esteira, correndo na esteira, tremores, palmas e aceno de tchau) em 3 experimentos, e em um último experimento (quarto experimento) foram

acrescentadas as categorias de movimentos: andando em círculo, apagando o quadro, subindo e descendo escada e penteando o cabelo. Foi desenvolvido um aplicativo na plataforma android e embarcado no *smartphone* para a aquisição dos dados. Os dados capturados formam um conjunto de sinais discretizados irregulares em amplitude e frequência. Os voluntários realizaram movimentos periódicos (repetidos durante um período de tempo para cada uma das atividades ou categorias objetos de estudo), conforme projeto com a descrição detalhada de todos os procedimentos para o comitê permanente de ética em pesquisa envolvendo seres humanos. O objetivo principal deste estudo, foi desenvolver uma técnica que aplica a triangulação ou os princípios da geometria Euclidiana e estatística básica na extração de novas características visando o reconhecimento de padrões. Foram comparados quatro conjuntos de características que aplicam a técnica de triangulação, ou seja, triangulação aplicando a soma (TrS), triangulação aplicando a média (TrM), triangulação aplicando o desvio padrão (TrDP) e triangulação aplicando a variância (TrV) e dois conjuntos de características que utilizam as principais características (clássicas) encontradas na literatura, um composto de características no domínio do tempo (TDF) e outro elaborado com características no domínio da frequência (FDF), de modo que, os dois últimos conjuntos de características extraídos da literatura, foram associados (*merge*) para formar um conjunto com todas as características calculadas no domínio tempo-frequência (TFDF).

A principal contribuição do método de triangulação proposto é a extração de novas características calculadas simultaneamente nos domínios do tempo e da frequência, tendo em vista que são geradas linhas retas (*rs*, *rd* e *rb*), respectivamente reta de subida, reta de descida e reta de base, formando sequências de triângulos a partir das coordenadas amplitude (*a*) e tempo (*t*), pontos de máximo (picos) e pontos de mínimo (vales), correspondendo a um novo sinal ou redução do sinal de entrada. No entanto, os métodos da literatura não realizam este procedimento, ou seja, extraem as características diretamente sobre as janelas de dados de entrada. Devido à equivalência entre os índices médios e individuais obtidos por categoria de movimento na classificação final, para os conjuntos de características que aplicam a triangulação com melhores resultados TrS e TrM e os conjuntos de características da literatura no domínio tempo-frequência TFDF, nesta pesquisa, especialmente para os padrões gerados com 36 características, utilizando janelas de dados de entrada com 200, 500 e 1000 pontos, no terceiro e quarto experimento, ou seja, utilizando 5 e 9 categorias de movimentos, respectivamente, a relevância e contribuição do método proposto foi comprovada no reconhecimento de movimentos humanos normais do dia a dia, bem como, movimentos anormais como os tremores (nos experimentos não foram testados movimentos aleatórios ou

estocásticos, ou seja, somente foram capturados movimentos repetidos periodicamente para todas as categorias objetos de estudo). É importante ressaltar que, as características extraídas pela triangulação podem ser associadas às características da literatura, conforme o último teste realizado no quarto experimento (tópico 5.4.1), com padrões compostos de 72 características, uma vez que, os resultados apresentaram melhora no índice de classificação final, conforme a Tabela 10. Sendo assim, em estudos futuros novos testes devem ser realizados com a aplicação do método de triangulação, como exemplo, a sua utilização em sistemas de monitoramento de saúde para análises de aquisições de movimentos em ambientes internos ou externos, principalmente para pessoas idosas como prevenção, ou mesmo, detectando uma queda remota usando mensagem SMS para pedido de ajuda, caso esteja imóvel por um determinado tempo (KHAN, LEE, *et al.*, 2010; LEE e CALISLE, 2011; LI, LIN *et al.*, 2014).

O estudo foi dividido em 4 experimentos, variando o número de categoria de movimentos, ou seja, 5 categorias nos experimentos 1, 2 e 3, e 9 categorias no quarto e último experimento. Também foram comparados padrões com diferentes quantidades de características (9, 15 e 36), bem como, foi variado o tamanho da janela de dados de entrada (100, 200, 500 e 1000 pontos) na fase de pré-processamento ou extração das características, para os conjuntos de características que aplicam a triangulação TrS, TrM, TrDP e TrV, bem como, para os conjuntos de características comuns da literatura no domínio do tempo TDF e domínio da frequência FDF. Os resultados dos índices de acerto individuais por categoria de movimento, bem como o índice médio entre as categorias (classes) na classificação final conforme a fase 3 (Figura 12), com o uso de dois classificadores MLP e KNN, de um modo geral, nos experimentos com 5 categorias de movimentos (experimentos 1, 2 e 3) e 9 categorias de movimentos (experimento 4), mostraram uma melhora nos índices de acerto com o aumento do número de características por padrão, bem como, com o aumento do tamanho da janela de dados de entrada.

No entanto, no quarto experimento aumentando o número de categorias de 5 para 9, todos os conjuntos de características (TrS, TrM, TrDP, TrV e TFDF) obtiveram uma pequena redução nos índices de classificação final, comparando com os experimentos anteriores (experimentos 1, 2 e 3). Também foi observado no quarto experimento resultados com índices médios um pouco mais baixos com os conjuntos de características que aplicam os métodos de triangulação (TrS, TrM, TrDP e TrV), em relação aos índices médios de acerto obtidos com os conjuntos de características clássicas encontradas na literatura (TFDF), para janelas de dados de entrada de 100 pontos, conforme os Gráficos 10 e 11, apesar de algumas categorias como os movimentos correndo na esteira, tremores, palmas e aceno de tchau, apresentarem

índices individuais equiparados, conforme o Quadro 5. Quanto a categoria de movimento tremores, apesar de ser um movimento simulado de um tremor patológico, os resultados apresentados em todos os experimentos foram interessantes, ou seja, os conjuntos de características que aplicam a triangulação e os conjuntos de características da literatura no domínio tempo-frequência, obtiveram índices de 100% de acerto na maioria dos casos. É importante observar que os tremores patológicos são objetos de estudo em diversas pesquisas na literatura (BAZGIR, *et al.*, 2015; PIERLEONI, *et al.*, 2014).

No quarto experimento houve um equilíbrio em relação aos índices médios de acerto obtidos com os conjuntos de características que aplicam a triangulação TrS e TrM (conjuntos de características com melhores resultados na pesquisa), comparado com o conjunto de características no domínio tempo-frequência (TFDF), para janelas 200, 500 e 1000 pontos, conforme os Gráficos 10 e 11, como também pode ser visto nos dados apresentados no Quadro 6.

O método de triangulação, no experimento 1, utilizando 5 categorias de movimentos e padrões compostos com 9 características, para o movimento andando na esteira obteve o índice médio de acerto de 100% utilizando janelas de dados de entrada de 1000 pontos, com o conjunto de características que aplica a triangulação e a soma (TrS), aplicando os classificadores MLP e KNN, conforme o Quadro 2. Para o movimento correndo na esteira, no experimento 2, utilizando 15 características, para janelas de dados de entrada de 1000 pontos, obteve o índice de 100% com o conjunto de características que aplica a triangulação e o desvio padrão (TrDP) e o conjunto de características que aplica a triangulação e a variância (TrV), ambos com o classificador MLP, conforme o Quadro 3. Os resultados apresentados na classificação com os movimentos andando e correndo, também são relevantes, de acordo com diversas aplicações encontradas na literatura, tais como: o monitoramento *online* de movimentos humanos utilizando *smartphone* (ALEMAYOH, LEE e OKAMOTO, 2021), monitoramento *online* de movimentos humanos usando sensores sem fio montados no pulso (SARCEVIC, KINCSES e PLETL, 2019), contagem de passos (DIRICAN e AKSOY, 2017), monitoramento de atletas (HOWE *et al.*, 2017), entre outros.

Nos experimentos 1, 2 e 3, os conjuntos de características aplicando a triangulação TrS e TrM obtiveram ótimos resultados na classificação final utilizando as 5 categorias de movimentos, comparando os índices médios obtidos com o conjunto de características da literatura no domínio tempo-frequência (TFDF), para janelas de dados de entrada de 200, 500 e 1000 pontos. O melhor resultado foi obtido com o conjunto de características que aplica a triangulação TrS, que alcançou o índice de acerto de 100% para todas as 5 categorias

movimentos, enquanto o conjunto de características da literatura no domínio tempo-frequência obteve o índice médio de acerto de 99,9%, ambos com o classificador MLP e janelas de dados de entrada de 1000 pontos, apresentando uma pequena diferença de 0,1% de vantagem, conforme Gráfico 7 e Quadro 7. Para janelas de 200 pontos, o conjunto de características que aplica a triangulação TrM obteve o índice médio de acerto de 99,6% com o classificador MLP, conforme o Gráfico 7 e Quadro 7, assim como, o conjunto de características da literatura no domínio tempo-frequência TFDF obteve o índice médio de acerto de 99,5% com o classificador KNN, conforme o Gráfico 8 e Quadro 7. Neste caso, apresentando uma diferença de 0,1% de vantagem para a triangulação. Para janelas de dados de entrada de 500 pontos, os índices médios de acerto obtidos foram iguais em 99,6% para o conjunto de características que aplica a triangulação TrS e para o conjunto de características da literatura TFDF, comprovando o equilíbrio entre os conjuntos de características comparados nesta pesquisa, na classificação das 5 categorias de movimentos.

Ficou evidenciada uma dificuldade maior na separação entre as classes ou categorias de movimentos utilizadas nesta pesquisa, na medida em que foi aumentado o número de categorias de movimentos de 5 (experimentos 1, 2 e 3) para 9 categorias de movimentos (quarto experimento).

No último experimento (quarto experimento) houve um equilíbrio entre o conjunto de características que aplicam a triangulação TrM e o conjunto de características no domínio tempo-frequência TFDF, utilizando janelas de dados de entrada de 1000 pontos, com índice médio de acerto de 99,5% para os dois conjuntos de características TrM e TFDF, ambos com o classificador KNN (Gráfico 11 e Quadro 7). Exceto para as janelas de 100 pontos, onde a diferença (taxas médias) entre os métodos comparados chegou a 3,9%, comparando o conjunto de características que aplica a triangulação (TrS) com índice de acerto médio de 94,8%, com o conjunto de característica da literatura no domínio tempo-frequência (TFDF) com índice de acerto médio de 98,7%, ambos com classificador MLP, conforme o Gráfico 10 e Quadro 7. Entretanto, para algumas categorias de movimentos, como o movimento correndo na esteira, tremores, palmas e aceno de tchau, para janelas de dados de entrada de 100 pontos, no quarto experimento, os índices individuais de acerto foram praticamente iguais em 100%.

Os resultados dos índices médios de acerto 98,9% e 99,5% foram obtidos com os classificadores MLP e KNN para $k=5$, respectivamente, para o conjunto de características da literatura no domínio tempo-frequência (TFDF), conforme os Gráficos 10 e 11 no experimento 4. Comparando com os novos conjuntos de características (72 características), ou seja, associando as características da extraídas pelo método de triangulação (36

características) com as características extraídas no domínio tempo-frequência (36 características), conforme a Tabela 10, foi obtido o índice de acerto de 99,2% com a associação dos conjuntos de características TrS e TFDF e para a associação dos conjuntos de características TrM e TFDF foi obtido o índice de acerto de 99,1%, ambos utilizando o classificador MLP. Sendo assim, para o classificador MLP, houve uma melhora de 0,3% no índice de acerto com a associação TrS e TFDF. No caso do classificador KNN, os resultados obtidos foram iguais com índice de acerto de 99,6% para os dois novos conjuntos de características, TrS composição com TFDF e TrM composição com TFDF, melhorando o índice de acerto em 0,1%. Pode-se concluir que os conjuntos de características que aplicam a triangulação TrS e TrM, contribuíram positivamente na composição dos novos padrões associados com as características da literatura no domínio tempo-frequência (TFDF), tendo em vista que, para os casos testados, houve melhora dos índices de acerto na classificação final.

A análise realizada nos Gráficos 21 a 32 foi positiva, validando os conjuntos de características que aplicam o método de triangulação, no caso, os dois conjuntos com melhores resultados nesta pesquisa TrS e TrM, comparados com os conjuntos de características clássicas da literatura no domínio tempo-frequência TFDF. Em todos os casos analisados, os quatro pontos plotados ficaram dentro do viés, ou seja, entre as diferenças médias e o intervalo de concordância de 95% das diferenças calculadas entre dois conjuntos de características aplicando o método de Bland Altman, onde os percentuais de concordância obtidos alcançaram o índice máximo de 100%.

Os resultados obtidos nesta pesquisa são promissores e comprovam a hipótese inicial como verdadeira na classificação de movimentos humanos, com índices médios de acerto muito próximos entre os conjuntos de características que aplicam a triangulação, especialmente os conjuntos de características TrS e TrM, comparados com os conjuntos de características encontrados na literatura no domínio tempo-frequência TFDF, para janelas de dados de entrada iguais ou superiores a 200 pontos, conforme os índices de acerto apresentados nos experimentos 1, 2, 3 e 4. Mesmo assim, não foi o objetivo desta pesquisa demonstrar superioridade do método de triangulação em relação aos métodos de comparação, mas testar sua eficiência na classificação de movimentos humanos, aplicando um método inovador, que utiliza somente cálculos geométricos e estatísticos básicos na extração de características visando o reconhecimento de padrões. No entanto, para a evolução desta pesquisa, novos testes devem ser realizados conforme descrito no próximo tópico em estudos futuros.

6.3 Estudos futuros

Novas comparações devem ser realizadas entre o método de triangulação e os principais métodos encontrados na literatura no domínio do tempo e domínio da frequência, incluindo outros métodos não testados e utilizando outras bases de dados (ALEMAYOH, LEE e OKAMOTO, 2021). Também incluir sensores colocados em locais diferentes do corpo humano, diversificando os pontos de captura, podendo ser mais de um *smartphone* devido à praticidade e baixo custo (ZHANG *et al.*, 2018), ou mesmo, no lugar do *smartphone* utilizar um *smartwatch*, mais leve e mais fácil de prender no corpo.

Efetuar testes com dados separados por indivíduo (voluntário), divididos por sexo, idade, altura, entre outros.

Identificar e eliminar no algoritmo que aplica a triangulação a existência de pequenos triângulos gerados por ruído. Também realizar testes aplicando ruído branco ou gaussiano.

Efetuar a análise estatística dos resultados aplicando Friedman e depois multicomparação.

Testar as ferramentas disponíveis na plataforma *Edge Impulse*, implementando o algoritmo de triangulação embarcado em um *smartphone* para classificar dados de movimentos humanos.

Efetuar a captura de dados e o reconhecimento de padrões *online* (ALEMAYOH, LEE e OKAMOTO, 2021; SARCEVIC, KINCSES e PLETL, 2019).

Nesta pesquisa foram utilizados dados capturados com acelerômetro, ou seja, sinais irregulares em amplitude e frequência. No entanto, na fase de aquisição de dados, os voluntários executaram os movimentos repetitivamente durante um período de tempo para cada uma das atividades ou categorias objetos de estudo. Novos testes devem ser realizados utilizando movimentos humanos não padronizados, ou dados com comportamento estocástico, como convulsões apresentadas em casos graves de epilepsia (ELEVANT, 1999; CUPPENS *et al.*, 2009; BHATTACHARYYA e PACHORI, 2017; WANG *et al.*, 2017), detecção de quedas (LEE e CARLISLE, 2011) ou mesmo para o reconhecimento de fala (ESPINOLA *et al.*, 2021).

REFERÊNCIAS

- ALEMAYOH, T. T.; LEE, J. H.; OKAMOTO, S. New sensor data structuring for deeper feature extraction in human activity recognition. **Sensors**, 21, n. 8, 16 April 2021. 2814.
- AL-FAIZ, M. Z.; ALI, A. A.; MIRY, A. H. A k-Nearest Neighbor based algorithm for human arm movements recognition using EMG signals. **Iraqi Journal for Electrical And Electronic Engineering**, 6, n. 2, December 2010. 158-166.
doi:<https://doi.org/10.33762/eej.2010.54888>
- ASUROGLU, T.; AÇICI, K.; ERDAS, C. B. OGUL, H. Texture of activities: exploiting local binary patterns for accelerometer data analysis. **IEEE12th International Conference on Signal-Image Technology & Internet-Based Systems (SITIS)**, 2016. 135-138.
doi:<https://doi.org/10.1109/SITIS.2016.29>.
- BARAN R.; PARTILA P., WILK R. (2018) Automated text detection and character recognition in natural scenes based on local image features and contour processing techniques. **Intelligent Human Systems Integration. IHSI. Advances in Intelligent Systems and Computing**, 722. 2018. 42-48. https://doi.org/10.1007/978-3-319-73888-8_8
- BAYAT, A.; BAYAT, A. H.; GHASEMI, A. S. Classifying human walking patterns using accelerometer data from smartphone. **Int. J. Comput. Sci. Mobile Comput**, 3, December 2017. 1-6.
- BAYAT, A.; POMPLUN, M.; TRAN, D. A. A study on human activity recognition using accelerometer data from smartphones. **Procedia Computer Science**, 34, 2014. 450-457.
- BAZGIR, O.; FROUNCHI, J.; HABIBI, S. A.; PALMA, L.; PIERLEONI, P. A neural network system for diagnosis and assessment of tremor in Parkinson disease patients. **22nd Iranian Conference on Biomedical Engineering (ICBME)**, Kauai, HI, USA, 2015. 1-5.
- BHATTACHARYYA, A.; PACHORI, R. B. A multivariate approach for patient-specific EEG seizure detection using empirical wavelet transform. **IEEE Transactions on Biomedical Engineering**, 64, n. 9, January 2017. 2003-2015.
- BUTEPAGE, J.; BLACK, M. J.; KRAGIC, D.; KJELLSTROM, H. Deep representation learning for human motion prediction and classification. **Proceedings of the IEEE conference on computer vision and pattern recognition**, 2017. 6158-6166.
- CAPELA, N. A.; LEMAIRE, E. D.; BADDOUR, N.; RUDOLF, M.; GOLJAR, N.; BURGER, H. . Evaluation of a smartphone human activity recognition application with able-bodied and stroke participants. **Journal of NeuroEngineering and Rehabilitation**, 13, n. 1, 20 January 2016. 1-10.
- CUI, X.; LIU, Y. . Z. Y.; WANG, C. Tire defects classification with multi-contrast convolutional neural networks. **International Journal of Pattern Recognition and Artificial Intelligence**, 32, n. 04, 2018. 1850011.

- CUPPENS, K.; LAGAE, L.; CEULEMANS, B.; VAN HUFFEL, S.; VANRUMSTE, B. Detection of nocturnal frontal lobe seizures in pediatric patients by means of accelerometers: a first study. **Annual International Conference of the IEEE Engineering in Medicine and Biology Society**, Minneapolis, MN, USA, 2009. 6608-6611.
- DALLAIRE, P.; EMOND, D.; GIGUERE, P.; CHAIB-DRAA, B. Artificial tactile perception for surface identification using a triple axis accelerometer probe. **2011 IEEE International Symposium on Robotic and Sensors Environments (ROSE)**, 2011.
- DE SOUZA, M.; CARVALHO, D. D.; BARTH, P.; RAMOS, J. V.; COMUNELLO, E.; VON WANGENHEIM, A. Using acceleration data from smartphones to interact with 3D medical data. **IEEE 2010 23rd SIBGRAPI Conference on Graphics, Patterns and Images**, August 2010. 339-345.
- DIRICAN, A. C.; AKSOY, S. Step counting using smartphone accelerometer and fast fourier transform. **Sigma J. Eng. Nat. Sci**, 8, n. 2, 2017. 175-182.
- ESPINOLA, C. W.; GOMES, J. C.; PEREIRA, J. M.; DOS SANTOS, W. P. Detection of major depressive disorder using vocal acoustic analysis and machine learning an exploratory study. **Research on Biomedical Engineering**, 37, n. 1, 2021. 53-64.
- GAO, Y.; KU, M.; QIAN, T.; WANG, J. FFT formulations of adaptive Fourier decomposition. **Journal of Computational and Applied Mathematics**, 324, November 2017. 204-215.
- GATTI, F.; LOPEZ-CABALLERO, F. Predicting short-period spectral ordinates of hybrid ground shaking prediction tools: a comparative benchmark. **13th International Conference on Applications of Statistics and Probability in Civil Engineering(ICASP13)**, May 2019.
- GIACOMOSSI, L. C. Método não invasivo utilizando acelerômetro para classificar movimentos normais e anormais de humanos. **Dissertação (Mestrado) - Universidade Tecnológica Federal do Paraná. Pós-Graduação em Engenharia Elétrica e Informática Industrial.**, Curitiba, 2011. 96.
- GIACOMOSSI, L.C.; PICHORIM, S. F. Pattern recognition of human movements using features extracted by triangulation method – A comparison with features of time and frequency domains. **Research on Biomedical Engineering**. 2022. doi:<http://doi.org/10.1007/s42600-022-00204-4>.
- GIAVARINA, D. Understanding Bland Altman analysis. *Biochemia medica*, 25, n. 2, 2015, pp. 141-151. doi:<https://doi.org/10.11613/BM.2015.015>.
- GUO, Q.; RUAN, Y.; XI, J.; SONG, L.; ZHU, X.; YU, Y.; TONG, J. 3D shape measurement of moving object with FFT-based spatial matching. **Optics & Laser Technology**, 100, 1 March 2018. 325-331.
- HASSAN, M.; AHMAD, T.; ALI, S. Comparative analysis study of human activity recognition using various techniques. **17th IEEE International Multi Topic Conference 2014**, Karachi, Pakistan, December 2014. 83-86.
- HAYKIN, S. **Redes Neurais: Princípios e práticas**. 2ª ed., Porto Alegre: Bookman, 2001.

HOWE, S. T.; AUGHEY, R. J.; HOPKINS, W. G.; STEWART, A. M. Quantifying important differences in athlete movement during collision-based team sports: Accelerometers outperform Global Positioning Systems. **IEEE International Symposium on Inertial Sensors and Systems (INERTIAL)**, 2017. 1-4.

JAIN, A.; KANHANGAD, V. Human activity classification in smartphones using accelerometer and gyroscope sensors. **IEEE Sensors Journal**, 18, n. 3, February 2018. 1169-1177.

JALAL, A.; QUAID, M. A.; SIDDUQI, M. A. A Triaxial acceleration-based human motion detection for ambient smart home system. **2019 16th International Bhurban Conference on Applied Sciences and Technology (IBCAST)**, 2019. 353-358.

KARANTONIS, D. M.; NARAYANAN, M. R.; MATHIE, M.; LOVELL, N. H.; CELLER, B. G. Implementation of a real-time human movement classifier using a triaxial accelerometer for ambulatory monitoring. **IEEE transactions on information technology in biomedicine**, 10, n. 1, January 2006. 156-167.

KHAN, A. M.; LEE, Y.-K.; LEE, S.; KIM, T.-S. Accelerometer's position independent physical activity recognition system for long-term activity monitoring in the elderly. **Medical & Biological Engineering & Computing**, 48, n. 12, 4 November 2010. 1271-1279.

LEE, R. Y.; CARLISLE, A. J. Detection of falls using accelerometers and mobile phone technology. **Age and ageing**, 40, n. 6, May 2011. 690-696.

LI, C.; LIN, M.; YANG, L. T.; DING, C. Integrating the enriched feature with machine learning algorithms for human movement and fall detection. **The Journal of Supercomputing**, 67, n. 3, March 2014. 854-865.

LU, W.; TONG, Z.; CHU, J. Dynamic hand gesture recognition with leap motion controller. **IEEE Signal Processing Letters**, 23, n. 9, 12 July 2016. 1188-1192.

NURHANIM, K.; ELAMVAZUTHI, I.; IZHAR, L. I.; GANESAN, T. Classification of human activity based on smartphone inertial sensor using support vector machine. **IEEE 3rd international symposium in robotics and manufacturing automation**, Roma, September 2017. 1-5. doi:<https://doi.org/10.1109/ROMA.2017.8231736>.

NURWULAN, N. R.; SELAMAJ, G. Random forest for human daily activity recognition. **Journal of Physics: Conference Series**, 1655, n. 1, 2020, 12087.

PIERLEONI, P.; PALMA, L.; BELLI, A.; PIERNINI, L. A real-time system to aid clinical classification and quantification of tremor in Parkinson's disease. **IEEE-EMBS International Conference on Biomedical and Health Informatics (BHI)**, Valencia, Spain, 2014. 113-116.

SAFI, K.; ATTAL, F.; MOHAMMED, S.; KHALIL, M.; AMIRAT, Y. Physical activity recognition using inertial wearable sensors—A review of supervised classification algorithms. **2015 International Conference on Advances in Biomedical Engineering (ICABME)**, September 2015. 313-316.

SARCEVIC, P.; KINCSES, Z.; PLETL, S. Online human movement classification using wrist-worn wireless sensors. **Journal of Ambient Intelligence and Humanized Computing**, 10, n. 1, 2019. 89-106. doi:<https://doi.org/10.1007/s12652-017-0606-1>.

- SARCEVIC, P.; PLETL, S.; KINCSES, Z. Comparison of time-and frequency-domain features for movement classification using data from wrist-worn sensors. **IEEE 15th International Symposium on Intelligent Systems and Informatics (SISY)**, 2017. 261-266. doi:<https://doi.org/10.1109/SISY.2017.8080564>.
- SEO, S.; JO, S. H.; KIM, S.; SHIM, J.; OH, S.; KIM, J-H.; HEO, K.; CHOI, J-H.; CHOI, C.; OH, S.; KUZUM, D.; WONG, H.-S. P.; PARK, J-H. Artificial optic-neural synapse for colored and color-mixed pattern recognition. **Nature Communication**. 9, 2018. 5106. <https://doi.org/10.1038/s41467-018-07572-5>
- SONG, J.; ZHU, A.; TU, Y.; WANG, Y.; ARIF, M. A.; SHEN, H.; SHEN, Z. Human body mixed motion pattern recognition method based on multi-source feature parameter fusion. **Sensors**, 20. n. 2, 2020. 537. doi:<https://doi.org/10.3390/s20020537>.
- SONG, Y.; SHIN, S.; KIM, S.; LEE, D.; LEE, K.H. Speed estimation from a tri-axial accelerometer using neural networks. **29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBS)**, 2007. 3224-3227.
- WANG, L.; XUE, W.; LI, Y.; LUO, M.; HUANG, J.; CUI, W.; HUANG, C. Automatic epileptic seizure detection in EEG signals using multi-domain feature extraction and nonlinear analysis. **Entropy**, 19, n. 6, 2017. 222.
- WEBBER, M.; ROJAS, R. F. Human activity recognition with accelerometer and gyroscope: A data fusion approach, **IEEE Sensors Journal**, vol. 21, n. 15, 16979-16989, 1 August 2021. doi: 10.1109/JSEN.2021.3079883.
- YANG, X.; CHEN, X.; CAO, X.; WEI, S.; ZHANG, X. Chinese sign language recognition based on an optimized tree-structure framework. **IEEE journal of biomedical and health informatics**, 21, n. 4, 3 July 2017. 994-1004.
- YANG, X.; DINH, A.; CHEN, L. Implementation of a wearable real-time system for physical activity recognition based on Naive Bayes classifier. **IEEE 2010 International Conference on Bioinformatics and Biomedical Technology**, April 2010. 101-105.
- ZHANG, M.; CHEN, S.; ZHAO, X.; YANG, Z. Research on construction workers' activity recognition based on smartphone, 18, n. 8, 2018. 2667.
- ZHOU, J.; KWAN, C. Anomaly detection in low quality traffic monitoring videos using optical flow. In: Pattern Recognition and Tracking XXIX. **International Society for Optics and Photonics**, 30 April 2018. 106490F.

APÊNDICES – tabelas com os valores de correlação

Coefficientes de correlação para o conjunto de características TrS, 5 classes (A – andando na esteira, B – correndo na esteira, C - tremores, D - palmas, E – aceno de tchau) e janelas de dados de entrada de 1000 pontos. Ocorrências: fraco (w) $\leq 0,30$, moderado (m) 0,31 até 0,69 e forte (s) $\geq 0,70$

Características	A	B	C	D	E	Ocorrências		
Contador Triâng eixo x	-0,22	-0,13	0,70	0,31	-0,62	1s	2m	2w
Contador Triâng eixo y	-0,23	-0,36	0,88	0,01	-0,26	1s	1m	3w
Contador Triâng eixo z	-0,21	-0,05	0,16	-0,19	0,32		1m	4w
Área A_T eixo x	-0,34	-0,11	-0,21	-0,26	0,95	1s	1m	3w
Área A_T eixo y	-0,27	0,79	-0,35	-0,11	-0,10	1s	1m	3w
Área A_T eixo z	-0,44	0,15	0,11	0,58	-0,36		3m	2w
Perímetro <i>per</i> eixo x	-0,73	0,20	0,22	-0,04	0,42	1s	1m	3w
Perímetro <i>per</i> eixo y	-0,44	0,74	-0,24	0,16	-0,23	1s	1m	3w
Perímetro <i>per</i> eixo z	-0,51	0,29	-0,03	0,62	-0,32		3m	2w
Compr base <i>rb</i> eixo x	-0,47	0,51	0,21	0,13	-0,35		3m	2w
Compr base <i>rb</i> eixo y	-0,34	0,68	-0,21	0,09	-0,23		2m	3w
Compr base <i>rb</i> eixo z	-0,43	0,35	-0,20	0,59	-0,29		3m	2w
Compr desc <i>rd</i> eixo x	-0,68	0,00	0,17	-0,11	0,68		2m	3w
Compr desc <i>rd</i> eixo y	-0,46	0,73	-0,25	0,19	-0,21	1s	1m	3m
Compr desc <i>rd</i> eixo z	-0,55	0,24	0,08	0,61	-0,34		3m	2w
Compr subida <i>rs</i> eixo x	-0,69	0,01	0,17	-0,10	0,68		2m	3w
Compr subida <i>rs</i> eixo y	-0,46	0,73	-0,24	0,18	-0,22	1s	1m	3w
Compr subida <i>rs</i> eixo z	-0,55	0,24	0,08	0,61	-0,34		3m	2w
Derivada <i>devs</i> eixo x	-0,62	-0,18	0,62	0,41	-0,13		3m	2w
Derivada <i>devs</i> eixo y	-0,50	0,15	0,13	0,57	-0,31		3m	2w
Derivada <i>devs</i> eixo z	-0,44	0,02	-0,01	0,70	-0,22	1s	1m	3w
Derivada <i>devd</i> eixo x	-0,54	-0,24	0,47	0,66	-0,27		3m	2w
Derivada <i>devd</i> eixo y	-0,51	0,10	0,17	0,65	-0,36		3m	2w
Derivada <i>devd</i> eixo z	-0,48	0,02	0,05	0,68	-0,22		2m	3w
Derivada <i>devb</i> eixo x	-0,00	0,34	0,33	-0,65	-0,03		3m	2w
Derivada <i>devb</i> eixo y	-0,24	-0,08	-0,05	0,64	-0,23		1m	4w
Derivada <i>devb</i> eixo z	-0,13	0,05	-0,16	0,34	-0,10		1m	4w
Âng subida <i>angs</i> eixo x	-0,40	-0,09	0,80	0,22	-0,49	1s	2m	2w
Âng subida <i>angs</i> eixo y	-0,38	-0,16	0,88	-0,09	-0,18	1s	1m	2w
Âng subida <i>angs</i> eixo z	-0,51	0,08	0,29	-0,01	0,21		1m	4w
Âng desc <i>angd</i> eixo x	-0,39	-0,09	0,81	0,21	-0,48	1s	2m	2w
Âng desc <i>angd</i> eixo y	-0,40	-0,19	0,87	0,02	-0,24	1s	1m	2w
Âng desc <i>angd</i> eixo z	-0,51	0,08	0,30	-0,03	0,22		1m	4w
Âng base <i>angb</i> eixo x	-0,39	-0,03	0,74	0,30	-0,57	1s	2m	2w
Âng base <i>angb</i> eixo y	-0,41	-0,08	0,78	0,11	-0,35	1s	2m	2w
Âng base <i>angb</i> eixo z	-0,56	0,19	-0,11	0,19	0,12		1m	4w

Fonte: Autoria própria (2022)

Coefficientes de correlação para o conjunto de características TrM, 5 classes (A – andando na esteira, B – correndo na esteira, C - tremores, D - palmas, E – aceno de tchau) e janelas de dados de entrada de 1000 pontos. Ocorrências: fraco (w) $\leq 0,30$, moderado (m) 0,31 até 0,69 e forte (s) $\geq 0,70$

Características	A	B	C	D	E	Ocorrências		
Contador Triâng eixo x	-0,22	-0,13	0,70	0,31	-0,62	1s	2m	2w
Contador Triâng eixo y	-0,23	-0,36	0,88	0,01	-0,26	1s	1m	3w
Contador Triâng eixo z	-0,21	-0,05	0,16	-0,19	0,32		1m	4w
Área A_T eixo x	-0,28	-0,16	-0,25	-0,25	0,98	1s		4w
Área A_T eixo y	-0,18	0,72	-0,34	-0,16	-0,08	1s	1m	3w
Área A_T eixo z	-0,34	0,20	0,02	0,45	-0,32		3m	2w
Perímetro per eixo x	-0,40	0,05	-0,25	-0,25	0,88	1s	1m	3w
Perímetro per eixo y	-0,27	0,77	-0,41	-0,01	-0,11	1s	1m	3w
Perímetro per eixo z	-0,43	0,35	-0,09	0,53	-0,34		4m	1w
Compr base rb eixo x	-0,33	0,55	-0,22	-0,14	0,13		2m	3w
Compr base rb eixo y	-0,19	0,72	-0,41	-0,05	-0,11	1s	1m	3w
Compr base rb eixo z	-0,36	0,40	-0,22	0,49	-0,30		3m	2w
Compr desc rd eixo x	-0,37	0,07	-0,22	-0,24	0,95	1s	1m	3w
Compr desc rd eixo y	-0,30	0,78	-0,40	0,01	-0,11	1s	1m	3w
Compr desc rd eixo z	-0,46	0,30	0,00	0,55	-0,36		3m	2w
Compr subida rs eixo x	-0,37	-0,07	-0,22	-0,24	0,94	1s	1m	3w
Compr subida rs eixo y	-0,29	0,78	-0,40	0,00	-0,11	1s	1m	3w
Compr subida rs eixo z	-0,46	0,30	0,00	0,56	-0,30		2m	3w
Derivada $devs$ eixo x	-0,66	-0,13	0,05	0,10	0,72	1s	1m	2w
Derivada $devs$ eixo y	-0,45	0,48	-0,25	0,46	-0,23		3m	2w
Derivada $devs$ eixo z	-0,43	0,03	-0,04	0,77	-0,27	1s	1m	3w
Derivada $devd$ eixo x	-0,72	-0,23	0,10	0,57	0,37	1s	2m	2w
Derivada $devd$ eixo y	-0,47	0,44	-0,25	0,59	-0,29		3m	2w
Derivada $devd$ eixo z	-0,48	0,03	0,00	0,77	-0,29	1s	1m	2w
Derivada $devb$ eixo x	-0,02	0,46	0,16	-0,58	-0,05		2m	3w
Derivada $devb$ eixo y	-0,24	0,01	-0,13	0,59	-0,21		1m	4w
Derivada $devb$ eixo z	-0,14	0,05	-0,17	0,40	-0,12		1m	4w
Âng subida $angs$ eixo x	-0,79	0,12	0,33	-0,15	0,57	1ss	2m	2w
Âng subida $angs$ eixo y	-0,51	0,60	0,05	-0,27	0,14		2m	3w
Âng subida $angs$ eixo z	-0,77	0,26	0,34	0,34	-0,10	1s	2m	2w
Âng desc $angd$ eixo x	-0,80	0,12	0,38	-0,17	0,54	1s	2m	2w
Âng desc $angd$ eixo y	-0,62	0,54	0,13	0,03	-0,05		2m	3w
Âng desc $angd$ eixo z	-0,79	0,26	0,40	0,31	-0,09	1s	2m	2w
Âng base $angb$ eixo x	-0,52	0,42	0,40	0,22	-0,50		4m	1w
Âng base $angb$ eixo y	-0,40	0,63	-0,09	0,14	-0,28		2m	3w
Âng base $angb$ eixo z	-0,59	0,37	-0,06	0,50	-0,17		3m	2w

Fonte: Autoria própria (2022)

Coefficientes de correlação para o conjunto de características TrDP, 5 classes (A – andando na esteira, B – correndo na esteira, C - tremores, D - palmas, E – aceno de tchau) e janelas de dados de entrada de 1000 pontos. Ocorrências: fraco (w) $\leq 0,30$, moderado (m) 0,31 até 0,69 e forte (s) $\geq 0,70$

Características	A	B	C	D	E	Ocorrências		
Contador Triâng eixo x	-0,22	-0,13	0,71	0,29	-0,62	1s	1m	3w
Contador Triâng eixo y	-0,24	-0,36	0,88	0,05	-0,27	1s	1m	3w
Contador Triâng eixo z	-0,25	-0,07	0,11	-0,06	0,30			5w
Área A_T eixo x	-0,23	0,33	-0,31	-0,27	0,47		3m	2w
Área A_T eixo y	-0,16	0,73	-0,41	-0,09	-0,12	1s	1m	3w
Área A_T eixo z	-0,25	0,43	-0,12	0,22	-0,28		1m	4w
Perímetro per eixo x	-0,29	0,62	-0,22	-0,05	-0,07		1m	4w
Perímetro per eixo y	-0,25	0,73	-0,50	0,20	-0,22	1s	1m	3w
Perímetro per eixo z	-0,37	0,40	-0,19	0,52	-0,36		4m	1w
Compr base rb eixo x	-0,25	0,47	-0,27	-0,07	0,11		1m	4w
Compr base rb eixo y	-0,16	0,69	-0,53	0,15	-0,20		2m	3w
Compr base rb eixo z	-0,29	0,33	-0,25	0,52	-0,30		2m	3w
Compr desc rd eixo x	-0,34	0,57	-0,23	-0,16	0,15		2m	3w
Compr desc rd eixo y	-0,24	0,80	-0,45	0,00	-0,14	1s	1m	3w
Compr desc rd eixo z	-0,38	0,38	0,19	0,55	-0,35		4m	1w
Compr subida rs eixo x	-0,39	0,50	-0,24	-0,10	0,23		2m	3w
Compr subida rs eixo y	-0,29	0,71	-0,46	0,25	-0,24	1s	1m	3w
Compr subida rs eixo z	-0,39	0,46	-0,13	0,43	-0,35		4m	1w
Derivada $devs$ eixo x	-0,51	0,07	-0,01	0,63	-0,12		2m	3w
Derivada $devs$ eixo y	-0,35	0,20	-0,26	0,71	-0,27	1s	1m	3w
Derivada $devs$ eixo z	-0,33	-0,02	-0,18	0,82	-0,24	1s	1m	3w
Derivada $devd$ eixo x	-0,39	-0,13	-0,05	0,91	-0,28	1s	2m	2w
Derivada $devd$ eixo y	-0,35	0,16	-0,29	0,81	-0,30	1s	1m	3w
Derivada $devd$ eixo z	-0,35	-0,04	-0,19	0,89	-0,26	1s	1m	3w
Derivada $devb$ eixo x	-0,45	0,29	0,03	0,34	-0,18		2m	3w
Derivada $devb$ eixo y	-0,40	0,36	-0,30	0,61	-0,26		3m	2w
Derivada $devb$ eixo z	-0,34	0,02	-0,18	0,78	-0,24	1s	1m	3w
Âng subida $angs$ eixo x	0,39	0,05	-0,27	0,44	-0,65		3m	2w
Âng subida $angs$ eixo y	-0,01	-0,14	-0,27	0,75	-0,32	1s	1m	3w
Âng subida $angs$ eixo z	0,50	-0,06	-0,41	-0,12	0,05		2m	3w
Âng desc $angd$ eixo x	0,38	0,10	-0,22	0,50	-0,81	1s	2m	2w
Âng desc $angd$ eixo y	0,21	-0,14	-0,39	0,50	-0,21		2m	3w
Âng desc $angd$ eixo z	0,47	-0,08	-0,40	-0,06	0,02		2m	3w
Âng base $angb$ eixo x	-0,17	0,14	0,20	0,36	-0,11		1m	4w
Âng base $angb$ eixo y	-0,20	0,08	-0,30	0,48	-0,04		1m	4w
Âng base $angb$ eixo z	-0,09	0,16	0,04	-0,14	0,03			5w

Fonte: Autoria própria (2022)

Coefficientes de correlação para o conjunto de características TrV, 5 classes (A – andando na esteira, B – correndo na esteira, C - tremores, D - palmas, E – aceno de tchau) e janelas de dados de entrada de 1000 pontos. Ocorrências: fraco (w) $\leq 0,30$, moderado (m) 0,31 até 0,69 e forte (s) $\geq 0,70$

Características	A	B	C	D	E	Ocorrências		
Contador Triâng eixo x	-0,22	-0,13	0,71	0,29	-0,62	1s	1m	3w
Contador Triâng eixo y	-0,24	-0,36	0,88	0,05	-0,27	1s	1m	3w
Contador Triâng eixo z	-0,25	-0,07	0,11	-0,06	0,30			5w
Área A_T eixo x	-0,20	0,33	-0,21	-0,20	0,27		1m	4w
Área A_T eixo y	-0,15	0,65	-0,24	-0,13	-0,17		1m	4w
Área A_T eixo z	-0,17	0,42	-0,13	0,04	-0,17		1m	4w
Perímetro per eixo x	-0,22	0,59	-0,18	-0,11	-0,10		1m	4w
Perímetro per eixo y	-0,25	0,70	-0,31	0,05	-0,22	1s	1m	3w
Perímetro per eixo z	-0,32	0,39	-0,22	0,44	-0,29		3m	2w
Compr base rb eixo x	-0,20	0,46	-0,19	-0,11	0,02		1m	4w
Compr base rb eixo y	-0,20	0,67	-0,32	0,03	-0,21		2m	3w
Compr base rb eixo z	-0,26	0,32	-0,22	0,40	-0,24		2m	3w
Compr desc rd eixo x	-0,25	0,56	-0,19	-0,17	0,03		1m	4w
Compr desc rd eixo y	-0,23	0,74	-0,27	-0,09	-0,18	1s		4w
Compr desc rd eixo z	-0,33	0,37	-0,22	0,47	-0,29		3m	2w
Compr subida rs eixo x	-0,28	0,50	-0,21	-0,15	0,13		1m	4w
Compr subida rs eixo y	-0,27	0,69	-0,30	0,10	-0,24		1m	4w
Compr subida rs eixo z	-0,31	0,47	-0,18	0,30	-0,28		2m	3w
Derivada $devs$ eixo x	-0,28	-0,02	-0,10	0,59	-0,15		1m	4w
Derivada $devs$ eixo y	-0,24	0,06	-0,20	0,62	-0,21		1m	4w
Derivada $devs$ eixo z	-0,20	-0,12	-0,15	0,67	-0,17		1m	4w
Derivada $devd$ eixo x	-0,27	-0,19	-0,15	0,87	-0,22	1s		4w
Derivada $devd$ eixo y	-0,26	-0,02	-0,22	0,76	-0,23	1s		4w
Derivada $devd$ eixo z	-0,25	-0,15	-0,19	0,83	-0,21	1s		4w
Derivada $devb$ eixo x	-0,32	0,28	-0,02	0,25	-0,17		1m	4w
Derivada $devb$ eixo y	-0,33	0,25	-0,26	0,60	-0,25		2m	3w
Derivada $devb$ eixo z	-0,22	-0,08	-0,16	0,66	-0,18		1m	4w
Âng subida $angs$ eixo x	0,39	-0,04	-0,35	0,52	-0,55		4m	1w
Âng subida $angs$ eixo y	-0,05	-0,15	-0,27	0,80	-0,30	1s		4w
Âng subida $angs$ eixo z	0,51	-0,08	-0,40	-0,11	0,02		2m	3w
Âng desc $angd$ eixo x	0,35	-0,02	-0,35	0,61	-0,63		4m	1w
Âng desc $angd$ eixo y	0,20	-0,13	-0,39	0,53	-0,22		2m	3w
Âng desc $angd$ eixo z	0,50	-0,11	-0,36	-0,06	-0,02		2m	3w
Âng base $angb$ eixo x	-0,21	0,15	-0,20	0,36	-0,10		1m	4w
Âng base $angb$ eixo y	-0,22	0,10	-0,30	0,49	-0,05		1m	4w
Âng base $angb$ eixo z	-0,12	0,19	0,06	-0,12	0,00			5w

Fonte: Autoria própria (2022)

Coefficientes de correlação para o conjunto de características TFDF, 5 classes (A – andando na esteira, B – correndo na esteira, C - tremores, D - palmas, E – aceno de tchau) e janelas de dados de entrada de 1000 pontos. Ocorrências: fraco (w) $\leq 0,30$, moderado (m) 0,31 até 0,69 e forte (s) $\geq 0,70$

Características	A	B	C	D	E	Ocorrências	
Média eixo x	-0,02	0,10	-0,36	-0,42	0,69	3m	2w
Média eixo y	-0,23	0,51	-0,63	0,49	-0,15	3m	2w
Média eixo z	-0,06	0,05	0,34	0,29	-0,61	2m	3w
Desvio Padrão eixo x	-0,37	0,29	-0,30	0,29	0,68	2m	3w
Desvio Padrão eixo y	-0,12	0,79	-0,52	0,02	-0,18	1s	1m 3w
Desvio Padrão eixo z	-0,34	0,45	-0,19	-0,46	-0,38	4m	1w
Área eixo x	-0,02	0,10	-0,36	-0,42	0,69	3m	2w
Área eixo y	-0,23	0,51	-0,63	0,49	-0,15	3m	2w
Área eixo z	-0,06	0,05	0,34	-0,29	-0,61	2m	3w
Variância eixo x	0,34	0,26	-0,29	0,29	0,66	2m	3w
Variância eixo y	-0,17	0,76	-0,31	0,10	-0,20	1s	1m 3w
Variância eixo z	-0,31	0,47	-0,21	-0,37	-0,31	4m	1w
Máximo eixo x	-0,39	0,30	-0,36	-0,15	0,62	3m	2w
Máximo eixo y	-0,16	0,73	-0,53	0,14	-0,23	1s	1m 3w
Máximo eixo z	-0,32	0,37	-0,08	-0,53	-0,48	4m	1w
Mínimo eixo x	0,54	-0,16	-0,14	-0,14	-0,14	1m	4w
Mínimo eixo y	0,21	-0,17	-0,17	0,04	0,08		5w
Mínimo eixo z	0,29	-0,29	0,50	-0,25	-0,26	1m	4w
RMS eixo x	-0,12	0,17	-0,35	-0,39	0,70	1s	2m 2w
RMS eixo y	-0,23	0,57	-0,63	0,42	-0,16	3m	2w
RMS eixo z	-0,15	0,19	0,21	0,35	-0,59	2m	3w
Freq. Pico Pot. eixo x	-0,49	-0,15	0,64	-0,12	0,18	2m	3w
Freq. Pico Pot. eixo y	-0,39	-0,12	0,59	-0,09	0,07	2m	3w
Freq. Pico Pot. eixo z	-0,54	-0,20	0,72	0,01	0,08	1s	1m 3w
Pico Tensão eixo x	-0,30	0,20	-0,29	-0,27	0,67	1m	4w
Pico Tensão eixo y	-0,07	0,66	-0,34	-0,12	-0,18	2m	3w
Pico Tensão eixo z	-0,23	0,55	-0,20	0,10	-0,24	1m	4w
Potência Tot. eixo x	-0,33	0,25	-0,29	-0,29	0,68	2m	3w
Potência Tot. eixo y	-0,18	0,75	-0,34	-0,06	-0,21	1s	1m 3w
Potência Tot. eixo z	-0,31	0,46	-0,20	0,37	-0,32	4m	1w
Freq. Média eixo x	-0,53	-0,31	0,54	0,63	-0,24	4m	1w
Freq. Média eixo y	-0,54	-0,23	0,73	0,33	-0,21	1s	2m 2w
Freq. Média eixo z	-0,61`	-0,14	0,32	0,38	0,13	3m	2w
Média Pot. eixo x	-0,33	0,25	-0,29	-0,29	0,67	2m	3w
Média Pot. eixo y	-0,18	0,75	-0,34	-0,06	-0,21	1s	1m 3w
Média Pot. eixo z	-0,30	0,46	-0,20	0,37	-0,32	3m	2w

Fonte: Autoria própria (2022)

Coefficientes de correlação para o conjunto de características TFDF, 9 classes (A – andando na esteira, B – correndo na esteira, C - tremores, D - palmas, E – aceno de tchau, F – andando em círculo, G – apagando quadro, H – subindo e descendo escada, I – penteando o cabelo) e janelas de dados de entrada de 1000 pontos. Ocorrências: fraco (w) $\leq 0,30$, moderado (m) 0,31 até 0,69 e forte (s) $\geq 0,70$

Carac.	A	B	C	D	E	F	G	H	I	Ocorrência
Méd x	0,02	0,12	-0,27	-0,31	0,59	0,29	-0,24	-0,21	-0,02	2m 7w
Méd y	-0,11	0,41	-0,41	0,39	-0,07	-0,28	0,47	-0,43	-0,02	5m 4w
Méd z	0,07	0,15	-0,35	0,31	-0,36	-0,35	-0,37	0,14	0,03	5m 4w
DP x	-0,14	0,38	0,11	-0,10	0,69	-0,31	-0,15	-0,32	-0,08	4m 5w
DP y	0,02	0,75	-0,32	0,09	-0,05	-0,29	0,07	-0,38	0,02	1s 2m 6w
DP z	-0,11	0,52	-0,01	0,51	-0,17	-0,27	-0,24	-0,29	-0,06	2m 7w
Área x	0,02	0,12	-0,27	-0,31	0,59	0,29	-0,24	-0,21	-0,02	2m 7w
Área y	-0,11	0,41	-0,41	0,39	-0,06	-0,28	0,47	-0,43	-0,02	5m 4w
Área z	0,07	0,15	-0,35	0,31	-0,35	-0,35	-0,37	0,14	0,03	5m 4w
Var x	-0,17	-0,34	0,15	-0,15	0,69	-0,21	-0,17	-0,21	-0,05	2m 7w
Var y	-0,07	0,76	-0,22	-0,02	-0,11	-0,20	-0,01	-0,22	-0,01	1s 8w
Var z	-0,16	0,53	-0,10	0,43	-0,18	-0,19	-0,18	-0,19	-0,05	2m 7w
Máx x	-0,14	0,39	-0,15	0,02	0,63	-0,15	-0,28	-0,35	-0,08	3m 6w
Máx y	-0,02	0,69	-0,34	0,20	-0,10	-0,29	0,19	-0,41	-0,03	3m 6w
Máx z	-0,08	0,45	-0,08	0,56	-0,24	-0,32	-0,34	-0,17	-0,04	4m 5w
Mín x	0,03	-0,20	0,18	-0,18	-0,18	0,77	-0,16	0,11	0,09	1s 8w
Mín y	-0,10	-0,17	-0,16	-0,11	-0,10	-0,06	0,92	-0,14	-0,02	1s 8w
Mín z	0,10	-0,23	-0,24	-0,20	-0,21	-0,12	-0,19	0,60	0,13	1m 8w
RMS x	-0,04	0,20	-0,25	-0,27	0,64	0,17	-0,24	-0,25	-0,04	1m 8w
RMS y	-0,10	0,46	-0,41	0,36	-0,07	-0,28	0,44	-0,43	-0,02	5m 4w
RMS z	0,02	0,27	0,27	0,38	-0,34	-0,35	-0,37	0,06	0,01	4m 5w
Freq PP x	-0,22	0,04	0,65	0,04	0,29	-0,22	-0,27	-0,31	-0,09	2m 7w
Freq PP y	-0,18	0,03	0,62	0,04	0,18	-0,22	-0,22	-0,26	-0,07	1m 8w
Freq PP z	-0,24	0,02	0,70	0,16	0,21	-0,33	-0,23	-0,30	-0,09	1s 1m 7w
Pico T x	-0,16	0,28	-0,18	-0,16	0,70	-0,18	-0,13	-0,18	-0,04	1s 8w
Pico T y	-0,02	0,59	-0,25	-0,06	-0,11	-0,22	0,24	-0,23	0,03	1m 8w
Pico T z	-0,12	0,59	-0,11	0,17	-0,15	-0,15	-0,14	-0,15	-0,03	1m 8w
Pot Tot x	-0,17	0,33	-0,16	-0,16	0,69	-0,19	-0,17	-0,21	-0,05	2m 7w
Pot Tot y	-0,08	0,75	-0,24	0,02	-0,12	-0,21	0,04	-0,23	-0,01	1s 8w
Pot Tot z	-0,15	0,52	-0,08	0,43	-0,19	-0,20	-0,19	-0,18	-0,05	2m 7w
Freq M x	-0,27	-0,10	0,58	0,65	-0,06	-0,21	-0,33	-0,24	-0,06	3m 6w
Freq M y	-0,27	-0,03	0,73	0,40	-0,03	-0,24	-0,29	-0,25	-0,11	1s 1m 7w
Freq M z	-0,23	0,08	0,40	0,44	0,26	-0,30	-0,42	-0,26	-0,08	2m 7w
Méd Pot x	-0,17	0,33	-0,16	-0,16	0,69	-0,19	-0,17	-0,21	-0,05	2m 7w
Méd Pot y	-0,08	0,75	-0,24	0,02	-0,12	-0,21	0,04	-0,23	-0,01	1s 8w
Méd Pot z	-0,15	0,52	-0,08	0,43	-0,19	-0,20	-0,19	-0,18	-0,05	2m 7w

Fonte: Autoria própria (2022)

Coefficientes de correlação para o conjunto de características TrS, 9 classes (A – andando na esteira, B – correndo na esteira, C - tremores, D - palmas, E – aceno de tchau, F – andando em círculo, G – apagando quadro, H – subindo e descendo escada, I – penteando o cabelo) e janelas de 1000 pontos de entrada.

Ocorrências: fraco (w) $\leq 0,30$, moderado (m) 0,31 até 0,69 e forte (s) $\geq 0,70$

Carac.	A	B	C	D	E	F	G	H	I	Ocorrência	
<i>CT x</i>	-0,18	-0,10	0,68	0,29	-0,55	-0,12	0,00	-0,02	0,11	2m	7w
<i>CT y</i>	-0,19	-0,30	-0,79	0,06	-0,22	-0,08	-0,22	0,19	0,00	1s	8w
<i>CT z</i>	-0,26	-0,11	0,04	-0,10	0,19	-0,11	0,33	-0,05	0,10	1m	8w
<i>AT x</i>	-0,16	-0,03	-0,15	-0,15	0,97	-0,16	-0,16	-0,16	-0,04	1s	8w
<i>AT y</i>	-0,06	0,69	-0,20	0,05	0,03	-0,18	-0,08	-0,22	-0,06	1m	8w
<i>AT z</i>	-0,13	0,45	0,13	0,27	-0,14	-0,19	-0,22	-0,21	-0,05	1m	8w
<i>Per x</i>	-0,19	0,13	-0,10	-0,11	0,90	-0,22	-0,21	-0,23	-0,06	1s	8w
<i>per y</i>	-0,09	0,77	-0,25	0,11	0,02	-0,23	-0,12	-0,29	-0,07	1s	8w
<i>Per z</i>	-0,18	0,43	0,10	0,55	-0,14	-0,25	-0,27	-0,27	-0,07	2m	7w
<i>Rb x</i>	-0,08	0,48	-0,11	-0,02	0,28	-0,19	-0,19	-0,22	-0,07	1m	8w
<i>Rb y</i>	-0,06	0,70	-0,30	0,11	0,01	-0,21	-0,03	-0,29	-0,06	1s	8w
<i>Rb z</i>	-0,12	0,38	-0,05	0,49	-0,12	-0,19	-0,21	-0,21	-0,06	2m	7w
<i>Rd x</i>	-0,19	0,06	-0,09	-0,12	0,94	-0,20	-0,19	-0,21	-0,05	1s	8w
<i>Rd y</i>	-0,10	0,78	-0,22	0,12	0,02	-0,23	-0,16	-0,29	-0,07	1s	8w
<i>Rd z</i>	-0,20	0,41	0,15	0,57	-0,15	-0,26	-0,28	-0,28	-0,07	2m	7w
<i>Rs x</i>	-0,19	0,06	0,10	-0,11	0,94	-0,20	-0,19	-0,21	-0,05	1s	8w
<i>Rs y</i>	-0,10	0,79	-0,22	0,09	0,03	-0,23	-0,16	-0,28	-0,07	1s	8w
<i>Rs z</i>	-0,19	0,44	0,18	0,51	-0,14	-0,27	-0,29	-0,29	-0,07	2m	7w
<i>Devs x</i>	-0,30	0,08	0,21	0,17	0,73	-0,31	-0,28	-0,31	-0,08	1s	2m 6w
<i>Devs y</i>	-0,19	0,49	-0,07	0,56	-0,05	-0,26	0,26	-0,27	-0,07	2m	7w
<i>Devs z</i>	-0,21	0,14	0,07	0,80	-0,11	-0,23	-0,23	-0,24	-0,06	1s	8w
<i>Devd x</i>	-0,33	-0,05	0,26	0,49	0,52	-0,34	-0,30	-0,34	-0,08	5m	4w
<i>Devd y</i>	-0,19	0,51	0,06	0,61	-0,08	-0,27	-0,28	-0,29	-0,07	2m	7w
<i>Devd z</i>	-0,22	0,14	0,11	0,82	-0,11	-0,25	-0,25	-0,26	-0,06	1s	8w
<i>Devb x</i>	-0,02	0,38	0,11	-0,35	0,12	-0,02	-0,03	-0,03	0,00	2m	7w
<i>Devb y</i>	-0,19	-0,19	0,04	0,46	0,00	-0,06	0,00	-0,07	-0,02	1m	8w
<i>Devb z</i>	-0,10	-0,04	-0,15	0,66	-0,09	-0,10	-0,09	-0,09	-0,02	1m	8w
<i>Angs x</i>	0,09	0,30	0,37	0,14	0,47	-0,51	-0,20	-0,53	-0,15	4m	5w
<i>Angs y</i>	-0,06	0,51	0,25	0,10	0,28	-0,36	-0,38	-0,54	-0,15	4m	5w
<i>Angs z</i>	0,00	0,35	0,36	0,37	0,19	-0,41	-0,40	-0,55	-0,09	6m	3w
<i>Angd x</i>	-0,10	0,30	0,38	0,11	0,48	-0,51	-0,19	-0,52	-0,15	4m	5w
<i>Angd y</i>	-0,04	0,48	0,25	0,24	0,22	-0,36	-0,43	-0,53	-0,15	4m	5w
<i>Angd z</i>	0,00	0,35	0,36	0,36	0,20	-0,39	-0,42	-0,55	-0,09	6m	3w
<i>Angb x</i>	-0,03	-0,39	-0,31	0,33	-0,14	-0,38	-0,15	-0,44	0,13	5m	4w
<i>Angb y</i>	-0,01	0,54	0,06	0,33	0,13	-0,40	0,23	-0,53	0,12	4m	5w
<i>Angb z</i>	0,00	0,31	0,20	0,49	0,09	-0,41	-0,30	-0,46	-0,12	4m	5w

Fonte: Autoria própria (2022)

Coefficientes de correlação para o conjunto de características TrM, 9 classes (A – andando na esteira, B – correndo na esteira, C - tremores, D - palmas, E – aceno de tchau, F – andando em círculo, G – apagando quadro, H – subindo e descendo escada, I – penteando o cabelo) e janelas de 1000 pontos de entrada.

Ocorrências: fraco (w) $\leq 0,30$, moderado (m) 0,31 até 0,69 e forte (s) $\geq 0,70$

Carac.	A	B	C	D	E	F	G	H	I	Ocorrência	
<i>CT x</i>	-0,18	-0,10	0,68	0,29	-0,55	-0,12	0,00	-0,02	0,11	2m	7w
<i>CT y</i>	-0,19	-0,30	0,79	0,06	-0,22	-0,08	-0,22	0,19	0,00	1s	8w
<i>CT z</i>	-0,26	-0,11	0,04	-0,10	0,19	-0,11	0,33	0,05	0,10		9w
<i>AT x</i>	-0,19	0,09	-0,09	-0,13	0,92	0,20	-0,19	-0,21	-0,06	1s	8w
<i>AT y</i>	-0,09	0,79	-0,18	0,03	0,05	-0,22	-0,20	-0,26	-0,07	1s	8w
<i>AT z</i>	-0,18	0,44	0,21	0,42	-0,13	-0,25	-0,28	-0,27	-0,07	2m	7w
<i>Per x</i>	-0,29	0,30	0,31	0,09	0,53	-0,34	-0,29	-0,34	-0,09	4m	5w
<i>per y</i>	-0,16	0,73	-0,05	0,33	-0,02	-0,30	-0,27	-0,32	-0,08	1s	2m 6w
<i>Per z</i>	-0,22	0,36	0,14	0,65	-0,11	-0,28	-0,28	-0,29	-0,07	2m	7w
<i>Rb x</i>	-0,15	0,45	0,22	0,20	-0,12	-0,23	-0,19	-0,23	-0,06	1m	8w
<i>Rb y</i>	-0,14	0,66	-0,09	0,35	-0,05	-0,28	-0,21	-0,30	-0,07	2m	7w
<i>Rb z</i>	-0,16	0,32	-0,02	0,60	-0,09	-0,22	-0,21	-0,23	-0,06	2m	7w
<i>Rd x</i>	-0,29	0,20	0,30	0,02	0,68	-0,32	-0,28	-0,33	-0,08	3m	6w
<i>Rd y</i>	-0,17	0,72	-0,03	0,33	-0,01	-0,30	-0,28	-0,32	-0,08	1s	2m 6w
<i>Rd z</i>	-0,23	0,34	0,20	0,66	-0,11	-0,29	-0,29	-0,30	-0,07	2m	7w
<i>Rs x</i>	-0,30	0,20	0,29	0,06	0,68	-0,33	-0,29	-0,33	-0,08	3m	6w
<i>Rs y</i>	-0,16	0,74	-0,03	0,29	-0,01	-0,29	-0,28	-0,32	-0,08	1s	1m 7w
<i>Rs z</i>	-0,23	0,38	0,23	0,60	-0,10	-0,30	-0,30	-0,31	-0,07	3m	6w
<i>Devs x</i>	-0,30	0,03	0,68	0,38	0,04	-0,29	-0,25	-0,28	-0,06	2m	7w
<i>Devs y</i>	-0,22	0,22	0,22	0,65	-0,12	-0,26	0,28	-0,23	-0,06	1m	8w
<i>Devs z</i>	-0,22	0,11	0,08	0,76	-0,07	-0,23	-0,21	-0,23	-0,05	1s	8w
<i>Devd x</i>	-0,29	-0,03	0,60	0,60	-0,08	-0,28	-0,24	-0,27	-0,06	2m	7w
<i>Devd y</i>	-0,23	0,22	0,26	0,68	-0,14	-0,30	-0,30	-0,24	-0,07	1m	8w
<i>Devd z</i>	-0,23	0,12	0,12	0,77	-0,07	-0,25	-0,23	-0,25	-0,06	1s	8w
<i>Devb x</i>	0,00	0,27	0,21	-0,40	-0,06	-0,02	-0,02	-0,02	0,00	1m	8w
<i>Devb y</i>	-0,10	-0,19	-0,02	0,54	-0,03	-0,07	-0,03	-0,08	-0,02	1m	8w
<i>Devb z</i>	-0,11	-0,05	-0,15	0,69	-0,09	-0,10	-0,08	-0,09	-0,02	1m	8w
<i>Angs x</i>	0,16	0,07	0,80	0,29	-0,27	-0,33	-0,12	-0,30	-0,06	1s	1m 7w
<i>Angs y</i>	-0,09	0,06	0,82	0,12	0,02	-0,28	-0,34	-0,31	-0,10	1s	2m 6w
<i>Angs z</i>	-0,13	0,24	0,34	0,26	0,30	-0,38	-0,24	-0,45	-0,04	3m	6w
<i>Angd x</i>	-0,16	0,08	0,80	0,27	-0,26	-0,33	-0,11	-0,30	-0,06	1s	1m 7w
<i>Angd y</i>	-0,10	0,05	0,80	0,21	-0,01	-0,28	-0,37	-0,31	-0,10	1s	2m 6w
<i>Angd z</i>	-0,12	0,24	0,35	0,26	0,31	-0,38	-0,26	-0,45	-0,05	4m	5w
<i>Angb x</i>	-0,13	0,11	0,66	0,39	-0,35	-0,28	-0,12	-0,29	-0,07	3m	6w
<i>Angb y</i>	-0,09	0,14	0,63	0,34	-0,03	-0,35	-0,29	-0,38	-0,09	4m	5w
<i>Angb z</i>	-0,11	0,23	0,25	0,41	0,19	-0,41	-0,19	-0,42	-0,09	3m	6w

Fonte: Autoria própria (2022)

Coefficientes de correlação para o conjunto de características TrDP, 9 classes (A – andando na esteira, B – correndo na esteira, C - tremores, D - palmas, E – aceno de tchau, F – andando em círculo, G – apagando quadro, H – subindo e descendo escada, I – penteando o cabelo) e janelas de 1000 pontos de entrada

Carac.	A	B	C	D	E	F	G	H	I	Ocorrência		
<i>CT x</i>	-0,18	-0,10	0,68	0,29	-0,55	-0,12	0,00	-0,02	0,11	2m	7w	
<i>CT y</i>	-0,19	-0,30	0,79	0,06	-0,22	-0,08	-0,22	0,19	0,00	1s	8w	
<i>CT z</i>	-0,26	-0,11	0,04	-0,10	0,19	-0,11	0,33	0,05	0,10	1m	8w	
<i>AT x</i>	-0,08	0,40	-0,18	-0,14	0,52	-0,18	-0,20	-0,20	-0,06	2m	7w	
<i>AT y</i>	-0,04	0,57	-0,22	0,00	-0,02	-0,18	0,06	-0,22	-0,05	1m	8w	
<i>AT z</i>	-0,10	0,49	0,01	0,29	-0,15	-0,18	-0,21	-0,19	-0,05	1m	8w	
<i>Per x</i>	-0,09	0,66	-0,06	0,08	0,07	-0,22	-0,23	-0,26	-0,08	1m	8w	
<i>per y</i>	-0,09	0,71	-0,31	0,26	-0,08	-0,25	0,01	-0,31	-0,04	1s	2m	6w
<i>Per z</i>	-0,15	0,48	-0,03	0,57	-0,16	-0,24	-0,26	-0,25	-0,07	2m	7w	
<i>Rb x</i>	-0,08	0,53	-0,13	0,04	0,20	-0,19	-0,20	-0,23	-0,07	1m	8w	
<i>Rb y</i>	-0,05	0,63	-0,36	0,19	-0,09	-0,24	0,16	-0,30	-0,02	2m	7w	
<i>Rb z</i>	-0,11	0,41	-0,11	0,57	-0,15	-0,21	-0,22	-0,21	-0,06	2m	7w	
<i>Rd x</i>	-0,12	0,61	-0,05	0,01	0,25	-0,25	-0,25	-0,28	-0,08	1m	8w	
<i>Rd y</i>	-0,08	0,77	-0,28	0,10	-0,02	-0,26	-0,01	-0,32	-0,05	1s	1m	7w
<i>Rd z</i>	-0,16	0,46	-0,02	0,59	-0,15	-0,25	-0,25	-0,26	-0,07	2m	7w	
<i>Rs x</i>	-0,16	0,56	-0,06	0,06	0,33	-0,26	-0,24	-0,29	-0,08	2m	7w	
<i>Rs y</i>	-0,10	0,71	-0,27	0,32	-0,04	-0,26	-0,09	-0,30	-0,05	1s	1m	7w
<i>Rs z</i>	-0,16	0,52	0,03	0,48	-0,15	-0,25	-0,26	-0,26	-0,07	2m	7w	
<i>Devs x</i>	-0,25	0,21	0,13	0,65	0,05	-0,28	-0,25	-0,28	-0,07	1m	8w	
<i>Devs y</i>	-0,16	0,30	-0,11	0,73	-0,12	-0,22	-0,22	-0,23	-0,06	1s	8w	
<i>Devs z</i>	-0,17	0,09	-0,06	0,83	-0,11	-0,19	-0,19	-0,20	-0,05	1s	8w	
<i>Devd x</i>	-0,21	0,02	0,07	0,90	-0,13	-0,22	-0,20	-0,22	-0,06	1s	8w	
<i>Devd y</i>	-0,15	0,27	-0,12	0,81	-0,13	-0,23	-0,24	-0,24	-0,06	1s	8w	
<i>Devd z</i>	-0,18	0,08	-0,06	0,89	-0,12	-0,21	-0,21	-0,21	-0,05	1s	8w	
<i>Devb x</i>	-0,20	0,39	0,16	0,41	-0,01	-0,28	-0,23	-0,29	-0,07	2m	7w	
<i>Devb y</i>	-0,14	-0,45	-0,10	0,63	-0,06	-0,28	-0,24	-0,31	-0,07	3m	6w	
<i>Devb z</i>	-0,17	0,14	-0,05	0,79	-0,11	-0,20	-0,20	-0,21	-0,05	1s	8w	
<i>Angs x</i>	0,34	0,03	-0,27	0,40	-0,62	-0,01	0,16	-0,04	-0,08	3m	6w	
<i>Angs y</i>	0,17	0,06	-0,05	0,68	-0,09	-0,18	-0,18	-0,44	-0,14	2m	7w	
<i>Angs z</i>	0,45	-0,05	-0,38	-0,11	0,05	0,10	0,01	-0,12	-0,01	2m	7w	
<i>Angd x</i>	0,32	0,06	-0,24	0,44	-0,78	0,03	0,18	-0,01	-0,06	1s	2m	6w
<i>Angd y</i>	0,32	0,04	-0,09	0,47	0,03	-0,09	-0,30	-0,49	-0,18	3m	6w	
<i>Angd z</i>	0,45	-0,07	-0,37	-0,06	0,01	0,14	0,01	-0,12	0,01	2m	7w	
<i>Angb x</i>	0,12	0,28	0,06	0,39	0,12	-0,41	-0,10	-0,51	-0,18	3m	6w	
<i>Angb y</i>	0,15	0,27	0,07	0,42	0,19	-0,37	-0,22	-0,60	-0,14	3m	6w	
<i>Angb z</i>	0,18	0,31	0,22	0,12	0,21	-0,32	-0,31	-0,48	-0,11	4m	5w	

Fonte: Autoria própria (2022)

Coefficientes de correlação para o conjunto de características TrV, 9 classes (A – andando na esteira, B – correndo na esteira, C - tremores, D - palmas, E – aceno de tchau, F – andando em círculo, G – apagando quadro, H – subindo e descendo escada, I – penteando o cabelo) e janelas de 1000 pontos de entrada.

Ocorrências: fraco (w) $\leq 0,30$, moderado (m) 0,31 até 0,69 e forte (s) $\geq 0,70$

Carac.	A	B	C	D	E	F	G	H	I	Ocorrência		
<i>CT x</i>	-0,18	-0,10	0,68	0,29	-0,55	-0,12	0,00	-0,02	0,11	2m	7w	
<i>CT y</i>	-0,19	-0,30	0,79	0,06	-0,22	-0,08	-0,22	0,19	0,00	1s	8w	
<i>CT z</i>	-0,26	-0,11	0,04	-0,10	0,19	-0,11	0,33	0,05	0,10	1m	8w	
<i>AT x</i>	-0,11	0,37	-0,13	-0,12	0,32	-0,12	-0,12	-0,12	-0,03	2m	7w	
<i>AT y</i>	-0,07	0,29	-0,11	-0,06	-0,08	-0,10	0,19	-0,10	-0,02		9w	
<i>AT z</i>	-0,10	0,45	0,07	0,09	-0,11	-0,10	-0,10	-0,10	-0,03	1m	8w	
<i>Per x</i>	-0,11	0,62	-0,09	-0,03	-0,01	-0,14	-0,14	-0,15	-0,04	1m	8w	
<i>per y</i>	-0,13	0,69	-0,21	0,11	-0,13	-0,18	-0,02	-0,19	-0,04	1m	8w	
<i>Per z</i>	-0,18	0,45	-0,11	0,49	-0,17	-0,18	-0,18	-0,18	-0,04	2m	7w	
<i>Rb x</i>	-0,10	0,50	-0,11	-0,04	0,09	-0,12	-0,13	-0,13	-0,03	1m	8w	
<i>Rb y</i>	-0,11	0,61	-0,22	0,07	-0,13	-0,18	-0,12	0,20	-0,03	1m	8w	
<i>Rb z</i>	-0,14	0,38	-0,12	0,44	-0,14	-0,15	-0,15	-0,15	-0,04	2m	7w	
<i>Rd x</i>	-0,13	0,60	-0,10	-0,08	0,10	-0,15	-0,15	-0,16	-0,04	1m	8w	
<i>Rd y</i>	-0,13	0,74	-0,18	-0,02	-0,09	-0,17	-0,03	-0,18	-0,04	1s	8w	
<i>Rd z</i>	-0,18	0,43	-0,11	0,52	-0,17	-0,18	-0,18	-0,18	-0,04	2m	7w	
<i>Rs x</i>	-0,16	0,55	-0,11	-0,08	0,20	-0,16	-0,16	-0,16	-0,04	1m	8w	
<i>Rs y</i>	-0,15	0,71	-0,19	0,17	-0,13	-0,18	-0,09	-0,19	-0,04	1s	8w	
<i>Rs z</i>	-0,18	0,52	-0,08	0,36	-0,16	-0,17	-0,17	-0,17	-0,04	2m	7w	
<i>Devs x</i>	-0,17	0,07	-0,02	0,62	-0,06	-0,15	-0,15	-0,15	-0,04	1m	8w	
<i>Devs y</i>	-0,15	0,13	-0,12	0,64	-0,12	-0,13	-0,13	-0,13	-0,03	1m	8w	
<i>Devs z</i>	-0,12	-0,05	-0,09	0,69	-0,10	-0,10	-0,10	-0,10	-0,03	1m	8w	
<i>Devd x</i>	-0,16	-0,10	-0,07	0,88	-0,13	-0,13	-0,13	-0,13	-0,03	1s	8w	
<i>Devd y</i>	-0,15	0,07	-0,13	0,77	-0,14	-0,14	-0,14	-0,14	-0,03	1s	8w	
<i>Devd z</i>	-0,15	-0,07	-0,11	0,84	-0,13	-0,13	-0,13	-0,13	-0,03	1s	8w	
<i>Devb x</i>	-0,19	0,35	0,07	0,31	-0,08	-0,17	-0,16	-0,17	-0,04	2m	7w	
<i>Devb y</i>	-0,18	0,33	-0,14	0,64	-0,12	-0,19	-0,18	-0,19	-0,05	2m	7w	
<i>Devb z</i>	-0,13	0,00	-0,09	0,68	-0,11	-0,11	-0,11	-0,11	-0,03	1m	8w	
<i>Angs x</i>	0,37	-0,03	-0,31	0,49	-0,50	-0,06	0,13	-0,11	-0,09	4m	5w	
<i>Angs y</i>	0,11	0,03	-0,08	0,76	-0,11	-0,19	-0,18	-0,37	-0,11	1s	1m	7w
<i>Angs z</i>	0,48	-0,06	-0,35	-0,08	0,09	0,08	-0,01	-0,15	0,00	2m	7w	
<i>Angd x</i>	0,33	-0,01	-0,32	0,58	-0,59	-0,05	0,15	-0,10	-0,08	4m	5w	
<i>Angd y</i>	0,32	0,08	-0,12	0,52	0,00	-0,12	-0,29	-0,45	-0,14	3m	6w	
<i>Angd z</i>	0,46	-0,08	-0,32	-0,04	-0,01	0,12	-0,02	-0,15	0,01	2m	7w	
<i>Angb x</i>	0,07	0,29	0,04	0,41	0,11	-0,39	-0,14	-0,46	-0,14	3m	6w	
<i>Angb y</i>	0,11	0,27	0,03	0,47	0,17	-0,37	-0,24	-0,51	-0,12	3m	6w	
<i>Angb z</i>	0,14	0,33	0,22	0,11	0,19	-0,33	-0,31	-0,44	-0,10	4m	5w	

Fonte: Autoria própria (2022)

ANEXO – Parecer consubstanciado do CEP



UNIVERSIDADE ESTADUAL DE
MARINGÁ



PARECER CONSUBSTANCIADO DO CEP

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: Técnica de triangulação aplicada sobre sinais elétricos irregulares em amplitude e frequência visando à extração de características e o reconhecimento de padrões.

Pesquisador: Luiz Carlos Giacomossi

Área Temática:

Versão: 3

CAAE: 54991716.0.0000.0104

Instituição Proponente: INSTITUTO FEDERAL DE EDUCACAO, CIENCIA E TECNOLOGIA DO PARANA

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 1.717.907

Apresentação do Projeto:

Trata-se de projeto de pesquisa proposto por pesquisador vinculado ao Instituto Federal de Educação, Ciência e Tecnologia do Paraná.

Objetivo da Pesquisa:

Avaliar a técnica de triangulação aplicada sobre sinais irregulares capturados com um sensor acelerômetro 3D (integrado a um dispositivo móvel celular) de movimentos humanos normais do dia a dia como uma caminhada e corrida. Os movimentos humanos serão identificados pelo modo de caminhar ou correr e servirão de base para avaliar a força das características extraídas por tal técnica (método geométrico), além de ser comparada com características calculadas por outros métodos. Os índices de classificação com o uso de redes neurais determinarão a eficácia do método proposto.

Avaliação dos Riscos e Benefícios:

Avalia-se que os possíveis riscos a que estarão submetidos os sujeitos da pesquisa serão suportados pelos benefícios apontados.

Comentários e Considerações sobre a Pesquisa:

Os sinais elétricos correspondentes a aceleração de movimentos humanos divididos em categorias

Endereço: Av. Colombo, 5790, UEM-PPG

Bairro: Jardim Universitário

CEP: 87.020-900

UF: PR

Município: MARINGÁ


Telefone: (44)3011-4597

Fax: (44)3011-4444

E-mail: copep@uem.br



UNIVERSIDADE ESTADUAL DE
MARINGÁ



Continuação do Parecer: 1.717.907

(movimentos do dia a dia), serão capturados de voluntários adultos, através de um aplicativo embarcado (desenvolvido na linguagem de programação Java) na memória de um dispositivo móvel celular smartphone. Os dados de aquisição serão gravados em arquivos textos considerando a aceleração dos 3 planos ortogonais (eixos x, y e z do acelerômetro interno) e enviados para um endereço de email. O celular será colocado no bolso de uma camisa ou calça de voluntários adultos, os quais deverão caminhar e correr sobre uma esteira ergométrica nas velocidades 5 km/h e 8 km/h respectivamente. O método proposto, transforma os dados de entrada (sinais elétricos digitalizados) em um novo sinal baseado em sequências de triângulos gerados entre os valores máximos e mínimos de tensão. Para a extração das características (sempre baseadas em retas, ângulos e áreas) são utilizados os princípios Euclidianos através do cálculo das retas entre os referidos pontos, bem como o cálculo das retas entre dois máximos e mínimos. O sinal é sempre segmentado (tamanho definido nas configurações de entrada), de modo que o conjunto de características irá formar um padrão. O conjunto de padrões será dividido em 2/3 para o treinamento e 1/3 para a fase de testes na classificação das categorias de movimentos objetos de estudo com o uso de redes neurais. As taxas de classificação são utilizadas como forma de medida da eficácia do método geométrico (técnica de triangulação). Para o desenvolvimento e avaliação da técnica de triangulação proposta neste projeto de pesquisa deverão ser elaboradas três importantes fases, de acordo com o que segue: Fase 1 ou fase de aquisição de dados; Fase 2 ou fase de pré-processamento dos dados e Fase 3 ou fase da classificação final com o uso de redes neurais. Na Fase 1 - Um módulo sensor baseado no dispositivo eletrônico acelerômetro 3D integrado a um dispositivo móvel celular (smartphone). Os dados de aquisição de movimentos humanos serão capturados de voluntários adultos com o celular colocado em um suporte no braço (suporte de braço para celular), andando e correndo em uma esteira ergométrica regulada nas velocidades 5 km/h e 8 km/h respectivamente. Os voluntários serão selecionados de acordo com as seguintes faixas etárias e sexo: 18 a 30 anos (10 de cada sexo), 31 a 45 anos (10 de cada sexo). Cada voluntário irá executar os dois movimentos durante um tempo médio de 2 min. Fase 2 – Corresponde ao algoritmo de pré-processamento o qual deverá ser implementado ou programado na plataforma Matlab 7.9 e na plataforma android utilizando a linguagem de programação Java. Fase 3: Corresponde à etapa de processamento dos padrões gerados na fase 2, ou seja, os dados serão separados ou classificados através do elemento classificador com o uso de redes neurais. Nesta fase a técnica proposta é avaliada através dos índices de acerto obtidos durante as validações e testes com a rede neural. O projeto proposto tem origem do INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO PARANÁ,

Endereço: Av. Colombo, 5790, UEM-PPG

Bairro: Jardim Universitário

CEP: 87.020-900

UF: PR

Município: MARINGÁ

Telefone: (44)3011-4597

Fax: (44)3011-4444

E-mail: copep@uem.br



UNIVERSIDADE ESTADUAL DE
MARINGÁ



Continuação do Parecer: 1.717.907

sede em Curitiba e tem área temática de Engenharia Biomédica. A proposta do projeto inscrito na Plataforma Brasil é da utilização de 40 voluntários (homens e mulheres em diferentes faixas etárias) para os testes. Terá custos de R\$1.500,00 e financiamento próprio e o cronograma é exequível.

Considerações sobre os Termos de apresentação obrigatória:

Folha de rosto devidamente preenchida e assinada em anexo; TCLE em forma de carta convite, adequada às informações importantes aos participantes; Declaração de médica cardiologista que acompanhará o estudo em anexo.

Conclusões ou Pendências e Lista de Inadequações:

O Comitê Permanente de Ética em Pesquisa Envolvendo Seres Humanos da Universidade Estadual de Maringá é de parecer favorável à aprovação do protocolo de pesquisa apresentado.

Considerações Finais a critério do CEP:

Face ao exposto e considerando a normativa ética vigente, este Comitê se manifesta pela aprovação do protocolo de pesquisa em tela.

Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicas do Projeto	PB_INFORMAÇÕES_BÁSICAS_DO_PROJETO_639137.pdf	11/08/2016 20:02:05		Aceito
Outros	CARTA_CORRECOES_EFETUADAS.docx	01/08/2016 13:50:30	Luiz Carlos Giacomossi	Aceito
Projeto Detalhado / Brochura Investigador	PROJETO_DIGITALIZADO.pdf	01/08/2016 13:47:55	Luiz Carlos Giacomossi	Aceito
Declaração de Pesquisadores	DECLARACAO_MEDICA_CARDIO_DIGITALIZADA.pdf	01/08/2016 13:43:32	Luiz Carlos Giacomossi	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TERMO_DE_CONSENTIMENTO_LIVRE_E_ESCLARECIDO.docx	01/08/2016 13:35:24	Luiz Carlos Giacomossi	Aceito
Cronograma	CRONOGRAMA_PESQUISA.docx	31/03/2016 17:01:42	Luiz Carlos Giacomossi	Aceito
Folha de Rosto	Folha_de_rosto.pdf	16/03/2016 21:52:47	Luiz Carlos Giacomossi	Aceito

Situação do Parecer:

Aprovado

Endereço: Av. Colombo, 5790, UEM-PPG

Bairro: Jardim Universitário

CEP: 87.020-900

UF: PR

Município: MARINGÁ

Telefone: (44)3011-4597

Fax: (44)3011-4444

E-mail: copep@uem.br



UNIVERSIDADE ESTADUAL DE
MARINGÁ



Continuação do Parecer: 1.717.907

Necessita Apreciação da CONEP:

Não

MARINGÁ, 08 de Setembro de 2016

Assinado por:
Ricardo Cesar Gardiolo
(Coordenador)

Endereço: Av. Colombo, 5790, UEM-PPG
Bairro: Jardim Universitário **CEP:** 87.020-900
UF: PR **Município:** MARINGÁ
Telefone: (44)3011-4597 **Fax:** (44)3011-4444 **E-mail:** copep@uem.br